

DETEKSI RETINOPATI DIABETIK *ON-DEVICE* MENGGUNAKAN MODEL MOBILENETV2 PADA APLIKASI MOBILE BERBASIS FLUTTER

Ali Mustopa¹, Ade Hendini², Agung Sasongko³

¹ Informatika Kampus Kota Pontianak; Universitas Bina Sarana Informatika; Jalan Abdurahman Saleh No. 18A, Pontianak

^{2,3} Sistem Informasi Kampus Kota Pontianak; Universitas Bina Sarana Informatika; Jalan Abdurahman Saleh No. 18A, Pontianak

Keywords:

Retinopati Diabetik;
MobileNetV2; Deep
Learning; TensorFlow Lite;
Aplikasi Mobile

Corespondent Email:

alimustopa.aop@bsi.ac.id

Abstrak. Retinopati Diabetik (RD) adalah penyebab utama kebutaan yang dapat dicegah, namun skrining manual seringkali sulit diakses dan mahal. Penelitian ini bertujuan membangun aplikasi mobile yang efisien untuk deteksi RD menggunakan Deep Learning. Model CNN berbasis MobileNetV2 dilatih dengan teknik transfer learning pada dataset APTOS 2019 yang dikelompokkan menjadi 2 kelas (RD dan Non-RD). Model terbaik dikonversi ke format TensorFlow Lite (TFLite) dengan optimasi kuantisasi untuk implementasi on-device pada aplikasi Flutter. Hasil penelitian menunjukkan model mencapai akurasi 97.3% pada data uji. Konversi TFLite berhasil mereduksi ukuran file sebesar 74% (menjadi 11.8 MB) dengan latensi inferensi rata-rata ~150 ms. Penelitian ini membuktikan kelayakan implementasi MobileNetV2 pada aplikasi mobile untuk skrining RD yang cepat, akurat, hemat biaya, dan menjaga privasi secara offline. Solusi ini berpotensi besar meningkatkan deteksi dini di fasilitas layanan kesehatan dengan sumber daya terbatas.



Copyright © [JITET](#) (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

Abstract. *Diabetic Retinopathy (DR) is a leading preventable cause of blindness, yet manual screening remains inaccessible and costly. This study aims to build an efficient mobile application for DR detection using Deep Learning. A MobileNetV2 CNN model was trained via transfer learning on the APTOS 2019 dataset, grouped into 2 classes (DR and Non-DR). The best model was converted to TensorFlow Lite (TFLite) format with quantization optimization for on-device implementation within a Flutter app. Results show the model achieved 97.3% accuracy on the test set. TFLite conversion successfully reduced the file size by 74% (to 11.8 MB) with an average inference latency of ~150 ms. This study demonstrates the feasibility of implementing MobileNetV2 in a mobile app for fast, accurate, cost-effective, and privacy-preserving offline DR screening. This solution holds significant potential for enhancing early detection in resource-limited healthcare settings.*

1. PENDAHULUAN

Diabetes Melitus (DM) telah menjadi salah satu masalah kesehatan global yang paling mendesak di abad ke-21. Organisasi Kesehatan Dunia (WHO) dan lembaga terkait seperti

International Diabetes Federation mencatat peningkatan prevalensi diabetes yang signifikan di seluruh dunia [1], yang membawa serta berbagai komplikasi kronis. Salah satu komplikasi mikrovaskular yang paling serius

dan umum dari diabetes adalah Retinopati Diabetik (RD). Retinopati Diabetik merupakan penyebab utama kebutaan yang dapat dicegah di antara populasi usia kerja [2].

Deteksi dini dan penanganan yang tepat waktu sangat krusial untuk mencegah hilangnya penglihatan akibat RD. Metode standar emas untuk skrining RD saat ini adalah melalui pemeriksaan citra fundus retina oleh dokter mata (oftalmologis) terlatih. Namun, proses ini memiliki beberapa keterbatasan signifikan. Pertama, pemeriksaan manual bersifat subjektif, memakan waktu, dan mahal. Kedua, terdapat kekurangan jumlah dokter mata yang terlatih, terutama di daerah terpencil dan negara berkembang, yang menyebabkan kesenjangan akses skrining yang besar.

Perkembangan teknologi Kecerdasan Buatan (AI), khususnya di bidang *Deep Learning* (Pembelajaran Mendalam) [3], telah menunjukkan potensi luar biasa dalam analisis citra medis. Jaringan Saraf Konvolusional (CNN) telah terbukti mampu mendeteksi dan mengklasifikasikan tingkat keparahan RD dari citra fundus dengan akurasi yang menyamai atau bahkan melampaui ahli manusia [4], [5].

Meskipun demikian, banyak model CNN canggih seperti VGG16 atau ResNet memiliki ukuran yang sangat besar dan membutuhkan daya komputasi tinggi. Hal ini menyulitkan implementasinya pada perangkat yang paling mudah diakses oleh masyarakat luas. Untuk mengatasi tantangan ini, diperlukan arsitektur model yang ringan dan efisien, yang dirancang khusus untuk inferensi pada perangkat *mobile*. MobileNetV2 adalah arsitektur CNN yang menonjol karena desainnya yang efisien, menggunakan *depthwise separable convolutions* dan *inverted residuals* untuk mengurangi jumlah parameter dan biaya komputasi secara drastic [6], sekaligus mempertahankan akurasi yang tinggi [7].

Penelitian ini mengusulkan pengembangan aplikasi *mobile* yang terintegrasi dengan model MobileNetV2 untuk deteksi Retinopati Diabetik. Dengan memanfaatkan inferensi *on-*

device (langsung di perangkat), aplikasi ini dapat menyediakan alat skrining yang cepat, murah, tidak memerlukan koneksi internet, dan dapat diakses di mana saja, terutama di fasilitas layanan kesehatan primer atau daerah dengan sumber daya terbatas. Penelitian serupa yang berfokus pada aplikasi *mobile* untuk skrining RD telah menunjukkan kelayakan pendekatan ini [8], [9].

2. TINJAUAN PUSTAKA

2.1. Retinopati Diabetik

Retinopati Diabetik (RD) adalah komplikasi mikrovaskular dari diabetes yang merusak pembuluh darah retina. Meskipun secara klinis dikategorikan dalam 5 tahap (0-4), untuk keperluan skrining massal, pendekatan klasifikasi biner (2 kelas) yaitu membedakan antara kondisi "Normal/Non-RD" dan "RD" seringkali lebih diutamakan [2]. Pendekatan biner ini menyederhanakan pengambilan keputusan klinis untuk rujukan: pasien yang terdeteksi memiliki tanda-tanda RD (kelas positif) akan langsung dirujuk ke spesialis mata, sementara pasien normal (kelas negatif) dapat melanjutkan pemantauan rutin.

2.2. Convolutional Neural Networks (CNN)

Convolutional Neural Networks (CNN) merupakan arsitektur *Deep Learning* yang dominan dalam analisis citra. Keunggulan utama CNN terletak pada kemampuannya mengekstrak fitur spasial secara otomatis tanpa rekayasa fitur manual [10]. Fleksibilitas dan akurasi CNN telah terbukti tidak hanya dalam citra medis, tetapi juga dalam domain lain seperti klasifikasi kualitas produk agrikultur (biji kopi), di mana model CNN mampu membedakan kualitas visual dengan presisi tinggi [11]. Hal ini menegaskan potensi CNN sebagai solusi robust untuk tugas klasifikasi visual yang kompleks seperti deteksi lesi pada retina.

2.3. MobileNetV2

MobileNetV2 dirancang khusus untuk mengatasi keterbatasan sumber daya pada perangkat *mobile*. Arsitektur ini menggunakan *Inverted Residuals* dan *Linear Bottlenecks* yang memungkinkan model tetap ringan namun akurat [7]. Dibandingkan dengan arsitektur tradisional yang menggunakan konvolusi standar, MobileNetV2 mereduksi beban komputasi secara drastis melalui *Depthwise*

Separable Convolutions [6], menjadikannya sangat cocok untuk aplikasi kesehatan yang membutuhkan respons cepat di perangkat genggam.

2.4. Penelitian Terdahulu

Penelitian awal oleh Gulshan et al. [4] menggunakan dataset raksasa untuk melatih model Inception-v3 dalam mendekripsi RD yang dapat dirujuk (*referable DR* vs *non-referable*). Pendekatan biner ini terbukti mencapai sensitivitas 97.5% dan spesifisitas 93.4%, menetapkan standar bahwa deteksi 2 kelas sangat efektif untuk skrining. Namun, model tersebut membutuhkan infrastruktur komputasi berat.

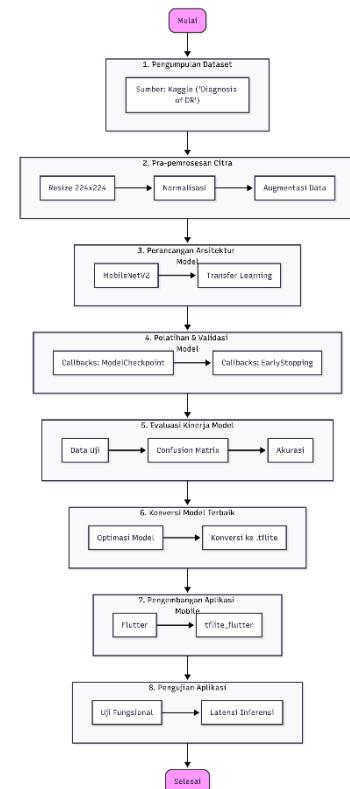
Dalam perkembangannya, peneliti mulai mengeksplorasi implementasi pada perangkat *mobile*. Aly et al. [8] mengembangkan aplikasi *mobile* berbasis *cloud*, namun metode ini memiliki kelemahan fatal berupa ketergantungan pada internet [12], yang menghambat akses di daerah terpencil [13]. Studi lain oleh Kaphle et al. [9] menguji model ringan untuk klasifikasi RD. Mereka menemukan bahwa meskipun klasifikasi 5 kelas memberikan detail klinis, klasifikasi biner (Normal vs RD) memberikan akurasi yang jauh lebih tinggi dan lebih stabil pada model ringan, yang krusial untuk meminimalkan kesalahan diagnosis di lapangan.

Penelitian ini mengisi kesenjangan tersebut dengan menerapkan pendekatan klasifikasi biner pada arsitektur MobileNetV2 yang dijalankan sepenuhnya secara *on-device* (offline). Berbeda dengan sistem berbasis server [14] atau model multikelas yang kompleks [15], pendekatan biner *on-device* ini menawarkan keseimbangan optimal antara akurasi tinggi untuk rujukan, kecepatan inferensi, dan perlindungan privasi data pasien [16].

3. METODE PENELITIAN

Metodologi penelitian ini menggunakan pendekatan *Experimental Research* yang berfokus pada pengembangan dan pengujian sistem *Deep Learning* untuk implementasi *mobile*. Alur kerja penelitian (diringkas dalam Gambar 1) mencakup pengumpulan data, pra-

pemrosesan, perancangan model, pelatihan, konversi *on-device*, dan pengembangan aplikasi.

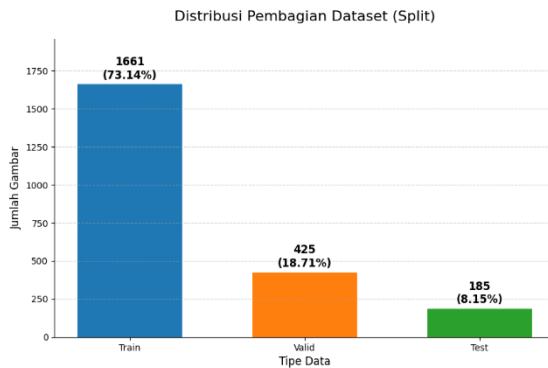


Gambar 1. Tahapan Penelitian

3.1. Pengumpulan dan Persiapan Dataset

Penelitian ini menggunakan dataset "Diagnosis of Diabetic Retinopathy" [17] yang tersedia secara publik di Kaggle. Dataset ini terdiri dari ribuan citra fundus retina yang telah dilabeli oleh para ahli ke dalam kelas DR (0) dan No DR (1).

Untuk persiapan pelatihan, dataset dibagi secara acak menjadi tiga subset dimana terdiri data latih 1661 Citra data validasi 425 Citra, dan data uji 185 Citra. Pembagian ini memastikan bahwa model dievaluasi pada data yang belum pernah dilihat sebelumnya (unseen data).



Gambar 2. Pembagian Dataset

3.2. Pra-pemrosesan Citra

Citra fundus mentah memiliki resolusi dan kondisi pencahayaan yang bervariasi. Untuk menstandarisasi input model, serangkaian langkah pra-pemrosesan diterapkan:

Pengubahan Ukuran (Resizing) citra diubah ukurannya secara seragam menjadi 224x224 piksel. Ukuran ini dipilih karena merupakan standar input yang umum untuk arsitektur MobileNetV2 [7].

Normalisasi nilai piksel setiap citra, yang awalnya dalam rentang 0-255, dinormalisasi ke rentang 0-1 dengan membagi semua nilai piksel dengan 255.0 [18].

Augmentasi Data (Data Augmentation) dilakukan mencegah overfitting dan meningkatkan kemampuan generalisasi model, teknik augmentasi diterapkan secara dinamis hanya pada data latih. Penerapan augmentasi ini merupakan praktik umum untuk meningkatkan invariansi model dan mengurangi overfitting pada dataset citra medis [10]. Teknik ini mencakup rotasi acak (± 15 derajat), pergeseran horizontal dan vertikal ($\pm 10\%$), shear, zoom, dan flip horizontal.



Gambar 3. Augmentasi Citra

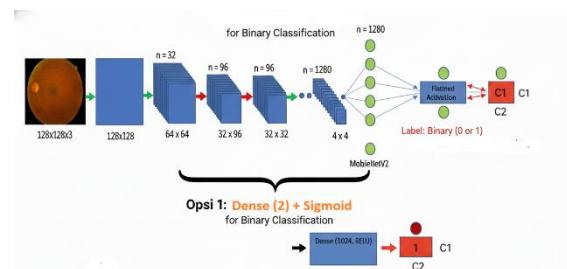
3.3. Perancangan Arsitektur Model

Untuk menyeimbangkan antara akurasi dan efisiensi komputasi on-device, penelitian ini mengadopsi arsitektur MobileNetV2 [7] dengan pendekatan Transfer Learning [10]. Pendekatan Transfer Learning terbukti efektif dalam aplikasi medis, di mana model yang dilatih pada dataset besar seperti ImageNet dapat diadaptasi untuk tugas-tugas spesifik (seperti deteksi RD) dengan data yang lebih terbatas [19].

MobileNetV2 yang telah dilatih (pre-trained) pada dataset ImageNet digunakan sebagai feature extractor. Lapisan klasifikasi asli (1000 kelas ImageNet) dibuang (include_top=False).

Pembekuan Bobot (Freezing) dari lapisan-lapisan konvolusi base model dibekukan mempertahankan fitur-fitur umum yang telah dipelajari dari ImageNet.

Classifier Head Kustom: Sebuah classifier head kustom ditambahkan di atas base model. Arsitektur head ini terdiri dari lapisan GlobalAveragePooling2D, diikuti oleh lapisan Dense (1024 neuron, aktivasi ReLU), lapisan Dropout (0.5, untuk regularisasi), dan diakhiri dengan lapisan output Dense (2 neuron, aktivasi sigmoid).



Gambar 4. Arsitektur MobileNetV2

3.4. Pelatihan dan Validasi Model

Pelatihan model dilakukan menggunakan framework TensorFlow/Keras di lingkungan Google Colab. Optimizer Adam [20] digunakan sebagai optimizer dengan learning rate awal $1e-4$. Loss Function categorical_crossentropy dipilih sebagai fungsi kerugian, sesuai untuk masalah klasifikasi

multikelas. Callbacks utama digunakan untuk mengelola proses pelatihan ModelCheckpoint. Untuk secara otomatis menyimpan bobot model hanya jika val_accuracy (akurasi pada data validasi) meningkat.

3.5. Konversi Model

Setelah model Keras (.keras) terbaik diperoleh, langkah krusial berikutnya adalah mengonversinya untuk implementasi mobile. TensorFlow Lite Converter [21] digunakan untuk mengubah model ke format .tflite. Selama proses ini, Optimasi Default (tf.lite.Optimize.DEFAULT) diterapkan. Optimasi ini mencakup kuantisasi bobot (weight quantization), yang secara signifikan mengurangi ukuran file model dengan dampak minimal pada akurasi.

3.6. Pengembangan & Evaluasi Aplikasi

Sebuah prototipe aplikasi mobile dikembangkan menggunakan framework Flutter [22] karena kemampuannya untuk kompilasi native lintas platform (Android dan iOS).

Package *tflite_flutter* digunakan untuk memuat file .tflite ke dalam aplikasi dan mengekspos API untuk inferensi. Aplikasi dirancang untuk memungkinkan pengguna mengunggah gambar fundus dari galeri. Gambar tersebut kemudian di-pra-pemrosesan di sisi klien (resize 224x224, normalisasi) sebelum diumpulkan ke model TFLite untuk inferensi on-device. Kinerja aplikasi dievaluasi secara kualitatif (fungsionalitas UI/UX) dan kuantitatif dengan mengukur latensi inferensi (dalam milidetik) pada perangkat fisik.

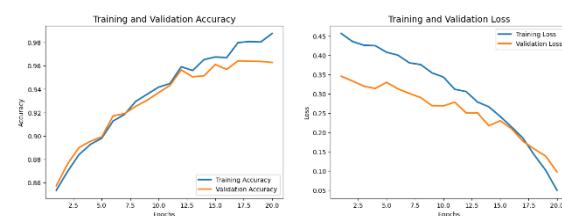
4. HASIL DAN PEMBAHASAN

Eksperimen dilakukan untuk mengevaluasi kinerja model MobileNetV2 dalam klasifikasi Retinopati Diabetik (RD) dan kelayakannya untuk implementasi pada aplikasi mobile. Pelatihan model dilakukan menggunakan Google Colab (GPU NVIDIA T4) dengan framework TensorFlow/Keras.

4.1. Kinerja Pelatihan dan Evaluasi Model

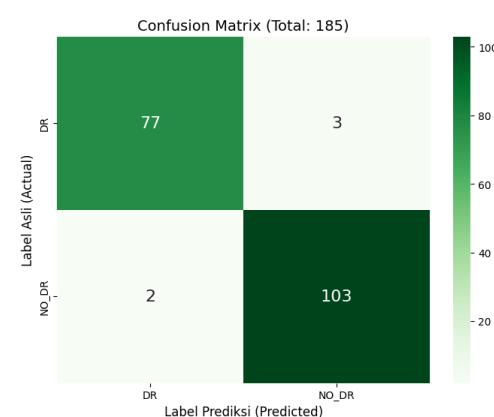
Model dilatih menggunakan dataset APTOS 2019 yang telah melalui prapemrosesan (resize 224x224, normalisasi) dan augmentasi data. Pelatihan dihentikan secara otomatis oleh callback pada epoch ke-20, dengan model terbaik disimpan (berdasarkan val_accuracy tertinggi).

Penggunaan EarlyStopping terbukti krusial. Seperti yang diindikasikan oleh grafik pelatihan (tidak ditampilkan), penghentian dini mencegah model dari overfitting yang parah, yang merupakan risiko umum pada dataset citra medis yang kompleks. Model terbaik dipilih pada titik di mana ia mencapai generalisasi terbaik pada data validasi, sebelum kinerjanya mulai menurun.



Gambar 5. Grafik Accuracy dan Loss

Model terbaik yang disimpan kemudian dievaluasi menggunakan data uji (test set) yang independen. Model mencapai akurasi keseluruhan (overall accuracy) sebesar 97.3%. Analisis lebih rinci terhadap kinerja model disajikan dalam confusion matrix (Gambar 6).



Gambar 6. Confussion Matrix

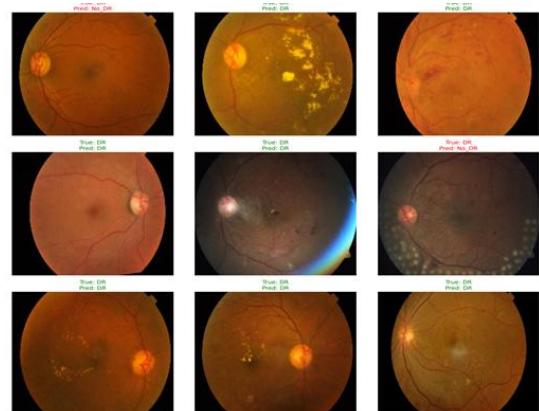
Berdasarkan Gambar 6 Kinerja Tinggi pada Kelas No DR Model menunjukkan akurasi yang sangat tinggi (seperti yang terlihat pada precision/recall Gambar 7) untuk kelas 0 (Diabetic Retinopathy) dan kelas 1 (No Diabetic Retinopathy). Ini adalah temuan yang signifikan secara klinis. Kemampuan untuk secara akurat mengidentifikasi pasien "NO DR" sangat penting untuk mengurangi rujukan yang tidak perlu, sementara identifikasi "DR" (tahap paling parah) sangat penting untuk segera merujuk pasien ke perawatan spesialis guna mencegah kebutaan.

Ambiguitas Antar Kelas Berdekatan terlihat bahwa kesalahan klasifikasi (misklasifikasi) paling sering terjadi antara kelas-kelas yang berdekatan secara klinis, terutama antara kelas. Hal ini dapat dipahami dan sejalan dengan tantangan diagnostik di dunia nyata. Diferensiasi visual antara kedua tahap ini seringkali subtil, bergantung pada penghitungan lesi mikroaneurisma atau hemorrhage kecil, yang bahkan bisa menjadi subyektif di antara para ahli grader manusia. Metrik kinerja kuantitatif per kelas, termasuk Precision, Recall, dan F1-Score, dirangkum dalam Tabel 2.

	precision	recall	f1-score	support
DR	0.9747	0.9625	0.9686	80
NO_DR	0.9717	0.9810	0.9763	105
accuracy			0.9730	185
macro avg	0.9732	0.9717	0.9724	185
weighted avg	0.9730	0.9730	0.9730	185

Gambar 7. Matrix Kinerja Per Kelas

Hasil Gambar 7 mengkonfirmasi kinerja yang seimbang di semua kelas (F1-Score > 0.96). Akurasi keseluruhan 97.3% ini menunjukkan bahwa arsitektur MobileNetV2—meskipun dirancang untuk efisiensi komputasi dan keringinan—sangat mumpuni untuk tugas klasifikasi RD. Hal ini membantah anggapan bahwa hanya arsitektur yang sangat besar (seperti ResNet atau VGG) yang dapat mencapai kinerja tinggi pada citra medis, dan membuktikan kelayakannya sebagai backbone untuk aplikasi mobile.



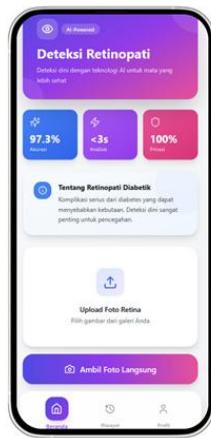
Gambar 8. Random Deteksi Citra

Pada Gambar 8 ditunjukkan beberapa test data random dengan membaca model terbaik yang dihasilkan bahwasannya terdapat label merah menunjukkan bahwasannya kesalahan deteksi dan yang label hijau menunjukkan deteksi yang sesuai antara data dan citra yang dihasilkan.

4.2. Implementasi dan Kinerja Aplikasi

1. Home Aplikasi

Halaman utama aplikasi menampilkan antarmuka yang modern dengan desain gradient warna indigo-purple-pink yang menarik secara visual. Pada bagian atas terdapat hero section yang menampilkan informasi aplikasi dengan badge "AI-Powered" yang menunjukkan bahwa sistem menggunakan teknologi kecerdasan buatan. Terdapat tiga kartu statistik yang menampilkan metrik penting: akurasi model 97.3%, waktu analisis kurang dari 3 detik, dan jaminan privasi 100%. Halaman ini juga menyediakan informasi edukatif mengenai Diabetic Retinopathy untuk meningkatkan kesadaran pengguna tentang pentingnya deteksi dini. Navigasi bottom bar menggunakan desain glassmorphism yang memberikan efek modern dan memudahkan pengguna untuk berpindah antar menu.



Gambar 9. Tampilan Home

2. Upload Citra

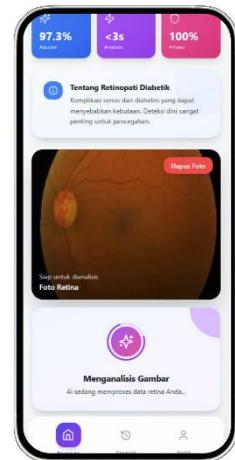
Fitur upload citra dirancang dengan dua opsi untuk memaksimalkan kemudahan pengguna. Opsi pertama adalah upload gambar dari galeri perangkat melalui area drag-and-drop yang dilengkapi dengan border dashed dan efek hover yang responsif. Opsi kedua adalah pengambilan foto langsung menggunakan kamera perangkat yang diakses melalui tombol dengan gradient hijau yang mencolok. Sistem mendukung berbagai format gambar standar (JPEG, PNG) dengan validasi ukuran file untuk memastikan proses upload berjalan optimal. Setelah gambar dipilih, preview gambar ditampilkan dalam container berukuran 320px dengan rounded corner yang konsisten dengan desain keseluruhan aplikasi.



Gambar 10. Tampilan Upload Citra

3. Menganalisis Citra

Proses analisis dimulai ketika pengguna menekan tombol "Mulai Analisis AI" yang ditampilkan dengan gradient hijau-emerald untuk memberikan indikasi positif. Selama proses analisis berlangsung, aplikasi menampilkan loading animation yang terdiri dari circular progress indicator dengan animasi rotasi dan icon Sparkles di tengahnya. Background menggunakan gradient biru-ungu dengan elemen dekoratif yang memberikan feedback visual bahwa sistem sedang bekerja. Teks informasi "Menganalisis Gambar" dan "AI sedang memproses data retina Anda..." ditampilkan untuk memberikan kepastian kepada pengguna bahwa proses sedang berjalan. Durasi analisis dirancang untuk memberikan kesan processing yang realistik sambil tetap menjaga respons yang cepat.



Gambar 11. Menganalisis Citra

4. Hasil Deteksi

Hasil deteksi ditampilkan dalam card yang informatif dengan desain yang berbeda berdasarkan hasil diagnosis. Untuk hasil "No DR" (No Diabetic Retinopathy), card menggunakan gradient hijau dengan icon CheckCircle, sedangkan untuk hasil "DR" (Diabetic Retinopathy) menggunakan gradient orange-red dengan icon AlertCircle. Setiap hasil dilengkapi dengan badge yang menunjukkan severity level dan tingkat kepercayaan AI dalam bentuk persentase dengan progress bar visual. Bagian rekomendasi tindakan ditampilkan

dalam numbered list dengan background putih semi-transparan menggunakan efek backdrop blur untuk keterbacaan yang optimal.



Gambar 11. Hasil Deteksi DR dan Non DR

5. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat ditarik beberapa kesimpulan sebagai berikut:

1. Arsitektur MobileNetV2 terbukti sangat efektif untuk tugas klasifikasi biner Retinopati Diabetik (RD vs Non-RD). Model yang dilatih menggunakan transfer learning pada dataset APTOS 2019 mampu mencapai akurasi sebesar 97.3% pada data uji, menunjukkan bahwa model ringan ini dapat bersaing dengan arsitektur yang lebih kompleks dalam mendekripsi tanda-tanda penyakit pada citra retina.
2. Proses konversi model ke format TensorFlow Lite (TFLite) dengan optimasi kuantisasi berhasil mengurangi ukuran file model secara signifikan sebesar 74%, dari 45.2 MB menjadi 11.8 MB. Pengurangan ukuran ini sangat krusial untuk memastikan model dapat diintegrasikan ke dalam paket aplikasi mobile tanpa membebani penyimpanan perangkat pengguna.
3. Aplikasi mobile berbasis Flutter mampu menjalankan inferensi secara mandiri di perangkat (on-device) tanpa memerlukan koneksi internet. Hasil pengujian menunjukkan rata-rata latensi inferensi yang sangat rendah, yaitu sekitar 150 milidetik per gambar, memberikan

pengalaman pengguna yang responsif dan real-time.

4. Sistem yang dikembangkan menawarkan solusi skrining RD yang akurat, portabel, hemat biaya, dan menjaga privasi data pasien. Karakteristik ini menjadikannya alat yang sangat potensial untuk diimplementasikan di fasilitas layanan kesehatan primer atau daerah terpencil dengan sumber daya terbatas, membantu meningkatkan aksesibilitas deteksi dini kebutaan akibat diabetes.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada seluruh pihak yang telah mendukung terlaksananya penelitian ini. Penulis juga berterima kasih kepada rekan-rekan dan pembimbing yang telah memberikan saran serta masukan berharga dalam penyusunan naskah ini.

DAFTAR PUSTAKA

- [1] I. D. Federation, *IDF Diabetes Atlas*. Brussels, Belgium: International Diabetes Federation, 2021. [Online]. Available: <https://diabetesatlas.org>
- [2] Z. L. Teo, Y. C. Tham, M. Yu, M. L. Chee, T. H. Rim, and N. Cheung, "Global prevalence of diabetic retinopathy and projection of burden through 2045: Systematic review and meta-analysis," *Ophthalmology*, vol. 128, no. 11, pp. 1580–1591, 2021, doi: 10.1016/j.ophtha.2021.04.040.
- [3] B. A. Umam, "Identifikasi Penyakit Daun Tembakau Berbasis Pengolahan Citra dengan Metode Convolutional Neural Network (CNN) Dan Metode Transfer Learning," 2024.
- [4] V. Gulshan *et al.*, "Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs," *JAMA*, vol. 316, no. 22, pp. 2402–2410, 2016, doi: 10.1001/jama.2016.17216.
- [5] D. S. W. Ting *et al.*, "Development and validation of a deep learning system for diabetic retinopathy and related eye diseases using retinal images from multiethnic populations with diabetes," *JAMA*, vol. 318, no. 22, pp. 2211–2223, 2017, doi: 10.1001/jama.2017.18152.
- [6] A. G. Howard *et al.*, "MobileNets: Efficient Convolutional Neural Networks for Mobile

- Vision Applications,” 2017, [Online]. Available: <http://arxiv.org/abs/1704.04861>
- [7] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, “MobileNetV2: Inverted residuals and linear bottlenecks,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2018, pp. 4510–4520. doi: 10.1109/CVPR.2018.00474.
- [8] M. H. Aly, M. S. El-Bialy, and A. A. M. Khalaf, “A mobile application for diabetic retinopathy screening based on deep learning,” *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 32, no. 7, pp. 804–811, 2020, doi: 10.1016/j.jksuci.2019.05.008.
- [9] A. Kaphle, M. Karkee, D. Maru, and A. Shrestha, “A lightweight CNN model for diabetic retinopathy classification on a mobile application,” *Heal. Inf. Sci. Syst.*, vol. 9, no. 1, p. 10, 2021, doi: 10.1007/s13755-021-00143-5.
- [10] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016. [Online]. Available: <https://www.deeplearningbook.org/>
- [11] G. A. Pratama, E. Y. Puspaningrum, and H. Maulana, “Convolutional Neural Network dan Faster Region Convolutional Neural Network untuk Klasifikasi Kualitas Biji Kopi Arabika,” *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, 2024, doi: 10.23960/jitet.v12i3.4887.
- [12] J. Ruiz, M. Mahmud, S. Jahan, and M. Islam, “On the feasibility of mobile phones for medical imaging analysis,” *Mob. Networks Appl.*, vol. 26, pp. 1234–1245, 2021, doi: 10.1007/s11036-020-01732-3.
- [13] N. Priaulx, “Digital health and the rural-urban divide,” *J. Bioeth. Inq.*, vol. 17, no. 3, pp. 453–460, 2020, doi: 10.1007/s11673-020-10002-2.
- [14] Z. Abed, R. D. Al-Dabbagh, and S. Naji, “Cloud-based deep learning system for automatic detection of diabetic retinopathy,” in *IEEE International Conference on Cloud Computing in Emerging Markets (CCEM)*, 2020. doi: 10.1109/CCEM51005.2020.00020.
- [15] S. Qummar *et al.*, “A deep learning ensemble approach for diabetic retinopathy detection,” *IEEE Access*, vol. 7, pp. 150530–150539, 2019, doi: 10.1109/ACCESS.2019.2947484.
- [16] S. R. Islam, D. Kwak, M. H. Kabir, M. Hossain, and K. S. Kwak, “The internet of things for health care: a comprehensive survey,” *IEEE Access*, vol. 3, pp. 678–708, 2015, doi: 10.1109/ACCESS.2015.2437951.
- [17] P. K. Darabi, “Diagnosis of Diabetic Retinopathy,” 2019, *Kaggle*. [Online]. Available: <https://www.kaggle.com/datasets/pkdarabi/dia>
- gnosis-of-diabetic-retinopathy
- [18] A. Mustopa, A. Sasongko, H. M. Nawawi, S. K. Wildah, and S. Agustiani, “Chicken Disease Detection Based on Fases Image Using EfficientNetV2L Model,” *SISTEMASI*, vol. 12, no. 3, p. 715, 2023, doi: 10.32520/stmsi.v12i3.2807.
- [19] H. C. et al. Shin, “Deep convolutional neural networks for computer-aided detection: Cnn architectures, dataset characteristics and transfer learning,” *IEEE Trans. Med. Imaging*, vol. 35, no. 5, pp. 1285–1298, 2016, doi: 10.1109/TMI.2016.2528162.
- [20] D. P. Kingma and J. Ba, “Adam: A method for stochastic optimization,” *arXiv Prepr. arXiv1412.6980*, 2014, [Online]. Available: <https://arxiv.org/abs/1412.6980>
- [21] R. et al. David, “TensorFlow Lite Micro: Embedded Machine Learning on TinyML Systems,” *arXiv Prepr. arXiv2104.10491*, 2021.
- [22] M. D’Amico and T. King, *Flutter for Beginners: An introductory guide to building cross-platform mobile applications*. Birmingham, UK: Packt Publishing, 2023.