

## PEMANFAATAN ARSITEKTUR MOBILENETV2 UNTUK DETEKSI DAN KLASIFIKASI PENYAKIT KATARAK

Pearl Aurellia Nafeesa Selang, Sancia Alicia Taligangsing,  
Marchel Rafelino Kotta, Pujo Hari Saputro, Sherwin Reinaldo Sompie

Teknik Informatika, Universitas Sam Ratulangi  
Jalan Kampus Unsrat, Manado, Indonesia  
pearlselang026@unsrat.ac.id

### ABSTRAK

Katarak merupakan salah satu penyebab utama gangguan penglihatan dan kebutaan global, sehingga deteksi dini menjadi sangat krusial untuk mencegah penurunan fungsi penglihatan yang lebih parah. Namun, keterbatasan infrastruktur komputasi dan tenaga ahli medis di daerah urban maupun terpencil sering kali menjadi hambatan dalam proses skrining awal. Penelitian ini mengusulkan sebuah sistem klasifikasi fase katarak senilis yang efisien menggunakan arsitektur jaringan saraf konvolusional ringan berbasis MobileNet melalui pendekatan transfer learning. Dataset asli yang digunakan berjumlah 1.500 citra, terbagi rata ke dalam tiga kategori (Normal, Immature, dan Mature Cataract) masing-masing 500 citra. Sebanyak 375 citra asli (125 citra per kelas) dipisahkan sejak awal sebagai set pengujian independen yang sepenuhnya steril dari augmentasi, sementara sisa data latih diperkaya melalui teknik augmentasi citra menggunakan pustaka Albumentations hingga mencapai total 15.000 citra latih (5.000 citra per kelas) guna mengatasi keterbatasan sampel medis dan meredam risiko overfitting. Hasil eksperimen menunjukkan kinerja pemodelan yang sangat unggul dengan akurasi sebesar 97,33%, presisi rata-rata (macro) 97,36%, sensitivitas (recall) rata-rata 97,33%, serta skor F1 makro sebesar 97,32%. Karakteristik arsitektur yang ringan namun memiliki akurasi tinggi ini menunjukkan potensi menjanjikan untuk diadopsi sebagai instrumen penapisan awal medis pada perangkat bersumber daya komputasi terbatas.

**Kata kunci :** Katarak, Klasifikasi Citra, Kecerdasan Buatan, MobileNet, Transfer Learning

### 1. PENDAHULUAN

Masalah utama dalam penanganan katarak di lapangan adalah penyebaran tenaga medis yang tidak merata, dimana mayoritas pakar terpusat di pusat perkantoran besar[1].

Untuk mengatasi kendala aksesibilitas tersebut, penelitian ini fokus pada pengembangan sistem klasifikasi dan deteksi otomatis yang dapat dijalankan pada perangkat dengan spesifikasi terbatas [2].

Penerapan teknologi deep learning menjadi relevan karena mampu memberikan hasil diagnosis yang objektif dan cepat tanpa bergantung penuh pada kehadiran seorang spesialis secara fisik[3].

Dalam perkembangan teknologi terbaru, salah satu arsitektur Convolutional Neural Network yaitu MobileNetV2 telah terbukti lebih efisien dibandingkan model berat lainnya seperti ResNet50-IBN dalam hal kebutuhan daya komputasi[4].

Teknik depthwise separable convolution dimanfaatkan oleh arsitektur ini yang memungkinkan model bekerja secara optimal pada lingkungan mobile atau web-based[5].

Struktur inverted residual dan linear bottleneck yang digunakan pada model ini memungkinkan aliran informasi yang lebih efisien di antara lapisan tanpa membebani memori perangkat secara berlebihan[5].

Optimasi tersebut terbukti mampu menghasilkan performa klasifikasi yang stabil dan akurat pada dataset citra medis yang kompleks, sehingga menjadikannya pilihan yang ideal untuk aplikasi skrining kesehatan mandiri di lapangan[6].

Tujuan dari penelitian ini adalah untuk menerapkan arsitektur MobileNet menggunakan teknik transfer learning untuk mengelompokkan tahapan katarak secara otomatis, sekaligus menganalisis pengaruh augmentasi data terhadap stabilitas model dalam menangani variasi citra mata yang kompleks. Melalui proses ini, maksud dari penelitian adalah mengukur kinerja model berdasarkan parameter akurasi, presisi, dan recall dalam membedakan kategori Normal, Immature, dan Mature Cataract, serta mengevaluasi efisiensi komputasi MobileNet sebagai solusi teknologi yang ringan dan fleksibel untuk diimplementasikan pada perangkat mobile demi mendukung sistem skrining kesehatan dini di masyarakat.

Manfaat penelitian ini mencakup aspek teknologi melalui pembuktian keefektifan MobileNet dan teknik augmentasi data dalam menghasilkan model klasifikasi katarak yang ringan namun akurat untuk diterapkan pada perangkat dengan sumber daya terbatas. Bagi sektor kesehatan, sistem ini berfungsi sebagai alat pendukung keputusan yang objektif bagi tenaga medis dalam melakukan skrining awal secara cepat, sekaligus memperluas jangkauan layanan kesehatan mata hingga ke daerah terpencil yang minim akses dokter spesialis. Secara sosial, keberadaan teknologi ini memungkinkan masyarakat untuk mendeteksi lebih dini gejala katarak guna mencegah risiko kebutaan permanen melalui proses pemeriksaan yang praktis, transparan, dan terjangkau bagi semua lapisan masyarakat.

Penelitian ini secara khusus dibatasi pada analisis citra optik dua dimensi (2D RGB) untuk deteksi penyakit mata spesifik, yaitu Katarak. Fokus dari proses klasifikasi penelitian ini terdiri dari tiga kategori tahapan pengembangan katarak (Normal, Immature, dan Mature Cataract). Model ini tidak dirancang untuk menggunakan data klinis pasien seperti riwayat medis atau usia sebagai variabel input. Sistem deteksi dikembangkan dengan pembatasan pada penggunaan arsitektur Convolutional Neural Network (CNN) kelas ringan, yaitu MobileNet, menggunakan pendekatan Transfer Learning. Penelitian ini difokuskan pada evaluasi efisiensi model yaitu dengan optimasi variasi data menggunakan teknik augmentasi (Albumentations) tanpa melakukan studi perbandingan dengan arsitektur *heavy-weight* (seperti ResNet, VGG, atau Vision Transformers). Hal ini sejalan dengan tujuan akhir penelitian untuk menghasilkan model yang berukuran kecil dan memiliki jeda rendah agar cocok diimplementasikan pada perangkat mobile.

## 2. TINJAUAN PUSTAKA


Dalam beberapa tahun terakhir, pendekatan Computer Vision berbasis Deep Learning telah menggantikan metode ekstraksi fitur manual tradisional dalam diagnosis penyakit mata. Sebuah sistem berbasis Convolutional Neural Network (CNN) yang dilakukan oleh Junayed dkk[7] untuk mendeteksi katarak secara otomatis, bernama CataractNet yang membuktikan bahwa jaringan saraf tiruan mampu mengenali pola kekeruhan lensa dengan presisi tinggi layaknya pakar oftalmologi.

Penelitian lain oleh Simanjuntak dkk[8] mengonfirmasi bahwa CNN dapat digunakan untuk mengelompokkan tahapan katarak menjadi beberapa level (seperti Normal, Immature, Mature, dan Hypermature) dengan memanfaatkan ekstraksi fitur tingkat dalam secara mandiri. Artikel ini secara spesifik membahas alasan di balik pemilihan MobileNetV2.

Suarjuna dkk. [6] menegaskan bahwa struktur model MobileNetV2 yang lightweight (ringan) serta kemampuannya merepresentasikan fitur yang kuat menjadikannya sangat cocok untuk di-deploy pada sistem medis portable dan embedded (seperti aplikasi mobile). Mereka menggunakan teknik Transfer Learning dari ImageNet untuk melakukan klasifikasi katarak (Mature dan Immature), yang persis sama dengan apa yang dilakukan penelitian kami.

## 3. METODE PENELITIAN

Metodologi penelitian ini diterapkan melalui serangkaian tahapan yang terstruktur dan terintegrasi dalam bentuk pipeline, mulai dari persiapan data hingga interpretasi hasil.



Gambar 1. Diagram alir metode penelitian

### 3.1. Data Preparation

Tahap penyiapan data diawali dengan penyelarasan dimensi seluruh citra mentah menjadi format RGB berukuran 224 x 224 piksel supaya menyesuaikan spesifikasi input arsitektur MobileNet, diikuti dengan normalisasi nilai piksel[6].

Selanjutnya, dataset dibagi secara berjenjang menjadi set testing independen yang mempertahankan citra asli sebanyak 375 citra (125 sampel per kelas) dan set training dasar. Untuk mengantisipasi keterbatasan sampel medis dan menghindari risiko penyeragaman (*overfitting*), teknik augmentasi diimplementasikan khusus pada data latih menggunakan library (pustaka) Albumentations melalui manipulasi ruang dan pencahayaan, sehingga volume data berkembang secara seimbang hingga mencapai total 15.000 citra teraugmentasi (5.000 sampel per kelas).

### 3.2. Exploratory Data Analytic

Tahap analisis eksplorasi data dilakukan secara kuantitatif dan kualitatif untuk menguji kelayakan citra sebelum pemodelan[9].

Secara kuantitatif, kami memeriksa distribusi data guna memastikan seluruh kategori terdistribusi seragam dengan proporsi seimbang sebesar 33,3% per kelas demi menghindari bias model. Sementara secara kualitatif, kami melakukan inspeksi visual acak pada sampel citra dari ketiga sumber Kaggle. Langkah ini bertujuan memvalidasi perbedaan fisik lensa mata pada tiap fase, yaitu kondisi jernih pada kelas Normal, kekeruhan tipis atau parsial pada fase Immature, serta opasitas pekat menyeluruh yang menjadi ciri khas utama kategori Mature.

### 3.3. Arsitektur Model dan Pemodelan

Sistem deteksi katarak dalam penelitian ini mengandalkan arsitektur MobileNet melalui pendekatan transfer learning berbasis bobot ImageNet untuk mengekstrak fitur klinis secara optimal di tengah keterbatasan data medis asli[10].


Guna memangkas beban komputasi dan menjaga fitur generik yang sudah terbentuk, seluruh lapisan konvolusi dasar pada *backbone* dikondisikan dalam status pasif atau dibekukan (*freezing*)[11].

Tepat di atas struktur dasar tersebut, kami menyematkan blok klasifikasi kustom (*custom head*) yang memadukan *Global Average Pooling* untuk menyederhanakan dimensi matriks citra, serta lapisan *Dropout* untuk meredam risiko *overfitting*. Aliran data kemudian diteruskan ke *Dense Layer* dengan fungsi aktivasi ReLU untuk memetakan hubungan nonlinear pada pola kekeruhan lensa, sebelum akhirnya diselesaikan oleh lapisan output Softmax tiga neuron yang mengeluarkan nilai probabilitas klasifikasi final untuk kelas Normal, Immature, dan Mature Cataract.

### 3.4. Pelatihan Model

Proses pelatihan dilakukan menggunakan Google Colab dengan dukungan GPU untuk mempercepat proses komputasi. Model MobileNetV2 menggunakan bobot awal (*pre-trained weight*) dari ImageNet, sedangkan seluruh layer *backbone* dibekukan (*freeze*) dan hanya lapisan klasifikasi (*custom head*) yang dilatih ulang. Pelatihan dilakukan selama 150 epoch (75 epoch per fase) menggunakan batch size 32 dengan optimizer Adam dan learning rate awal sebesar 0.00001. Fungsi kerugian Categorical Crossentropy dipasang untuk mengukur seberapa jauh melesetnya prediksi model terhadap label asli[12].

Fungsi aktivasi pada layer keluaran menggunakan Softmax karena penelitian melakukan klasifikasi tiga kelas. Selama proses pelatihan diterapkan callback *ReduceLROnPlateau* untuk menurunkan learning rate secara otomatis ketika validasi tidak mengalami peningkatan, serta *EarlyStopping* untuk menghentikan pelatihan apabila model tidak lagi menunjukkan peningkatan performa sehingga dapat meminimalkan risiko *overfitting*.



Gambar 2. Diagram alir arsitektur sistem klasifikasi katarak berbasis MobileNetV2.

### 3.5. Evaluasi Performa dan Analisa Hasil

Tahap kemudian dilakukan melalui pengujian independen menggunakan 375 citra asli dari Test Set yang sepenuhnya steril dari intervensi augmentasi guna menjamin objektivitas generalisasi model. Evaluasi performa kuantitatif diukur secara matematis melalui ekstraksi metrik standar klasifikasi medis yang meliputi nilai akurasi (*accuracy*), presisi (*precision*), sensitivitas (*recall*), serta F1-Score[13].

Distribusi detail mengenai akurasi prediksi dan pola kesalahan klasifikasi antar-kelas kemudian dipetakan secara visual ke dalam Confusion Matrix. Sebagai tambahan analisis kualitatif, sistem menampilkan visualisasi sampel citra yang berhasil diklasifikasikan dengan benar (*Correctly Classified Images*) dan citra yang salah tebak (*Misclassified Images*) untuk membedakan batas marginal fitur klinis yang memicu ambiguitas pada performa MobileNet[14].

### 3.6. Implementasi dan Integrasi Sistem

Integrasi ke aplikasi mobile dilakukan setelah model klasifikasi berhasil dilatih dan dikonversi ke format *.tflite*[15].

Model tersebut kemudian diintegrasikan ke dalam aplikasi mobile bernama CataractScan yang dikembangkan menggunakan Flutter dan Android Studio. Aplikasi memanfaatkan plugin camera, *image\_picker*, *tflite\_flutter*, dan *image* untuk mendukung proses pengambilan gambar, pemilihan gambar dari galeri, serta inferensi model secara lokal di perangkat.

Aplikasi terdiri atas halaman home, halaman scan atau pindai gambar mata, halaman riwayat hasil scan sebelumnya, serta halaman informasi mengenai project. Pada halaman scan, pengguna dapat memilih untuk mengambil foto menggunakan kamera atau mengunggah gambar dari galeri perangkat. Oleh karena itu, aplikasi memerlukan izin akses kamera dan galeri. Model TensorFlow Lite diintegrasikan melalui aset *assets/model.tflite* yang dipanggil oleh aplikasi Flutter[16].

Alur penggunaan aplikasi dimulai ketika pengguna memilih atau mengambil gambar mata yang akan dipindai. Gambar tersebut kemudian diproses di dalam aplikasi dan dijalankan melalui model untuk menghasilkan prediksi klasifikasi berupa normal, immature, atau mature beserta nilai confidence dari hasil prediksi. Selain menampilkan hasil klasifikasi, halaman home aplikasi juga memuat informasi mengenai gejala awal katarak dan tindak lanjut apabila pengguna memiliki kekhawatiran terhadap penyakit katarak.

## 4. HASIL DAN PEMBAHASAN

### 4.1. Evaluasi Kinerja Model

Ketajaman model dalam mengenali fase katarak diuji menggunakan set pengujian yang sepenuhnya independen berisi 375 citra murni. Pengujian ini sangat

krusial untuk mengukur daya generalisasi jaringan pada skenario pemeriksaan dunia nyata[17].

Hasil kalkulasi metrik menunjukkan bahwa arsitektur MobileNet berhasil mencapai tingkat akurasi pengujian sebesar 97,33%. Pencapaian ini sejalan dengan performa pada fase pelatihan yang menyentuh angka akurasi 94,57% sehingga mengonfirmasi ketiadaan indikasi *overfitting* yang drastis pada sistem. Lebih lanjut, rincian performa memperlihatkan kemampuan pengenalan yang terdistribusi seimbang, di mana nilai rata-rata presisi, sensitivitas (*recall*), dan skor F1 berturut-turut mencatatkan angka 97,36%, 97,33%, dan 97,32%. Tingginya perolehan metrik ini memvalidasi bahwa rasio setara yang diterapkan sejak awal pendefinisian dataset sukses menghindarkan model dari tendensi bias terhadap kelas tertentu[18].

Tabel 1. Tabel Laporan Klasifikasi

|              | Precision | Recall | F1-Score | Support |
|--------------|-----------|--------|----------|---------|
| Immature     | 0.9843    | 1.000  | 0.9921   | 125     |
| Mature       | 0.9832    | 0.9360 | 0.9590   | 125     |
| Normal       | 0,9535    | 0,9840 | 0,9685   | 125     |
| Accuracy     |           |        | 0.9733   | 375     |
| Macro Avg    | 0.9736    | 0.9733 | 0.9732   | 375     |
| Weighted Avg | 0.9736    | 0.9733 | 0.9732   | 375     |

#### 4.2. Analisis Confusion Matrix

Untuk membedah sebaran prediksi dan melacak area spesifik di mana model melakukan kesalahan tebak, kami memetakan output klasifikasi ke dalam Confusion Matrix (Gambar 1). Apabila diteliti lebih jauh, instrumen ini memperlihatkan bahwa model sangat tangguh dalam membedakan mata Normal dari fase katarak lanjut (Mature). Sebagian besar galat klasifikasi atau salah tebak justru terjadi pada area perbatasan klinis, khususnya antara kelas Immature dan Mature. Fenomena tumpang tindih (*overlapping*) prediksi pada kedua kelas ini sebenarnya wajar secara medis, mengingat transisi dari kekeruhan lensa parsial (Immature) menuju kekeruhan padat (Mature) sering kali memiliki gradasi piksel yang sangat samar pada citra digital dua dimensi[19].


Berdasarkan Gambar 1, model menunjukkan kinerja yang sangat baik dalam mengenali kelas Immature Cataract. Seluruh 125 citra pada kelas ini berhasil diklasifikasikan dengan benar tanpa adanya kesalahan prediksi ke kelas lain. Hasil tersebut menunjukkan bahwa karakteristik visual pada fase immature dapat dipelajari dengan baik oleh model, sehingga menghasilkan nilai *recall* sebesar 100%. Kemampuan ini mengindikasikan bahwa model memiliki sensitivitas yang sangat tinggi dalam mendeteksi keberadaan katarak pada fase tersebut.

Pada kelas Mature Cataract, dari total 125 citra uji, sebanyak 117 citra berhasil diklasifikasikan secara tepat. Namun demikian, masih terdapat delapan citra yang mengalami kesalahan klasifikasi, terdiri atas dua

citra yang diprediksi sebagai Immature Cataract dan enam citra yang diprediksi sebagai Normal. Pola kesalahan ini menunjukkan bahwa beberapa citra mature memiliki karakteristik visual yang belum sepenuhnya berbeda secara jelas dari kelas lainnya. Kondisi tersebut dapat dipengaruhi oleh variasi tingkat kekeruhan lensa, pencahayaan saat proses pengambilan gambar, maupun kualitas citra yang menyebabkan fitur visual menjadi kurang representatif.

Sementara itu, pada kelas Normal, model mampu mengklasifikasikan 123 dari 125 citra dengan benar. Hanya terdapat dua citra yang diprediksi sebagai Mature Cataract, sedangkan tidak ditemukan citra normal yang salah diklasifikasikan sebagai Immature Cataract. Jumlah kesalahan yang relatif kecil tersebut menunjukkan bahwa model mampu membedakan kondisi mata normal dengan mata yang mengalami katarak secara konsisten.

Apabila ditinjau secara keseluruhan, sebagian besar kesalahan klasifikasi terjadi pada kelas Mature Cataract. Hal ini menunjukkan bahwa model masih mengalami kesulitan dalam mengenali beberapa citra yang berada pada kondisi transisi atau memiliki karakteristik visual yang kurang jelas. Meskipun demikian, jumlah kesalahan tersebut relatif kecil dibandingkan dengan keseluruhan data uji, sehingga tidak memberikan pengaruh yang signifikan terhadap performa model secara umum. Hasil confusion matrix ini sejalan dengan nilai evaluasi yang diperoleh sebelumnya, yaitu akurasi sebesar 97,33%, *precision* rata-rata sebesar 97,36%, *recall* sebesar 97,33%, dan *F1-score* sebesar 97,32%. Konsistensi tersebut menunjukkan bahwa model MobileNetV2 mampu melakukan klasifikasi tiga kategori katarak dengan tingkat keandalan yang tinggi serta memiliki kemampuan generalisasi yang baik terhadap data uji yang belum pernah digunakan selama proses pelatihan.



Gambar 3. Confusion Matrix

#### 4.3. Analisis Hasil Klasifikasi

Berdasarkan seluruh rangkaian eksperimen yang telah dieksekusi, dapat disimpulkan bahwa implementasi arsitektur jaringan saraf konvolusional

yang ringan berbasis MobileNet melalui pendekatan transfer learning terbukti sangat efektif dalam mengklasifikasikan fase katarak. Sistem yang dikembangkan berhasil menerjemahkan karakteristik fisis lensa mata dengan tingkat keandalan yang sangat tinggi, dibuktikan melalui pencapaian akurasi pengujian sebesar 97,33% serta skor F1 makro sebesar 97,32% pada set data independen murni. Integrasi teknik augmentasi citra menggunakan pustaka Albumentations dan kebijakan pembekuan lapisan konvolusi dasar (*layer freezing*) terbukti sempurna dalam menjaga stabilitas proses komputasi sekaligus meredam risiko *overfitting*. Dengan kombinasi performa yang superior namun tetap hemat konsumsi daya, model ini memiliki prospek yang sangat menjanjikan untuk diadopsi sebagai instrumen skrining awal klinis, khususnya pada lingkungan medis dengan keterbatasan infrastruktur komputasi perangkat keras.

#### 4.4. Inspeksi Kualitatif Hasil Klasifikasi

Evaluasi mendalam dilakukan dengan melakukan inspeksi visual langsung terhadap citra yang diklasifikasikan dengan benar maupun yang meleset (*misclassified*), seperti yang disajikan pada Gambar 4. Inspeksi kualitatif ini membuka membantu memahami alasan di balik kekeliruan prediksi [14].



Gambar 4. Sampel Citra Prediksi Tepat dan Meleset

Berdasarkan Tabel 1, kelas Immature mencapai recall sempurna (100%), yang berarti seluruh citra Immature pada set uji berhasil dikenali tanpa ada yang terlewat. Sebaliknya, kelas Mature memiliki recall terendah di antara ketiga kelas (93,60%), menandakan terdapat sejumlah citra Mature yang justru diprediksi sebagai kelas lain, sesuai dengan pola pada Confusion Matrix (Gambar 3) yang menunjukkan ada kesalahan klasifikasi antara Immature dan Mature. Sementara itu, kelas Normal memperoleh precision terendah (95,35%), yang menandakan adanya sejumlah kecil citra dari kelas lain yang keliru diklasifikasikan sebagai Normal. Dari pengamatan visual terhadap sampel *misclassified*, kegagalan model umumnya dipicu oleh faktor seperti pantulan cahaya (*glare*) dari flash kamera yang menutupi area pupil, atau resolusi gambar dari kamera *smartphone* tertentu yang menghasilkan *noise* berlebih [20]. Pada kasus citra Mature yang salah diprediksi sebagai Immature, pola ini umumnya terjadi pada tahap awal kekeruhan lensa padat yang secara visual masih menyisakan area transparan parsial, sehingga model cenderung menangkap fitur tersebut sebagai karakteristik Immature. Sementara pada kasus false positive kelas Normal, gangguan pendaran cahaya (*glare*) kerap kali diklasifikasikan secara keliru oleh jaringan konvolusi sebagai area putih kekeruhan yang identik dengan katarak.

#### 5. KESIMPULAN DAN SARAN

Berdasarkan seluruh rangkaian eksperimen yang telah dieksekusi, dapat disimpulkan bahwa implementasi arsitektur jaringan saraf konvolusional yang ringan berbasis MobileNetV2 dengan pendekatan transfer learning terbukti efektif dalam mengklasifikasikan fase katarak. Pada pengujian menggunakan 375 citra independen (125 citra per kelas) yang sepenuhnya steril dari augmentasi, sistem mencapai akurasi sebesar 97,33%, dengan presisi rata-rata (macro) 97,36%, sensitivitas (recall) rata-rata 97,33%, dan skor F1 makro 97,32%. Secara rinci per kelas, Immature memperoleh precision 98,43%, recall 100,00%, dan F1-score 99,21%; Mature memperoleh precision 98,32%, recall 93,60%, dan F1-score 95,90%; sedangkan Normal memperoleh precision 95,35%, recall 98,40%, dan F1-score 96,85%. Integrasi teknik augmentasi citra menggunakan Albumentations dan *layer freezing* terbukti sangat baik dalam menjaga stabilitas proses komputasi sekaligus meredam risiko *overfitting*. Model ini memiliki potensi menjanjikan untuk dikembangkan sebagai instrumen skrining awal klinis, khususnya pada lingkungan medis dengan keterbatasan infrastruktur komputasi perangkat keras. Untuk pengembangan penelitian mendatang, disarankan untuk dieksplorasi lebih lanjut menggunakan variasi arsitektur lightweight lain guna meningkatkan sensitivitas deteksi pada fase Mature, mengingat recall kelas ini masih relatif lebih rendah dibandingkan dua kelas lainnya.

## DAFTAR PUSTAKA

- [1] Kementerian Kesehatan Republik Indonesia, *Peta Jalan Penanggulangan gangguan penglihatan di Indonesia Tahun 2017-2030*. 2018.
- [2] Sofia Saidah, I. P. Y. N. Suparta, and E. Suhartono, "Modifikasi Convolutional Neural Network Arsitektur GoogLeNet dengan Dull Razor Filtering untuk Klasifikasi Kanker Kulit," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 11, no. 2, pp. 148–153, 2022, doi: 10.22146/jnteti.v11i2.2739.
- [3] A. Esteva *et al.*, "Deep learning-enabled medical computer vision," *npj Digit. Med.*, vol. 4, no. 1, pp. 1–9, 2021, doi: 10.1038/s41746-020-00376-2.
- [4] Z. Cui, Y. Cheng, S. Pan, Y. Zhu, and W. Dai, "A deep learning-driven cataract screening model derived from multicenter real-world dataset," *Front. Med.*, vol. 12, no. November, pp. 1–10, 2025, doi: 10.3389/fmed.2025.1691419.
- [5] M. Anas and R. Wulanningrum, "Model Prediktif Klasifikasi Tahap Katarak dari Citra Lensa Menggunakan MobileNetV2," vol. 5, pp. 398–404, 2026.
- [6] K. Suarjuna, I. P. Adi, and A. Naswin, "Cataract Classification in Eye Images Using MobileNetV2," vol. 8, no. December, pp. 114–125, 2025.
- [7] M. S. Junayed, M. B. Islam, A. Sadeghzadeh, and S. Rahman, "CataractNet: An automated cataract detection system using deep learning for fundus images," *IEEE Access*, vol. 9, pp. 128799–128808, 2021, doi: 10.1109/ACCESS.2021.3112938.
- [8] R. B. J. Simanjuntak, Y. Fu'Adah, R. Magdalena, S. Saidah, A. B. Wiratama, and I. Da'Wan Salim Ubaidah, "Cataract Classification Based on Fundus Images Using Convolutional Neural Network," *Int. J. Informatics Vis.*, vol. 6, no. 1, pp. 33–38, 2022, doi: 10.30630/joiv.6.1.856.
- [9] A. Alabduljabbar, S. U. Khan, A. Alsuhaibani, F. Almarshad, and Y. N. Altherwy, "Medical imaging datasets, preparation, and availability for artificial intelligence in medical imaging," *J. Alzheimer's Dis. Reports*, vol. 8, no. 1, pp. 1471–1483, 2024, doi: 10.3233/adr-240129.
- [10] H. E. Kim, A. Cosa-Linan, N. Santhanam, M. Jannesari, M. E. Maros, and T. Ganslandt, "Transfer learning for medical image classification: a literature review," *BMC Med. Imaging*, vol. 22, no. 1, pp. 1–13, 2022, doi: 10.1186/s12880-022-00793-7.
- [11] L. Alzubaidi *et al.*, *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*, vol. 8, no. 1. Springer International Publishing, 2021. doi: 10.1186/s40537-021-00444-8.
- [12] O. Elharrouss *et al.*, "Task-based Loss Functions in Computer Vision: A Comprehensive Review," 2025, [Online]. Available: <http://arxiv.org/abs/2504.04242>
- [13] S. A. Hicks *et al.*, "On evaluation metrics for medical applications of artificial intelligence," *Sci. Rep.*, vol. 12, no. 1, pp. 1–9, 2022, doi: 10.1038/s41598-022-09954-8.
- [14] Z. Salahuddin, H. C. Woodruff, A. Chatterjee, and P. Lambin, "Transparency of deep neural networks for medical image analysis: A review of interpretability methods," *Comput. Biol. Med.*, vol. 140, no. December 2021, p. 105111, 2022, doi: 10.1016/j.compbiomed.2021.105111.
- [15] S. Yadav and J. K. P. S. Yadav, "Automatic Cataract Severity Detection and Grading Using Deep Learning," *J. Sensors*, vol. 2023, 2023, doi: 10.1155/2023/2973836.
- [16] A. M. Sattar *et al.*, "Accelerating Cross-platform Development with Flutter Framework," *J. Open Source Dev.*, vol. 10, no. 2, pp. 1–11, 2023, doi: 10.37591/joosd.v10i2.580.
- [17] G. Varoquaux and V. Cheplygina, "Machine learning for medical imaging: methodological failures and recommendations for the future," *npj Digit. Med.*, vol. 5, no. 1, 2022, doi: 10.1038/s41746-022-00592-y.
- [18] A. R. Chłopowiec, K. Karanowski, T. Skrzypczak, M. Grzesiuk, A. B. Chłopowiec, and M. Tabakov, "Counteracting Data Bias and Class Imbalance—Towards a Useful and Reliable Retinal Disease Recognition System," *Diagnostics*, vol. 13, no. 11, 2023, doi: 10.3390/diagnostics13111904.
- [19] L. Maier-Hein *et al.*, "Metrics reloaded: recommendations for image analysis validation," *Nat. Methods*, vol. 21, no. 2, pp. 195–212, 2024, doi: 10.1038/s41592-023-02151-z.
- [20] B. Gu, M. Christopher, S. H. Lim, and S. L. Baxter, "Deep Learning-Based Analysis of Ocular Anterior Segment Diseases from Patient-Self-Captured Smartphone Images," *Informatics*, vol. 12, no. 1, pp. 14–17, 2025, doi: 10.3390/informatics12010002.