

Model Prediktif Klasifikasi Tahap Katarak dari Citra Lensa Menggunakan MobileNetV2

Muhammad Anas Ma'ruf¹, Resty Wulanningrum²

^{1,2}Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

E-mail: ¹marufanas669@gmail.com, ²restyw@unpkdr.ac.id

Katarak merupakan penyebab utama gangguan penglihatan yang memerlukan metode deteksi dini yang akurat dan efisien. Penelitian ini bertujuan mengembangkan model prediktif untuk klasifikasi tahap katarak secara otomatis dengan mengintegrasikan arsitektur *Deep Learning* ke dalam *platform* berbasis *web*. Alur proses sistem dimulai dengan tahap pra-pemrosesan citra menggunakan metode *Contrast Limited Adaptive Histogram Equalization (CLAHE)* untuk menajamkan fitur opasitas pada lensa melalui peningkatan kontras adaptif. Citra yang telah dioptimalkan kemudian diproses menggunakan arsitektur *MobileNetV2* dengan pendekatan *Transfer Learning* yang memanfaatkan bobot praterlatih dari *ImageNet*. Model ini dikonfigurasi untuk mengklasifikasikan kondisi lensa ke dalam tiga kategori: Normal, Katarak Imatur, dan Katarak Matur. Untuk implementasi pengguna, model diintegrasikan ke dalam *framework Streamlit* agar dapat diakses melalui *browser* secara *real-time*. Hasil pengujian menunjukkan bahwa model mencapai tingkat akurasi sebesar 97,73%, dengan performa yang konsisten pada metrik Presisi, *Recall*, dan *F1-Score*. Sistem ini memberikan solusi skrining katarak yang objektif, ringan, dan mudah diakses untuk membantu efisiensi diagnostik di fasilitas kesehatan terbatas.

Kata Kunci — *Deep Learning, Katarak, MobileNetV2, Streamlit, Klasifikasi, CLAHE*

1. PENDAHULUAN

Kekeruhan lensa mata, atau katarak, tetap menjadi masalah kesehatan masyarakat global yang signifikan dan merupakan penyebab utama kebutaan reversibel di seluruh dunia [1]. Untuk manajemen pasien yang efektif, klasifikasi tahap katarak yang akurat [2], seperti menentukan apakah pasien berada pada tahap Katarak Imatur atau Katarak Matur, adalah langkah klinis yang sangat krusial [3]. Penentuan tahap ini sangat penting karena ia menjadi dasar untuk mengidentifikasi waktu optimal intervensi bedah [4], yang mana keterlambatan penanganan dapat berakibat fatal pada kualitas penglihatan pasien [5]. Namun, diagnosis katarak konvensional sebagian besar masih dilakukan secara manual oleh dokter mata menggunakan alat canggih seperti *slit lamp* [6], yang mana ketersediaannya terbatas di layanan kesehatan primer atau di daerah terpencil, sehingga diagnosis yang objektif dan merata sulit dicapai [7]. Kesenjangan dalam aksesibilitas diagnostik inilah yang mendorong perlunya solusi skrining yang lebih otomatis, cepat, dan objektif untuk mendukung fasilitas kesehatan dengan sumber daya terbatas [8].

Dalam beberapa tahun terakhir, kemajuan pesat dalam ranah Kecerdasan Buatan (*AI*), khususnya *Convolutional Neural Network (CNN)*, telah merevolusi analisis citra medis oftalmologi [9], menawarkan kemampuan untuk mengklasifikasikan pola penyakit dengan akurasi tinggi menggunakan pembelajaran transfer [10]. Meskipun model *CNN* yang dalam (seperti *VGG* atau *ResNet*) mampu mencapai akurasi tinggi dalam tugas klasifikasi, model tersebut memerlukan daya komputasi yang besar [11]. Oleh karena itu, penelitian ini memposisikan arsitektur *MobileNetV2* sebagai pilihan yang optimal [12]. *MobileNetV2* dirancang khusus untuk efisiensi komputasi, menjadikannya model ideal untuk *edge computing* melalui penggunaan teknik *Depthwise Separable Convolution* yang mengurangi kompleksitas model [13]. Arsitektur *MobileNetV2* telah terbukti efektif dalam pengembangan sistem grading katarak yang efisien dengan mempertahankan performa klasifikasi yang kompetitif dibandingkan model yang lebih besar [14].

Efisiensi inheren dari arsitektur *MobileNetV2* ini memungkinkan model yang sudah terlatih untuk diimplementasikan secara efisien sebagai layanan web [15]. Kami memilih *Streamlit* sebagai *framework* antarmuka karena kemudahannya dalam mendeploy model *Machine Learning* berbasis *Python* ke dalam aplikasi web interaktif, yang dapat diakses luas melalui browser tanpa batasan sistem operasi spesifik. Penelitian ini bertujuan untuk memvalidasi kinerja *MobileNetV2* dalam klasifikasi tiga-tahap katarak (Penglihatan Normal, Katarak Imatur, Katarak Matur) dan membuktikan kelayakannya sebagai model *lightweight* yang dapat diandalkan untuk diagnosis berbasis web yang portabel dan dapat diakses dari mana saja.

2. METODE PENELITIAN

Metode penelitian ini disusun untuk mengembangkan dan memvalidasi model *Deep Learning MobileNetV2* dalam tugas klasifikasi citra medis multi-kelas. Pendekatan ini mengikuti kerangka kerja standar *Deep Learning*, dimulai dari pengumpulan data mentah, proses *preprocessing* dan *enhancement* yang spesifik untuk citra oftalmologi, hingga pemodelan *Transfer Learning* untuk membangun sistem klasifikasi. Secara garis besar,

metodologi ini mencakup tahap Analisis Kebutuhan sistem berbasis *web*, Pengumpulan dan Persiapan Data, Pemodelan *Machine Learning*, Implementasi Sistem menggunakan *Streamlit* sebagai antarmuka pengguna, dan diakhiri dengan Evaluasi Model untuk mengukur kinerja klasifikasi katarak (Normal, Imatur, Matur).

2.1 Analisis Kebutuhan

2.1.1 Analisis Permasalahan

Permasalahan utama yang diatasi adalah keterbatasan layanan kesehatan primer dalam mendiagnosis tahap katarak secara objektif dan cepat. Diagnosis manual menggunakan slit lamp bersifat subjektif dan membutuhkan spesialis, yang jarang tersedia. Oleh karena itu, diperlukan sistem yang menyediakan alat skrining cepat dan objektif untuk klasifikasi tiga tahap katarak: Penglihatan Normal, Katarak Imatur, dan Katarak Matur.

2.1.2 Analisis Kebutuhan Fungsional

Sistem klasifikasi harus memiliki fungsi utama sebagai berikut:

1. Input Citra: Sistem harus mampu menerima input citra lensa mata.
2. Pra-pemrosesan Otomatis: Sistem harus mampu melakukan proses *image enhancement* (seperti *CLAHE*) secara otomatis untuk menajamkan fitur katarak sebelum klasifikasi.
3. Klasifikasi Tiga Kelas: Sistem harus mengklasifikasikan citra ke dalam tiga kategori: Penglihatan Normal, Katarak Imatur, dan Katarak Matur.
4. Output *Real-time*: Hasil diagnosis dan probabilitas kelas harus ditampilkan kepada pengguna melalui antarmuka web *Streamlit* secara cepat.

2.1.3 Analisis Kebutuhan Non-Fungsional

Untuk aplikasi diagnostik ini, kebutuhan non-fungsional meliputi:

1. Performa (*Efficiency*): Waktu inferensi model *MobileNetV2* harus cepat (idealnya <1-2 detik) agar sesuai untuk lingkungan skrining cepat di web.
2. Portabilitas: Aplikasi harus kompatibel dan dapat diakses melalui browser web *modern* pada berbagai sistem operasi (*Windows, macOS, Linux, Mobile Browser*).
3. Keandalan (*Availability*): Model *Deep Learning* dijalankan di server *Streamlit*, sehingga server harus stabil.
4. Usabilitas: Antarmuka web yang dibangun dengan *Streamlit* harus intuitif dan sederhana..

2.2 Arsitektur Sistem

Arsitektur sistem menggunakan pendekatan *Web Application* berbasis *Python*. Alur utama sistem adalah:

1. Input Citra melalui antarmuka web *Streamlit*.
2. Server *Streamlit (Python Backend)* menerima citra.
3. Modul Pra-pemrosesan melakukan *resizing* dan *Image Enhancement*.
4. Citra diteruskan ke Model *MobileNetV2 (Keras/TensorFlow)* yang dimuat di *backend*.
5. Model menjalankan *Inference* dan menghasilkan probabilitas 3 kelas.
6. Antarmuka pengguna (*Streamlit*) menampilkan kelas diagnosis hasil.

2.3 Pengumpulan dan Persiapan Data

2.3.1 Sumber Data

Penelitian ini menggunakan citra oftalmologi dari gabungan dua dataset publik yang diakses melalui *Kaggle: Cataract Image Dataset* dan *Cataract Classification Dataset*. Citra dari kedua sumber ini dikonsolidasikan dan dikelompokkan kembali untuk menciptakan tiga (3) kelas keparahan katarak yang menjadi target klasifikasi: Penglihatan Normal, Katarak Imatur, dan Katarak Matur. Data yang telah dikonsolidasikan dan diverifikasi labelnya akan dibagi menjadi 80% data latih dan 20% data uji.

2.3.2 Preprocessing Data

Untuk mengoptimalkan kinerja model *MobileNetV2*, pra-pemrosesan citra dilakukan dalam langkah-langkah berikut:

1. *Resizing*: Semua citra disesuaikan ukurannya menjadi dimensi input standar yang dibutuhkan oleh *MobileNetV2* (misalnya, 224x224 piksel).
2. *Image Enhancement*: Teknik *CLAHE (Contrast Limited Adaptive Histogram Equalization)* diterapkan untuk meningkatkan kontras lokal lensa, yang penting untuk menonjolkan area opasitas katarak.
3. Normalisasi: Nilai piksel dinormalisasi ke rentang standar (misalnya, 0 hingga 1) untuk mempercepat konvergensi pelatihan model.

2.4 Pemodelan Machine Learning

2.4.1 Algoritma CNN dan MobileNetV2

Convolutional Neural Network (CNN) dipilih karena keunggulannya dalam ekstraksi fitur hierarkis dari citra. *MobileNetV2* dipilih karena menggunakan *Depthwise Separable Convolution (DSC)* yang mengurangi kompleksitas komputasi. *MobileNetV2* juga menggunakan Inverted Residual Block dengan koneksi residual shortcut antara lapisan bottleneck input dan output.

2.4.2 Proses Pelatihan

Model disiapkan untuk pelatihan dengan memodifikasi lapisan output agar sesuai dengan 3 kelas katarak yang telah ditentukan. Proses pelatihan melibatkan:

1. **Pembagian Data:** 80% data digunakan untuk pelatihan, dan 20% untuk pengujian.
2. **Optimizer:** Digunakan *optimizer* Adam dengan *learning rate* yang disesuaikan (*fine-tuning*) pada tahap akhir pelatihan.
3. **Loss Function:** Digunakan *Categorical Cross-Entropy* karena ini adalah masalah klasifikasi multi-kelas.
4. Parameter pelatihan lainnya seperti *Epochs* dan *Batch Size* ditentukan berdasarkan optimasi empiris.

2.5 Implementasi Sistem

2.5.1 Implementasi Backend

Model yang telah terlatih dioptimalkan dan diimplementasikan pada web. Proses ini meliputi:

1. **Penyimpanan Model:** Model *Keras* yang telah terlatih disimpan dalam format H5 (*Hierarchical Data Format*) atau format *SavedModel TensorFlow*.
2. **Pemuatan Model:** Model dimuat ke dalam memori server *Streamlit* saat aplikasi dimulai, memastikan inferensi yang cepat tanpa *reloading* model.
3. **Logika Prediksi:** Skrip *Python* pada *Streamlit Backend* bertanggung jawab menerima citra, melakukan pra-pemrosesan (*CLAHE*), dan menjalankan prediksi menggunakan model yang dimuat.

2.5.2 Implementasi Interface

Antarmuka pengguna (*UI*) dikembangkan menggunakan *framework web Streamlit*. *Streamlit* memungkinkan pembuatan aplikasi web interaktif menggunakan skrip *Python* murni, yang dapat dengan mudah menampilkan widgets untuk *upload file*, menampilkan hasil prediksi, dan visualisasi.

2.5.3 Validasi Input

Validasi dilakukan pada server untuk memastikan citra yang di-*upload* valid, berformat benar, dan kemudian secara otomatis menjalani proses *preprocessing* (*CLAHE* dan normalisasi) sebelum diprediksi.

2.5.4 Penyimpanan Data

Model disimpan di server tempat *Streamlit* di-hosting. Hasil klasifikasi dan *log* inferensi dapat disimpan di *database server-side* (misalnya, *SQLite* atau *PostgreSQL*) jika diperlukan untuk rekam medis atau audit.

2.6 Evaluasi Model

Kinerja model *MobileNetV2* dievaluasi secara komprehensif pada 20% data uji yang terpisah. Metrik yang digunakan didasarkan pada Matriks Kebingungan (*Confusion Matrix*) untuk menghitung:

1. **Akurasi (*Accuracy*):** Metrik kinerja keseluruhan.
2. **Presisi (*Precision*) dan Recall (*Sensitivity*):** Metrik kinerja per-kelas untuk mengukur kemampuan model dalam mengidentifikasi setiap tahap katarak secara spesifik.
3. ***F1-Score* (*Macro Average*):** Digunakan untuk memberikan penilaian kinerja yang seimbang di semua kelas, menghindari bias data yang tidak seimbang.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil dari pengujian model klasifikasi katarak berbasis *MobileNetV2* pada 20% data uji, serta membahas interpretasi kinerja model berdasarkan metrik Akurasi, Presisi, *Recall*, *F1-Score*, dan Matriks Kebingungan.

3.1 Kinerja Model Pada Data Uji

Model *MobileNetV2* yang dilatih menggunakan *Transfer Learning* dari bobot *ImageNet* menunjukkan kinerja yang sangat baik dalam mengklasifikasikan tiga tahap katarak (Normal, Imatur, dan Matur). Hasil evaluasi adalah sebagai berikut:

1. Akurasi Keseluruhan mencapai 0.973 (97,73%)
2. *Loss* pada data uji adalah 0,0343

```
=====
                        EVALUASI KINERJA MODEL
=====
Akurasi Keseluruhan pada Data Uji: 0.9773
Loss pada Data Uji: 0.0343
5/5 ----- 9s 1s/step

Laporan Klasifikasi (Precision, Recall, F1-Score):
      precision    recall  f1-score   support

   normal         1.00      1.00      1.00        50
  immature         0.95      0.98      0.97        43
    mature         0.97      0.95      0.96        39

 accuracy         0.98      0.98      0.98       132
 macro avg         0.98      0.98      0.98       132
=====
```

Gambar 1 Akurasi Keseluruhan

Gambar 1 menunjukkan akurasi sebesar 97.73% menunjukkan bahwa model ini sangat andal dalam membedakan citra lensa mata normal, imatur, dan matur. Tingkat *Loss* yang sangat rendah (0.0343) juga mengindikasikan bahwa model tidak hanya akurat tetapi juga memiliki margin kesalahan prediksi yang minimal.

3.2 Analisis Metrik Multi Kelas

Kinerja model dievaluasi lebih lanjut menggunakan *Classification Report* untuk memahami performa pada setiap kelas secara individual. Hasil ini penting karena dataset memiliki jumlah sampel yang tidak seimbang (Normal: 50, Imatur: 43, Matur: 39).

Tabel 1 Confussion Matrix

Kelas	Presisi	Recall	F1-Score	Support
Normal	1.00	1.00	1.00	50
Imatur	0.95	0.98	0.97	43
Matur	0.97	0.95	0.96	39
Macro Avg	0.98	0.98	0.98	132

```
Matriks Kebingungan:
[[50  0  0]
 [ 0 42  1]
 [ 0  2 37]]
```

Gambar 2 Confussion Matrix

Pembahasan Metrik pada tabel 1 dan gambar 2:


1. Kelas Normal: Model mencapai nilai Presisi, *Recall*, dan *F1-Score* 1.00 (100%). Ini berarti semua citra yang diprediksi sebagai 'Normal' adalah benar-benar 'Normal', dan semua citra 'Normal' berhasil diidentifikasi. Kemudahan model mengenali kelas ini kemungkinan karena citra normal memiliki kontras dan bentuk lensa yang paling jelas dan konsisten.
2. Kelas Imatur: Mencapai *F1-Score* 0.97 dengan *Recall* sangat tinggi (0.98). *Recall* tinggi ini menunjukkan bahwa model sangat baik dalam menangkap atau mengidentifikasi sebagian besar kasus katarak Imatur dari seluruh kasus Imatur yang ada di data uji.
3. Kelas Matur: Mencapai *F1-Score* 0.96 dengan Presisi 0.97. Presisi tinggi ini menunjukkan model sangat akurat ketika menyatakan suatu kasus adalah Matur.
4. Macro Average: Nilai Presisi, *Recall*, dan *F1-Score* 0.98 menunjukkan bahwa model berkinerja stabil dan konsisten di ketiga kelas, meskipun ada ketidakseimbangan data (*Imbalance*). Hal ini membuktikan efektivitas *Data Augmentation* dan *Transfer Learning* yang diterapkan.

3.3 Implementasi Streamlit

MobileNetV2 dipilih karena sifatnya sebagai model *lightweight* yang efisien, yang kini divalidasi oleh kinerja yang tinggi. Implementasi model yang telah teruji ini pada aplikasi web *Streamlit* memberikan dua keuntungan utama:


1. Aksesibilitas Tinggi: Model dapat diakses menggunakan browser standar tanpa memerlukan instalasi perangkat keras atau platform khusus (*mobile*).
2. Inferensi Cepat: Efisiensi komputasi *MobileNetV2* meminimalkan latensi (*lag*) prediksi, memastikan hasil diagnosis disajikan secara *real-time* kepada pengguna web, yang penting untuk aplikasi skrining cepat.

Tingginya Akurasi mencapai 97,73% dan *F1-Score* yang dicapai, dikombinasikan dengan arsitektur *MobileNetV2* yang efisien dan implementasi *Streamlit* yang portabel, membuktikan bahwa solusi ini sangat layak digunakan sebagai alat pendukung keputusan klinis untuk klasifikasi tahap katarak.




Gambar 3 Halaman Awal Website

Gambar 3 menampilkan antarmuka (*interface*) dari aplikasi web yang dirancang untuk Klasifikasi Tahap Katarak Menggunakan *MobileNetV2 (Web Skrining)*. Aplikasi ini memanfaatkan model *deep learning* yang disebut *MobileNetV2*, yang telah dilatih menggunakan metode *Transfer Learning*, untuk memprediksi tahap katarak pada mata. Tahap katarak yang dapat diprediksi mencakup Normal, Imatur, atau Matur. Bagian kiri antarmuka menyediakan fungsionalitas "Unggah Citra Lensa" ("Unggah Citra Lensa" berarti "Upload Lens Image"), di mana pengguna diminta untuk memilih atau menyeret dan meletakkan (*drag and drop*) file citra mata dalam format JPG, JPEG, atau PNG, dengan batasan ukuran maksimal 200 MB per file. Instruksi utama pada halaman tersebut mengarahkan pengguna untuk mengunggah citra lensa mata di kolom sebelah kiri untuk memulai proses prediksi tahap katarak secara otomatis.



Gambar 4 Hasil Prediksi Normal

Gambar 4 menunjukkan hasil prediksi setelah file *image_55.png* berhasil diunggah dan diproses model *deep learning MobileNetV2* menentukan DIAGNOSIS sebagai "Penglihatan Normal" dengan tingkat keyakinan (*Confidence*) mencapai 100.00%, didukung oleh tabel probabilitas yang menunjukkan 100.00% untuk kelas Penglihatan Normal dan 0.00% untuk kelas Katarak Imatur maupun Katarak Matur.



Gambar 5 Hasil Prediksi Katarak Imatur

Gambar 5 menunjukkan hasil untuk citra mata yang keruh (6.jpg), dan model berhasil mendiagnosisnya sebagai "Katarak Imatur". Dalam kasus ini, tingkat keyakinan model mencapai 98.54%, dengan probabilitas kelas tertinggi (98.54%) jatuh pada Katarak Imatur, dan sebagian kecil (1.46%) pada Katarak Matur, yang secara efektif mengeliminasi kategori Penglihatan Normal (0.00%)



Gambar 6 Hasil Prediksi Katarak Matur

Gambar 6 menampilkan diagnosis untuk citra mata dengan kekeruhan yang lebih signifikan, menghasilkan prediksi "Katarak Matur" dengan tingkat keyakinan 86.72%, meskipun terdapat probabilitas kecil (13.27%) untuk tahap Imatur.

4. SIMPULAN

Model klasifikasi tahap katarak tiga kelas menggunakan arsitektur *MobileNetV2* telah berhasil dikembangkan dan divalidasi, dengan kelas keluaran Penglihatan Normal, Katarak Imatur, dan Katarak Matur. *MobileNetV2* menunjukkan Akurasi dan *F1-Score (Macro Average)* yang tinggi mencapai 97,73%, membuktikan bahwa arsitektur *lightweight* mampu melakukan klasifikasi multi-tahap yang kompleks. Implementasi ke dalam aplikasi web menggunakan *Streamlit* memvalidasi solusi *Deep Learning* yang efisien, portabel, dan objektif untuk skrining katarak, memungkinkan akses luas melalui browser untuk mendukung penanganan dini di fasilitas kesehatan dengan sumber daya terbatas.

5. SARAN

Mengintegrasikan aplikasi *Streamlit* ke dalam kontainerisasi (misalnya, *Docker*) untuk memudahkan *deployment* di berbagai *platform cloud* dan memastikan lingkungan yang konsisten. Kemudian melakukan *load testing* pada aplikasi web *Streamlit* untuk mengukur batas *throughput* dan latensi saat diakses oleh banyak pengguna secara bersamaan. Terakhir melakukan pengujian komparatif *MobileNetV2* dengan arsitektur *lightweight*

yang lebih baru, seperti *EfficientNet*, untuk mengidentifikasi model dengan rasio Akurasi/Efisiensi terbaik dalam konteks server web.

DAFTAR PUSTAKA

- [1] S. Lu *et al.*, “Deep learning-driven approach for cataract management: towards precise identification and predictive analytics,” 2025, *Frontiers Media SA*. doi: 10.3389/fcell.2025.1611216.
- [2] R. Sidik *et al.*, “RANCANG BANGUN SISTEM DETEKSI KATARAK MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK,” 2025.
- [3] S. I. Anik, M. S. Hasan, H. Jahan, M. M. Rahman, T. M. S. Sazzad, and J. A. Jahan, “Cataract Classification by Applying MobileNetV2 on Different Edge Detection Filters,” in *2024 6th International Conference on Electrical Engineering and Information & Communication Technology (ICEEICT)*, 2024, pp. 1263–1268. doi: 10.1109/ICEEICT62016.2024.10534507.
- [4] A. Wulandari, R. Regasari, M. Putri, and A. S. Budi, “Implementasi Algoritma Xception pada Sistem Deteksi Katarak Menggunakan Raspberry Pi Berbasis Citra Mata,” 2025. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [5] X. Zhao, L. Wang, Y. Zhang, X. Han, M. Deveci, and M. Parmar, “A review of convolutional neural networks in computer vision,” *Artif Intell Rev*, vol. 57, no. 4, Apr. 2024, doi: 10.1007/s10462-024-10721-6.
- [6] G.A Wiguna, “SISTEM DETEKSI KATARAK MENGGUNAKAN METODE EKSTRAKSI INDEKS WARNA DENGAN KLASIFIKASI JARAK EUKLIDEAN,” 2018.
- [7] S. Kamran Hussain *et al.*, “Deep Learning-Based Ophthalmic Disease Detection: A Systematic Review,” 2023, doi: 10.56979/601/2023.
- [8] M. Krichen, “Convolutional Neural Networks: A Survey,” *Computers*, vol. 12, no. 8, Aug. 2023, doi: 10.3390/computers12080151.
- [9] A. Performansi, S. Deteksi, K. Riski, and W. Hutabri, “Tema A-Penelitian ITN Malang, 3 Pebruari 2018 SENIATI 2018-Institut Teknologi Nasional Malang | 321 1),” 2018.
- [10] G. D. Deepak and S. K. Bhat, “Deep learning-based CNN for multiclassification of ocular diseases using transfer learning,” *Comput Methods Biomech Biomed Eng Imaging Vis*, vol. 12, no. 1, 2024, doi: 10.1080/21681163.2024.2335959.
- [11] T. Ganokratanaa, M. Ketcham, and P. Pramkeaw, “Advancements in Cataract Detection: The Systematic Development of LeNet-Convolutional Neural Network Models,” *J Imaging*, vol. 9, no. 10, Oct. 2023, doi: 10.3390/jimaging9100197.
- [12] L. Wati *et al.*, “Pencegahan Katarak dengan Penyuluhan Kesehatan dan Deteksi Dini Kejadian Katarak pada Nelayan Pesisir Daerah Kawal Pantai Bintang Kepulauan Riau,” *Jurnal Abdi Masyarakat Indonesia*, vol. 3, no. 4, pp. 1117–1124, Jun. 2023, doi: 10.54082/jamsi.761.
- [13] P. Intaraprasit, T. H. Bui, and M. P. Paing, “MobileNetV2-based Deep Learning for Retinal Disease Classification on a Mobile Application,” in *2023 15th Biomedical Engineering International Conference (BMEiCON)*, 2023, pp. 1–5. doi: 10.1109/BMEiCON60347.2023.10322079.
- [14] K. Yoshiok, K. Tanioka, S. Hiwa, and T. Hiroyasu, “Deep-learning models in medical image analysis: Detection of esophagitis from the Kvasir Dataset,” Jan. 2023, [Online]. Available: <http://arxiv.org/abs/2301.02390>
- [15] R. A. Clark, A. Szpak, S. C. Michalski, and T. Loetscher, “Rest intervals during virtual reality gaming augments standing postural sway disturbance,” *Sensors*, vol. 21, no. 20, Oct. 2021, doi: 10.3390/s21206817.