

IMPLEMENTASI SISTEM KLASIFIKASI KATARAK PADA PUPIL MATA MENGUNAKAN CONVOLUTIONAL NEURAL NETWORK

Muhammad Yaasiin Hidayatulloh^{1*}, Imam Much Ibnu Subroto²

^{1,2}Universitas Islam Sultan Agung, Indonesia

myaasiinh@gmail.com¹

imam@unissula.ac.id^{2*}

Received: 12-12-2025

Revised: 20-01-2026

Approved: 15-02-2026

ABSTRAK

Katarak merupakan penyebab utama kebutaan global yang memerlukan solusi deteksi dini yang efisien, murah, dan mudah diakses. Tujuan Penelitian ini bertujuan mengembangkan sistem klasifikasi katarak end-to-end yang diimplementasikan pada perangkat mobile untuk skrining mandiri. Metode Pendekatan Deep Learning berbasis Convolutional Neural Network (CNN) diterapkan dengan membandingkan dua arsitektur CNN Kustom dan MobileNetV3Small. Proses diawali dengan pra-pemrosesan citra menggunakan teknik cropping ROI (Region of Interest) pupil otomatis melalui fungsi `crop_pupil()` yang mengintegrasikan Gaussian blur, thresholding, dan contour detection. Hasil Berdasarkan pengujian menggunakan dataset yang dibagi menjadi 80% data latih dan 20% data validasi, model CNN Kustom menunjukkan performa terbaik dengan akurasi 91,61% dan F1-score 91,59% pada epoch ke-33. Implementasi model ke dalam aplikasi berbasis Flutter menggunakan format TensorFlow Lite menghasilkan latensi inferensi rata-rata 50 ms per citra. Kesimpulan Penelitian ini membuktikan bahwa integrasi metode pra-pemrosesan pupil dan arsitektur CNN yang ringan efektif digunakan untuk deteksi katarak berbasis mobile dengan keseimbangan akurasi dan kecepatan yang optimal.

Kata kunci: Klasifikasi Katarak, Preprocessing Pupil, Convolutional Neural Network, Deep Learning, TensorFlow Lite

PENDAHULUAN

Katarak, yang ditandai dengan kekeruhan pada lensa mata, tetap menjadi penyebab utama gangguan penglihatan dan kebutaan di tingkat global. Menurut data kesehatan global, katarak bertanggung jawab atas sebagian besar kasus kebutaan yang dapat dicegah jika didiagnosis tepat waktu [1]. Di Indonesia, prevalensi katarak cukup signifikan, namun penanganannya sering terkendala oleh distribusi layanan kesehatan mata yang tidak merata, terutama di wilayah geografis yang sulit dijangkau [2], [3]. Metode diagnosis konvensional yang mengandalkan pemeriksaan slit lamp oleh dokter spesialis memiliki keterbatasan aksesibilitas dan biaya, serta rentan terhadap subjektivitas pemeriksa [4], [5]. Oleh karena itu, pengembangan sistem deteksi otomatis yang efisien dan murah menjadi kebutuhan mendesak untuk mendukung skrining massal [6].

Perkembangan teknologi Deep Learning, khususnya Convolutional Neural Network (CNN), telah menawarkan solusi menjanjikan dalam analisis citra medis oftalmologi. Berbagai arsitektur CNN telah dieksplorasi untuk klasifikasi katarak. Simanjuntak dkk. [7] memanfaatkan citra fundus retina menggunakan CNN kustom yang mencapai akurasi kompetitif, sejalan dengan penelitian Du dkk. [8] yang menerapkan transfer learning untuk pengenalan penyakit mata. Namun, penggunaan citra fundus memerlukan alat oftalmoskop khusus yang jarang tersedia di fasilitas kesehatan tingkat pertama. Sebagai alternatif, penggunaan citra mata bagian luar (pupil) yang diambil menggunakan kamera digital atau smartphone mulai

dikembangkan karena kemudahannya [9].

Studi literatur terbaru pada tahun 2024 dan 2025 menunjukkan tren peningkatan akurasi melalui modifikasi arsitektur. L.P.L dkk. [10] memperkenalkan CSDNet untuk deteksi kondisi katarak yang lebih presisi, sementara Olaniyan dkk. [11] dan Feng dkk. [12] mengusulkan pendekatan hibrida (hybrid deep learning) untuk meningkatkan transparansi dan akurasi model dalam menghadapi variasi citra klinis. Lebih lanjut, Tashkandi [13] menekankan pentingnya prediksi penyakit mata berbasis citra retina, dan Nguyen serta Lin [14] mengembangkan pendekatan hibrida CNN dengan image quadrature untuk diagnosis yang lebih presisi. Meskipun demikian, tantangan utama pada klasifikasi citra pupil menggunakan perangkat mobile adalah adanya gangguan noise seperti pantulan cahaya (glare) dan variasi pencahayaan yang dapat menurunkan akurasi model ringan [15].

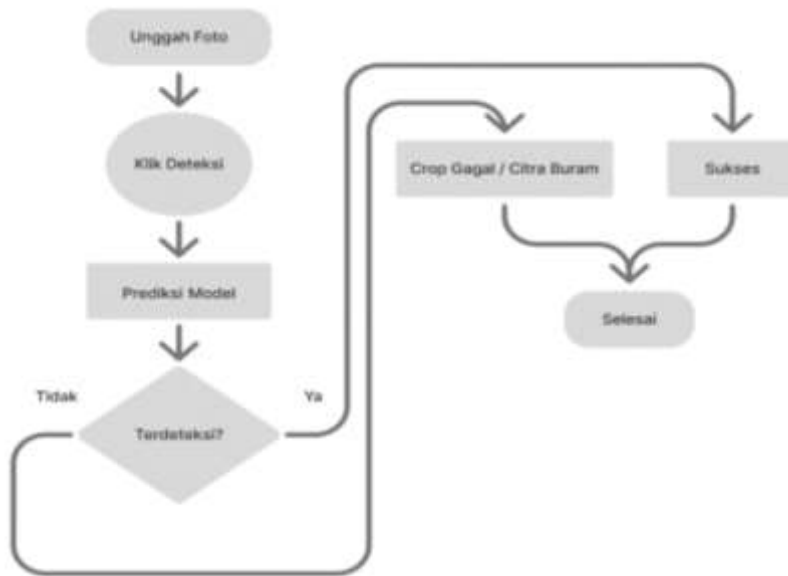
Penelitian terdahulu telah menerapkan berbagai strategi untuk meningkatkan performa model pada citra mata. Sudarsono dkk. [16] mengusulkan optimasi CNN menggunakan diffGrad untuk mempercepat konvergensi. Pratama dan Utaminigrum [17] menerapkan metode U-Net untuk memisahkan area pupil sebelum klasifikasi. Implementasi sistem berbasis web juga telah dilakukan oleh Firdaus dkk. [18], namun implementasi pada perangkat mobile dengan latensi rendah masih menjadi tantangan tersendiri [19]. Oleh sebab itu, penerapan arsitektur jaringan saraf yang dirancang khusus untuk efisiensi CPU seluler, seperti keluarga MobileNet, menjadi pendekatan krusial dalam mengatasi keterbatasan komputasi pada perangkat bergerak [20].

Berdasarkan kesenjangan tersebut, penelitian ini bertujuan untuk mengembangkan pipeline klasifikasi katarak yang mengintegrasikan teknik pra-pemrosesan cropping ROI pupil otomatis dan klasifikasi menggunakan arsitektur CNN yang dioptimalkan. Sistem ini dirancang untuk beroperasi secara mandiri pada smartphone (Android/iOS) menggunakan format TensorFlow Lite, menawarkan solusi skrining yang cepat, akurat, dan dapat diakses tanpa bergantung pada koneksi internet.

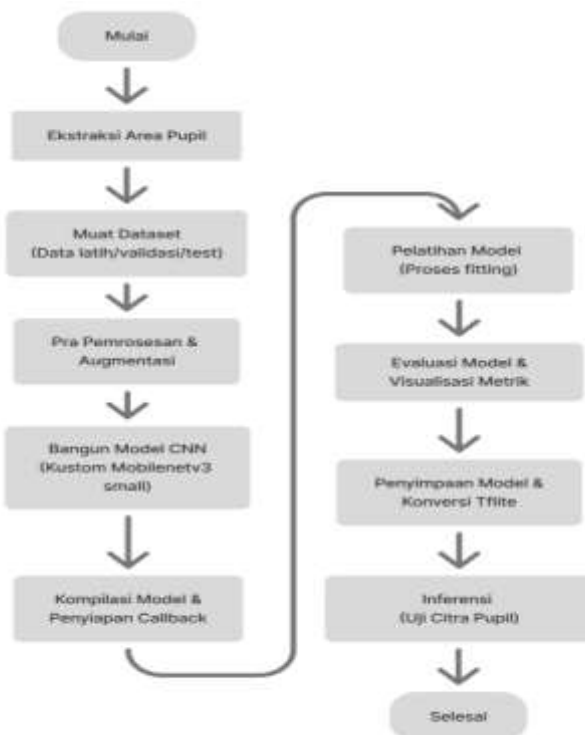
METODE PENELITIAN

Beberapa penelitian sebelumnya memanfaatkan teknik preprocessing berupa Gaussian blur, thresholding, dan contour detection untuk mengekstrak area pupil dari citra grayscale. Selain itu, arsitektur CNN berlapis konvolusi dan pooling telah banyak digunakan di bidang medis untuk klasifikasi citra karena kemampuannya mengekstrak fitur spasial yang efektif. Model ini terbukti andal dalam klasifikasi katarak dan berbagai kondisi kesehatan mata.

Alur sistem menjelaskan proses kerja deteksi foto katarak mata pupil ditunjukkan pada gambar 1. Alur sistem deteksi katarak Dimana ada sebuah proses unggah foto, lalu berikutnya klik deteksi, setelah itu muncul prediksi model dimana ada sebuah kondisi keputusan jika tidak maka tampilkan pesan hasil crop gagal atau citra buram, dan jika berhasil yang akan tampilkan hasil sukses.



Gambar 1. Alur sistem deteksi katarak

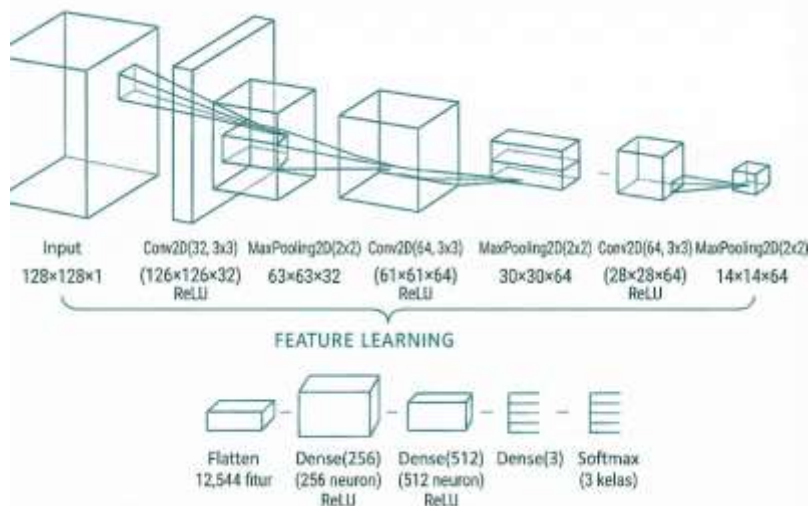


Gambar 2. Metode Deteksi Katarak Mata

Model arsitektur CNN

Tabel 1. Arsitektur CNN

Lapisan	Output Shape	Aktivasi
Input	128 × 128 × 1	-
Conv2D(32, 3×3)	126 × 126 × 32	ReLU
MaxPooling2D(2×2)	63 × 63 × 32	-
Conv2D(64, 3×3)	61 × 61 × 64	ReLU
MaxPooling2D(2×2)	30 × 30 × 64	-
Conv2D(64, 3×3)	28 × 28 × 64	ReLU
MaxPooling2D(2×2)	14 × 14 × 64	-
Flatten	12 544 fitur	-
Dense(256)	256 neuron	ReLU
Dense(512)	512 neuron	ReLU
Dense(3), Softmax	3 kelas	Softmax



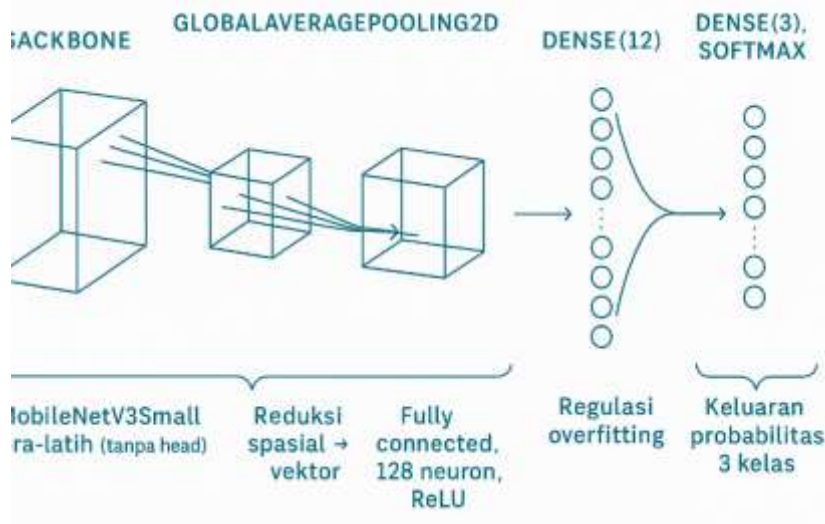
Gambar 3. Arsitektur CNN

Pada gambar 3 menerangkan bahwa contoh lapisan pada arsitektur CNN dimana Model CNN ini dirancang untuk mengklasifikasikan citra *grayscale* berukuran 128x128 piksel ke dalam tiga kategori. Proses ekstraksi fitur dilakukan melalui tiga blok konvolusi dan *pooling* secara berurutan. Blok pertama menggunakan 32 filter, sedangkan blok kedua dan ketiga menggunakan 64 filter untuk menangkap pola visual yang lebih kompleks. Setiap operasi konvolusi diikuti oleh *MaxPooling* (2x2) yang secara progresif mereduksi dimensi spasial input dari 128x128 hingga menjadi 14x14x64. Setelah tahap ekstraksi, *feature map* diratakan (*flatten*) menjadi vektor tunggal berukuran 12.544 elemen. Vektor ini kemudian diproses oleh jaringan saraf tiruan (*fully connected layers*) yang terdiri dari dua lapisan tersembunyi dengan masing-masing 256 dan 512 neuron menggunakan aktivasi ReLU. Arsitektur diakhiri dengan lapisan output yang memiliki 3 neuron dan fungsi aktivasi *Softmax* untuk menghasilkan probabilitas prediksi kelas akhir.

Model arsitektur mobilenet v3 small

Tabel 2. Arsitektur Mobilenet v3 small

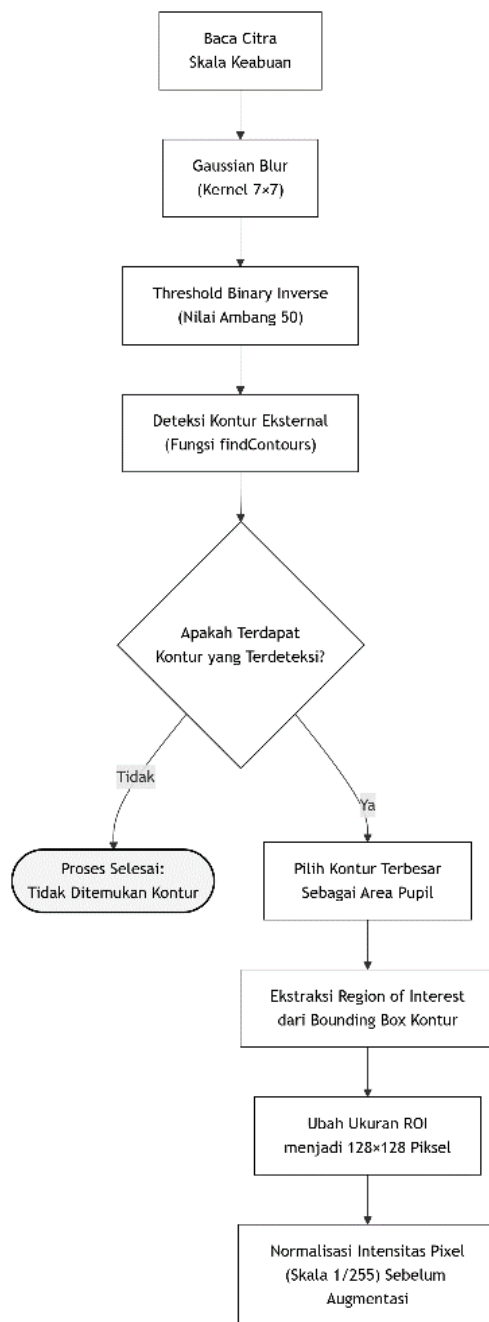
Komponen	Deskripsi
Backbone	MobileNetV3Small pra-latih (tanpa head)
GlobalAveragePooling2D	Reduksi spasial → vektor
Dense(128)	Fully connected, 128 neuron, ReLU
Dropout	Regulasi overfitting
Dense(3), Softmax	Keluaran probabilitas 3 kelas



Gambar 4. Arsitektur Mobilenet v3 small

Pada Gambar 4 menerangkan bahwa mengilustrasikan alur pemrosesan data pada arsitektur modifikasi MobileNetV3 Small. Tahapan ini diawali dengan Backbone MobileNetV3Small yang bersifat *pra-latih* (pre-trained) dan *tanpa head*, yang berfungsi sebagai pengekstraksi fitur utama dari citra input. Hasil ekstraksi fitur tersebut kemudian melewati lapisan GlobalAveragePooling2D untuk melakukan reduksi dimensi spasial, mengubah data dari bentuk matriks 3D menjadi vektor 1D agar lebih efisien. Selanjutnya, vektor fitur diproses oleh lapisan Dense(12) (lapisan *fully connected* dengan 12 neuron) yang berperan dalam mempelajari pola spesifik sekaligus membantu regulasi untuk mencegah *overfitting*. Tahap terakhir adalah lapisan Dense(3) yang menggunakan fungsi aktivasi Softmax; lapisan ini merupakan lapisan keluaran (output layer) dengan 3 neuron yang merepresentasikan jumlah kelas target, di mana Softmax bertugas menghasilkan nilai probabilitas untuk menentukan prediksi akhir dari ketiga kelas tersebut.

Proses preprocessing



Gambar 5. Preprocessing Ekstraksi fitur

Pada Gambar 5 menerangkan bahwa tidak ada proses ekstraksi fitur manual seperti LBPH atau perhitungan histogram khusus. Fitur langsung diambil oleh model CNN (baik model kustom maupun MobileNetV3Small) melalui lapisan konvolusi mereka. Prosesnya meliputi:

1. Normalisasi: Intensitas piksel ROI dinormalisasi ke rentang $[0, 1]$ dengan $\text{rescale}=1./255$ di ImageDataGenerator.
2. Augmentasi: Citra dirotasi, digeser, dishear, di-zoom, dan dibalik untuk meningkatkan keragaman data.
3. Ekstraksi Otomatis: CNN mempelajari fitur spasial dan tekstur pada layer konvolusi, menghasilkan representasi abstrak yang digunakan untuk klasifikasi.

Model tidak memerlukan fitur terhandcrafted; seluruh pengekstrakan dan seleksi fitur dilakukan oleh jaringan selama pelatihan.

Pelatihan model

Melatih model CNN menggunakan ImageDataGenerator untuk augmentasi, dengan callback khusus yang menghentikan pelatihan bila akurasi dan F1-score baik pada data latih maupun validasi telah melebihi 90 %.

Pengenalan foto mata.

Melakukan inferensi pada citra pupil yang sudah di-crop dan dinormalisasi dengan mengeluarkan prediksi kelas berdasarkan probabilitas tertinggi dari output model. Pengenalan Foto Mata (Inference)

HASIL DAN PEMBAHASAN

Hasil Evaluasi Model

Berdasarkan hasil pelatihan, model CNN Kustom menunjukkan kinerja yang lebih unggul dibandingkan arsitektur lain yang diuji dalam penelitian ini. Model CNN Kustom mencapai akurasi validasi sebesar 91,61% dengan F1-score 91,59% pada epoch ke-33. Hal ini menunjukkan bahwa arsitektur yang dibangun mampu mengekstrak fitur katarak (imatur dan matur) serta mata normal dengan baik meskipun dengan parameter yang relatif ringan.

Sebaliknya, meskipun MobileNetV3Small merupakan arsitektur yang efisien, pada dataset spesifik ini, CNN Kustom memberikan keseimbangan yang lebih baik antara kompleksitas model dan akurasi deteksi. Kemampuan model untuk membedakan gradasi kekeruhan pada lensa mata divalidasi melalui matriks konfusi yang menunjukkan tingkat kesalahan prediksi (false positive/negative) yang rendah antar kelas

Hasil Pengembangan Sistem

Model terbaik (CNN Kustom) dikonversi ke format TensorFlow Lite (.tflite) dan ditanamkan ke dalam aplikasi mobile bernama "Itaract". Aplikasi ini dikembangkan menggunakan framework Flutter.

Halaman Result Detection



Gambar 6. Hasil Deteksi Katarak

Seperti terlihat pada Gambar 6, setelah pengguna mengambil atau mengunggah gambar mata, sistem melakukan inferensi secara real-time. Hasil pengujian pada perangkat smartphone menunjukkan rata-rata waktu inferensi hanya 50 milidetik.

Aplikasi menampilkan label kelas (misal: "Katarak Imatur") dan tingkat kepercayaan (confidence score) seperti "95.36%". Fitur ini menjawab tujuan penelitian untuk menyediakan alat skrining cepat.

Halaman Histori Detection



Gambar 7. Hasil Histori Katarak Di simpan

Untuk mendukung pemantauan berkala, aplikasi menyediakan fitur riwayat (Gambar 7). Data hasil deteksi disimpan lokal, memungkinkan pengguna melacak perkembangan kondisi mata mereka dari waktu ke waktu tanpa memerlukan koneksi database eksternal yang berat.

KESIMPULAN

Penelitian ini telah berhasil mengembangkan dan mengimplementasikan sistem klasifikasi katarak berbasis Convolutional Neural Network pada perangkat mobile. Berdasarkan hasil pengujian, penerapan teknik pra-pemrosesan cropping pupil otomatis yang dikombinasikan dengan arsitektur CNN Kustom terbukti efektif menangani noise pada citra mata. Model ini menghasilkan performa terbaik dengan akurasi 91,61% dan F1-Score 91,59%, yang mengungguli kriteria kelayakan untuk sistem skrining awal. Lebih lanjut, keberhasilan integrasi model dalam format TensorFlow Lite ke dalam aplikasi "Itaract" dengan latensi rendah (50 ms) menawarkan solusi deteksi dini katarak yang aksesibel, user-friendly, dan tidak bergantung pada infrastruktur internet. Hal ini menjadikan sistem sangat cocok untuk diterapkan di daerah dengan fasilitas kesehatan terbatas.

DAFTAR PUSTAKA

- [1] Z. Q. Ik, S. L. Lau, dan J. B. Chan, "Mobile cataract screening app using a smartphone," *2015 IEEE Conf. e-Learning, e-Management e-Services, IC3e 2015*, no. August, hal. 110–115, 2016, doi: 10.1109/IC3e.2015.7403496.
- [2] R. Sigit, E. Triyana, dan M. Rochmad, "Cataract Detection Using Single Layer Perceptron Based on Smartphone," *ICICOS 2019 - 3rd Int. Conf. Informatics Comput. Sci. Accel. Informatics Comput. Res. Smarter Soc. Era Ind. 4.0, Proc.*, 2019, doi: 10.1109/ICICoS48119.2019.8982445.
- [3] F. Fadilatunnisa dan A. M. Widodo, "The Implementation of a Convolutional Neural Network for The Detection of Cataract Disease Severity in Eyes," *Infact Int. J. Comput.*, vol. 9, no. 01, hal. 35–43, 2025, doi: 10.61179/infact.v9i01.712.
- [4] S. Agustin, E. N. Putri, dan I. N. Ichsan, "Design of A Cataract Detection System based on The Convolutional Neural Network," *J. ELTIKOM*, vol. 8, no. 1, hal. 1–8, 2024, doi: 10.31961/eltikom.v8i1.1019.

- [5] K. Y. Son *dkk.*, “Deep Learning-Based Cataract Detection and Grading from Slit-Lamp and Retro-Illumination Photographs: Model Development and Validation Study,” *Ophthalmol. Sci.*, vol. 2, no. 2, hal. 100147, 2022, doi: 10.1016/j.xops.2022.100147.
- [6] S. V. Nair dan P. Shete, “Mobile Application for Cataract Detection Using Convolution Neural Network,” *2023 Int. Conf. Network, Multimed. Inf. Technol. NMITCON 2023*, hal. 1–6, 2023, doi: 10.1109/NMITCON58196.2023.10276326.
- [7] R. B. J. Simanjuntak, Y. Fu’Adah, R. Magdalena, S. Saidah, A. B. Wiratama, dan I. Da’Wan Salim Ubaidah, “Cataract Classification Based on Fundus Images Using Convolutional Neural Network,” *Int. J. Informatics Vis.*, vol. 6, no. 1, hal. 33–38, 2022, doi: 10.30630/joiv.6.1.856.
- [8] F. Du *dkk.*, “Recognition of eye diseases based on deep neural networks for transfer learning and improved D-S evidence theory,” *BMC Med. Imaging*, vol. 24, no. 1, hal. 1–14, 2024, doi: 10.1186/s12880-023-01176-2.
- [9] C. J. Lai, P. F. Pai, M. Marvin, H. H. Hung, S. H. Wang, dan D. N. Chen, “The Use of Convolutional Neural Networks and Digital Camera Images in Cataract Detection,” *Electron.*, vol. 11, no. 6, 2022, doi: 10.3390/electronics11060887.
- [10] L. P.L, R. Vaddi, M. O. Elish, V. Gonuguntla, dan S. S. Yellampalli, “CSDNet: A Novel Deep Learning Framework for Improved Cataract State Detection,” *Diagnostics*, vol. 14, no. 10, hal. 1–12, 2024, doi: 10.3390/diagnostics14100983.
- [11] J. Olaniyan, D. Olaniyan, I. C. Obagbuwa, B. M. Esiefarienne, dan M. Odighi, “Transformative Transparent Hybrid Deep Learning Framework for Accurate Cataract Detection,” *Appl. Sci.*, vol. 14, no. 21, hal. 1–20, 2024, doi: 10.3390/app142110041.
- [12] Z. Feng, K. Xu, L. Li, dan Y. Wang, “Hybrid Deep Learning Model for Cataract Diagnosis Assistance,” *Appl. Sci.*, vol. 14, no. 23, hal. 1–17, 2024, doi: 10.3390/app142311314.
- [13] A. Tashkandi, “Eye Care : Predicting Eye Diseases Using Deep Learning Based on Retinal Images,” hal. 1–22, 2025.
- [14] V. V. Nguyen dan C. L. Lin, “Enhancing Cataract Detection through Hybrid CNN Approach and Image Quadrature: A Solution for Precise Diagnosis and Improved Patient Care,” *Electron.*, vol. 13, no. 12, 2024, doi: 10.3390/electronics13122344.
- [15] A. Rusdy Prasetyo, Sussi, dan B. Aditya, “Analisis Perbandingan Algoritma Support Vector Machine (Svm) Dan Convolutional Neural Network (Cnn) Untuk Sistem Deteksi Katarak,” *J. Ilm. Tek. Mesin, Elektro dan Komput.*, vol. 3, no. 1, hal. 1–10, 2023, doi: 10.51903/juritek.v3i1.604.
- [16] E. Sudarsono, A. Bustamam, dan P. P. Tampubolon, “An optimized convolutional neural network using diffgrad for cataract image classification,” *AIP Conf. Proc.*, vol. 2296, no. March, 2020, doi: 10.1063/5.0030746.
- [17] A. A. Pratama dan F. Utamingrum, “Sistem Pendeteksi Tingkat Keparahan Katarak Berdasarkan Citra Digital Menggunakan Metode U-Net dan CNN,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 8, no. 1, hal. 1–9, 2024.
- [18] J. Kecerdasan, T. Informasi, D. H. Firdaus, B. Imran, L. D. Bakti, dan E. Suryadi, “Klasifikasi Penyakit Katarak Pada Mata Menggunakan Metode Convolutional Neural Network (Cnn) Berbasis Web Web-Based Classification of Cataract in the Eyes Using Convolutional Neural Network (Cnn) Method,” *J. Kecerdasan Buatan dan Teknol. Inf.*, vol. 1, no. 3, hal. 18–26, 2022.
- [19] F. Ramadhani, A. Satria, dan S. Salamah, “Implementasi Algoritma Convolutional

- Neural Network dalam Mengidentifikasi Dini Penyakit pada Mata Katarak," *sudo J. Tek. Inform.*, vol. 2, no. 4, hal. 167–175, 2023, doi: 10.56211/sudo.v2i4.408.
- [20] A. Howard *dkk.*, "Searching for mobileNetV3," *Proc. IEEE Int. Conf. Comput. Vis.*, hal. 1314–1324, 2019, doi: 10.1109/ICCV.2019.00140.