

Deteksi Penyakit Glaukoma Menggunakan Analisis Retina dengan Model *Convolutional Neural Network* (CNN)

Rahmat Fauzi Prihastanto^{1*}, Selly Septiani²

¹⁻² Universitas Pamulang

*Corresponding email: zeekun0910@gmail.com^{1*}, dosen10011@unpam.ac.id²

Abstrak: Glaukoma merupakan penyebab utama kebutaan permanen yang memerlukan deteksi dini secara cepat dan akurat. Penelitian ini mengembangkan sistem deteksi glaukoma berbasis analisis citra retina menggunakan Convolutional Neural Network (CNN) yang diintegrasikan ke dalam aplikasi web Streamlit. Permasalahan yang dikaji meliputi integrasi model CNN ke aplikasi berbasis web dan pengaruh preprocessing terhadap performa klasifikasi. Penelitian menggunakan metode kuantitatif eksperimental dengan tahapan preprocessing (resizing, normalisasi, augmentasi), pelatihan model CNN, evaluasi menggunakan confusion matrix, serta pengujian blackbox. Hasil penelitian menunjukkan sistem berhasil diimplementasikan dan mampu mengklasifikasikan citra retina dengan akurasi 80%, precision 71%, recall 100%, dan F1-score 83%. Penelitian ini berkontribusi menyediakan sistem skrining glaukoma berbasis web yang praktis, mudah diakses, serta mendukung deteksi dini pada layanan kesehatan.

Kata kunci: Citra Retina; *Convolutional Neural Network* (CNN); Deteksi Dini; Glaukoma; Streamlit.

Abstract: *Glaucoma is one of the leading causes of permanent blindness and requires early, accurate detection. This study develops a glaucoma detection system based on retinal image analysis using a Convolutional Neural Network (CNN) integrated into a Streamlit web application. The problems addressed include integrating the trained CNN model into a web-based application and analyzing the effect of preprocessing on classification performance. The study employs a quantitative experimental method consisting of preprocessing (resizing, normalization, augmentation), CNN model training, evaluation using a confusion matrix, and black-box testing. The results show that the system was successfully implemented and achieved an accuracy of 80%, precision of 71%, recall of 100%, and an F1-score of 83% in classifying retinal images. This research contributes a practical, accessible web-based glaucoma screening system that supports early detection in health services.*

Keywords: *Convolutional Neural Network (CNN); early detection; glaucoma; retinal image; Streamlit*

PENDAHULUAN

Glaukoma merupakan salah satu penyebab utama kebutaan permanen di dunia dan menjadi isu kesehatan masyarakat yang memerlukan perhatian serius karena kerusakan progresif pada saraf optik yang ditimbulkannya sering kali tidak menunjukkan gejala pada tahap awal. World Health Organization memperkirakan jumlah penderita glaukoma mencapai lebih dari 80 juta jiwa pada tahun 2020 dan diproyeksikan meningkat menjadi 111,8 juta jiwa pada tahun 2040, sehingga dibutuhkan strategi deteksi dini yang lebih efektif, cepat, presisi, dan terjangkau. Di Indonesia, glaukoma menjadi penyebab kebutaan terbesar ketiga setelah katarak dan gangguan refraksi. Data Riskesdas dan DataBox (2023) menunjukkan bahwa sekitar 90 persen pasien glaukoma di Indonesia terlambat terdiagnosis karena keterbatasan alat diagnostik seperti Optical Coherence Tomography (OCT) yang mahal serta belum meratanya fasilitas skrining retina, khususnya di fasilitas kesehatan tingkat pertama dan wilayah pedesaan.

Citra retina memuat informasi struktural penting, seperti rasio cup-to-disc, bentuk optic disc, dan pola vaskularisasi, yang dapat digunakan untuk mengidentifikasi indikasi glaukoma secara dini. Convolutional Neural Network (CNN) telah terbukti efektif mengekstraksi pola visual tersebut secara hierarkis dan otomatis melalui lapisan konvolusinya. Penelitian (Y. N. U. R. Fuadah et al., 2022) menunjukkan bahwa optimasi CNN dengan K-Fold Cross Validation mampu menghasilkan performa klasifikasi glaukoma yang tinggi, sementara (Agus et al., 2025) membuktikan bahwa penerapan transfer learning pada arsitektur CNN mampu meningkatkan akurasi klasifikasi citra medis secara signifikan. Pada level internasional, (Chincholi & Koestler, 2023) dan (Wang et al., 2024) menegaskan bahwa arsitektur Vision Transformer juga mampu meningkatkan performa deteksi glaukoma melalui

pemahaman struktur retina yang lebih mendalam, sedangkan pada level nasional (Saintikom et al., 2025) dan (Ali et al., 2025) membuktikan bahwa jaringan saraf tiruan dan teknik ekstraksi ciri berbasis CNN efektif digunakan untuk klasifikasi citra medis secara stabil dan akurat.

Metode pemeriksaan glaukoma konvensional, seperti tonometri dan funduskopi, masih memiliki keterbatasan karena memerlukan tenaga ahli dan alat diagnostik yang mahal, sehingga fasilitas kesehatan primer sering kali harus merujuk pasien ke rumah sakit besar dan memperlambat proses diagnosis (Latha, 2024). Meskipun berbagai penelitian terdahulu menunjukkan perkembangan yang kuat pada sisi akurasi model, sebagian besar masih berfokus pada performa CNN tanpa menyediakan implementasi berbasis web yang siap digunakan secara praktis oleh tenaga kesehatan. Kondisi ini menjadi celah penting yang perlu dijembatani. Penelitian ini karenanya mengembangkan model CNN yang diintegrasikan ke dalam platform web Streamlit agar tenaga medis dapat melakukan skrining dini glaukoma secara cepat, dilengkapi dengan metrik evaluasi akurasi, presisi, recall, dan F1-score untuk memastikan kualitas hasil klasifikasi. Secara akademik, penelitian ini memperkaya literatur mengenai penerapan CNN pada citra medis, dan secara praktis diharapkan menjadi solusi inovatif dalam mempercepat pemerataan skrining glaukoma di Indonesia.

LANDASAN TEORI

Glaukoma. Glaukoma adalah penyakit mata kronis yang menyebabkan kerusakan saraf optik dan berpotensi mengakibatkan kebutaan permanen apabila tidak terdeteksi sejak dini. Kerusakan tersebut umumnya disebabkan oleh peningkatan tekanan intraokular serta perubahan struktur anatomis retina seperti optic disc dan pola vaskular retina, sehingga deteksi dini melalui citra fundus menjadi salah satu pendekatan yang banyak dikaji dalam literatur. Penelitian (Y. N. Fuadah et al., 2022) yang mengklasifikasikan citra fundus ke dalam kategori normal hingga deep glaucoma menggunakan CNN dengan 5-fold cross-validation memperoleh akurasi mendekati 99%, sementara (Mulyasari et al., 2024) yang mengembangkan model klasifikasi penyakit mata menggunakan arsitektur AlexNet memperoleh presisi, recall, dan F1-score berkisar 88%.

Citra Retina. Citra retina umumnya diperoleh melalui fundus photography, yaitu representasi dua dimensi struktur belakang mata yang meliputi retina, pembuluh darah, optic disc, dan optic cup. Citra ini bersifat non-invasif, relatif murah, dan mudah diakses dibanding pemeriksaan lanjutan seperti OCT sehingga cocok digunakan sebagai alat skrining awal (Indraswari et al., 2022). Perubahan struktur seperti pelebaran cup-to-disc ratio dan penipisan neuroretinal rim dapat diidentifikasi sebagai indikator glaukoma (Cao et al., 2021), meskipun kualitas citra raw sangat bervariasi sehingga umumnya memerlukan tahap preprocessing agar struktur retina terlihat lebih jelas dan konsisten (Lin et al., 2025). Pemanfaatan citra fundus bersama metode deep learning telah banyak dikembangkan sebagai sistem computer-aided diagnosis (CAD) yang mendukung deteksi dini secara cepat, terjangkau, dan dapat diakses secara luas (Meedeniya et al., 2025).

Convolutional Neural Network (CNN). CNN merupakan arsitektur deep learning yang dirancang khusus untuk memproses data citra melalui mekanisme ekstraksi fitur otomatis pada lapisan konvolusi. CNN bekerja dengan menerapkan filter (kernel) untuk menangkap pola visual seperti tepi, tekstur, dan bentuk, kemudian mereduksi dimensi melalui operasi pooling sebelum melakukan klasifikasi pada lapisan fully connected. Kemampuan ini menjadikan CNN sebagai metode yang efektif dalam analisis citra medis karena mampu mengenali pola kompleks tanpa memerlukan ekstraksi fitur manual.

Streamlit. Streamlit merupakan framework open-source berbasis Python yang memungkinkan pengembangan aplikasi web interaktif secara cepat tanpa memerlukan keahlian pengembangan front-end yang kompleks. Framework ini banyak digunakan untuk

mengimplementasikan model machine learning dan deep learning ke dalam antarmuka yang sederhana dan mudah digunakan oleh pengguna akhir, termasuk tenaga kesehatan non-teknis.

METODE

Penelitian ini menggunakan pendekatan kuantitatif eksperimental berbasis supervised learning dengan memanfaatkan arsitektur Convolutional Neural Network (CNN) untuk mengklasifikasikan citra retina ke dalam kategori glaukoma dan normal. Pendekatan kuantitatif dipilih karena penelitian berorientasi pada pengukuran performa model secara numerik menggunakan indikator statistik seperti akurasi, presisi, recall, dan F1-score, sedangkan desain eksperimental diterapkan karena penelitian melibatkan pelatihan model secara terkontrol, pengujian pada data yang belum pernah dilatih, serta evaluasi kuantitatif terhadap hasil klasifikasi untuk menilai kemampuan generalisasi model.

Data yang digunakan merupakan data sekunder berupa citra retina fundus dua dimensi berformat JPG beresolusi 512×512 piksel yang diperoleh dari dataset publik EyePACS AIROGS Light V2 melalui platform Kaggle dan telah melalui proses pelabelan medis oleh ahli oftalmologi. Dataset terbagi menjadi dua kategori, yaitu Referable Glaucoma (RG) untuk citra dengan indikasi glaukoma dan Non-Referable Glaucoma (NRG) untuk citra normal, dengan label numerik 1 untuk RG dan 0 untuk NRG. Pembagian dataset dilakukan dengan metode hold-out validation menjadi tiga subset seperti disajikan pada Tabel 1.


Tabel 1 Dataset Penelitian

Subset Dataset	RG	NRG	Total
Training Set	4.000	4.000	8.000
Validation Set	385	385	770
Testing Set	385	385	770
Total	4.770	4.770	9.540

Preprocessing Data. Sebelum digunakan untuk pelatihan, seluruh citra retina diproses melalui tiga tahap, yaitu (a) resizing ke ukuran 512×512 piksel untuk menyeragamkan dimensi input sekaligus mempertahankan detail struktur optic disc, optic cup, dan pola pembuluh darah; (b) normalisasi nilai piksel dari rentang 0–255 menjadi 0–1 untuk menstabilkan skala data dan mempercepat konvergensi pelatihan; dan (c) standardisasi menggunakan nilai mean [0,485; 0,456; 0,406] dan standar deviasi [0,229; 0,224; 0,225] untuk mengurangi perbedaan intensitas pencahayaan antar citra. Pada salah satu skenario eksperimen diterapkan pula augmentasi data berupa rotasi dan horizontal flip pada data training untuk meningkatkan variasi citra dan mengurangi risiko overfitting, tanpa diterapkan pada data validation maupun testing agar objektivitas evaluasi tetap terjaga.

Perancangan dan Pelatihan Model CNN. Arsitektur CNN dirancang secara bertingkat dengan beberapa lapisan konvolusi yang diikuti fungsi aktivasi ReLU, batch normalization, dan max pooling untuk mengekstraksi serta mereduksi fitur visual. Setelah proses ekstraksi fitur, digunakan Global Average Pooling untuk mereduksi jumlah parameter sebelum diteruskan ke fully connected layer, dengan fungsi aktivasi sigmoid pada lapisan akhir untuk menghasilkan klasifikasi biner. Model dilatih menggunakan optimizer Adam, fungsi loss Binary Crossentropy, epoch sebanyak 50, dan batch size 8. Selama pelatihan digunakan callback EarlyStopping untuk mencegah overfitting dan ReduceLROnPlateau untuk

menurunkan learning rate ketika performa stagnan, sehingga proses optimasi berjalan lebih stabil.



Gambar 1 Arsitektur Model CNN

Evaluasi performa model dilakukan menggunakan data testing dengan metrik akurasi, presisi, recall, F1-score, dan confusion matrix, sebagaimana dirumuskan pada Persamaan (1) hingga (4) (Informatics et al., 2025).

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (1)$$

$$\text{Precision} = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

$$\text{Recall} = \frac{TP}{TP+FN} \times 100\% \quad (3)$$

$$\text{F1-Score} = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (4)$$

Implementasi Sistem. Model terbaik yang diperoleh dari proses pelatihan dan evaluasi kemudian diintegrasikan ke dalam aplikasi web menggunakan framework Streamlit. Pada alur kerja sistem, pengguna mengunggah citra retina melalui antarmuka web, citra diproses melalui tahap preprocessing yang sama seperti pada pelatihan model, kemudian dimasukkan ke dalam model CNN untuk menghasilkan prediksi probabilitas kelas. Sistem selanjutnya menampilkan hasil klasifikasi berupa kategori glaukoma atau normal beserta nilai kepercayaannya. Pengujian fungsional sistem dilakukan menggunakan metode blackbox testing, yaitu dengan mengamati kesesuaian keluaran sistem terhadap berbagai skenario masukan tanpa meninjau struktur kode program, mencakup pengujian unggah citra dengan berbagai format, validasi file, proses preprocessing dan klasifikasi, tampilan hasil prediksi, serta penanganan kondisi input yang tidak sesuai.

Penelitian ini dilaksanakan pada lingkungan pengembangan berbasis cloud, yaitu Google Colab, dengan bahasa pemrograman Python serta pustaka deep learning TensorFlow dan Keras, sehingga proses pelatihan model dapat memanfaatkan dukungan GPU tanpa memerlukan perangkat keras khusus.


HASIL DAN PEMBAHASAN

Hasil Evaluasi Performa Model CNN

Pengujian dilakukan terhadap 30 sampel citra retina pada data testing dengan membandingkan label ground truth dan hasil prediksi model. Berdasarkan hasil pengujian tersebut diperoleh nilai True Positive (TP) sebesar 15, True Negative (TN) sebesar 9, False Positive (FP) sebesar 6, dan False Negative (FN) sebesar 0, sebagaimana direkapitulasi pada Tabel 2.

Tabel 2 Tabel Hasil Evaluasi Performa Model

Komponen Evaluasi	Jumlah	Keterangan
True Positive (TP)	15	Citra RG diprediksi benar sebagai RG
True Negative (TN)	9	Citra NRG diprediksi benar sebagai NRG
False Positive (FP)	6	Citra NRG salah diprediksi sebagai RG
False Negative (FN)	0	Citra RG salah diprediksi sebagai NRG
Total Sampel	30	Jumlah seluruh data testing yang digunakan



Gambar 2 Confusion Matrix Sampel Penelitian

Nilai TP sebesar 15 menunjukkan bahwa seluruh sampel RG pada data pengujian berhasil dikenali dengan tepat oleh model, sehingga model memiliki sensitivitas yang baik terhadap ciri-ciri visual glaukoma. Nilai TN sebesar 9 menunjukkan bahwa sebagian citra normal dapat dikenali dengan benar, meskipun jumlahnya lebih rendah dibandingkan total sampel NRG sehingga kemampuan model membedakan citra normal masih perlu disempurnakan. Nilai FP sebesar 6 menunjukkan adanya enam citra normal yang salah diklasifikasikan sebagai glaukoma, yang dapat disebabkan oleh kemiripan pola optic disc pada citra normal dan citra glaukoma ringan, variasi kualitas citra, atau pencahayaan. Adapun nilai FN sebesar 0 merupakan hasil yang penting dalam konteks skrining medis karena tidak ada kasus glaukoma yang terlewat oleh model, sehingga risiko keterlambatan diagnosis dapat diminimalkan.

Berdasarkan nilai confusion matrix tersebut, dihitung empat metrik evaluasi utama menggunakan persamaan akurasi, presisi, recall, dan F1-score, dengan hasil sebagaimana disajikan pada Tabel 3.

Tabel 3 Rekapitulasi Hasil Performa Evaluasi Model


Metrik Evaluasi	Nilai	Interpretasi
Akurasi	80%	Model mampu mengklasifikasikan 24 dari 30 sampel secara benar
Precision	71%	Dari seluruh prediksi RG, sebagian besar benar RG, namun masih terdapat false positive
Recall	100%	Seluruh citra RG berhasil terdeteksi oleh model

Metrik Evaluasi	Nilai	Interpretasi
F1-Score	83%	Model memiliki keseimbangan performa yang cukup baik antara precision dan recall


Nilai akurasi sebesar 80% menunjukkan bahwa secara umum model CNN memiliki kemampuan klasifikasi yang cukup baik dalam membedakan citra retina glaukoma dan normal, meskipun akurasi tidak dapat dijadikan satu-satunya ukuran keberhasilan dalam konteks medis karena jenis kesalahan prediksi memiliki dampak yang berbeda. Nilai precision sebesar 71% dipengaruhi oleh enam kasus false positive, yang dalam praktiknya dapat menyebabkan pasien normal direkomendasikan pemeriksaan lanjutan meskipun sebenarnya tidak menunjukkan indikasi glaukoma. Sebaliknya, nilai recall sebesar 100% menunjukkan bahwa model tidak melewatkan satu pun kasus glaukoma yang sebenarnya, sehingga sangat sesuai dengan tujuan sistem sebagai alat bantu skrining dini yang mengutamakan sensitivitas terhadap kasus positif. Nilai F1-score sebesar 83% menegaskan bahwa model memiliki keseimbangan yang cukup baik antara ketepatan dan kepekaan deteksi, meskipun performanya belum sepenuhnya optimal karena masih terdapat kesalahan klasifikasi pada kelas NRG.

Implementasi dan Pengujian Sistem Berbasis Website

Model CNN terbaik yang diperoleh dari proses pelatihan berhasil diintegrasikan ke dalam aplikasi berbasis website menggunakan Streamlit. Sistem memungkinkan pengguna mengunggah citra retina, kemudian secara otomatis melakukan preprocessing dan klasifikasi, serta menampilkan hasil deteksi berupa kategori Referable Glaucoma (RG) atau Non-Referable Glaucoma (NRG) beserta nilai kepercayaan secara langsung pada halaman website. Berdasarkan hasil pengujian blackbox terhadap fitur-fitur utama sistem, seperti proses unggah citra dengan berbagai format (JPG, JPEG, PNG), validasi file, preprocessing, klasifikasi, tampilan hasil prediksi, tampilan confidence score, hingga penanganan kondisi input yang tidak sesuai, seluruh fungsi berjalan sesuai dengan skenario yang dirancang. Hal ini menunjukkan bahwa sistem berhasil tidak hanya dari sisi performa model deep learning, tetapi juga dari sisi implementasi perangkat lunak, sehingga layak digunakan sebagai alat bantu skrining awal oleh tenaga kesehatan, khususnya di fasilitas pelayanan primer.



Gambar 4. 1 Hasil Deteksi RG



Gambar 4. 2 Hasil Deteksi NRG

Kesesuaian Hasil dengan Tujuan Penelitian

Hasil penelitian menunjukkan bahwa sistem yang dikembangkan telah menjawab kedua rumusan masalah penelitian. Tujuan pertama tercapai karena model CNN berhasil

diintegrasikan ke dalam aplikasi Streamlit dan dapat digunakan untuk klasifikasi citra retina secara otomatis. Tujuan kedua juga tercapai karena penelitian telah mengevaluasi performa model menggunakan metrik akurasi, presisi, recall, dan F1-score, sekaligus membuktikan bahwa penerapan preprocessing berupa resizing, normalisasi, dan augmentasi membantu menyeragamkan ukuran serta distribusi nilai piksel citra sehingga model dapat mempelajari pola visual retina secara lebih stabil.

Kelebihan dan Keterbatasan Sistem

Sistem yang dikembangkan memiliki sejumlah kelebihan, di antaranya mampu melakukan klasifikasi citra retina secara otomatis ke dalam kategori RG dan NRG, mempercepat proses skrining awal karena pengguna hanya perlu mengunggah citra, mengekstraksi fitur visual tanpa memerlukan ekstraksi fitur manual, memiliki antarmuka Streamlit yang sederhana dan mudah digunakan, mendukung format citra JPG, JPEG, dan PNG, serta dapat menampilkan hasil klasifikasi secara langsung. Di sisi lain, sistem masih memiliki keterbatasan, yaitu hanya melakukan klasifikasi biner sehingga belum dapat menentukan tingkat keparahan glaukoma, hasil prediksi masih sangat bergantung pada kualitas citra yang diunggah, belum menggantikan diagnosis dokter spesialis mata, dataset yang digunakan masih terbatas pada dataset publik sehingga belum sepenuhnya merepresentasikan karakteristik pasien di Indonesia, serta belum dilengkapi fitur interpretasi visual seperti Grad-CAM untuk menunjukkan area retina yang paling berpengaruh terhadap hasil prediksi.

SIMPULAN

Berdasarkan hasil penelitian dan pembahasan, dapat disimpulkan bahwa integrasi model Convolutional Neural Network (CNN) ke dalam aplikasi berbasis website menggunakan Streamlit berhasil dilakukan dan dapat digunakan sebagai alat bantu skrining dini glaukoma. Sistem yang dikembangkan mampu menerima input citra retina, melakukan preprocessing secara otomatis, menjalankan klasifikasi menggunakan model CNN, serta menampilkan hasil deteksi secara langsung kepada pengguna, dengan seluruh fitur utama berjalan sesuai skenario berdasarkan hasil pengujian blackbox. Dengan demikian, rumusan masalah pertama mengenai integrasi model CNN ke dalam aplikasi website telah terjawab dan tujuan penelitian pertama tercapai.

Teknik preprocessing citra retina yang meliputi resizing, normalisasi, dan augmentasi terbukti memberikan pengaruh positif terhadap performa model CNN dalam klasifikasi glaukoma dengan menyeragamkan ukuran dan distribusi nilai piksel citra, sehingga model dapat mempelajari pola visual retina secara lebih stabil. Hasil evaluasi menunjukkan model CNN memperoleh akurasi sebesar 80%, precision sebesar 71%, recall sebesar 100%, dan F1-score sebesar 83%, dengan nilai recall yang mencapai 100% menandakan bahwa seluruh citra retina terindikasi glaukoma berhasil dideteksi tanpa menghasilkan false negative. Dengan demikian, rumusan masalah kedua mengenai pengaruh preprocessing terhadap performa CNN telah terjawab dan tujuan penelitian kedua tercapai.

Penelitian selanjutnya disarankan menggunakan data citra retina dari rumah sakit atau klinik mata di Indonesia agar model memiliki kemampuan generalisasi yang lebih representatif, serta mengeksplorasi arsitektur deep learning yang lebih modern seperti ResNet, DenseNet, EfficientNet, atau Vision Transformer untuk menekan kesalahan false positive tanpa mengurangi kemampuan mendeteksi kasus glaukoma. Pengembangan sistem juga dapat diarahkan pada klasifikasi tingkat keparahan glaukoma serta penambahan fitur Explainable Artificial Intelligence (XAI) untuk meningkatkan transparansi dan kepercayaan pengguna terhadap hasil klasifikasi. Hasil sistem ini sebaiknya digunakan sebagai alat bantu pendukung keputusan, bukan pengganti diagnosis medis, sehingga pemeriksaan lanjutan oleh

dokter spesialis mata tetap diperlukan untuk memastikan diagnosis dan penanganan yang tepat.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada dosen pembimbing serta Program Studi Sistem Informasi S-1 Universitas Pamulang (Kampus Kota Serang) atas bimbingan dan dukungan yang diberikan selama proses penelitian dan penulisan artikel ini.

DAFTAR PUSTAKA

- Agus, I. P., Hidjah, K., Sulistianingsih, N., & Hendro, G. (2025). *Jtim : Jurnal Teknologi Informasi Dan Multimedia Implementasi Arsitektur Deep Convolutional Neural Network (Cnn) Dengan Transfer Learning Untuk Klasifikasi Penyakit Kulit*. 7(3), 461–477.
- Ali, M., Yudono, S., Ridha, F. F., Mardiyana, D., Al-Ghozi, F., Putra, U. N., Korespondensi, P., & Network, B. N. (2025). *Klasifikasi Katarak Berdasarkan Optic Disc Citra Fundus Smartphone : Perbandingan Ekstraksi Ciri Tekstur Dan Metode Cataract Classification Based On Optic Disc In Smartphone Fundus Images : Comparison Of Texture Feature Extraction And Neural*. 12(1), 203–212. <https://doi.org/10.25126/Jtiik.2025129254>
- Chincholi, F., & Koestler, H. (2023). *Transforming Glaucoma Diagnosis : Transformers At The Forefront*.
- Fuadah, Y. N., Saidah, S., Sy, N. K., Magdalena, R., & Da, I. (2022). *Glaucoma Classification Based On Fundus Images Processing With Convolutional Neural Network Klasifikasi Glaukoma Berdasarkan Pengolahan Citra Fundus*. 3(3), 717–722.
- Fuadah, Y. N. U. R., Ubaidullah, I. D., Ibrahim, N. U. R., Taliningsing, F. F., Sy, N. K., & Adnan, M. (2022). *Optimasi Convolutional Neural Network Dan K-Fold Cross Validation Pada Sistem Klasifikasi Glaukoma*. 10(3), 728–741.
- Indraswari, R., Herulambang, W., Rokhana, R., Informasi, D. S., Studi, P., Informatika, T., Bhayangkara, U., & Elektro, D. T. (2022). *Deteksi Penyakit Mata Pada Citra Fundus Menggunakan Convolutional Neural Network (Cnn)*. 21(2), 378–389.
- Informatics, A., Segara, A. P., Andryan, M., Saputra, W., Ranggianto, N. A., & Info, A. (2025). *Perbandingan Performa Algoritma Random Tree , K-Nn , Dan A-Nn Untuk Deteksi Serangan Ddos Pada Software Defined Network (Sdn)*. 08(2), 427–436.
- Latha, G. (2024). *Glaucoma Detection And Severity Diagnosis From Fundus Images Using Dual Cnn Architectures*. 16(6), 17–31. <https://doi.org/10.5815/Ijigsp.2024.06.02>
- Lin, J., Zheng, J., & Lin, B. (2025). *A Review Of Deep Learning For Fundus Image Enhancement*.
- Meedeniya, D., Shyamalee, T., Lim, G., & Yogarajah, P. (2025). *Glaucoma Identification With Retinal Fundus Images Using Deep Learning: Systematic Review. Informatics In Medicine Unlocked*, 56, 101644. <https://doi.org/https://doi.org/10.1016/J.Imu.2025.101644>
- Mulyasari, C. R., Hadiana, A. I., Komarudin, A., Jenderal, U., Yani, A., Jenderal, U., Yani, A., Jenderal, U., & Yani, A. (2024). *Deteksi Penyakit Diabetes , Katarak Dan*. 8(1), 53–68.
- Saintikom, J., Sains, J., Informatika, M., Simanjorang, R. M., Sitohang, A., Sembiring, A., & Simanjorang, S. (2025). *Implementasi Jaringan Syaraf Tiruan Dalam Klasifikasi Citra Medis*. 24, 64–72.
- Wang, C., Nguyen, H., Fan, W., Lue, J., Saenprasarn, P., Chen, M., Huang, S., Lin, F., & Wang, H. (2024). *Glaucoma Detection Through A Novel Hyperspectral Imaging Band Selection And Vision Transformer Integration*.