

Penerapan Convolutional Block Attention Module untuk Meningkatkan Klasifikasi Glaukoma Menggunakan ResNeXt

Chalifa Chazar ^{(1)*}, Arib Arkaan Fadhlullah ⁽²⁾, Milda Gutiana Husada ⁽³⁾, Uung Ungkawa ⁽⁴⁾

Departemen Informatika, Institut Teknologi Nasional Bandung, Bandung, Indonesia

e-mail : {chalifa,mghusada,uung}@itenas.ac.id, arib.arkaan@mhs.itenas.ac.id.

* Penulis korespondensi.

Artikel ini diajukan 27 Januari 2026, direvisi 17 Mei 2026, diterima 2 Juni 2026, dan dipublikasikan 25 September 2026.

Abstract

Glaucoma is a chronic ocular disease characterized by progressive optic nerve damage and is one of the leading causes of irreversible blindness. Manual analysis of retinal fundus images is time-consuming, particularly under high clinical workloads. To improve the efficiency of clinical diagnostic workflows, this study aims to develop a glaucoma classification system using a hybrid deep learning model that integrates the ResNeXt architecture with a Convolutional Block Attention Module (CBAM). In the proposed approach, ResNeXt is employed to capture complex feature representations, while CBAM enhances feature extraction by directing the model's attention to more informative spatial and channel-wise features. Performance evaluation demonstrates that the proposed model outperforms the baseline architecture. The standard ResNeXt model achieves an accuracy of 91.61%, an F1-score of 88.98%, and an AUC of 93.1%. In contrast, the ResNeXt model integrated with CBAM shows improved performance, attaining an accuracy of 92.70%, an F1-score of 90.60%, and an AUC of 95.6%. These results indicate that the integration of CBAM effectively enhances the sensitivity and robustness of the glaucoma classification model compared to the standard architecture.

Keywords: *Glaucoma Detection, Deep Learning, ResNeXt, CBAM, Retinal Fundus Image*

Abstrak

Glaukoma adalah penyakit mata kronis yang ditandai dengan kerusakan saraf optik progresif dan merupakan salah satu penyebab utama kebutaan permanen. Saat ini, analisis manual terhadap citra fundus retina memakan waktu, terutama dalam kondisi beban kerja klinis yang tinggi. Untuk meningkatkan alur proses pemeriksaan dokter terhadap pasien, penelitian ini bertujuan mengembangkan sistem klasifikasi penyakit glaukoma menggunakan model *deep learning* hibrida yang mengintegrasikan arsitektur ResNeXt dengan Convolutional Block Attention Module (CBAM). Pada metode yang diusulkan, ResNeXt bertugas menangkap fitur kompleks, sementara CBAM secara spesifik meningkatkan ekstraksi fitur dengan memfokuskan atensi model pada informasi spasial dan kanal yang lebih relevan. Evaluasi kinerja menunjukkan keunggulan model usulan dibandingkan *baseline*. Model ResNeXt standar mencatat akurasi 91,61%, F1-Score 88,98%, dan AUC 93,1%. Sebaliknya, model ResNeXt dengan integrasi modul atensi CBAM menunjukkan peningkatan performa dengan akurasi 92,7%, F1-Score 90,60%, dan AUC 95,6%. Temuan ini mengindikasikan bahwa integrasi CBAM mampu meningkatkan sensitivitas dan ketangguhan model klasifikasi secara keseluruhan dibandingkan dengan arsitektur standar.

Kata Kunci: *Deteksi Glaukoma, Deep Learning, ResNeXt, CBAM, Citra Fundus Retina*

1. PENDAHULUAN

Glaukoma merupakan penyakit mata kronis yang ditandai dengan kerusakan progresif pada saraf optik. Kondisi ini umumnya berkaitan dengan peningkatan tekanan intraokular (Intraocular Pressure atau IOP) akibat terganggunya drainase cairan aqueous humor yang berfungsi mempertahankan tekanan dan bentuk bola mata serta menutrisi jaringan mata (Sunderland & Sapra, 2023). Manifestasi kerusakan saraf optik ini sering kali diidentifikasi melalui perubahan ukuran *cup-to-disc ratio* (CDR), yaitu rasio antara diameter vertikal *Optic Cup* (OC) dan *Optic Disc* (OD). Secara klinis, tingkat keparahan glaukoma diklasifikasikan menjadi beberapa tingkatan, yaitu *mild* (ringan) dengan nilai CDR 0,3–0,5, *moderate* (sedang) dengan nilai CDR



0,5–0,7, dan *severe* (parah) dengan nilai CDR di atas 0,7 (Vyndi, 2021). Penyakit ini berkembang secara perlahan dan sering kali tidak menunjukkan gejala hingga tahap lanjut. Glaukoma merupakan penyebab kebutaan permanen kedua di dunia, dengan lebih dari 76 juta penderita pada tahun 2020. Sekitar 4,5 juta penderita mengalami gangguan penglihatan sedang hingga berat dan 3,2 juta lainnya mengalami kebutaan. Dengan meningkatnya populasi lanjut usia, jumlah kasus glaukoma diperkirakan mencapai 112 juta pada tahun 2040 (Shan et al., 2024). Di Indonesia, terdapat enam juta dari 270 juta penduduk Indonesia yang menderita glaukoma dan satu juta di antaranya telah kehilangan penglihatan secara permanen (Lions Eye Institute, 2024).

Hal ini terkadang membuat dokter spesialis menghadapi volume pasien yang tinggi. Selain itu, proses diagnosis manual menuntut pemeriksaan cermat terhadap citra medis untuk mengidentifikasi anomali halus pada berbagai kondisi seperti degenerasi makula terkait usia (AMD), glaukoma, hingga retinopati diabetik. Prosedur manual ini cenderung melelahkan serta rentan terhadap kesalahan manusia (*human error*) dan inkonsistensi (Sathishkumar et al., 2024). Tantangan ini menegaskan urgensi penerapan teknologi otomatis untuk mendukung kinerja dokter mata.

Dalam sistem skrining atau proses pemeriksaan awal, teknologi *deep learning* menawarkan solusi untuk membantu proses skrining glaukoma. Berbagai arsitektur jaringan konvolusional telah menunjukkan kemampuan dalam menangani tugas-tugas kompleks, termasuk analisis citra medis. ResNet yang menjadi fondasi banyak penelitian karena kemampuannya mengekstraksi fitur secara mendalam (Islam et al., 2022). Namun, struktur ResNet cenderung berat dan kurang fleksibel dalam menangani variasi fitur yang kompleks (Bairaboina & Battula, 2023). Kondisi ini mendorong kebutuhan akan pendekatan arsitektur yang lebih baik dalam menangani kompleksitas tersebut tanpa membebani komputasi secara berlebihan.

Sebagai solusi atas keterbatasan struktural ResNet, penelitian yang dilakukan oleh (Bairaboina & Battula, 2023a) memperlihatkan keunggulan nyata dari Residual Networks with Aggregated Transformations (ResNeXt) dalam tugas klasifikasi morfologi sel tunggal, di mana arsitektur ini berhasil mencapai akurasi 98,61%. Performansi tersebut tercapai berkat mekanisme *split-transform-merge*, yang tidak hanya memperkaya diversitas fitur yang dipelajari, tetapi juga mengoptimalkan beban komputasi model dibandingkan dengan model sebelumnya. Namun, model ResNeXt masih memiliki kekurangan dalam memfokuskan pada area dan fitur yang relevan atau *background noise* pada citra (Bairaboina & Battula, 2023).

Berkaca pada upaya peningkatan kinerja model, penambahan modul atensi seperti Convolutional Block Attention Module (CBAM) dalam penelitian yang dilakukan oleh (Islam et al., 2022)) menunjukkan bahwa penambahan modul atensi pada ResNet50 mampu meningkatkan kemampuan klasifikasi lesi payudara, dengan peningkatan nilai Area Under the Curve (AUC) dari 0,77 menjadi 0,87. Hal ini membuktikan bahwa modul atensi unggul dalam memandu jaringan untuk lebih fokus pada area dan fitur yang lebih relevan pada citra medis. Oleh karena itu, modul atensi ini diharapkan dapat diterapkan pada arsitektur usulan, yaitu ResNeXt, sebagai solusi untuk mengatasi keterbatasan seleksi fitur pada model sebelumnya.

Namun, berdasarkan studi literatur yang telah dilakukan, penerapan integrasi arsitektur ResNeXt dengan modul atensi CBAM pada klasifikasi glaukoma berbasis citra fundus retina masih terbatas. Sebagian besar penelitian sebelumnya lebih berfokus pada penggunaan arsitektur CNN (convolutional neural network) konvensional atau ResNet tanpa mekanisme atensi tambahan (Islam et al., 2022; Nugraha & Hadiani, 2023). Padahal, kombinasi kemampuan ekstraksi fitur ResNeXt dan mekanisme perhatian CBAM berpotensi meningkatkan fokus model terhadap area penting pada citra fundus retina serta mengurangi pengaruh *background noise* pada proses klasifikasi.

Setelah diketahui kekurangan dan kelebihan dari masing-masing model, penelitian ini berfokus pada klasifikasi dan evaluasi model *deep learning* yang mengintegrasikan arsitektur ResNeXt dengan modul atensi CBAM untuk klasifikasi citra fundus retina. Pendekatan ini memanfaatkan




kemampuan ResNeXt dalam menangkap variasi fitur kompleks dan modul atensi CBAM untuk memandu perhatian model pada area dan fitur yang relevan. Kontribusi utama penelitian ini adalah penerapan dan evaluasi integrasi ResNeXt dan CBAM pada klasifikasi glaukoma berbasis citra fundus retina menggunakan *multi-dataset* publik, serta analisis tambahan menggunakan parameter CDR sebagai pendukung interpretasi klinis. Sistem ini ditujukan sebagai alat bantu skrining atau proses pemeriksaan awal yang dapat mendukung tenaga medis saat menghadapi volume pasien yang tinggi atau kondisi kerja yang melelahkan.

2. METODE PENELITIAN

Metode penelitian memberikan informasi mengenai data dan proses penelitian yang dilakukan. Informasi tersebut diperlukan sebagai acuan bagi pembaca dalam menganalisis hasil penelitian. Sumber data dan mekanisme penelitian yang digunakan akan dijelaskan pada bab ini.

2.1 Dataset

Penelitian ini memanfaatkan tiga *dataset* citra fundus publik yang memiliki kredibilitas klinis, yaitu ACRIMA, FIVES, dan EyePACS AIROGS-Light. Seluruh data diakses secara langsung dari laman web resmi atau repositori publik masing-masing institusi penerbit. Data tersebut kemudian diunduh untuk digunakan dalam penelitian.



Gambar 1 Dataset Citra Fundus

Pada Gambar 1, *dataset* ACRIMA diperoleh dari FISABIO Oftalmología Médica di Valencia, Spanyol. Pelabelan *dataset* divalidasi oleh ahli glaukoma berpengalaman sesuai dengan standar etika Declaration of Helsinki (1964). *Dataset* ini memiliki dua label, yaitu normal yang terdiri dari 309 citra dan glaukoma yang terdiri dari 396 citra.

Selanjutnya, *dataset* FIVES bersumber dari *The Second Affiliated Hospital of Zhejiang University* (SAHZU), Tiongkok. Validasi *dataset* ini dilakukan melalui pemeriksaan langsung oleh tiga dokter spesialis mata dan 24 tenaga medis terlatih, dengan mengacu pada pedoman *American Academy of Ophthalmology* (AAO) serta persetujuan *Medical Ethics Committee of SAHZU* dengan dua label utama, yaitu glaukoma (g) dan normal (N), yang masing-masing berjumlah 200 citra. *Dataset* ini hanya menyediakan pembagian *train* 150 citra dan *test* 50 citra tanpa *validation set* bawaan. Selain itu, jumlah citra pada masing-masing label relatif terbatas, sehingga pada penelitian ini menggunakan pembagian data bawaan yang telah disediakan oleh pihak penerbit. Terakhir, *dataset* EyePACS AIROGS-Light dikumpulkan dari Venu Eye Institute and Research Centre (VEIRC) di New Delhi, India. *Dataset* ini memiliki dua label, yaitu glaukoma yang dinamakan Referable Glaucoma (RG) sebanyak 1.133 citra dan mata sehat yang dinamakan



Non-Referable Glaucoma (NRG) sebanyak 1.208 citra, yang telah divalidasi secara langsung oleh para dokter mata (ophthalmologists). Penggunaan *multi-dataset* pada penelitian ini bertujuan untuk meningkatkan keberagaman distribusi citra fundus retina sehingga model dapat memiliki kemampuan generalisasi yang lebih baik.

Tabel 1 Jumlah Citra Dataset


Dataset	Normal	Glaukoma	Total	Pembagian
ACRIMA	309	396	705	Test/Train/Val
FIVES	200	200	400	Test/Train
AIROGS-Light	1208	1133	2341	Test/Train/Val

2.2 Preprocessing

Preprocessing data dilakukan untuk menstandarkan format citra sebelum proses pelatihan model. Seluruh citra fundus retina diubah ukurannya menjadi 256×256 piksel agar seluruh data memiliki dimensi yang seragam dan sesuai dengan ukuran input model. Setelah proses *resize* dilakukan, citra dinormalisasi ke rentang [-1, 1] untuk menjaga kestabilan distribusi data dan membantu mempercepat konvergensi model selama proses pelatihan.

2.3 Arsitektur ResNeXt

Model ResNeXt merupakan pengembangan dari arsitektur *residual network* yang memperkenalkan konsep *cardinality*, yaitu jumlah jalur transformasi paralel untuk meningkatkan kemampuan representasi fitur tanpa meningkatkan kompleksitas komputasi secara signifikan (Acosta-Jiménez et al., 2025; Lu et al., 2025; Robet et al., 2024). Gambar 2 menunjukkan arsitektur ResNeXt yang digunakan pada penelitian ini dengan *cardinality* sebesar 32. Setiap jalur transformasi terdiri atas tiga lapisan konvolusi berurutan, yaitu konvolusi 1×1, 3×3, dan 1×1. Konvolusi 1×1 pertama digunakan untuk melakukan reduksi dimensi channel sehingga proses komputasi menjadi lebih efisien. Selanjutnya, konvolusi 3×3 digunakan untuk mengekstraksi fitur spasial dari citra fundus retina. Setelah proses ekstraksi fitur dilakukan, konvolusi 1×1 terakhir digunakan untuk mengembalikan dimensi channel ke ukuran semula sehingga informasi fitur dapat digabungkan kembali melalui mekanisme residual learning (Raj et al., 2023).




Gambar 2 Arsitektur ResNeXt (Raj et al., 2023)

2.4 Integrasi CBAM pada ResNeXt

Setelah proses ekstraksi fitur yang dilakukan oleh ResNeXt selesai, akan ada intervensi dari modul atensi CBAM sebagaimana yang telah diilustrasikan pada Gambar 3. Ilustrasi pada Gambar 3 memperlihatkan mekanisme arsitektur ResNeXt yang diintegrasikan dengan modul



atensi CBAM. Proses ini terbagi menjadi beberapa tahapan layer sebelum akhirnya diintervensi oleh modul atensi CBAM untuk menghasilkan output fitur yang lebih optimal. Blok putih berlabel CONV1 merupakan lapisan konvolusi tunggal yang menggunakan kernel berukuran 7×7 , Lapisan ini berfungsi menerima citra input mentah, melakukan kompresi dimensi awal, serta mengekstraksi fitur dasar seperti garis dan warna (Boukhari, 2025). Selanjutnya, proses ekstraksi fitur dilanjutkan dari Layer 1 hingga Layer 4 menggunakan blok konvolusi bertingkat (1×1 , 3×3 , dan 1×1) sebagaimana telah dijelaskan pada Gambar 2. Pada tahap akhir, fitur-fitur yang telah diekstraksi tersebut diproses oleh modul atensi CBAM untuk memperkuat representasi fitur yang paling relevan (Lu et al., 2025).



Gambar 3 Arsitektur ResNeXt with Attention (Lu et al., 2025)


Detail dari arsitektur CBAM-nya sendiri pada Ilustrasi Gambar 3 dipaparkan pada kotak merah dengan label Combined Attention. Alur ini menjelaskan bahwa modul atensi CBAM memiliki dua sub-modul yang beroperasi, yaitu Channel Attention Module (CAM) dan Spatial Attention Module (SAM). Proses ini bertujuan untuk memperkaya representasi fitur dengan, "fitur apa yang penting?" (*channel*) dan "di mana fitur itu berada?" (*spatial*) (Guo et al., 2022).

2.5 Blok Diagram Sistem

Blok diagram pada Gambar 4 memperlihatkan proses pengolahan dan klasifikasi data citra fundus glaukoma dan normal untuk menentukan golongan dari citra fundus baru yang akan diinput. Proses ini memiliki 2 jalur yang berbeda, bertujuan untuk membandingkan jalur mana yang memiliki hasil terbaik, pada jalur atas memiliki alur yang menggunakan ResNeXt sebagai model untuk melakukan ekstraksi fitur, model ini digunakan karena Keandalan arsitektur dalam klasifikasi (Acosta-Jiménez et al., 2025) dan yang sudah dipaparkan pada ilustrasi Gambar 2, yang menempatkan model ini sebagai salah satu arsitektur utama untuk tugas klasifikasi medis.

Jalur bawah mengintegrasikan model ResNeXt dengan Modul atensi CBAM, Modul atensi tambahan ini memperkuat sensitivitas model ResNeXt terhadap fitur yang lebih relevan terhadap data citra fundus yang sudah melewati tahapan ekstraksi fitur (Chiang et al., 2024; Zhang et al., 2023), Setelah proses ekstraksi fitur selesai maka akan lanjut ke beberapa tahap dalam klasifikasi antara lain Global Average Pooling (GAP), Teknik ini dipilih untuk mereduksi dimensi spasial secara baik (Gong et al., 2024; Nugraha & Hadiani, 2023), lalu setelahnya akan dilanjutkan dengan proses Fully Connected layer (FCL) untuk pembelajaran pola tingkat tinggi, dan diakhiri dengan fungsi aktivasi softmax untuk klasifikasi probabilitas kelas (Glaukoma atau Normal) (Fu'adah et al., 2022).





Gambar 4 Blok Diagram Sistem

2.6 Metrik Evaluasi Model

Setelah tahap klasifikasi, proses dilanjutkan dengan evaluasi kinerja model menggunakan metrik akurasi, presisi, recall, F1-Score, dan AUC untuk menilai seberapa akurat dan konsisten model dalam melakukan klasifikasi (Nouri et al., 2025), penilaian terhadap evaluasi kinerja model dengan metrik akurasi, presisi, dan recall akan mengikuti 4 komponen *confusion matrix* seperti yang diperlihatkan pada Tabel 2 yaitu True Positive (TP), False Positive (FP), False Negative (FN), dan True Negative (TN).

Tabel 2 Confusion Matrix

		Aktual	
		Positif	Negatif
Prediksi	Positif	True Positive (TP)	False Positive (FP)
	Negatif	False Negative (FN)	True Negative (TN)

Adapun detail perhitungan dan kegunaan dari masing-masing metrik ini seperti akurasi (*Accuracy*) yang ditunjukkan pada Pers. (1) di mana probabilitas diagnosis yang dikeluarkan sistem (entah itu sakit atau sehat) adalah tepat (Nouri et al., 2025), Presisi (*Precision*) seperti yang ditunjukkan pada Pers. (2) berdampak pada Tingkat Kepercayaan (*Reliability*) untuk menjamin sistem tidak memberikan alarm palsu (Aljohani & Aburasain, 2024), Recall / Sensitivitas (*Sensitivity*) seperti yang ditunjukkan pada Pers. (3) mengukur kemampuan model untuk menemukan kembali (*retrieve*) seluruh kasus positif yang ada di data, Jika nilai Recall rendah berarti banyak data sakit yang dianggap sehat dalam sistem sehingga bisa merusak kepercayaan terhadap hasil selanjutnya (Chiang et al., 2024), lalu F1-score seperti yang ditunjukkan pada Pers. (4) di mana menjadi penyeimbang ketika presisi dan recall memiliki nilai yang timpang dan menghindari penilaian yang berpihak ke satu kelas (Aljohani & Aburasain, 2024).

AUC seperti yang ditunjukkan pada Pers. (5) di mana memiliki perhitungan yang berbeda dibandingkan perhitungan metrik lainnya untuk mengukur kemampuan model dalam membedakan kelas positif (Glaukoma) dan negatif (normal), dengan detail rumus seperti n_p merupakan jumlah sampel positif, n_n jumlah sampel negatif, dan $I(\cdot)$ adalah fungsi indikator yang bernilai 1 jika skor prediksi $f(x_i)$ pada sampel positif lebih besar dibandingkan skor prediksi $f(x_j)$ pada sampel negatif, serta bernilai 0 jika sebaliknya (Chiang et al., 2024).



$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$precision = \frac{TP}{TP + FP} \quad (2)$$

$$recall = \frac{TP}{TP + FN} \quad (3)$$


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

$$AUC = \frac{1}{\eta_p \times \eta_n} \sum_{i=1}^{\eta_p} \sum_{j=1}^{\eta_n} I(f(x_i) > f(x_j)) \quad (5)$$

Setelah evaluasi, akan dilanjutkan ke tahap menyimpan hasil model yang berfungsi sebagai titik pos (checkpoint) untuk mengamankan bobot dan metrik evaluasi dari model terbaik yang telah dilatih. Langkah ini memastikan bahwa hanya model yang telah lolos tahap evaluasi kinerja dengan hasil optimal yang akan dilanjutkan ke tahap analisis perbandingan (Erukude et al., 2025; Kurniawan et al., 2025; Malau, 2025). Lalu dilakukan perbandingan untuk melihat alur proses yang memiliki hasil terbaik di antara kedua proses yang telah dilakukan.

2.7 Cup to Disc Ratio

Cup-to-Disc Ratio (CDR) merupakan rasio yang membandingkan diameter vertikal optic cup terhadap diameter vertikal optic disc pada citra fundus retina. Nilai CDR digunakan sebagai parameter klinis untuk membantu mengidentifikasi tingkat kerusakan saraf optik akibat glaukoma. Semakin besar nilai CDR, semakin besar kemungkinan terjadinya progresivitas glaukoma.



Gambar 5 Contoh Gambar Fundus dengan Optik Disk dan Cup (CDR)

Pada Gambar 4 terlihat optic disc atau optic cup yang ditandai dengan lingkaran kecil (optic cup) dan juga dengan lingkaran besar (optic disc). Pada penelitian ini, proses perhitungan CDR dilakukan secara otomatis berdasarkan hasil identifikasi area optic cup dan optic disc pada citra fundus retina. Diameter vertikal dari masing-masing area dihitung dalam satuan piksel, kemudian nilai rasio diperoleh dengan membandingkan tinggi vertikal optic cup terhadap tinggi vertikal optic disc menggunakan Pers. (6).

$$CDR = \frac{Height_{cup}}{Height_{disc}} \quad (6)$$

Nilai CDR yang diperoleh kemudian digunakan untuk mendukung interpretasi tingkat keparahan glaukoma berdasarkan standar kategori klinis. Kategori mild berada pada rentang 0,3–0,5,



kategori moderate berada pada rentang 0,5–0,7, sedangkan kategori severe memiliki nilai CDR di atas 0,7. Parameter ini digunakan sebagai analisis tambahan untuk mendukung hasil klasifikasi model *deep learning* terhadap citra fundus retina.

3. HASIL DAN PEMBAHASAN

Penelitian ini menerapkan model ResNeXt dan integrasinya dengan modul atensi CBAM untuk melihat seberapa baik modul atensi dalam membantu pembelajaran model mengenali objek citra fundus mata yang terjangkit penyakit glaukoma. Tahapan penelitian dapat diuraikan sebagai berikut. Hasil dari setiap tahapan penelitian selanjutnya dianalisis untuk mengevaluasi kinerja model yang digunakan.

3.1 Pembagian *Dataset*

Penelitian ini menggunakan tiga sumber *dataset* publik yang berbeda. Pembagian *dataset* dilakukan dengan rasio 60:20:20, yaitu 60% untuk pelatihan (*training*), 20% untuk pengujian (*testing*), dan 20% untuk validasi. Detail jumlah data pada setiap pembagian dapat dilihat pada Tabel 3.

Tabel 3 Pembagian *Dataset*

<i>Dataset</i>	Kelas	Splitting Data	Jumlah Data
ACRIMA	Glaukoma	Test	60
		Train	277
		Validation	59
	Normal	Test	46
		Train	216
		Validation	47
FIVES	Glaukoma	Test	50
		Train	150
		Validation	-
	Normal	Test	50
		Train	150
		Validation	-
EyePACS AIROGS - Light Normal	Glaukoma	Test	290
		Train	573
		Validation	270
	Normal	Test	304
		Train	634
		Validation	270
Total <i>Dataset</i>			3446
Glaukoma		Test	400
		Train	1000
		Validation	329
Normal		Test	400
		Train	1000
		Validation	317

Pembagian *dataset* dilakukan dengan menyesuaikan jumlah citra yang tersedia pada masing-masing sumber data. Proses pembagian data *training* dan *testing* menggunakan gabungan citra dari ketiga *dataset*, yaitu ACRIMA, FIVES, dan EyePACS AIROGS-Light. Sementara itu, data *validation* hanya menggunakan citra dari *dataset* ACRIMA dan EyePACS AIROGS-Light karena kedua *dataset* tersebut memiliki jumlah data yang lebih memadai untuk dibagi ke dalam tiga subset data.


Rincian jumlah citra untuk setiap subset data dari ketiga sumber tersebut disajikan pada Tabel 3. Sebagaimana tertera pada Tabel 3, *dataset* FIVES tidak digunakan pada tahap *validation* karena



pihak penerbit hanya menyediakan pembagian data *training* dan *testing* tanpa *validation set* bawaan. Selain itu, jumlah citra pada *dataset* FIVES relatif lebih sedikit dibandingkan dua *dataset* lainnya. Oleh karena itu, pada perhitungan total *dataset* di Tabel 3, jumlah keseluruhan data *validation* hanya mengakumulasi data dari ACRIMA dan EyePACS AIROGS-Light untuk kedua label (*Normal* dan *Glaukoma*).

3.2 Pelatihan Model

Pelatihan dari kedua metode mencapai angka yang cukup baik, pelatihan yang dilakukan dengan model ResNeXt tanpa ada bantuan modul atensi mencapai akurasi pelatihan 86% setelah *early stopping* pada epoch ke 3, sedangkan pelatihan yang dilakukan dengan model ResNeXt yang diintergrasikan dengan modul atensi CBAM mencapai akurasi pelatihan 92% setelah *early stopping* pada epoch ke 6, grafik pada gambar 5 memperlihatkan pelatihan model pada setiap epoch menggunakan ResNeXt dan gambar 6 dibawah memperlihatkan pelatihan model pada setiap epoch menggunakan ResNeXt dengan modul atensi CBAM.



Gambar 6 Grafik Pembelajaran model ResNeXt


Hasil pembelajaran model ResNeXt *baseline* pada Gambar 6 bagian (a) menunjukkan bahwa train loss menurun secara konsisten dari sekitar 0,42 pada epoch awal menjadi sekitar 0,14 pada epoch terakhir. Pola ini menunjukkan proses pembelajaran berjalan stabil dan model mampu menyesuaikan parameter terhadap data latih. *Validation loss* berada di sekitar 0,32 pada awal pelatihan, turun hingga titik terendah sekitar 0,24 pada epoch kedua, lalu sedikit meningkat menjadi sekitar 0,25 pada epoch akhir. Kondisi ini mengindikasikan kecenderungan overfitting ringan setelah epoch terbaik, namun masih dalam batas yang wajar.

Gambar 6 bagian (b) menunjukkan peningkatan train accuracy dari sekitar 81,6 persen menjadi sekitar 95 persen seiring bertambahnya epoch. *Validation accuracy* juga meningkat secara bertahap dari sekitar 87,8 persen hingga mencapai nilai terbaik sebesar 91,61 persen. Nilai akurasi terbaik diperoleh pada epoch dengan selisih terkecil antara akurasi pelatihan dan validasi, sehingga epoch tersebut dipilih sebagai kondisi pelatihan optimal untuk model dengan *batch size* 16. Sedangkan untuk hasil perhitungan matriks *Area Under Curve* (AUC) dari pelatihan ini, didapatkan angka 93,1 persen.


Kurva Receiver Operating Characteristic (ROC) pada Gambar 7 menunjukkan kemampuan model ResNeXt *baseline* dalam membedakan kelas glaukoma dan normal berdasarkan



perbandingan True Positive Rate (TPR) dan *False Positive Rate* (FPR). Berdasarkan hasil evaluasi, model *baseline* memperoleh nilai *Area Under Curve* (AUC) sebesar 0,931. Nilai tersebut menunjukkan bahwa model memiliki kemampuan klasifikasi yang baik dalam membedakan kedua kelas citra fundus retina. Kurva ROC yang cenderung mendekati sudut kiri atas juga mengindikasikan bahwa model mampu mempertahankan sensitivitas dan spesifisitas yang cukup baik selama proses klasifikasi.



Gambar 7 Grafik ROC model ResNeXt




Gambar 8 Grafik Pembelajaran model ResNeXt dengan CBAM

Gambar 8 memperlihatkan hasil pembelajaran model usulan, di mana ResNeXt dengan modul atensi CBAM terlihat pada bagian (a), menunjukkan bahwa *train loss* menurun tajam dari sekitar 0,16 pada epoch awal menjadi sekitar 0,06 pada epoch akhir. Penurunan ini menunjukkan proses pembelajaran berlangsung efektif dan konvergen. Sementara itu, *validation loss* berada pada rentang 0,27 hingga 0,30 dan cenderung berfluktuasi ringan, dengan nilai terendah sekitar 0,27 pada epoch awal dan kembali meningkat di epoch berikutnya. Pola ini mengindikasikan adanya kecenderungan overfitting ringan meskipun masih dalam batas yang terkendali.



Gambar 8 bagian (b) memperlihatkan bahwa *train accuracy* meningkat dari sekitar 97,0 persen hingga mendekati 98,0 persen, kemudian relatif stabil pada epoch akhir. Sebaliknya, *validation accuracy* berfluktuasi pada kisaran 91,9 persen hingga 92,7 persen, dengan nilai terbaik terjadi pada epoch awal. Sedangkan untuk hasil perhitungan matriks *Area Under Curve* (AUC) dari pelatihan model usulan mendapatkan hasil di angka 95,6 persen.



Gambar 9 Grafik ROC model ResNeXt+CBAM

Kurva *Receiver Operating Characteristic* (ROC) pada Gambar 9 menunjukkan performa model usulan ResNeXt yang diintegrasikan dengan modul atensi CBAM dalam membedakan kelas glaukoma dan normal. Berdasarkan hasil evaluasi, model usulan memperoleh nilai *Area Under Curve* (AUC) sebesar 0,956. Nilai tersebut menunjukkan bahwa model memiliki kemampuan diskriminasi yang sangat baik terhadap kedua kelas citra fundus retina. Kurva ROC yang mendekati sudut kiri atas mengindikasikan bahwa integrasi modul atensi CBAM membantu meningkatkan sensitivitas model terhadap fitur penting pada citra fundus retina serta menekan kesalahan klasifikasi selama proses prediksi.

3.3 Confusion Matrix

Confusion Matrix merupakan metode evaluasi kinerja model klasifikasi yang membandingkan hasil prediksi dengan data aktual untuk menentukan tingkat keakuratan (Sathyanarayanan, 2024). Perhitungan matriks pada kinerja model klasifikasi untuk 2 label, yaitu glaukoma dan normal, pada penggunaan model ResNeXt (Gambar 10) dan penggunaan ResNeXt yang diintegrasikan dengan modul atensi CBAM (Gambar 11).


Berdasarkan *confusion matrix* pada Gambar 10, model ResNeXt *baseline* berhasil mengklasifikasikan 503 data normal secara benar dan 517 data glaukoma secara benar. Terdapat 63 data normal yang salah diprediksi sebagai glaukoma dan 48 data glaukoma yang salah diklasifikasikan sebagai normal. Hasil ini menunjukkan bahwa model memiliki kemampuan deteksi glaukoma yang baik, dengan jumlah *false negative* lebih rendah dibandingkan *false positive*.

Berdasarkan *confusion matrix* pada Gambar 11, model usulan ResNeXt dengan modul atensi CBAM berhasil mengklasifikasikan 514 data normal dan 511 data glaukoma secara benar. Terdapat 52 data normal yang salah diprediksi sebagai glaukoma serta 54 data glaukoma yang salah diklasifikasikan sebagai normal.


Proses pelatihan model dijalankan pada lingkungan komputasi berbasis CPU dengan konfigurasi *hyperparameter* yang disesuaikan untuk menjaga stabilitas sumber daya, meliputi penggunaan



batch size 16 dipilih untuk menjaga stabilitas penggunaan memori dan mempertahankan keseimbangan antara kecepatan pelatihan dan kestabilan gradien, *learning rate* sebesar 1×10^{-4} digunakan untuk menghindari perubahan bobot yang terlalu besar selama proses optimasi sehingga pelatihan model dapat berlangsung lebih stabil, serta mekanisme *early stopping* dengan *patience* 3 dari total 30 epoch diterapkan untuk mengurangi risiko *overfitting* ketika *validation loss* tidak lagi mengalami perbaikan. Selain itu, pengaturan pemuatan data menggunakan *num_workers*=0 dan *pin_memory*=False diterapkan untuk menjaga integritas penggunaan memori selama proses pelatihan. Evaluasi performa model dilakukan menggunakan parameter *accuracy*, *precision*, *recall*, F1-score, dan Area Under Curve (AUC) yang hasilnya ditampilkan pada Tabel 4.



Gambar 10 Confusion Matrix (ResNeXt)



Gambar 11 Confusion Matrix (ResNeXt+CBAM)

Tabel 4 menunjukkan perbandingan performa antara arsitektur ResNeXt standar dan model usulan ResNeXt yang diintegrasikan dengan modul atensi CBAM. Berdasarkan hasil pengujian,



Artikel ini didistribusikan mengikuti lisensi Atribusi-NonKomersial CC BY-NC sebagaimana tercantum pada <https://creativecommons.org/licenses/by-nc/4.0/>.

model ResNeXt+CBAM menunjukkan peningkatan performa secara konsisten pada seluruh metrik evaluasi dibandingkan model *baseline* ResNeXt. Model usulan memperoleh nilai accuracy sebesar 92,7%, lebih tinggi dibandingkan model *baseline* sebesar 91,6%. Selain itu, peningkatan juga terlihat pada nilai precision, recall, F1-score, dan AUC.

Tabel 4 Evaluasi Matrix

	Akurasi	Presisi	Recall	F1-Score	AUC
ResNeXt	0.9161	0.8914	0.8887	0.8898	0.931
ResNeXt+CBAM	0.9270	0.9076	0.9040	0.9060	0.956

Selain itu, nilai F1-Score pada batch 16 mencapai 90,60%, menunjukkan keseimbangan yang lebih baik antara presisi dan sensitivitas pada model usulan. Peningkatan nilai AUC dari 0,931 menjadi 0,956 juga menegaskan bahwa model ResNeXt yang diintegrasikan dengan modul atensi CBAM memiliki kapabilitas yang lebih unggul dalam membedakan antara kelas Glaukoma dan Normal. Dengan begitu, hasil *training* yang dilakukan oleh model *Baseline* dan juga model usulan.

Tabel 5 Hasil Pengujian Model ResNeXt dan Nilai CDR

Nama File	Label Asli	Prediksi ResNeXt	Probabilitas	Nama File	Label Asli
104_G.png	Glaukoma	Glaukoma	99.54%	0.6	Glaukoma Sedang
108_G.png	Glaukoma	Glaukoma	99.96%	0.5	Glaukoma Sedang
107_G.png	Glaukoma	Glaukoma	92.39%	0.5	Glaukoma Ringan
111_G.png	Glaukoma	Glaukoma	99.08%	0.4	Glaukoma Ringan
145_G.png	Glaukoma	Glaukoma	99.98%	0.4	Normal
image_00004.png	Normal	Normal	60.53%	0.09	Normal
image_00006.png	Normal	Normal	78.34%	0.2	Glaukoma Ringan
image_00007.png	Normal	Normal	67.99%	0.4	Normal
image_00017.png	Normal	Normal	82.58%	0.2	Normal
image_00019.png	Normal	Normal	99.32%	0.2	Glaukoma Sedang

Berdasarkan data rekapitulasi pengujian, model ResNeXt menunjukkan performa klasifikasi yang baik pada seluruh sampel uji. Pada kasus positif glaukoma, model menunjukkan tingkat keyakinan (*confidence*) yang sangat tinggi dan stabil, berkisar antara 92% hingga 99,91%, yang didukung oleh hasil pengukuran CDR dalam rentang 0,3 hingga 0,6 untuk keperluan penentuan stadium keparahan (*grading*) dari tingkat Ringan hingga Sedang. Temuan signifikan teramati pada variabilitas deteksi kasus normal, di mana probabilitas model berkisar antara 60,53% dan 93,82%.

Mayoritas berdasarkan Tabel 6, hasil pengujian menggunakan model usulan ResNeXt-yang diintegrasikan dengan modul *Convolutional Block Attention Module* (CBAM) menunjukkan peningkatan stabilitas dan akurasi yang lebih baik dibandingkan model *baseline*. Pada pengujian terhadap sampel acak citra glaukoma, model mampu mempertahankan prediksi yang presisi dengan tingkat probabilitas rata-rata di atas 92%, mencapai puncaknya pada 99,98% untuk sampel 145_G.png.

Keunggulan utama arsitektur ResNeXt yang diintegrasikan oleh modul atensi CBAM terlihat jelas pada kemampuannya menangani variabilitas citra normal. Terjadi peningkatan *confidence score* yang nyata pada sampel normal, seperti pada image_00019.png yang mencapai 99,46%. Nilai



CDR seperti yang dipaparkan pada Tabel 5 dan Tabel 6 menjadi parameter tambahan sebagai bahan pertimbangan dalam menilai sebuah citra fundus apakah citra tersebut termasuk berlabel glaukoma dengan tingkatan ringan, sedang, dan berat atau berlabel normal.

Tabel 6 Hasil Pengujian Model ResNeXt+CBAM dan Nilai CDR4

Nama File	Label Asli	Prediksi ResNeXt+CBAM	Probabilitas ResNeXt+CBAM	Nilai CDR	Status CDR
104_G.png	Glaukoma	Glaukoma	99.54%	0.6	Glaukoma Sedang
108_G.png	Glaukoma	Glaukoma	99.96%	0.5	Glaukoma Sedang
107_G.png	Glaukoma	Glaukoma	92.39%	0.5	Glaukoma Sedang
111_G.png	Glaukoma	Glaukoma	99.08%	0.4	Glaukoma Ringan
145_G.png	Glaukoma	Glaukoma	99.98%	0.4	Glaukoma Ringan
image_00004.png	Normal	Normal	80.33%	0.09	Normal
image_00006.png	Normal	Normal	95.49%	0.2	Normal
image_00007.png	Normal	Normal	85.30%	0.4	Glaukoma Ringan
image_00017.png	Normal	Normal	98.20%	0.2	Normal
image_00019.png	Normal	Normal	99.46%	0.2	Normal

4. KESIMPULAN

Berdasarkan hasil penelitian, perancangan sistem, dan evaluasi pengujian yang telah dilakukan terhadap sistem klasifikasi glaukoma menggunakan arsitektur ResNeXt yang diintegrasikan dengan Convolutional Block Attention Module (CBAM) serta fitur pengukuran Cup-to-Disc Ratio (CDR), dapat ditarik beberapa kesimpulan sebagai berikut. Model klasifikasi glaukoma berhasil dirancang menggunakan arsitektur ResNeXt untuk mengekstraksi fitur visual kompleks pada citra fundus retina dan modul atensi CBAM untuk meningkatkan fokus model terhadap area penting seperti optic disc dan optic cup. Integrasi modul atensi membantu sistem dalam mengurangi pengaruh background noise dan variasi pencahayaan yang tidak relevan selama proses klasifikasi. Peningkatan integrasi modul atensi CBAM pada arsitektur ResNeXt mampu meningkatkan performa klasifikasi dibandingkan dengan model baseline. Model usulan (ResNeXt+CBAM) memperoleh akurasi pengujian sebesar 92,70% dan nilai Area Under Curve (AUC) sebesar 95,6%, sedangkan model baseline (ResNeXt) memperoleh akurasi sebesar 91,61% dan nilai AUC sebesar 93,1%.

Peningkatan performa pada model ResNeXt yang diintegrasikan dengan CBAM menunjukkan hasil yang sejalan dengan penelitian Islam et al. (2022), di mana modul atensi mampu meningkatkan kemampuan model dalam memfokuskan fitur penting pada citra medis dengan peningkatan nilai AUC dari 0,77 menjadi 0,87. Selain itu, penggunaan ResNeXt sebagai backbone juga mendukung temuan Bairaboina & Battula (2023) terkait kemampuan arsitektur tersebut dalam mengekstraksi variasi fitur kompleks secara efisien dengan akurasi klasifikasi mencapai 98,61% pada tugas klasifikasi morfologi sel tunggal. Pada penelitian ini, integrasi kedua pendekatan tersebut menghasilkan peningkatan nilai AUC dari 0,931 pada model baseline menjadi 0,956 pada model usulan, serta peningkatan akurasi validasi dari 91,61% menjadi 92,70%. Dengan hasil yang diperoleh, penelitian ini diharapkan dapat menjadi referensi dalam pengembangan sistem skrining glaukoma berbasis deep learning serta mendukung tenaga medis dalam proses pemeriksaan awal glaukoma secara lebih cepat dan baik.

Penelitian selanjutnya dapat mempertimbangkan penggunaan dataset dengan variasi yang lebih luas, baik dari spesifikasi perangkat kamera fundus, sehingga kinerja sistem dapat diuji pada karakteristik pigmentasi retina yang lebih beragam. Selain itu, penggunaan dataset yang memuat



kondisi patologis mata lainnya (seperti katarak atau retinopati diabetik) juga dapat dipertimbangkan agar sistem mampu membedakan glaukoma dari kelainan mata lain yang memiliki kemiripan visual. Pada tahap preprocessing, metode segmentasi area optik disk dan cawan (optic cup) dapat ditingkatkan agar sistem tetap mampu menghitung nilai CDR secara akurat pada citra dengan kondisi pencahayaan rendah, kontras minim, atau adanya noise refleksi cahaya.

DAFTAR PUSTAKA

- Acosta-Jiménez, S., Maeda-Gutiérrez, V., Galván-Tejada, C. E., Mendoza-Mendoza, M. M., Reveles-Gómez, L. C., Celaya-Padilla, J. M., Galván-Tejada, J. I., & García-Domínguez, A. (2025). Assessing ResNeXt and RegNet Models for Diabetic Retinopathy Classification: A Comprehensive Comparative Study. *Diagnostics*, 15(15), Article ID: 1966. <https://doi.org/10.3390/diagnostics15151966>
- Aljohani, A., & Aburasain, R. Y. (2024). A Hybrid Framework for Glaucoma Detection Through Federated Machine Learning and Deep Learning Models. *BMC Medical Informatics and Decision Making*, 24(1), Article ID: 115. <https://doi.org/10.1186/s12911-024-02518-y>
- Bairaboina, S. S. R., & Battula, S. R. (2023). Ghost-ResNeXt: An Effective Deep Learning Based on Mature and Immature WBC Classification. *Applied Sciences*, 13(6), Article ID: 4054. <https://doi.org/10.3390/app13064054>
- Boukhari, D. E. (2025). *Mamba-CNN: A Hybrid Architecture for Efficient and Accurate Facial Beauty Prediction*. <http://arxiv.org/abs/2509.01431>
- Chiang, Y.-Y., Chen, C.-L., & Chen, Y.-H. (2024). Deep Learning Evaluation of Glaucoma Detection Using Fundus Photographs in Highly Myopic Populations. *Biomedicines*, 12(7), Article ID: 1394. <https://doi.org/10.3390/biomedicines12071394>
- Erukude, S. T., Chaitanya Marella, V., & Veluru, S. R. (2025). Explainable Deep Learning in Medical Imaging: Brain Tumor and Pneumonia Detection. *2025 4th International Conference on Innovative Mechanisms for Industry Applications (ICIMIA)*, 906–911. <https://doi.org/10.1109/ICIMIA67127.2025.11200629>
- Fu'adah, Y. N., Saidah, S., Khofiya, N., Magdalena, R., & Salim, I. D. (2022). Glaucoma Classification Based on Fundus Images Processing with Convolutional Neural Network. *Jurnal Teknik Informatika (JUTIF)*, 3(3), 717–722. <https://doi.org/10.20884/1.jutif.2022.3.3.276>
- Gong, Aj., Fu, W., Li, H., Guo, N., & Pan, T. (2024). A Siamese ResNeXt Network for Predicting Carotid Intimal Thickness of Patients with T2DM from Fundus Images. *Frontiers in Endocrinology*, 15, 1–15. <https://doi.org/10.3389/fendo.2024.1364519>
- Guo, M.-H., Xu, T.-X., Liu, J.-J., Liu, Z.-N., Jiang, P.-T., Mu, T.-J., Zhang, S.-H., Martin, R. R., Cheng, M.-M., & Hu, S.-M. (2022). Attention Mechanisms in Computer Vision: A Survey. *Computational Visual Media*, 8(3), 331–368. <https://doi.org/10.1007/s41095-022-0271-y>
- Islam, W., Jones, M., Faiz, R., Sadeghipour, N., Qiu, Y., & Zheng, B. (2022). Improving Performance of Breast Lesion Classification Using a ResNet50 Model Optimized with a Novel Attention Mechanism. *Tomography*, 8(5), 2411–2425. <https://doi.org/10.3390/tomography8050200>
- Kurniawan, R., Badriyah, T., Apriandy, K. I., & Syarif, I. (2025). The Impact of Image Pre-processing for Tuberculosis Prediction System Based on Chest X-ray Images. *Jurnal Informatika: Jurnal Pengembangan IT*, 10(4), 933–944. <https://doi.org/10.30591/jpit.v10i4.9086>
- Lions Eye Institute. (2024). *Lions Eye Institute in Indonesia: Global Connections*. <https://www.lei.org.au/wp-content/uploads/2024/08/Lions-Eye-Institute-in-Indonesia.pdf>
- Lu, Z., Sun, C., Dou, J., He, B., Zhou, M., & You, H. (2025). SC-ResNeXt: A Regression Prediction Model for Nitrogen Content in Sugarcane Leaves. *Agronomy*, 15(1), Article ID: 175. <https://doi.org/10.3390/agronomy15010175>
- Malau, F. R. (2025). Optimizing CNN Performance for AI-Generated Image Classification: A Comparative Study of Architectures and Optimizers Using K-Fold Cross-Validation. *Jurnal INSTEK (Informatika Sains dan Teknologi)*, 9(2), 385–397. <https://doi.org/10.24252/instek.v9i2.54193>



- Nouri, A., M. Merzah, B., Mosayyebpour, S., Mousa, R., & Hesaraki, S. (2025). *Evaluation Metrics in Learning Systems: A Survey*. <https://doi.org/10.20944/preprints202508.1594.v1>
- Nugraha, C., & Hadiani, S. (2023). Glaucoma Detection in Fundus Eye Images Using Convolutional Neural Network Method with Visual Geometric Group 16 and Residual Network 50 Architecture. *Journal Medical Informatics Technology*, 36–41. <https://doi.org/10.37034/medinftech.v1i2.7>
- Raj, R., Kumar, U. S., & Maik, V. (2023). Enhanced Premature Ventricular Contraction Pulse Detection and Classification Using Deep Convolutional Neural Network. *Physical and Engineering Sciences in Medicine*, 46(4), 1677–1691. <https://doi.org/10.1007/s13246-023-01329-1>
- Robet, R., Perangin-Angin, J. T. K., & Pribadi, O. (2024). Implementation of Deep Learning Model for Classification of Household Trash Image. *Sinkron: Jurnal dan Penelitian Teknik Informatika*, 8(4), 2575–2583. <https://doi.org/10.33395/sinkron.v8i4.14198>
- Sathishkumar, R., Karthikeyan, T., Kumar, P. P., Rengarajan, C., Tharagesh, A., & Govindarajan, M. (2024). Enhancing Eye Health Diagnosis through Deep Transfer Learning: Unveiling Insights from Low Quality Fundus Images. *2024 International Conference on System, Computation, Automation and Networking (ICSCAN)*, 1–6. <https://doi.org/10.1109/ICSCAN62807.2024.10894600>
- Sathyanarayanan, S. (2024). Confusion Matrix-Based Performance Evaluation Metrics. *African Journal of Biomedical Research*, 27(4), 4023–4031. <https://doi.org/10.53555/AJBR.v27i4S.4345>
- Shan, S., Wu, J., Cao, J., Feng, Y., Zhou, J., Luo, Z., Song, P., & Rudan, I. (2024). Global Incidence and Risk Factors for Glaucoma: A Systematic Review and Meta-Analysis of Prospective Studies. *Journal of Global Health*, 14, 04252. <https://doi.org/10.7189/jogh.14.04252>
- Sunderland, D. K., & Sapra, A. (2023). Physiology, Aqueous Humor Circulation. In *StatPearls*. StatPearls. <http://www.ncbi.nlm.nih.gov/pubmed/15106942>
- Vyndi, M. (2021). *Deteksi Tingkatan Glaukoma dengan Perhitungan Nilai Cup-to-Disc Ratio dari Citra Fundus Optik Menggunakan Metode Ellipse Fitting* [Institut Teknologi Sepuluh Nopember]. <http://repository.its.ac.id/87331/>
- Zhang, Y., Li, Z., Nan, N., & Wang, X. (2023). TranSegNet: Hybrid CNN-Vision Transformers Encoder for Retina Segmentation of Optical Coherence Tomography. *Life*, 13(4), Article ID: 976. <https://doi.org/10.3390/life13040976>

