

**PERBANDINGAN ARSITEKTUR *XCEPTION*, *INCEPTION-RESNET V2*,
DAN *CONVNEXT* UNTUK KLASIFIKASI PENYAKIT GLAUKOMA
BERDASARKAN CITRA RETINA**

(Skripsi)

Oleh:

PUTRI MAHARANI

NPM 2117051033



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

ABSTRAK

PERBANDINGAN ARSITEKTUR *XCEPTION*, *INCEPTION-RESNET V2*, DAN *CONVNEXT* UNTUK KLASIFIKASI PENYAKIT GLAUKOMA BERDASARKAN CITRA RETINA

Oleh

PUTRI MAHARANI

Deteksi dini glaukoma sangat penting untuk mencegah kerusakan saraf optik yang bersifat permanen. Penelitian ini membandingkan kinerja tiga arsitektur *deep learning*, yaitu *Xception*, *Inception-ResNetV2*, dan *ConvNeXt*, dalam mengklasifikasikan glaukoma berdasarkan citra retina. *Dataset* ACRIMA yang digunakan terdiri dari 705 citra fundus yang terbagi menjadi 396 citra glaukoma dan 309 citra *non glaukoma*. Proses penelitian meliputi *pre-processing* berupa *resize* dan normalisasi citra, pembagian data menjadi latih, validasi, dan uji, serta augmentasi untuk meningkatkan keragaman data. Masing-masing model dilatih menggunakan parameter yang seragam, lalu dievaluasi berdasarkan akurasi, presisi, *recall*, dan *f1-score*, baik tanpa *early stopping* maupun dengan *early stopping*. Hasil evaluasi menunjukkan bahwa setiap arsitektur memiliki karakteristik kinerja yang berbeda, namun *ConvNeXt* cenderung memberikan performa paling stabil dengan kombinasi akurasi dan *f1-score* yang lebih tinggi dibandingkan dua model lainnya. *Inception-ResNetV2* menunjukkan performa baik tetapi lebih sensitif terhadap *overfitting*, sedangkan *Xception* memberikan hasil yang kompetitif dengan keunggulan pada efisiensi komputasi. Secara keseluruhan, penelitian ini menunjukkan bahwa pemilihan arsitektur CNN yang tepat berpengaruh signifikan terhadap keberhasilan klasifikasi glaukoma, dan *ConvNeXt* dapat direkomendasikan sebagai model paling optimal untuk sistem deteksi dini berbasis citra retina.

Kata Kunci: Citra *Digital*, *Convolutional Neural Network*, *Deep Learning*, Glaukoma, Klasifikasi.

ABSTRACT

COMPARISON OF XCEPTION, INCEPTION-RESNET V2, AND CONVNEXT ARCHITECTURES FOR CLASSIFYING GLAUCOMA DISEASE BASED ON RETINAL IMAGES

By

PUTRI MAHARANI

Early detection of glaucoma is crucial to prevent permanent damage to the optic nerve. This study compares the performance of three deep learning architectures, namely Xception, Inception-ResNetV2, and ConvNeXt, in classifying glaucoma based on retinal images. The ACRIMA dataset used consisted of 705 fundus images divided into 396 glaucoma images and 309 non-glaucoma images. The research process included pre-processing in the form of image resizing and normalization, data division into training, validation, and testing, as well as augmentation to increase data diversity. Each model was trained using uniform parameters, then evaluated based on accuracy, precision, recall, and f1-score, both without early stopping and with early stopping. The evaluation results showed that each architecture had different performance characteristics, but ConvNeXt tended to provide the most stable performance with a higher combination of accuracy and f1-score compared to the other two models. Inception-ResNetV2 showed good performance but was more sensitive to overfitting, while Xception provided competitive results with advantages in computational efficiency. Overall, this study shows that the selection of the appropriate CNN architecture has a significant effect on the success of glaucoma classification, and ConvNeXt can be recommended as the most optimal model for early detection systems based on retinal images.

Keywords: *Classification, Convolutional Neural Network, Deep Learning, Digital Image, Glaucoma.*

**PERBANDINGAN ARSITEKTUR *XCEPTION*, *INCEPTION-RESNET V2*,
DAN *CONVNEXT* UNTUK KLASIFIKASI PENYAKIT GLAUKOMA
BERDASARKAN CITRA RETINA**

Oleh

PUTRI MAHARANI

Skripsi

**Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA ILMU KOMPUTER**

Pada

**Jurusan Ilmu Komputer
Fakultas Matematika dan Ilmu Pengetahuan Alam**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

Judul Skripsi : **PERBANDINGAN ARSITEKTUR
XCEPTION, INCEPTION-RESNET V2, DAN
CONVNEXT UNTUK KLASIFIKASI
PENYAKIT GLAUKOMA BERDASARKAN
CITRA RETINA**

Nama Mahasiswa : **Putri Maharani**

Nomor Pokok Mahasiswa : **2117051033**


Program Studi : **S1 Ilmu Komputer**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**

MENYETUJUI

1. **Komisi Pembimbing**



Tristiyanto, M.I.S., Ph.D.
NIP. 19810414 200501 1 001



Dewi Asiah Shofiana, S.Komp., M.Kom.
NIP. 19950929 202012 2 030

2. **Mengetahui**

Ketua Jurusan Ilmu Komputer

**Ketua Program Studi
S1 Ilmu Komputer**


Dwi Sakethi, S.Si., M.Kom.
NIP. 19680611 199802 1 001



Tristiyanto, M.I.S., Ph.D.
NIP. 19810414 200501 1 001

MENGESAHKAN

1. Tim Penguji


Ketua

: **Tristiyanto, M.I.S., Ph.D.**



Sekretaris



: **Dewi Asiah Shofiana, S.Komp., M.Kom.**



Penguji

Bukan Pembimbing

: **Dr. rer. nat. Akmal Junaidi, M.Sc.**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng/Heri Satria, S.Si., M.Si.

NIP. 19741001 200501 1 002

Tanggal Lulus Ujian Skripsi: 18 Desember 2025

PERNYATAAN

Saya bertanda tangan di bawah ini:

Nama : Putri Maharani

NPM : 2117051033

Dengan ini menyatakan bahwa skripsi saya yang berjudul **“Perbandingan Arsitektur Xception, Inception-Resnet V2, dan Convnext Untuk Klasifikasi Penyakit Glaukoma Berdasarkan Citra Retina”** merupakan hasil karya saya sendiri dan bukan karya orang lain. Seluruh tulisan yang tertuang di skripsi ini telah mengikuti kaidah penulisan karya ilmiah Universitas Lampung. Apabila di kemudian hari terbukti skripsi saya merupakan hasil penjiplakan atau dibuat orang lain, maka saya bersedia menerima sanksi berupa pencabutan gelar yang telah saya terima.

Bandar Lampung, 23 Desember 2025



Putri Maharani

NPM. 2117051033

RIWAYAT HIDUP



Penulis bernama Putri Maharani dilahirkan pada 30 Juni 2003 di Kota Bandar Lampung, Provinsi Lampung sebagai anak kedua dari pasangan Bapak Sugeng Bagio dan Ibu Heni Hariati.

Penulis Pendidikan di Taman Kanak-Kanak (TK) Setia Kawan Panjang Utara pada tahun 2008 dan melanjutkan pendidikan di Sekolah Dasar Negeri 2 Panjang Utara pada tahun 2009-2015. Kemudian penulis melanjutkan pendidikan menengah pertama di SMP Kartika II Bandar Lampung pada tahun 2015-2018, dan pendidikan menengah atas di YP UNILA Bandar Lampung di tahun 2018-2021.

Pada Tahun 2021 penulis terdaftar sebagai mahasiswa Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur SNMPTN. Selama menjadi mahasiswa, penulis melakukan beberapa kegiatan antara lain:

1. Pada bulan Juni 2024 melaksanakan KKN di Desa Sukaraja Tiga, Kecamatan Marga Tiga, Lampung Timur.
2. Pada bulan Desember 2023 penulis melaksanakan Kerja Praktik di SMA YP UNILA Bandar Lampung.
3. Mengikuti Kegiatan Karya Wisata Ilmiah XXXII Tahun 2021.

MOTTO

1. *“Aku berjalan dengan keyakinan bahwa Allah tidak membebaniku melebihi kemampuan. Setiap perjuangan adalah bukti bahwa aku lebih kuat dari yang pernah kupikirkan”*
(QS Al-Baqarah:286)

2. *“Sebutlah nama-Nya, tetap di jalan-Nya, kelak kau mengingat, kau akan teringat”*
(Perunggu)

3. *“Hidup bukan tentang seberapa cepat saya sampai pada tujuan, tetapi tentang bagaimana saya belajar dari setiap jatuh, setiap luka, dan setiap doa yang saya bisikkan dalam diam. Dari proses itulah saya menemukan diri yang lebih kuat”*
(Putri Maharani)

PERSEMBAHAN

Alhamdulillahirabbil'alamiin

Puji syukur kehadiran Allah Subhanahu Wa Ta'ala atas segala rahmat dan karunia-Nya sehingga skripsi ini dapat diselesaikan dengan sebaik-baiknya. Shalawat serta salam senantiasa tercurahkan kepada suri teladan Nabi Muhammad Shallallahu 'Alaihi Wasallam.

Kupersembahkan karya ini kepada:

Ayah, Ibu, Kakak dan Adik Tercinta

Atas setiap doa, dukungan, dan kasih sayang yang tak pernah putus.
Terima kasih atas pengorbanan, semangat, dan kepercayaan yang telah menjadi kekuatan terbesar selama menempuh pendidikan ini.

Seluruh Keluarga Besar Ilmu Komputer 2021

Yang telah memberikan ilmu, bantuan, dan dukungan selama masa perkuliahan.

Almamater Tercinta, Universitas Lampung dan Jurusan Ilmu Komputer

Tempat bertumbuh, belajar, dan mendapatkan bekal hidup.

SANWACANA

Segala puji dan syukur penulis panjatkan ke hadirat Allah Subhanahu Wa Ta'ala atas segala limpahan nikmat, rahmat, dan hidayah-Nya sehingga penulisan skripsi ini dapat terselesaikan dengan baik dan lancar. Shalawat serta salam semoga senantiasa tercurah kepada Nabi besar Muhammad Shallallahu 'Alaihi Wasallam, pembawa risalah kebenaran bagi umat manusia. Skripsi berjudul **“Perbandingan Arsitektur Xception, Inception-Resnet V2, dan Convnext Untuk Klasifikasi Penyakit Glaukoma Berdasarkan Citra Retina”** telah disusun dengan sebaik-baiknya dan sebagai salah satu syarat untuk mendapatkan gelar sarjana ilmu komputer di Universitas Lampung.


Penulis menyadari bahwa dalam proses penyusunan skripsi ini tidak terlepas dari dukungan, bimbingan, serta bantuan dari berbagai pihak. Oleh karena itu, penulis mengucapkan terima kasih sebesar-besarnya kepada:

1. Allah Subhanahu Wa Ta'ala, yang senantiasa melimpahkan nikmat, petunjuk, serta ridho-Nya, sehingga penulisan karya ilmiah ini dapat diselesaikan dengan baik dan tepat waktu.
2. Ayah, Ibu, Kakak, dan Adik yang selalu memberikan cinta, doa, semangat, serta dukungan tanpa henti. Terima kasih atas segala pengorbanan, motivasi, dan perhatian yang tulus, yang menjadi sumber kekuatan penulis dalam menyelesaikan pendidikan dan penulisan skripsi ini.
3. Bapak Dr. Eng. Heri Satria, S.Si., M.Si. selaku Dekan FMIPA Universitas Lampung.

4. Bapak Dwi Sakethi, S.Si., M. Kom. selaku Ketua Jurusan Ilmu Komputer FMIPA Universitas Lampung.
5. Ibu Yunda Heningtyas, M. Kom. selaku Sekretaris Jurusan Ilmu Komputer FMIPA Universitas Lampung.
6. Bapak Tristiyanto, S. Kom., M.I.S., Ph.D. selaku Ketua Program Studi Ilmu Komputer FMIPA Universitas Lampung sekaligus Pembimbing Akademik dan Pembimbing Utama skripsi saya.
7. Ibu Dewi Asiah Shofiana, S.Komp., M.Kom. selaku Pembimbing Pembantu, yang telah memberikan arahan, masukan, dan motivasi yang sangat membantu dalam proses penyusunan skripsi ini. Terima kasih atas kesediaan, ketelitian, serta perhatian Ibu dalam membimbing penulis hingga skripsi ini dapat terselesaikan dengan baik.
8. Bapak Dr. rer. nat. Akmal Junaidi, M.Sc. selaku dosen Pembahas, yang telah memberikan kritik, saran, dan masukan konstruktif yang sangat berarti bagi penyempurnaan skripsi ini. Terima kasih atas perhatian dan kontribusi Bapak dalam proses akademik penulis.
9. Bapak dan Ibu Dosen Jurusan Ilmu Komputer FMIPA Universitas Lampung, yang telah membagikan ilmu, motivasi, serta pengalaman berharga selama penulis menempuh pendidikan di Jurusan Ilmu Komputer Universitas Lampung.
10. Seluruh staf dan karyawan Jurusan Ilmu Komputer, Ibu Ade Nora Maela, Bang Zainuddin, Mas Syam, dan Mas Nofal, yang telah membantu kelancaran berbagai urusan administrasi, laboratorium, serta peminjaman ruangan selama masa perkuliahan penulis di Jurusan Ilmu Komputer.

Penulis menyadari bahwa skripsi ini masih memiliki berbagai kekurangan dan belum mencapai kesempurnaan. Namun demikian, penulis berharap karya ini dapat memberikan manfaat, khususnya bagi civitas akademika Universitas Lampung, serta menjadi referensi dan kontribusi positif bagi mahasiswa Ilmu Komputer.

Bandar Lampung, 23 Desember 2025



Putri Maharani
NPM. 2117051033

DAFTAR ISI

	Halaman
DAFTAR GAMBAR.....	xi
DAFTAR TABEL	xiii
DAFTAR KODE PROGRAM	xiv
I. PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah	4
1.3 Tujuan Penelitian	5
1.4 Manfaat Penelitian.....	5
1.5 Batasan Masalah	5
II. TINJAUAN PUSTAKA	7
2.1 Penelitian Terdahulu.....	7
2.2 Glaukoma.....	9
2.2.1 Dampak Glaukoma Terhadap Kesehatan Masyarakat	11
2.2.2 Pentingnya Deteksi Dini	12
2.3.1 Pengertian dan Fungsi Citra Fundus Retina	13
2.3.2 Karakteristik Visual Glaukoma dalam Citra Retina	14
2.4 Pemrosesan Data Gambar	15
2.4.1 <i>Pre-Processing</i> Citra Retina	15
2.4.2 Pembagian <i>Dataset</i>	16
2.4.3 <i>Encoding</i> Label dan Format <i>Input</i>	16
2.5 Machine Learning.....	17
2.6 Deep Learning	17
2.6.1 Input Layer.....	18
2.6.2 Hidden Layer	18

2.6.3 Output Layer	19
2.7 Convolutional Neural Network (CNN)	19
2.7.1 Lapisan Konvolusi	20
2.7.2 Fungsi Aktivasi	20
2.7.2.1 <i>Sigmoid</i>	21
2.7.2.2 <i>Hyperbolic Tangent</i>	21
2.7.2.3 <i>ReLU</i>	22
2.7.3 Lapisan <i>Pooling</i>	22
2.8 Xception	23
2.9 Inception-ResNetV2	23
2.10 ConvNeXt.....	24
2.11 Augmentasi Data	25
2.12 Early Stopping.....	26
2.13 Confusion Matrix	26
2.13.1 Akurasi	27
2.13.2 Presisi.....	27
2.13.3 <i>Recall</i>	28
2.13.4 F1-score	28
2.14 Underfitting	29
2.15 Overfitting	29
III. METODOLOGI PENELITIAN	30
3.1 Tempat dan Waktu Penelitian.....	30
3.1.1 Tempat Penelitian.....	30
3.1.2 Waktu Penelitian	30
3.2 Data dan Perangkat Penelitian	31
3.2.1 Data.....	31
3.2.2 Perangkat Penelitian	32
3.3 Tahap Penelitian.....	33
3.3.1 Pengumpulan Data	34
3.3.2 Pre-Processing	35
3.3.3 Pembagian Data	35
3.3.4 Augmentasi Data.....	35
3.3.5 Pembuatan Model	36

3.3.6 Pengujian dan Evaluasi.....	36
IV. HASIL DAN PEMBAHASAN	37
4.1 Pengumpulan Dataset.....	37
4.2 Pembagian Data	38
4.3 Augmentasi Data	38
4.4 Evaluasi.....	39
4.4.1 Hasil Pelatihan tanpa <i>Early Stopping</i>	40
4.4.1.1 Hasil Pelatihan Model Xception tanpa <i>Early Stopping</i>	40
4.4.1.2 Hasil Pelatihan Model Inception Resnet V2 tanpa <i>Early Stopping</i>	42
4.4.1.3 Hasil Pelatihan Model <i>ConvNeXt</i> tanpa <i>Early Stopping</i>	46
4.4.1.4 Visualisasi Pelatihan tanpa <i>Early Stopping</i>	49
4.4.2 Confusion Matrix tanpa Early Stopping	53
4.4.2.1 <i>Confusion Matrix</i> Model Xception tanpa <i>Early Stopping</i>	53
4.4.2.2 <i>Confusion Matrix</i> Model Inception Resnet V2 tanpa <i>Early Stopping</i>	55
4.4.2.3 <i>Confusion Matrix</i> Model <i>ConvNeXt</i> tanpa <i>Early Stopping</i>	56
4.4.3 Hasil Pelatihan dengan <i>Early Stopping</i>	58
4.4.3.1 Hasil Pelatihan Model Xception dengan <i>Early Stopping</i>	58
4.4.3.2 Hasil Pelatihan Model Inception Resnet V2 dengan <i>Early Stopping</i>	60
4.4.3.3 Hasil Pelatihan Model <i>ConvNeXt</i> dengan <i>Early Stopping</i>	62
4.4.3.4 Visualisasi Pelatihan dengan <i>Early Stopping</i>	64
4.4.4 Confusion Matrix dengan Early Stopping	68
4.4.4.1 <i>Confusion Matrix</i> Model Xception dengan <i>Early Stopping</i>	68
4.4.4.2 <i>Confusion Matrix</i> Model Inception Resnet V2 dengan <i>Early Stopping</i>	70
4.4.4.3 <i>Confusion Matrix</i> Model <i>ConvNeXt</i> dengan <i>Early Stopping</i>	72
4.4.5 Evaluasi Kesalahan Klasifikasi.....	75
4.4.5.1 Kesalahan Klasifikasi Model Xception.....	76
4.4.5.2 Kesalahan Klasifikasi Model Inception Resnet V2	77
4.4.5.3 Kesalahan Klasifikasi Model <i>ConvNeXt</i>	79
V. SIMPULAN DAN SARAN	82

5.1 Simpulan	82
5.2 Saran	83
DAFTAR PUSTAKA	85

DAFTAR GAMBAR

Gambar	Halaman
1. Contoh Glaukoma (Puchaicela-Lozano et al., 2023).	11
2. Arsitektur CNN (Khan et al., 2018).	20
3. Arsitektur <i>Xception</i> (Abunasser et al., 2022).	23
4. Arsitektur <i>Inception-ResNet V2</i> (Hindarto, 2023).	24
5. Arsitektur <i>ConvNeXt</i> (Mustapha & Ozsahin, 2025).	25
6. Rasio Jumlah Gambar per Kelas.	32
7. Tahap Penelitian (Puchaicela-Lozano et al., 2023).	34
8. Contoh Data Gambar Glaukoma dan <i>Non Glaukoma</i> (Puchaicela Lozano et al., 2023).	37
9. Akurasi dan <i>Loss</i> Pelatihan dan Validasi <i>Xception Epoch 20 Batch Size</i>	50
10. Akurasi dan <i>Loss</i> Pelatihan dan Validasi <i>Inception Resnet V2 Epoch</i>	51
11. Akurasi dan <i>Loss</i> Pelatihan dan Validasi <i>ConvNeXt Epoch 30 Batch Size</i> 32.	53
12. <i>Confusion Matrix</i> Model <i>Xception Epoch 20 Batch Size 16</i>	55
13. <i>Confusion Matrix</i> Model <i>Inception ResNet V2 Epoch 30 Batch Size 64</i>	56
14. <i>Confusion Matrix</i> Model <i>ConvNeXt Epoch 30 Batch Size 32</i>	57
15. Akurasi dan <i>Loss</i> Pelatihan dan Validasi <i>Xception dengan Early Stopping Epoch 30 Batch Size 16</i>	65
16. Akurasi dan <i>Loss</i> Pelatihan dan Validasi <i>Inception Resnet V2 dengan Early Stopping Epoch 50 Batch Size 32</i>	67

17. Akurasi dan <i>Loss</i> Pelatihan dan Validasi <i>ConvNeXt</i> dengan <i>Early Stopping</i> Epoch 50 Batch Size 64.....	68
18. <i>Confusion Matrix</i> Model <i>Xception</i> dengan <i>Early Stopping</i> Epoch 30 Batch Size 16.	70
19. <i>Confusion Matrix</i> Model <i>Inception Resnet V2</i> dengan <i>Early Stopping</i> Epoch 50 Batch Size 32.	72
20. <i>Confusion Matrix</i> Model <i>ConvNeXt</i> dengan <i>Early Stopping</i> Epoch 50 Batch Size 64.	73
21. Sampel <i>False Negative</i> Model <i>Xception</i>	76
22. Sampel <i>False Positive</i> Model <i>Xception</i>	77
23. Sampel <i>False Negative</i> Model <i>Inception Resnet V2</i>	78
24. Sampel <i>False Positive</i> Model <i>Inception Resnet V2</i>	79
25. Sampel <i>False Negative</i> Model <i>ConvNeXt</i>	80
26. Sampel <i>False Positive</i> Model <i>ConvNeXt</i>	80

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terdahulu Terkait Klasifikasi Glaukoma.....	7
2. <i>Hyperparameter</i> Model.....	36
3. Distribusi <i>Dataset</i> per Kelas	38
4. Parameter Augmentasi dan Deskripsi	39
5. Hasil <i>Training</i> Model Xception tanpa <i>Early Stopping</i>	42
6. Hasil <i>Training</i> Model Inception Resnet V2 tanpa <i>Early Stopping</i>	45
7. Hasil <i>Training</i> Model <i>ConvNeXt</i> tanpa <i>Early Stopping</i>	48
8. Hasil <i>Training</i> Model <i>Xception</i> dengan <i>Early Stopping</i>	59
9. Hasil <i>Training</i> Model Inception Resnet V2 dengan <i>Early Stopping</i>	61
10. Hasil <i>Training</i> Model <i>ConvNeXt</i> Dengan <i>Early Stopping</i>	63
11. Evaluasi Tanpa <i>Early Stopping</i>	74
12. Evaluasi dengan <i>Early Stopping</i>	75

DAFTAR KODE PROGRAM

Kode Program	Halaman
1. Implementasi Model <i>Xception</i>	40
2. Implementasi Model <i>Inception Resnet V2</i>	43
3. Implementasi Model ConvNeXt.	46

I. PENDAHULUAN

1.1 Latar Belakang

Glaukoma mempengaruhi sekitar 3,5% populasi global yang berusia 40 hingga 80 tahun, dengan proyeksi yang mengindikasikan bahwa 111,8 juta orang akan menderita glaukoma pada tahun 2040 (Kang & Tanna, 2021). Glaukoma terjadi akibat peningkatan tekanan cairan yang disebut *Intraocular Pressure* (IOP) pada saraf optik (Deepika & Maheswari, 2018). Glaukoma merupakan penyakit mata yang dapat menyebabkan kebutaan permanen jika tidak terdeteksi sejak dini (Subbarayudu et al., 2024). Oleh karena itu, deteksi dini sangat penting untuk mencegah kerusakan saraf optik yang tidak bisa diperbaiki. Salah satu metode yang mulai digunakan dalam diagnosis glaukoma adalah *deep learning* berbasis citra retina. Teknologi ini memungkinkan komputer untuk mengenali pola dalam gambar fundus mata yang sering kali sulit dideteksi oleh dokter secara manual, sehingga meningkatkan akurasi diagnosis pada tahap awal penyakit (Shoukat et al., 2023). Penerapan *deep learning* dalam mendeteksi glaukoma telah menunjukkan hasil yang menjanjikan dengan akurasi tinggi dalam membedakan mata normal dari yang mengalami glaukoma (Prsath et al., 2023).

Metode konvensional dalam diagnosis glaukoma biasanya memerlukan pemeriksaan oleh dokter spesialis mata dan alat medis khusus untuk mengukur tekanan intraokular serta mengevaluasi kondisi saraf optik. Proses ini memerlukan biaya yang tidak sedikit dan waktu yang cukup lama (Juneja et al., 2020). Di sisi lain, *deep learning* menawarkan solusi otomatis yang lebih akurat dan efisien dalam menganalisis citra retina untuk mendeteksi tanda-tanda awal glaukoma tanpa memerlukan prosedur medis yang kompleks. Salah satu metode *deep learning*

yang paling efektif adalah *Convolutional Neural Networks* (CNN), yang telah terbukti memiliki performa tinggi dalam klasifikasi penyakit berbasis gambar medis (Ajitha *et al.*, 2021).

Namun, klasifikasi citra retina untuk mendeteksi glaukoma memiliki tantangan tersendiri, terutama karena variasi warna, resolusi, dan pencahayaan dalam gambar fundus mata yang dapat mempengaruhi akurasi analisis (Das *et al.*, 2024). Selain itu, perbedaan antara mata sehat dan mata yang mengalami glaukoma sangat tipis, sehingga sulit dideteksi secara manual. Oleh karena itu, diperlukan model *deep learning* yang dapat mengekstrak fitur kompleks dengan akurasi tinggi, seperti perbedaan rasio *cup-to-disc* dan penipisan lapisan serat saraf retina (Prsath *et al.*, 2023). Pemilihan arsitektur CNN yang tepat menjadi kunci dalam meningkatkan kinerja model, dengan beberapa studi menunjukkan bahwa arsitektur seperti *ResNet*, *EfficientNet*, dan *GoogLeNet* memiliki hasil yang lebih akurat dibandingkan model lainnya (Bruntha *et al.*, 2024).

CNN banyak digunakan dalam dunia medis, termasuk dalam diagnosis penyakit mata seperti glaukoma, retinopati diabetik, dan degenerasi makula. Beberapa arsitektur CNN, seperti *Xception*, *Inception-ResNet*, dan *ConvNeXt*, memiliki pendekatan berbeda dalam mengekstrak fitur dari citra retina, masing-masing dengan keunggulan dalam kedalaman jaringan, jumlah parameter, serta efisiensi komputasi (Das *et al.*, 2024). Setiap model memiliki teknik khusus dalam mengenali pola kompleks pada gambar medis, seperti perubahan morfologi saraf optik dan rasio *cup-to-disc* yang menjadi indikator utama glaukoma (Prsath *et al.*, 2023). Oleh karena itu, diperlukan penelitian yang membandingkan berbagai model untuk menentukan arsitektur yang paling optimal dalam mendeteksi glaukoma, guna meningkatkan akurasi diagnosis dan efisiensi sistem berbasis kecerdasan buatan (Bruntha *et al.*, 2024).

Salah satu arsitektur *deep learning* yang dirancang untuk meningkatkan efisiensi dalam klasifikasi citra medis adalah *Xception*. Model ini menggunakan teknik *depthwise separable convolution*, yang memungkinkan pemrosesan fitur lebih efisien dengan beban komputasi lebih ringan (Ajitha *et al.*, 2021). Meskipun memiliki jumlah parameter yang lebih sedikit dibandingkan CNN konvensional,

Xception tetap mampu menangkap pola spasial yang kompleks, menjadikannya pilihan yang efisien untuk analisis gambar medis (Sumitha & Gokila, 2023). Beberapa studi menunjukkan bahwa *Xception* memiliki performa yang unggul dalam klasifikasi gambar medis, termasuk deteksi penyakit berbasis gambar fundus mata (Lavric et al., 2021). Namun, meskipun hasilnya menjanjikan, efektivitasnya dalam diagnosis glaukoma masih perlu divalidasi lebih lanjut untuk memastikan kemampuannya dalam mengenali perubahan struktural pada saraf optik yang menjadi indikator utama penyakit ini (Geethalakshmi, 2023).

Selain *Xception*, *Inception-ResNet* merupakan arsitektur *deep learning* yang menggabungkan keunggulan *Inception* dalam menangkap fitur multi-skala dengan *residual learning* dari *ResNet*, yang meningkatkan efisiensi serta akurasi dalam klasifikasi citra medis (Varghese & Pandian, 2023). Pendekatan ini memungkinkan model mengenali pola kompleks dalam gambar retina dan meningkatkan deteksi dini penyakit mata, termasuk glaukoma (Singh et al., 2021). Keunggulan utama dari model ini adalah kemampuannya dalam menyeimbangkan akurasi tinggi dengan efisiensi komputasi, sehingga sering digunakan dalam sistem berbasis kecerdasan buatan untuk diagnosis otomatis (Neto et al., 2022). Namun, masih diperlukan penelitian lebih lanjut untuk mengevaluasi efektivitasnya dalam analisis citra retina, terutama dalam deteksi dini glaukoma guna meningkatkan presisi diagnosis dan intervensi medis (Alotaibi & Alotaibi, 2020).

Sementara itu, *ConvNeXt* adalah arsitektur CNN *modern* yang dikembangkan sebagai evolusi dari model konvolusi sebelumnya, dengan *desain* yang lebih mirip dengan arsitektur *transformer*, memungkinkan peningkatan kinerja dalam tugas klasifikasi gambar (Todi et al., 2023). Model ini mengoptimalkan struktur konvolusi dengan berbagai peningkatan, seperti normalisasi yang lebih efisien dan pemrosesan fitur yang lebih baik, sehingga meningkatkan akurasi tanpa menambah kompleksitas komputasi secara signifikan (Mehmood & Bajwa, 2024). Beberapa penelitian menunjukkan bahwa *ConvNeXt* memiliki performa yang lebih unggul dalam tugas visi komputer, termasuk klasifikasi gambar medis, dengan hasil yang mendekati model berbasis *transformer* (Panthakkan et al., 2023). Meskipun demikian, penerapan *ConvNeXt* dalam deteksi glaukoma masih perlu diteliti lebih

lanjut untuk menilai efektivitasnya dalam menganalisis citra retina dan mendeteksi tanda-tanda awal penyakit ini (Wu et al., 2022).

Berbagai penelitian sebelumnya telah membahas perbandingan model CNN dalam klasifikasi penyakit mata. Masruroh et al. (2023) membandingkan kinerja beberapa arsitektur *deep learning*, seperti *Inception-ResNet v2*, *Xception*, *Inception-v3*, dan *ResNet50*, dalam klasifikasi bentuk wajah. Hasil penelitian menunjukkan bahwa *Inception-ResNet v2* mencapai akurasi tertinggi, yaitu 92%. Sementara itu, penelitian oleh (Abdullah et al., 2024) meninjau berbagai model *deep learning* dalam klasifikasi penyakit mata seperti glaukoma, katarak, dan retinopati diabetik. Studi ini menemukan bahwa *Xception* memiliki keunggulan dalam menangkap fitur kompleks dari citra retina dan menghasilkan akurasi lebih tinggi dibandingkan model lainnya. Namun, penelitian ini juga mencatat tantangan seperti ketidakseimbangan data dan keterbatasan jumlah gambar medis untuk pelatihan model (Abdullah et al., 2024).

Oleh karena itu, penelitian ini bertujuan untuk membandingkan kinerja beberapa model *deep learning*, seperti *Xception*, *Inception-ResNetV2*, dan *ConvNeXt*, dalam mendeteksi glaukoma dari gambar retina. Dengan membandingkan model-model ini, penelitian ini berupaya menemukan model yang paling akurat dan efisien dalam menganalisis gambar medis untuk diagnosis glaukoma. Hasil dari penelitian ini diharapkan dapat memberikan rekomendasi model terbaik yang dapat digunakan dalam sistem berbasis kecerdasan buatan untuk membantu tenaga medis dalam mendeteksi glaukoma dengan lebih cepat dan akurat.

1.2 Rumusan Masalah

Rumusan masalah pada penelitian ini yaitu:

1. Bagaimana performa arsitektur *Xception*, *Inception-ResNetV2*, dan *ConvNeXt* dalam mendeteksi glaukoma menggunakan citra retina?
2. Bagaimana perbandingan tingkat akurasi, presisi, *recall*, dan *f1-score* dari ketiga arsitektur tersebut?
3. Model manakah di antara *Xception*, *Inception-ResNetV2*, dan *ConvNeXt* yang paling optimal untuk digunakan dalam diagnosis dini glaukoma?

1.3 Tujuan Penelitian

Tujuan dari penelitian ini yaitu:

1. Menganalisis dan membandingkan performa model *Xception*, *Inception-ResNetV2*, dan *ConvNeXt* dalam mendeteksi glaukoma menggunakan citra retina.
2. Menentukan Model terbaik berdasarkan tingkat akurasi, presisi, *recall*, dan *f1-score*.
3. Memberikan rekomendasi model yang paling optimal untuk digunakan dalam sistem deteksi dini glaukoma berbasis *deep learning*.

1.4 Manfaat Penelitian

Manfaat dari penelitian ini yaitu:

1. Membantu dunia medis dalam membuat sistem *Artificial Intelligence* (AI) yang lebih cepat dan akurat untuk mendeteksi glaukoma.
2. Penelitian ini dapat menjadi referensi bagi peneliti *deep learning* dalam menentukan model *Convolutional Neural Networks* (CNN) yang tepat untuk memproses citra medis.
3. Penelitian ini dapat menjadi acuan bagi pengembang teknologi kesehatan dalam merancang aplikasi *Artificial Intelligence* (AI) untuk mendeteksi penyakit mata.

1.5 Batasan Masalah

Batasan masalah pada penelitian ini adalah:

1. Penelitian ini hanya berfokus pada klasifikasi glaukoma menggunakan gambar retina dan tidak mempertimbangkan faktor klinis lain, seperti riwayat kesehatan pasien.
2. *Dataset* yang digunakan berasal dari kumpulan gambar retina yang tersedia secara publik, bukan dari data pasien rumah sakit secara langsung.

3. Perbandingan model dalam penelitian ini terbatas pada *Xception*, *Inception-ResNetV2*, dan *ConvNeXt*, tanpa melibatkan arsitektur lain.
4. Evaluasi model dilakukan berdasarkan akurasi, presisi, *recall*, dan *f1-score* tanpa mempertimbangkan sejauh mana model dapat diinterpretasikan.

II. TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Penelitian mengenai klasifikasi glaukoma berbasis citra retina telah banyak dilakukan sebelumnya. Berbagai pendekatan, mulai dari metode konvensional hingga arsitektur *deep learning* terkini, telah diterapkan untuk memperoleh hasil klasifikasi yang lebih akurat dan andal. Ringkasan beberapa penelitian terdahulu yang membahas metode klasifikasi glaukoma beserta hasil evaluasinya dapat dilihat pada Tabel 1.

Tabel 1. Penelitian Terdahulu Terkait Klasifikasi Glaukoma

No	Judul	Data	Metode	Hasil
1.	<i>Deep learning for Glaucoma Detection: R-CNN ResNet-50 and Image Segmentation</i> (Puchaicela-Lozano et al., 2023)	ACRIMA 396 citra danglaukoma 309 citra sehat ORIGA 382 citra glaukoma dan 168 citra sehat	<i>R-CNN ResNet-50</i>	Akurasi 95%
2	<i>Artificial Intelligence–Assisted Early Detection of Retinitis Pigmentosa — the Most Common Inherited Retinal Degeneration</i> (Chen et al., 2021)	Taiwan Inherited Retinal Degeneration Project 1.670 citra fundus	<i>Xception</i>	Akurasi 96%

Tabel 1. Lanjutan

No	Judul	Data	Metode	Hasil
3	<i>Evaluations of Deep learning Approaches for Glaucoma Screening Using Retinal Images from Mobile Device</i> (Neto et al., 2022)	RIM-ONE r3 85 citra normal (sehat) dan 74 citra glaukoma DRISHTI-GS 31 citra sehat dan 70 citra glaukoma REFUGE 360 citra sehat 40 citra glaukoma	<i>Xception, ResNet152 V2 dan Inception ResNet V2</i>	Akurasi <i>Xception</i> (C1) : 91% <i>ResNet152V2</i> (C2) : 90% <i>Inception-ResNetV2</i> (C3) : 88%
4	<i>Early-stage prediction of glaucoma disease to reduce surgical requirements using deep-learning</i> (Thakur & Juneja, 2021)	DRISHTI-GS 30 citra normal, 71 citra glaukoma RIM-ONE 92 citra normal, 74 citra glaukoma	<i>Xception, Inception, ResNet, DenseNet, dan VGG</i>	Akurasi <i>Xception</i> : 93.1% <i>DenseNet</i> : 92.1% <i>Inception</i> : 90.6% <i>ResNet</i> : 83.2% <i>VGG</i> : 81.6%

Penelitian mengenai klasifikasi glaukoma berbasis citra retina menggunakan arsitektur *deep learning* telah banyak dilakukan. Neto et al. (2022) membandingkan performa arsitektur *Xception*, *ResNet152V2*, dan *Inception-ResNetV2* dalam mendeteksi glaukoma dari citra retina yang diperoleh melalui perangkat *mobile*. Penelitian ini juga menggunakan *U-Net* untuk segmentasi dan estimasi *cup-to-disc ratio (CDR)*, yang menjadi indikator penting dalam diagnosis glaukoma. Hasilnya menunjukkan bahwa model-model tersebut memiliki performa mendekati metode *state-of-the-art*, meskipun citra yang digunakan berkualitas rendah (Neto et al., 2022).

Penelitian mengenai deteksi glaukoma menggunakan pendekatan *deep learning* yang menggabungkan *R-CNN*, *ResNet-50*, dan teknik segmentasi citra telah menunjukkan hasil yang menjanjikan. Puchaicela-Lozano et al. (2023)

mengusulkan metode hibrid yang memanfaatkan model R-CNN berbasis *ResNet-50* untuk mendeteksi keberadaan glaukoma melalui citra fundus, serta melakukan segmentasi area *cup-to-disc* menggunakan segmen optik berbasis gradien warna. Penelitian ini menggunakan *database* ACRIMA dan ORIGA, menghasilkan akurasi sebesar 95 % dan tingkat kepercayaan rata-rata 0,879 untuk model deteksi, serta korespondensi hasil segmentasi *cup-to-disc* sebanyak 80 % dengan *confidence level* 0,84.

Chen et al. (2021) meneliti penggunaan arsitektur *Xception*, *InceptionV3*, dan *Inception-ResNetV2* untuk mendeteksi penyakit retina *Retinitis Pigmentosa* (RP) melalui citra fundus. Walaupun objek penelitiannya berbeda, pendekatan yang digunakan tetap relevan karena model yang dievaluasi serupa. Dalam penelitian ini, model *Xception* menunjukkan kinerja terbaik dengan AUROC sebesar 96,74%, yang mendekati hasil diagnosis dari dokter spesialis retina (Chen et al., 2021). Thakur & Juneja (2021) membandingkan arsitektur *Xception*, *Inception*, *ResNet*, *DenseNet*, dan *VGG* dalam klasifikasi glaukoma berbasis citra retina. Penelitian ini menekankan keunggulan arsitektur *Xception* dalam hal efisiensi dan akurasi, menjadikannya kandidat yang cocok untuk diterapkan pada sistem deteksi glaukoma otomatis menggunakan kamera fundus portabel (Thakur & Juneja, 2021).

Pemilihan arsitektur *Xception*, *Inception-ResNetV2*, dan *ConvNeXt* dalam penelitian ini didasarkan pada keunggulan masing-masing dalam mengekstraksi fitur kompleks dari citra retina, serta kemampuannya dalam menghasilkan akurasi tinggi dengan efisiensi komputasi yang baik. Sementara itu, glaukoma dipilih sebagai objek karena merupakan penyebab utama kebutaan permanen di dunia, dengan perkembangan yang lambat dan sulit dikenali secara dini tanpa bantuan teknologi. Oleh karena itu, sistem klasifikasi otomatis berbasis *deep learning* sangat potensial untuk meningkatkan deteksi dini glaukoma.

2.2 Glaukoma

Glaukoma merupakan salah satu penyakit mata kronis yang menyebabkan kerusakan progresif pada saraf optik, terutama akibat tekanan intraokular

(*Intraocular Pressure/IOP*) yang meningkat. Penyakit ini termasuk penyebab utama kebutaan permanen di seluruh dunia. Deteksi dini sangat penting karena kerusakan saraf optik yang terjadi bersifat *irreversible* atau tidak dapat diperbaiki (Subbarayudu et al., 2024). Menurut Kang & Tanna (2021) glaukoma diperkirakan akan memengaruhi 111,8 juta orang pada tahun 2040, menjadikannya ancaman besar bagi kesehatan mata global. Diagnosis glaukoma umumnya dilakukan melalui pemeriksaan tekanan intraokular, pemeriksaan lapang pandang, dan analisis struktur retina, khususnya rasio *cup-to-disc* (CDR). Namun, metode ini memerlukan alat khusus dan tenaga medis ahli, sehingga mendorong pemanfaatan teknologi berbasis kecerdasan buatan (*Artificial Intelligence*) dan pengolahan citra digital untuk mempercepat dan meningkatkan akurasi diagnosis.

Glaukoma sudut terbuka atau *Primary Open-Angle Glaucoma* (POAG) dan sudut tertutup atau *Primary Angle-Closure Glaucoma* (PACG) memiliki mekanisme patologis yang berbeda meskipun sama-sama menyebabkan kerusakan saraf optik. *Primary Open-Angle Glaucoma* (POAG) terjadi ketika sudut antara iris dan kornea tetap terbuka, namun terdapat hambatan aliran pada jaringan trabekular yang menyebabkan peningkatan tekanan intraokular secara perlahan dan progresif. Sebaliknya, *Primary Angle-Closure Glaucoma* (PACG) ditandai dengan penyempitan atau penutupan sudut *drainase*, yang menyebabkan peningkatan tekanan secara cepat dan sering disertai gejala akut seperti nyeri dan penglihatan kabur (J. A. Sun et al., 2024); (Wang et al., 2024). Meskipun keduanya menyebabkan kehilangan penglihatan, *Primary Angle-Closure Glaucoma* (PACG) memiliki risiko kebutaan yang lebih tinggi dan progresi yang lebih cepat dibandingkan *Primary Open-Angle Glaucoma* (POAG) (George et al., 2022).

Selain itu, perbedaan antara mata sehat dan mata yang mengalami glaukoma sangat tipis, sehingga sulit dideteksi secara manual. Oleh karena itu, diperlukan model *deep learning* yang dapat mengekstrak fitur kompleks dengan akurasi tinggi, seperti perbedaan rasio *cup-to-disc* dan penipisan lapisan serat saraf retina (Prsath et al., 2023). Pemilihan arsitektur CNN yang tepat menjadi kunci dalam meningkatkan kinerja model, dengan beberapa studi menunjukkan bahwa arsitektur seperti *ResNet*, *EfficientNet*, dan *GoogLeNet* memiliki hasil yang lebih akurat dibandingkan

model lainnya (Bruntha *et al.*, 2024). Contoh penyakit glaukoma dapat dilihat pada Gambar 1.



Gambar 1. Contoh Glaukoma (Puchaicela-Lozano *et al.*, 2023).

2.2.1 Dampak Glaukoma Terhadap Kesehatan Masyarakat

Glaukoma merupakan salah satu penyebab utama kebutaan permanen di dunia dan diproyeksikan terus meningkat seiring bertambahnya usia penduduk global. Secara global, diperkirakan 111,8 juta orang akan menderita glaukoma pada tahun 2040, naik drastis dari 64,5 juta kasus pada tahun 2014 (Kang & Tanna, 2021). Di Amerika Serikat, sekitar 4,22 juta orang hidup dengan glaukoma pada tahun 2022, dan sekitar 1,49 juta di antaranya mengalami gangguan penglihatan signifikan (Ehrlich *et al.*, 2024)

Peningkatan prevalensi glaukoma sangat dipengaruhi oleh penuaan populasi, status sosial ekonomi, dan kurangnya akses terhadap pelayanan kesehatan mata, terutama di negara-negara berkembang (Lin *et al.*, 2023). Di wilayah dengan indeks pembangunan manusia rendah, prevalensi glaukoma dan kebutaan terkait lebih tinggi akibat keterbatasan dalam deteksi dini dan pengobatan (Sun *et al.*, 2022). Kehilangan penglihatan akibat glaukoma bersifat permanen karena kerusakan saraf optik yang tidak dapat dipulihkan. Hal ini memiliki konsekuensi besar terhadap kualitas hidup, termasuk menurunnya mobilitas, meningkatnya risiko jatuh, dan ketergantungan pada bantuan orang lain (Castellanos-Perilla *et al.*, 2023).

Beban ekonomi dari glaukoma juga signifikan, baik dari segi biaya pengobatan langsung maupun biaya tidak langsung seperti kehilangan produktivitas kerja. Individu dengan glaukoma lebih mungkin mengalami absen kerja, penurunan

pendapatan, bahkan pengangguran dibandingkan dengan individu tanpa gangguan penglihatan (Inayat et al., 2024). Studi lain menunjukkan bahwa pengaruh glaukoma tidak hanya terbatas pada individu penderita, tetapi juga berdampak pada keluarga dan sistem kesehatan masyarakat. Kebutuhan akan perawatan jangka panjang dan dukungan sosial dapat membebani *caregiver* serta meningkatkan pengeluaran sistem kesehatan (Guedes, 2021).

Data dari *Global Burden of Disease (GBD) Study* juga menunjukkan bahwa beban glaukoma meningkat hampir 70% antara tahun 1990 dan 2019 dalam bentuk peningkatan jumlah kasus dan tahun hidup dengan disabilitas (*DALYs*) (Chen et al., 2024). Di tingkat nasional, seperti di Kolombia, glaukoma menjadi salah satu penyakit mata dengan insiden tinggi, terutama pada populasi lanjut usia. Studi menunjukkan bahwa glaukoma secara signifikan berkorelasi dengan penurunan kemampuan melakukan aktivitas sehari-hari seperti mengelola uang dan memasak (Cifuentes-González et al., 2024).

Ketimpangan dalam deteksi dan pengelolaan glaukoma juga menjadi perhatian utama. Negara-negara dengan sistem pencatatan elektronik pasien seperti Kazakhstan menunjukkan bahwa kurangnya *monitoring* jangka panjang memperburuk hasil klinis dan meningkatkan disabilitas akibat glaukoma (Yermukhanova et al., 2024). Secara keseluruhan, glaukoma bukan hanya tantangan *oftalmologis* tetapi juga masalah kesehatan masyarakat yang kompleks. Upaya pencegahan, deteksi dini, dan intervensi sosial sangat dibutuhkan untuk menekan beban kesehatan dan ekonomi yang ditimbulkan oleh penyakit ini.

2.2.2 Pentingnya Deteksi Dini

Deteksi dini glaukoma merupakan langkah krusial dalam mencegah kerusakan permanen pada saraf optik dan kebutaan yang tidak dapat disembuhkan. Glaukoma sering kali bersifat asimtomatik pada tahap awal, sehingga pasien tidak menyadari kehilangan penglihatan hingga kerusakan telah terjadi. Oleh karena itu, metode skrining yang efisien, akurat, dan terjangkau sangat penting untuk mengidentifikasi kasus sedini mungkin (Shoukat et al., 2021). Pemeriksaan fundus bersifat murah, aman, dan dapat dilakukan di berbagai tingkat fasilitas kesehatan, termasuk daerah

dengan sumber daya terbatas. Citra fundus dapat disimpan dan dianalisis ulang, yang meningkatkan efisiensi diagnosis dan memungkinkan sistem deteksi berbasis kecerdasan buatan untuk beroperasi secara otomatis (Jain & Panneer, 2024).

Peran klasifikasi berbasis citra retina semakin penting dalam konteks otomatisasi diagnosis. Dengan menggunakan model pembelajaran mesin seperti *Convolutional Neural Networks* (CNN), sistem dapat mempelajari pola pada ribuan citra fundus untuk mengenali indikasi glaukoma. Teknik ini telah terbukti akurat dalam membedakan mata normal dan mata dengan glaukoma, bahkan melebihi kemampuan diagnostik manusia dalam beberapa studi (Aguilar et al., 2024). Model-model klasifikasi ini dapat mencapai akurasi tinggi. Misalnya, model *InceptionCaps* yang berbasis *Capsule Network* telah menunjukkan akurasi hingga 95,6% pada *Dataset RIM-ONE v2*, menandakan bahwa pendekatan ini cukup andal dalam lingkungan dengan keterbatasan data label (Manohar & O'Reilly, 2023). Metode berbasis fundus ini juga memungkinkan pemantauan progresi glaukoma dari waktu ke waktu. Dengan membandingkan citra dari waktu berbeda, sistem dapat mendeteksi perubahan struktur optik yang menunjukkan perkembangan penyakit, sehingga pengobatan dapat disesuaikan secara lebih presisi (Sandoval-Cuellar et al., 2021).

Deteksi otomatis juga mengurangi beban kerja tenaga medis. Dalam kondisi sistem kesehatan yang kekurangan spesialis mata, sistem klasifikasi otomatis berbasis citra retina dapat memberikan rekomendasi awal, memungkinkan prioritas penanganan bagi kasus dengan risiko tinggi (Elmoufidi et al., 2023). Selain akurasi, keunggulan lain dari deteksi berbasis citra fundus adalah kemampuannya diintegrasikan dengan teknologi seluler dan telemedisin. Hal ini menjadikan skrining glaukoma berbasis *AI* sebagai solusi potensial untuk menjangkau populasi di daerah terpencil atau *underserved* (Sidhu & Mansoori, 2024).

2.3 Citra Retina dalam Diagnosis Medis

2.3.1 Pengertian dan Fungsi Citra Fundus Retina

Citra fundus retina adalah gambar dari bagian belakang bola mata, termasuk retina, makula, *disc optic* (*optic disc*), dan pembuluh darah retina. Citra ini diperoleh

secara *non-invasif* menggunakan kamera fundus dan berfungsi sebagai alat penting dalam diagnosis berbagai penyakit mata seperti glaukoma, retinopati diabetik, dan degenerasi makula. Dalam konteks oftalmologi, citra fundus memberikan gambaran rinci mengenai struktur retina dan menjadi alat penting dalam deteksi dini dan pemantauan progresivitas penyakit mata kronis (Pishnamaz, 2021). Komponen visual utama dalam citra retina meliputi *disc optic* (*optic disc*), *cup* optik (*optic cup*), dan pembuluh darah retina. *Disc optic* adalah titik keluar saraf optik dari retina dan merupakan area penting untuk analisis struktur mata. Di dalam *disc optic* terdapat *cup* optik, yaitu bagian tengah yang lebih terang, dan rasio *cup* terhadap *disc* (*cup-to-disc ratio*/CDR) menjadi indikator utama dalam diagnosis glaukoma (Murugan et al., 2024). Pembuluh darah retina, yang menjalar dari sekitar *disc optic*, juga dianalisis untuk mendeteksi kondisi sistemik seperti hipertensi dan penyakit kardiovaskular. Pengukuran diameter arteri dan vena retina dapat digunakan sebagai indikator risiko penyakit vaskular (Varshan et al., 2023).

2.3.2 Karakteristik Visual Glaukoma dalam Citra Retina

Karakteristik visual utama glaukoma yang dapat diamati melalui citra retina adalah perubahan pada rasio *cup-to-disc* (CDR) dan morfologi *disc optic*. CDR adalah rasio antara diameter vertikal dari *cup* optik terhadap *disc optic*, dan merupakan indikator klinis paling umum dalam diagnosis glaukoma. Peningkatan nilai CDR menunjukkan pelebaran *cup* optik akibat kerusakan serabut saraf retina dan penurunan jaringan saraf di sekitar *disc optic* (Duraismy & Suganthi, 2021; Yunitasari et al., 2021). Dalam kondisi normal, CDR berada dalam kisaran 0,3–0,5, dan nilai lebih dari 0,6 menandakan kemungkinan glaukoma yang perlu evaluasi lanjut (Liu et al., 2024).

Selain nilai CDR, perubahan morfologi *disc optic* juga menjadi indikator penting. Pada mata yang terkena glaukoma, terjadi penipisan tepi *neuroretinal rim* dan pelebaran *cup* yang menyebabkan tampilan *disc* menjadi lebih cekung dan asimetris. Area superior dan inferior biasanya paling awal menunjukkan tanda-tanda kerusakan ini. Deteksi otomatis menggunakan segmentasi citra retina menunjukkan performa tinggi dalam mengenali perubahan ini melalui metode *deep*

learning seperti *U-Net* dan *Mask R-CNN* (Bhattacharya et al., 2023; Kim et al., 2022). Dengan pemantauan nilai CDR dan morfologi *disc* secara berkala melalui *fundus imaging*, glaukoma dapat terdeteksi lebih awal dan ditangani sebelum terjadi kehilangan penglihatan permanen.

2.4 Pemrosesan Data Gambar

2.4.1 Pre-Processing Citra Retina

Pre-processing citra retina merupakan tahap krusial dalam *pipeline* pengolahan citra medis, terutama dalam konteks deteksi glaukoma berbasis *deep learning*. Tahapan pertama yang umum dilakukan adalah *resize* gambar, yaitu mengubah ukuran semua citra retina menjadi dimensi standar seperti 224×224 atau 299×299 piksel, agar sesuai dengan format *input* pada arsitektur CNN populer seperti ResNet atau EfficientNet (Subha et al., 2024). Langkah ini memastikan konsistensi dimensi *input* sehingga model dapat memproses data dengan efisien dan tanpa *error* teknis.

Selanjutnya, dilakukan normalisasi warna untuk meningkatkan kualitas *input* citra. Nilai piksel biasanya diskalakan ke rentang $[0,1]$ atau dinormalisasi berdasarkan *mean* dan standar deviasi *dataset* ImageNet jika menggunakan *transfer learning*. Hal ini penting untuk mempercepat konvergensi model dan menjaga kestabilan distribusi data sepanjang pelatihan (Das et al., 2024). Untuk meningkatkan kualitas visual fitur penting seperti *disc optic* dan *cup* optik, diterapkan teknik *noise reduction* dan *contrast enhancement*. Salah satu metode yang umum digunakan adalah *Contrast Limited Adaptive Histogram Equalization* (CLAHE), yang secara signifikan meningkatkan kontras lokal tanpa memperkuat *noise*, sangat bermanfaat dalam segmentasi struktur kecil seperti pembuluh darah atau tepi *disc optic* (Marciniak & Stankiewicz, 2024).

Teknik CLAHE ini juga dapat dikombinasikan dengan metode lain seperti *N4 bias field correction* untuk memperbaiki pencahayaan tidak merata dalam citra, yang terbukti meningkatkan *recall* dalam segmentasi pembuluh darah retina (Owler & Rockett, 2021). Dengan peningkatan kualitas kontras dan pengurangan *noise*, fitur diagnostik menjadi lebih mudah dikenali oleh sistem deteksi otomatis. Kombinasi

preprocessing tersebut bukan hanya meningkatkan performa model, tetapi juga membuka peluang penerapan sistem deteksi glaukoma dalam skala besar seperti telemedisin atau *screening massal*. Dengan *preprocessing* yang tepat, model dapat bekerja stabil pada variasi pencahayaan, resolusi, dan warna antar alat kamera fundus (Victo et al., 2025).

2.4.2 Pembagian Dataset

Dalam pengolahan citra retina untuk deteksi glaukoma menggunakan pembelajaran mesin, proses pembagian *dataset* menjadi langkah penting untuk memastikan generalisasi model yang baik. *Dataset* ACRIMA yang digunakan terdiri dari 705 citra, dengan distribusi kelas yang cukup seimbang yaitu 396 citra glaukoma dan 309 citra *non-glaukoma*. Oleh karena itu, tidak diperlukan teknik penyeimbangan kelas tambahan seperti *oversampling* atau *undersampling*.

Pembagian umum yang digunakan adalah rasio 70:15:15 atau 80:10:10. Rasio ini dipilih untuk memastikan bahwa model memiliki cukup data untuk belajar dan diuji secara adil. Hal yang penting dalam pembagian ini adalah mempertahankan distribusi kelas yang proporsional di setiap *subset*, agar akurasi validasi dan pengujian mencerminkan performa sebenarnya dari model di lingkungan nyata (Bhuria, 2024).

2.4.3 Encoding Label dan Format Input

Dalam proses klasifikasi citra retina menggunakan *deep learning*, *encoding* label adalah langkah penting untuk mengadaptasi label kelas ke dalam format yang dapat diproses oleh model. Untuk tugas klasifikasi dua kelas seperti deteksi glaukoma (*non glaukoma* vs glaukoma), *binary encoding* umumnya digunakan, di mana label diberikan sebagai 0 untuk *non glaukoma* dan 1 untuk glaukoma. Sementara itu, untuk klasifikasi multi-kelas, label biasanya direpresentasikan dalam bentuk *one-hot encoding*, di mana setiap kelas dikodekan sebagai vektor biner dengan satu nilai “1” menunjukkan kelas aktif (Shah & Aamodt, 2023). Pendekatan ini memungkinkan jaringan saraf untuk menghitung probabilitas antar kelas secara eksplisit menggunakan fungsi aktivasi seperti *sigmoid* pada *layer output*.

Di sisi lain, citra retina yang digunakan sebagai *input* diproses menjadi *array* numerik, biasanya dalam format *NumPy array*. Setiap citra dikonversi dari format RGB ke tensor numerik yang memiliki dimensi *batch size, height, width, channels*, yang kemudian digunakan sebagai *input* untuk *framework deep learning* seperti *TensorFlow* atau *PyTorch*. *Framework* ini mengharuskan data diatur dalam *batch* untuk efisiensi pelatihan dan inferensi (Xu et al., 2021). Format *input* yang konsisten memudahkan pemrosesan paralel di GPU dan memungkinkan *training* yang lebih stabil.

Proses *encoding* dan format *input* yang tepat juga berpengaruh pada akurasi model akhir, terutama dalam aplikasi medis seperti klasifikasi penyakit retina. Penggunaan *encoding* yang optimal dapat mengurangi kesalahan prediksi dan meningkatkan *recall* deteksi kondisi minoritas seperti glaukoma, terutama dalam *dataset* dengan distribusi label yang tidak seimbang (Gould et al., 2024).

2.5 Machine Learning

Machine learning (ML) merupakan cabang dari kecerdasan buatan yang fokus pada pengembangan algoritma yang memungkinkan sistem komputer untuk belajar langsung dari data tanpa perlu diprogram secara eksplisit. Teknologi ini telah diterapkan secara luas dalam berbagai bidang, seperti analisis perilaku konsumen, prediksi penyakit, pengolahan data genomik, dan pengenalan pola dalam data berskala besar (Shaveta, 2023). ML menjadi komponen utama dalam komputasi *modern*, karena pendekatannya yang berbasis statistik memungkinkan sistem untuk menghasilkan keputusan secara otomatis berdasarkan pola yang dipelajari dari data (Kühl et al., 2022).

2.6 Deep Learning

Deep learning (DL) adalah cabang dari *machine learning* yang menggunakan jaringan saraf tiruan berlapis-lapis (*deep neural networks*) untuk memahami representasi data yang kompleks. Tidak seperti metode *machine learning* tradisional yang mengandalkan rekayasa fitur manual, DL secara otomatis

mengekstraksi fitur langsung dari data mentah, seperti gambar, teks, atau suara. Dengan kemampuannya membangun representasi hierarkis dari data, DL mampu mencapai kinerja unggul dalam berbagai tugas analitik dan klasifikasi. Studi terbaru oleh Hussain (2024) menegaskan bahwa arsitektur *deep learning*, seperti CNN, RNN, dan *autoencoder*, dapat secara efektif mengubah data mentah menjadi fitur berlapis yang optimal untuk tugas prediktif, tanpa intervensi manual dalam proses ekstraksi fitur (Hussain, 2024). Secara umum, struktur DL terdiri dari lapisan *input*, beberapa lapisan tersembunyi (*Hidden Layers*), dan lapisan *output* yang menghasilkan prediksi atau keputusan akhir.

2.6.1 Input Layer

Input layer merupakan tahap awal dalam arsitektur *deep learning* yang bertugas menerima data mentah dari luar sistem untuk diteruskan ke lapisan-lapisan berikutnya. Meskipun lapisan ini tidak melakukan proses perhitungan seperti lapisan tersembunyi, *input layer* memiliki peran penting dalam menyajikan data dalam bentuk representasi numerik yang dapat dikenali oleh jaringan, seperti vektor piksel dari gambar atau sinyal *digital* lainnya. Representasi awal ini sangat memengaruhi kualitas fitur yang diekstraksi di lapisan selanjutnya, sehingga berpengaruh langsung pada performa akhir model. Sebagai contoh, penelitian oleh Qiao et al. (2022) menunjukkan bagaimana desain *input* yang tepat dengan pemisahan berdasarkan frekuensi dapat meningkatkan efisiensi ekstraksi fitur dalam tugas seperti *image denoising* (Qiao et al., 2022).

2.6.2 Hidden Layer

Hidden layer merupakan pusat pemrosesan utama dalam jaringan *neural* yang berperan dalam mengekstraksi fitur serta mengenali pola dari data *input*. Lapisan ini terdiri dari sejumlah *neuron* yang menggunakan fungsi aktivasi *non-linear* untuk mengubah data mentah menjadi representasi yang lebih abstrak, sehingga jaringan dapat memahami hubungan yang kompleks dalam data (Bengio et al., 2007). Penambahan jumlah *hidden layer* dalam arsitektur *deep learning* dapat meningkatkan kemampuan jaringan dalam mengenali pola yang rumit, namun juga


berpotensi menambah beban komputasi serta risiko terjadinya masalah seperti *vanishing gradient*.

2.6.3 Output Layer

Output layer merupakan lapisan terakhir dalam jaringan *neural* yang bertugas menghasilkan prediksi akhir dari model berdasarkan hasil pemrosesan di *hidden layer*. Lapisan ini mengubah representasi *internal* yang kompleks menjadi bentuk yang dapat diinterpretasikan, seperti probabilitas dalam klasifikasi atau nilai kontinu dalam regresi. Pemilihan fungsi aktivasi pada *output layer* sangat bergantung pada jenis tugas yang dilakukan, fungsi *softmax* biasanya digunakan dalam klasifikasi multi-kelas untuk menghasilkan nilai probabilitas, sedangkan fungsi linear cocok untuk regresi. Studi oleh Ther et al. (2023) menekankan pentingnya efisiensi perhitungan fungsi aktivasi di lapisan *output*, terutama *softmax*, yang digunakan luas untuk klasifikasi dan sangat memengaruhi akurasi dan kecepatan inferensi model *deep learning* (Ther et al., 2023).

2.7 Convolutional Neural Network (CNN)

Convolutional Neural Networks (CNN) merupakan salah satu jenis arsitektur *deep learning* yang dirancang khusus untuk memproses data berpola *grid* seperti citra atau gambar. CNN memanfaatkan operasi konvolusi dan *pooling* untuk mengekstraksi fitur penting dari data *input*, dan telah menjadi pendekatan utama dalam tugas seperti klasifikasi gambar, deteksi objek, hingga pengenalan wajah. Jaringan ini terdiri dari beberapa lapisan konvolusional yang dapat mengenali pola dari tingkat sederhana hingga kompleks. Studi oleh Cai (2024) menunjukkan bahwa CNN mampu mencapai akurasi tinggi dalam klasifikasi gambar CIFAR-10 dengan penerapan teknik seperti augmentasi data dan *dropout* untuk meningkatkan performa model (Cai, 2024). Arsitektur CNN terdiri dari berbagai lapisan yang bekerja secara berurutan untuk mempelajari representasi data secara bertahap, yang dapat dilihat pada Gambar 2.



Gambar 2. Arsitektur CNN (Khan et al., 2018).

2.7.1 Lapisan Konvolusi

Lapisan konvolusi merupakan komponen utama dalam arsitektur *Convolutional Neural Network* (CNN) yang berfungsi untuk mengekstraksi fitur penting dari data citra melalui proses matematis yang disebut *convolution*. Proses ini dilakukan dengan mengalikan sebagian kecil dari citra (*local receptive field*) dengan filter atau *kernel*, kemudian menjumlahkannya untuk menghasilkan *feature map* yang merepresentasikan pola atau tepi tertentu pada citra *input* (Wang & Yang, 2020).

Setiap filter dalam lapisan konvolusi belajar untuk mengenali pola tertentu, seperti garis, tepi, atau tekstur. Dengan menumpuk beberapa lapisan konvolusi, jaringan mampu membangun representasi hierarkis dari fitur citra, mulai dari fitur sederhana di lapisan awal hingga fitur kompleks di lapisan yang lebih dalam (Handa et al., 2021).

2.7.2 Fungsi Aktivasi

Fungsi aktivasi adalah komponen vital dalam jaringan saraf tiruan yang berfungsi untuk mentransformasikan sinyal input menjadi sinyal output, yang kemudian diteruskan sebagai input ke lapisan berikutnya dalam arsitektur jaringan (Sharma et al., 2020). Fungsi aktivasi bekerja dengan mengubah nilai masukan (*weighted sum*) pada setiap *neuron* menjadi sinyal keluaran yang kemudian diteruskan ke lapisan berikutnya. Beberapa fungsi aktivasi yang umum digunakan antara lain *Sigmoid*, *Hyperbolic Tangent (tanh)*, dan *Rectified Linear Unit (ReLU)*. *Sigmoid* dan *tanh*

sering digunakan pada jaringan tradisional, sedangkan *ReLU* dan turunannya seperti Leaky *ReLU*, *ELU*, dan *Swish* lebih populer pada jaringan dalam (*deep neural networks*) karena mampu mengurangi masalah *vanishing gradient* dan mempercepat konvergensi (Feng & Lu, 2019; Florek & Miłosz, 2023).

2.7.2.1 Sigmoid

Fungsi aktivasi *sigmoid* merupakan fungsi *non-linear* yang umum digunakan dalam jaringan saraf tiruan (*Artificial Neural Networks*) untuk memetakan nilai *input* ke rentang antara 0 dan 1 dengan rumus Persamaan 1:

$$f(x) = \frac{1}{1+e^{-x}} \quad (1)$$

Fungsi ini memungkinkan model untuk menangkap hubungan *non-linear* antar data serta menjaga stabilitas nilai *output* selama proses pelatihan. Menurut Pratiwi et al. (2020) fungsi *sigmoid* terbukti efektif dalam meningkatkan akurasi model jaringan saraf pada data dengan pola yang kompleks, khususnya pada kasus prediksi berbasis klasifikasi.

Selain itu, penelitian oleh Kilian & Siegelmann (1996) menunjukkan bahwa fungsi *sigmoid* memiliki sifat *universal approximation*, yaitu kemampuan untuk mendekati berbagai fungsi *non-linear* dengan presisi tinggi. Hal ini menjadikan *sigmoid* salah satu fungsi dasar yang sangat penting dalam pembelajaran mesin, terutama pada jaringan saraf yang membutuhkan kemampuan representasi kompleks.

2.7.2.2 Hyperbolic Tangent

Fungsi aktivasi *Tanh* adalah jenis fungsi aktivasi yang dikembangkan dari fungsi *Sigmoid*. *Tanh* memetakan nilai input ke dalam rentang -1 hingga 1, yang membuatnya lebih cocok untuk data yang memiliki nilai positif dan negatif. Fungsi ini membantu dalam menormalkan distribusi data pada *hidden layer*, yang meningkatkan stabilitas dan efisiensi pelatihan. Seperti *Sigmoid*, *Tanh* juga

memiliki kelemahan berupa *vanishing gradient* pada nilai input yang ekstrim (Abdelouahab et al., 2017). Dalam penggunaannya, fungsi *Tanh* dituliskan menggunakan Persamaan 2.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2)$$

2.7.2.3 ReLU

Fungsi aktivasi *ReLU* digunakan untuk memperkenalkan non-linearitas ke dalam CNN dengan memetakan nilai negatif menjadi nol dan mempertahankan nilai positif. Fungsi ini membantu mengatasi masalah *vanishing gradient*, sehingga mempercepat proses pelatihan dan meningkatkan efisiensi model secara keseluruhan (Jiang & Cheng, 2019). Namun, *ReLU* memiliki kekurangan seperti masalah "*dying ReLU*", di mana neuron menjadi tidak aktif sepenuhnya jika output terus-menerus bernilai negatif selama pelatihan (Wang et al., 2020). Fungsi *ReLU* dituliskan dalam Persamaan 3.

$$f(x) = \max(0, x) \quad (3)$$

2.7.3 Lapisan Pooling

Lapisan *pooling* merupakan salah satu komponen penting dalam arsitektur *Convolutional Neural Network* (CNN) yang berfungsi untuk mengurangi dimensi spasial dari *feature map* hasil lapisan konvolusi. Proses ini dilakukan dengan cara mengambil nilai representatif (misalnya nilai maksimum atau rata-rata) dari setiap wilayah kecil pada *feature map*, yang menghasilkan peta fitur dengan resolusi lebih rendah namun tetap mempertahankan informasi penting (Gholamalinezhad & Khosravi, 2020).


Terdapat beberapa jenis teknik pooling yang umum digunakan, antara lain *max pooling*, *average pooling*, dan *stochastic pooling*. *Max pooling* memilih nilai maksimum dalam setiap area kecil, yang efektif dalam menonjolkan fitur dominan seperti tepi atau pola kuat. Sementara itu, *average pooling* menghitung rata-rata

nilai dalam area tersebut untuk mempertahankan informasi secara lebih halus (Galanis et al., 2022).

2.8 Xception

Xception (Extreme Inception) merupakan pengembangan dari arsitektur *Inception* yang mengganti konvolusi standar dengan *depthwise separable convolution*, yaitu pemisahan antara proses konvolusi spasial dan *channel-wise*. Studi oleh Sumitha & Gokila (2023) menunjukkan bahwa *Xception* mampu mendeteksi penyakit berbasis citra retina dengan akurasi tinggi walau parameter lebih sedikit.

Selain itu, keunggulan utama dari arsitektur *Xception* adalah kemampuannya mencapai kinerja tinggi dengan jumlah parameter yang relatif lebih sedikit dibandingkan model konvolusi standar, sehingga lebih hemat sumber daya komputasi dan cocok digunakan dalam berbagai aplikasi medis yang memerlukan kecepatan dan akurasi tinggi, arsitektur *Xception* dapat dilihat pada Gambar 3.




Gambar 3. Arsitektur *Xception* (Abunasser et al., 2022).

2.9 Inception-ResNetV2

Inception-ResNetV2 adalah arsitektur yang menggabungkan dua modul Inception (untuk multi-skala *feature extraction*) dan *Residual connections* dari *ResNet* (untuk mengatasi masalah *vanishing gradient*). Model ini terbukti unggul dalam banyak kompetisi klasifikasi gambar medis, dengan akurasi yang konsisten tinggi

(Varghese & Pandian, 2023). Arsitektur ini memiliki desain yang lebih efisien dibandingkan jaringan konvolusional konvensional karena modul Inception dapat menangkap informasi lokal dan global secara bersamaan, sementara residual *connections* memastikan gradien tetap mengalir dengan baik di seluruh lapisan. Keunggulan ini membuat Inception-ResNetV2 menjadi salah satu model yang banyak digunakan dalam berbagai kompetisi maupun penelitian, khususnya dalam bidang analisis citra medis, arsitektur Inception-ResNet V2 dapat dilihat pada Gambar 4.




Gambar 4. Arsitektur *Inception-ResNet V2* (Hindarto, 2023).

2.10 ConvNeXt

ConvNeXt adalah arsitektur CNN *modern* yang dirancang untuk menyaingi performa model *Vision Transformer* (ViT) dengan tetap menggunakan prinsip dasar CNN. *ConvNeXt* menunjukkan keunggulan dalam klasifikasi citra medis dan mendekati performa *transformer* (Panthakkan et al., 2023), namun aplikasinya pada glaukoma masih relatif baru. Keunggulan lainnya adalah stabilitas pelatihan yang lebih konsisten dan kemampuannya menangani *dataset* berskala besar tanpa kehilangan efisiensi. Walaupun aplikasinya pada kasus glaukoma masih relatif baru dan belum banyak dieksplorasi, potensi *ConvNeXt* sangat besar karena mampu menggabungkan kekuatan CNN tradisional dengan inovasi dari ViT (*Vision Transformer*). Hal ini menjadikannya sebagai kandidat arsitektur *modern* yang menjanjikan untuk dikembangkan lebih lanjut dalam sistem diagnosis berbantuan

komputer, khususnya dalam mendeteksi penyakit mata berbasis citra retina, arsitektur *ConvNeXt* dapat dilihat pada Gambar 5.



Gambar 5. Arsitektur *ConvNeXt* (Mustapha & Ozsahin, 2025).

2.11 Augmentasi Data

Augmentasi data merupakan metode dalam pemrosesan data yang digunakan untuk memperbanyak dan memperkaya variasi data pelatihan dengan cara menerapkan berbagai transformasi terhadap data asli. Teknik ini sangat umum digunakan dalam bidang *computer vision*, khususnya untuk mengatasi keterbatasan data dan mengurangi risiko *overfitting* pada model *deep learning*. Transformasi yang diterapkan dapat berupa rotasi, *flipping* (pencerminan), *cropping*, atau penyesuaian kecerahan gambar, tanpa mengubah makna dasar dari citra tersebut (Kebaili et al., 2023).

Tujuan utama dari augmentasi data adalah untuk meningkatkan generalisasi model dengan memperkenalkan variasi buatan agar model lebih tahan terhadap perubahan kondisi *input* saat diuji dengan data baru. Teknik ini juga membantu mengatasi ketimpangan kelas (*class imbalance*) dan sangat berguna saat pengumpulan data tambahan sulit atau mahal. Selain itu, kebaruan pendekatan menggunakan *generative* model seperti GAN, VAE, atau *diffusion* model telah memungkinkan terciptanya data sintetis yang lebih realistis dan bervariasi dalam bidang citra medis (Kebaili *et al.*, 2023).

2.12 Early Stopping

Early stopping merupakan teknik regulasi yang umum digunakan dalam pelatihan model *deep learning* untuk mencegah *overfitting*. Teknik ini bekerja dengan cara menghentikan proses pelatihan secara otomatis ketika performa model pada data validasi tidak menunjukkan perbaikan dalam sejumlah iterasi tertentu. Dengan demikian, *early stopping* dapat membantu menjaga keseimbangan antara akurasi model pada data pelatihan dan kemampuan generalisasi pada data baru. Penelitian menunjukkan bahwa *early stopping* efektif untuk mencegah model terlalu menyesuaikan diri dengan *noise* atau pola yang tidak representatif dalam data pelatihan, sehingga dapat meningkatkan performa keseluruhan model pada data yang belum pernah dilihat sebelumnya (Hussein & Shareef, 2024). Selain itu, studi lain mengonfirmasi bahwa jika waktu pelatihan menjadi pertimbangan, *early stopping* merupakan salah satu metode paling efisien dalam mencegah *overfitting* dibandingkan teknik regulasi lainnya seperti L1/L2 atau *dropout* (Rezaeezade & Batina, 2024).

2.13 Confusion Matrix

Confusion matrix merupakan sebuah tabel yang digunakan untuk menilai performa model klasifikasi dengan membandingkan hasil prediksi model terhadap label sebenarnya pada data uji. Tabel ini terdiri dari empat komponen utama yang menggambarkan jumlah prediksi benar dan salah untuk masing-masing kelas.

1. *True Positive* (TP): Prediksi positif yang benar.

2. *False Negative* (FP): Prediksi positif yang salah (*Type I Error*).
3. *True Negative* (TN): Prediksi negatif yang benar.
4. *False Negative* (FN): Prediksi negatif yang salah (*Type II Error*).

2.13.1 Akurasi

Akurasi merupakan salah satu metrik evaluasi yang menunjukkan seberapa banyak prediksi model yang benar dibandingkan dengan seluruh jumlah prediksi yang dilakukan. Metrik ini menggambarkan persentase data yang berhasil diklasifikasikan secara tepat, baik dalam kategori positif maupun negatif. Akurasi dihitung menggunakan Persamaan 4.

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

Meskipun akurasi merupakan metrik evaluasi yang mudah dipahami dan sering digunakan, metrik ini memiliki keterbatasan dalam konteks *dataset* yang tidak seimbang. Dalam situasi seperti ini, sebuah model dapat terlihat memiliki performa tinggi hanya dengan mendominasi prediksi pada kelas mayoritas, tanpa benar-benar memahami atau memprediksi dengan baik kelas minoritas. Hal ini menyebabkan akurasi memberikan gambaran yang menyesatkan terhadap kinerja sebenarnya dari model. Penelitian oleh Farhadpour et al. (2024) menegaskan bahwa akurasi, termasuk bentuk turunannya seperti *micro-averaged f1-score* dan *dice loss*, cenderung tidak tepat untuk digunakan dalam skenario data yang tidak seimbang karena memberikan bias terhadap kelas dominan dan mengaburkan kegagalan model dalam mengenali kelas minoritas (Farhadpour et al., 2024).

2.13.2 Presisi

Presisi adalah metrik evaluasi yang mengukur proporsi dari prediksi positif yang benar-benar merupakan kasus positif. Dengan kata lain, presisi menunjukkan seberapa andal model dalam menghindari kesalahan dalam memprediksi kelas positif. Presisi yang tinggi berarti bahwa sebagian besar prediksi positif yang dibuat oleh model adalah benar. Dalam penelitian terbaru, Tripathi et al. (2023) menunjukkan bahwa model *machine learning* yang digunakan untuk klasifikasi

subtipe kanker payudara mencapai presisi hingga 98,61%, yang menunjukkan efektivitas tinggi dalam menghindari prediksi positif yang salah, khususnya pada data medis yang sangat sensitif terhadap kesalahan klasifikasi (Tripathi et al., 2023). Perhitungan presisi menggunakan Persamaan 5.

$$Presisi = \frac{TP}{TP+FP} \quad (5)$$

2.13.3 Recall

Recall atau dikenal juga sebagai *true positive rate*, adalah metrik yang mengukur seberapa baik suatu model dalam mengenali data yang termasuk dalam kategori positif atau benar-benar memiliki kondisi tertentu. Untuk menghitung *recall* dapat menggunakan rumus seperti Persamaan 6.

$$Recall = \frac{TP}{TP+FN} \quad (6)$$

2.13.4 F1-score

F1-score merupakan metrik evaluasi yang menggabungkan presisi dan *recall* ke dalam satu nilai menggunakan rata-rata harmonik. Metrik ini sangat berguna pada *dataset* yang tidak seimbang, karena mampu memberikan keseimbangan antara kemampuan model dalam mengidentifikasi kelas positif secara akurat (presisi) dan mendeteksi semua kasus positif yang ada (*recall*). Riyanto et al. (2023) menekankan bahwa dalam klasifikasi data yang tidak seimbang, *f1-score* menjadi metrik yang paling representatif dibandingkan akurasi, karena mampu memberikan gambaran yang lebih adil terhadap performa model pada kelas minoritas (Riyanto et al., 2023). Untuk menghitung *f1-score* dapat menggunakan rumus seperti Persamaan 7.

$$F1 - score = 2 \times \frac{Recall \times Presisi}{Recall + Presisi} \quad (7)$$

2.14 *Underfitting*

Underfitting adalah kondisi ketika model pembelajaran mesin gagal menangkap pola penting dalam data karena terlalu sederhana atau tidak cukup dilatih. Akibatnya, model memiliki akurasi rendah baik pada data pelatihan maupun pengujian. Hal ini sering disebabkan oleh arsitektur model yang terlalu dangkal, jumlah *epoch* yang terlalu sedikit, atau fitur yang kurang representatif (Li et al., 2021).

2.15 *Overfitting*

Overfitting adalah kondisi ketika model mempelajari data pelatihan secara terlalu mendetail, termasuk *noise* atau pola yang tidak relevan, sehingga performanya menurun drastis ketika dihadapkan pada data baru. Hal ini umumnya terjadi pada model yang terlalu kompleks atau dilatih dengan data terbatas. Ciri khas *overfitting* adalah akurasi tinggi pada data pelatihan, namun rendah pada data validasi. Beberapa teknik umum untuk mengatasi *overfitting* meliputi *dropout*, regularisasi L1/L2, dan *early stopping*. Studi oleh Rezaeezade & Batina (2024) menunjukkan bahwa L1 dan L2 regularisasi efektif dalam meningkatkan kinerja model, sementara *early stopping* terbukti paling efisien dalam menghemat waktu pelatihan tanpa mengorbankan akurasi (Rezaeezade & Batina, 2024). Selain itu, pendekatan berbasis histori validasi seperti yang diajukan oleh Li et al. (2024) mampu menghentikan pelatihan lebih cepat dari metode *early stopping* konvensional, sekaligus menjaga kualitas model (Li et al., 2024).

III. METODOLOGI PENELITIAN

3.1 Tempat dan Waktu Penelitian

Penjelasan mengenai tempat dan waktu penelitian adalah sebagai berikut.

3.1.1 Tempat Penelitian

Penelitian dilaksanakan di Gedung Ilmu Komputer (GIK), Jurusan Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung yang beralamat di Jalan Prof. Dr. Soemantri Brodjonegoro No.1, Gedung Meneng, Kota Bandar Lampung, Lampung 35144.

3.1.2 Waktu Penelitian

Penelitian ini dilaksanakan pada semester genap tahun akademik 2025/2026, yang berlangsung mulai dari bulan Februari 2025 hingga September 2025. Dalam kurun waktu tersebut, seluruh rangkaian kegiatan penelitian direncanakan dan dilaksanakan secara bertahap serta terstruktur, mulai dari tahap pengumpulan data, *pre-processing* citra, pembagian *dataset*, proses augmentasi, hingga pelatihan dan evaluasi model. Setiap tahap memiliki jadwal pelaksanaan yang saling berkaitan agar penelitian dapat berjalan secara sistematis dan mencapai tujuan yang telah ditetapkan. Perencanaan waktu yang matang ini juga dimaksudkan untuk meminimalkan risiko keterlambatan dalam penyelesaian penelitian. Dengan adanya pembagian waktu yang jelas, diharapkan seluruh proses dapat terkontrol dengan baik dan hasil penelitian dapat diperoleh sesuai target yang direncanakan.


3.2 Data dan Perangkat Penelitian

3.2.1 Data

Dataset yang digunakan dalam penelitian ini diperoleh dari penelitian Diaz-Pinto et al. (2019). Data ini terdiri dari 705 data yang terbagi menjadi 396 glaukoma dan 309 *non* glaukoma. Namun, klasifikasi citra retina untuk mendeteksi glaukoma memiliki tantangan tersendiri, terutama karena variasi warna, resolusi, dan pencahayaan dalam gambar fundus mata yang dapat mempengaruhi akurasi analisis (Puchaicela-Lozano et al., 2023).

Ukuran asli gambar dalam *dataset* ini memiliki resolusi yang cukup bervariasi, yaitu mulai dari 178×178 piksel hingga 1420×1420 piksel. Variasi ini mencerminkan perbedaan signifikan dalam kualitas dan ukuran *file* gambar yang tersedia dalam *dataset*, yang dapat memengaruhi proses pelatihan model *deep learning*. Perbedaan resolusi ini perlu diperhatikan dalam tahap *preprocessing*, karena model konvolusional biasanya mengharuskan semua *input* gambar memiliki ukuran yang seragam. Oleh karena itu, proses normalisasi ukuran gambar menjadi langkah penting untuk memastikan konsistensi dan efisiensi selama pelatihan.

Dataset ACRIMA merupakan himpunan data citra fundus mata yang secara khusus dilabeli untuk mendeteksi penyakit glaukoma. *Dataset* ini berasal dari proyek ACRIMA (TIN2013-46751-R) yang didanai oleh *Ministerio de Economía y Competitividad* Spanyol dengan tujuan mengembangkan algoritma otomatis untuk pemeriksaan penyakit retina. ACRIMA terdiri dari 705 citra fundus, mencakup 396 citra dengan glaukoma dan 309 *non* glaukoma. Pengambilan gambar dilakukan menggunakan kamera retina *Topcon* TRC dan sistem *ImageNet Capture* dengan sudut pandang 35°, difokuskan pada area *disc optic* setelah dilatasi mata. Seleksi pasien dan *labeling* citra dilakukan oleh para ahli berdasarkan temuan klinis, sementara citra yang memiliki artefak, *noise*, atau kontras rendah telah dikeluarkan dari *dataset* untuk menjaga kualitas data. Rasio jumlah gambar per kelas dapat dilihat pada Gambar 6.



Gambar 6. Rasio Jumlah Gambar per Kelas.

3.2.2 Perangkat Penelitian

Berikut perangkat yang digunakan dalam penelitian ini:

1. Perangkat Keras (*Hardware*)

Perangkat keras berupa laptop yang digunakan dengan spesifikasi:

- a. Merk : Acer
- b. Model: Nitro 5
- c. *CPU* : AMD Ryzen 7 5800H
- d. *GPU* : NVIDIA GEFORCE RTX 3060 Laptop GPU
- e. Ram : 16GB

2. Perangkat Lunak

Perangkat lunak yang digunakan dalam penelitian ini:

- a. Sistem operasi *Windows* 11 64-bit versi 23H2
- b. Python 3.10.12

Python adalah bahasa pemrograman tingkat tinggi yang serbaguna, mudah dipelajari, dan banyak digunakan di berbagai bidang teknologi. Dengan tujuan untuk membuat bahasa pemrograman yang sederhana, efisien, dan mudah dibaca oleh manusia.

c. *Library TensorFlow* 2.17.1

TensorFlow adalah *library open-source* yang dikembangkan oleh *google* untuk memfasilitasi pengembangan dan pelatihan model pembelajaran mesin (*machine learning*) dan *deep learning*. *TensorFlow* dirancang untuk

bekerja pada berbagai perangkat, dari CPU, GPU, hingga TPU (*Tensor Processing Unit*), sehingga memungkinkan pengolahan data skala besar dengan performa tinggi.

d. *Library* Matplotlib 3.8.0

Matplotlib adalah sebuah *library* yang komprehensif untuk membuat visualisasi statis, animasi, dan interaktif dalam Python.

e. *Library* Scikit-learn 1.6.0

Scikit-learn adalah perpustakaan pembelajaran mesin sumber terbuka yang mendukung pembelajaran yang diawasi dan tidak diawasi. *Scikit-learn* juga menyediakan berbagai alat untuk penyesuaian model, prapemrosesan data, pemilihan model, evaluasi model, dan banyak utilitas lainnya.


f. *Roboflow*

Roboflow adalah sebuah *platform* yang dirancang untuk mempermudah proses pengembangan model *computer vision*, terutama dalam hal pengelolaan data, pelabelan (*labeling*), pelatihan model (*training*), dan *deployment*.

3.3 Tahap Penelitian

Penelitian ini akan melalui beberapa tahapan, mulai dari tahap pengumpulan data, pra-pemrosesan data, augmentasi data, pembagian *dataset*, perancangan model, hingga tahap evaluasi atau pengujian model. Tahapan penelitian ini diawali dengan pengumpulan data citra retina, kemudian dilakukan *pre-processing* berupa *resize* dan *preprocess_function* agar data siap digunakan. Setelah itu, data dibagi menjadi tiga bagian, yaitu data latih (80%), data validasi (10%), dan data uji (10%). Selanjutnya, pada data latih dilakukan proses augmentasi data untuk meningkatkan variasi citra dan memperkaya *dataset*, sehingga model dapat lebih *robust* terhadap perbedaan kondisi *input*. Setelah itu, dilakukan tahap pembuatan dan pelatihan model dengan menggunakan tiga arsitektur CNN *modern*, yaitu Xception, Inception-ResNet V2, dan ConvNeXt. Model dilatih dengan memanfaatkan data latih dan divalidasi menggunakan data validasi untuk memantau kinerja selama proses pelatihan. Terakhir, dilakukan pengujian dan evaluasi pada data uji untuk

menilai performa model menggunakan metrik evaluasi seperti akurasi, presisi, *recall*, dan *f1-score*. Tahapan selengkapnya dapat dilihat di Gambar 7.



Gambar 7. Tahap Penelitian (Puchaicela-Lozano et al., 2023).

3.3.1 Pengumpulan Data

Tahapan pertama pada penelitian ini adalah melakukan pengumpulan data. Pengumpulan data dilakukan dengan mengambil *dataset* dari *Figshare* yang telah digunakan oleh penelitian sebelumnya (Puchaicela-Lozano et al., 2023). *Dataset* tersebut terdiri dari 705 gambar yang terbagi menjadi 2 kelas yaitu glaukoma dan *non glaukoma* mencakup 396 citra dengan glaukoma dan 309 *non glaukoma*. *Dataset* dapat diakses di platform *figshare* dengan URL https://figshare.com/articles/dataset/CNNs_for_Automatic_Glaucoma_Assessment_using_Fundus_Images_An_Extensive_Validation/7613135.

3.3.2 Pre-Processing

Pre-processing merupakan tahap krusial yang bertujuan untuk meningkatkan kualitas *dataset* serta menunjang efisiensi dan efektivitas selama pelatihan model. Pada tahap ini, dilakukan berbagai prosedur, seperti mengubah dimensi gambar menjadi 299×299 piksel dan menggunakan fungsi *preprocess_function* dari *Roboflow* untuk pemrosesan data lanjutan.

3.3.3 Pembagian Data

Setelah melalui proses *pre-processing*, *dataset* kemudian dibagi menjadi tiga bagian: data latih, data uji, dan data validasi.

a. Data Latih

Digunakan dalam tahap pelatihan model, data latih diambil secara acak dari *dataset* keseluruhan dan mencakup 80% dari total data yaitu sebanyak 594 gambar.

b. Data Uji

Berfungsi untuk mengukur kinerja model setelah pelatihan selesai, dengan alokasi sebesar 10% dari seluruh *dataset* yaitu sebanyak 71 gambar.

c. Data Validasi

Digunakan selama pelatihan untuk memantau performa model di setiap iterasi serta mencegah terjadinya *overfitting*. Dalam penelitian ini, data validasi mencakup 10% dari total data yang tersedia yaitu sebanyak 70 gambar.

3.3.4 Augmentasi Data

Proses augmentasi data diterapkan pada data latih dengan tujuan menambah variasi serta jumlah data pelatihan. Teknik ini diharapkan dapat membantu model mengurangi risiko *overfitting*. Dalam penelitian ini, augmentasi dilakukan menggunakan *flip*, *crop*, *rotation* yang tersedia di *Roboflow*. Sebanyak 564 gambar pada data latih digunakan untuk proses augmentasi, yang terdiri dari 315 gambar kelas glaukoma dan 249 gambar kelas *non-glaukoma*.

3.3.5 Pembuatan Model

Proses pelatihan model dalam penelitian ini memanfaatkan arsitektur *Xception*, *Inception-ResNetV2*, dan *ConvNeXt*, dengan jumlah data pelatihan sebanyak 705 sampel. Selama pelatihan, digunakan sejumlah *hyperparameter* tertentu untuk mengoptimalkan kinerja model. Rincian *hyperparameter* yang digunakan dapat dilihat pada Tabel 2 untuk *hyperparameter* model.

Tabel 2. *Hyperparameter* Model

Parameter	Value		
	<i>Xception</i>	<i>Inception Resnet V2</i>	<i>Convnext</i>
<i>input_shape</i>	299×299	299×299	224×224
<i>batch_size</i>		16, 32, 64	
<i>epoch</i>		20, 30, 50	
<i>learning_rate</i>		0,0001	

3.3.6 Pengujian dan Evaluasi

Evaluasi model dilakukan dengan menggunakan *confusion matrix*, yang berfungsi untuk menghitung berbagai metrik evaluasi seperti akurasi, presisi, *recall*, dan *f1-score*. *Confusion matrix* memberikan informasi rinci mengenai hasil prediksi selama proses evaluasi, sehingga dapat memberikan gambaran menyeluruh terhadap kinerja model yang telah dibangun.

V. SIMPULAN DAN SARAN

5.1 Simpulan

Berdasarkan rangkaian penelitian dan analisis yang telah dilakukan, dapat diperoleh simpulan sebagai berikut:

1. Performa arsitektur Xception, Inception-ResNetV2, dan *ConvNeXt* dalam mendeteksi glaukoma menggunakan citra retina menunjukkan hasil yang cukup baik namun dengan karakteristik berbeda. Xception mampu memberikan akurasi tinggi serta *recall* yang baik terhadap kasus glaukoma, walaupun masih terdapat beberapa kesalahan pada klasifikasi *non-glaukoma*. Inception-ResNetV2 memperlihatkan performa yang lebih fluktuatif dengan kecenderungan menghasilkan lebih banyak *false positive*, sehingga presisinya lebih rendah meskipun *recall* cukup baik. Sementara itu, *ConvNeXt* tampil paling stabil dengan akurasi tinggi, *recall* yang konsisten, serta keseimbangan metrik evaluasi pada kedua kelas, sehingga memberikan hasil klasifikasi yang lebih handal.
2. Jika dibandingkan dari segi akurasi, presisi, *recall*, dan *f1-score*, *ConvNeXt* menunjukkan hasil yang lebih unggul dibandingkan Xception dan Inception-ResNetV2. Pada evaluasi tanpa *early stopping*, *ConvNeXt* memiliki akurasi tertinggi yaitu 0.9714, dengan presisi dan *recall* yang seimbang (0.96–1.00) sehingga menghasilkan *f1-score* yang sangat tinggi (0.96–0.98). Hal ini menunjukkan bahwa *ConvNeXt* mampu mengenali kedua kelas dengan baik dan konsisten. Sementara itu, Xception dan Inception ResNet V2 memiliki akurasi yang sama yaitu 0.9143, tetapi keduanya menunjukkan nilai *recall* yang lebih rendah pada kelas *non-glaukoma* (0.83), sehingga *f1-score* juga lebih

rendah (0.87). Setelah diterapkan *early stopping*, performa *Xception* tetap stabil dengan akurasi yang sama, sedangkan *Inception ResNet V2* mengalami penurunan akurasi menjadi 0.8857 serta penurunan presisi, *recall*, dan *f1-score* pada kelas *non-glaukoma*. Sebaliknya, *ConvNeXt* tetap menjadi arsitektur dengan kinerja terbaik dengan akurasi 0.9571, presisi dan *recall* yang tinggi, serta *f1-score* yang tetap unggul.

3. Model yang paling optimal untuk digunakan dalam diagnosis dini glaukoma adalah *ConvNeXt*. Keunggulan model ini terletak pada kemampuannya mendeteksi hampir semua kasus glaukoma dengan nilai *recall* yang sangat tinggi, sekaligus menjaga tingkat *precision* yang baik agar kesalahan klasifikasi tetap rendah. Dengan kombinasi akurasi, presisi, *recall*, dan *f1-score* yang lebih seimbang, *ConvNeXt* dinilai lebih layak dijadikan arsitektur utama dalam sistem klasifikasi citra retina untuk mendukung diagnosis dini glaukoma secara otomatis.

5.2 Saran

Dalam pengembangan penelitian di masa mendatang, terdapat sejumlah rekomendasi yang dapat dijadikan pertimbangan:

1. Disarankan agar dilakukan optimasi khusus guna meningkatkan *precision*, misalnya dengan menambahkan data latih non-glaukoma, menerapkan teknik regularisasi yang lebih kuat. Langkah ini bertujuan agar kesalahan diagnosis pada pasien sehat dapat diminimalisasi sehingga hasil klasifikasi menjadi lebih akurat dan dapat diandalkan.
2. Model yang telah dikembangkan dan dilatih dapat diimplementasikan ke dalam sistem berbasis aplikasi web atau perangkat *mobile* untuk membantu dokter umum atau tenaga kesehatan non-spesialis dalam melakukan skrining dini penyakit glaukoma, terutama di daerah dengan keterbatasan akses terhadap dokter mata.
3. Arsitektur seperti *EfficientNetV2*, *Swin Transformer*, atau *Vision Transformer* (ViT) dapat dijadikan alternatif untuk dibandingkan karena model-model ini telah menunjukkan performa tinggi dalam klasifikasi citra medis. Kombinasi

model atau teknik *ensemble* juga dapat dievaluasi untuk meningkatkan akurasi lebih lanjut.

DAFTAR PUSTAKA

- Abdelouahab, K., Pelcat, M., & Berry, F. (2017). PhD forum: Why TanH is a hardware friendly activation function for CNNs. *ACM International Conference Proceeding Series, Part F1322*, 199–201. <https://doi.org/10.1145/3131885.3131937>
- Abdullah, A. A., Aldhahab, A., & Al Abboodi, H. M. (2024). Review of Eye Diseases Detection and Classification Using Deep Learning Techniques. *BIO Web of Conferences*, 97, 00012. <https://doi.org/10.1051/bioconf/20249700012>
- Abunasser, B. S., AL-Hiealy, M. R. J., Zaqout, I. S., & Abu-Naser, S. S. (2022). Breast Cancer Detection and Classification using Deep Learning Xception Algorithm. *International Journal of Advanced Computer Science and Applications*, 13(7). <https://doi.org/10.14569/IJACSA.2022.0130729>
- Aguilar, K., Cavalcante, V., Carvalho, C., Sabino, W., & Oliveira, M. (2024). Automatic Glaucoma Classification and Feature Detection for the Jstraigs Challenge. *2024 IEEE International Symposium on Biomedical Imaging (ISBI)*, 1–4. <https://doi.org/10.1109/ISBI56570.2024.10635775>
- Ajitha, S., Akkara, J. D., & Judy, M. V. (2021). Identification of glaucoma from fundus images using deep learning techniques. *Indian Journal of Ophthalmology*, 69(10), 2702–2709. https://doi.org/10.4103/ijo.IJO_92_21
- Alotaibi, B., & Alotaibi, M. (2020). A Hybrid Deep ResNet and Inception Model for Hyperspectral Image Classification. *PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 88(6), 463–476. <https://doi.org/10.1007/s41064-020-00124-x>
- Bengio, Y., Lamblin, P., Popovici, D., & Larochelle, H. (2007). *Greedy Layer-Wise Training of Deep Networks*. In *Advances in Neural Information Processing Systems 19* (pp. 153–160). The MIT Press. <https://doi.org/10.7551/mitpress/7503.003.0024>
- Bhattacharya, R., Hussain, R., Chatterjee, A., Paul, D., Chatterjee, S., & Dey, D. (2023). PY-Net: Rethinking segmentation frameworks with dense pyramidal operations for optic disc and cup segmentation from retinal fundus images. *Biomedical Signal Processing and Control*, 85, 104895. <https://doi.org/10.1016/j.bspc.2023.104895>

- Bhuria, R. (2024). Automated Glaucoma Detection from Retinal Fundus Images: Leveraging EfficientNetV2 for Enhanced Diagnostic Accuracy. *2024 9th International Conference on Communication and Electronics Systems (ICCES)*, 1442–1448. <https://doi.org/10.1109/ICCES63552.2024.10859519>
- Bruntha, P. M., S, I. T. J., S, S., Narmadha, D., Subramanian, S., & Sundar, G. N. (2024). Glaucoma Prediction Using Deep Learning Techniques - A Comparative Study. *2024 1st International Conference on Cognitive, Green and Ubiquitous Computing (IC-CGU)*, 1–5. <https://doi.org/10.1109/IC-CGU58078.2024.10530743>
- Cai, G. (2024). Advanced Image Classification Using Convolutional Neural Networks. *Science and Technology of Engineering, Chemistry and Environmental Protection*, 1(9). <https://doi.org/10.61173/117trk02>
- Castellanos-Perilla, N., Garcia-Cifuentes, E., Pineda-Ortega, J., Lema, S., Gelvis, G., Cano-Gutierrez, C. A., & Mejia-Vergara, A. J. (2023). Self-reported glaucoma prevalence and related factors, contribution to reported visual impairment, and functional burden in a cross-sectional study in Colombia. *International Ophthalmology*, 43(7), 2447–2455. <https://doi.org/10.1007/s10792-023-02643-z>
- Chen, T.-C., Lim, W. S., Wang, V. Y., Ko, M.-L., Chiu, S.-I., Huang, Y.-S., Lai, F., Yang, C.-M., Hu, F.-R., Jang, J.-S. R., & Yang, C.-H. (2021). Artificial Intelligence–Assisted Early Detection of Retinitis Pigmentosa — the Most Common Inherited Retinal Degeneration. *Journal of Digital Imaging*, 34(4), 948–958. <https://doi.org/10.1007/s10278-021-00479-6>
- Chen, W., Xu, Y., Liu, Z., & Zhao, J. (2024). Global, regional and national burden of Glaucoma: an update analysis from the Global Burden of Disease Study 2019. *International Ophthalmology*, 44(1), 234. <https://doi.org/10.1007/s10792-024-03222-6>
- Cifuentes-González, C., Rojas-Carabali, W., Mejía Salgado, G., Pineda-Sierra, J. S., Polania, D., Garzón-Dangond, J. M., Orozco, J. S., Soto-Ariño, J., Lesley-Cruz, D., & de-la-Torre, A. (2024). Colombian ocular diseases epidemiology study (CODES): glaucoma incidence and sociodemographic characterisation 2015–2020. *Clinical and Experimental Optometry*, 1–7. <https://doi.org/10.1080/08164622.2024.2377386>
- Das, S., Mishra, M., & Majumder, S. (2024). Identification of Glaucoma from Retinal Fundus Images using Deep Learning Model, MobileNet. *ECTI Transactions on Computer and Information Technology (ECTI-CIT)*, 18(3), 371–380. <https://doi.org/10.37936/ecti-cit.2024183.256182>
- Deepika, E., & Maheswari, S. (2018). Earlier glaucoma detection using blood vessel segmentation and classification. *2018 2nd International Conference on Inventive Systems and Control (ICISC)*, 484–490. <https://doi.org/10.1109/ICISC.2018.8399120>
- Diaz-Pinto, A., Morales, S., Naranjo, V., Köhler, T., Mossi, J. M., & Navea, A. (2019). CNNs for Automatic Glaucoma Assessment using Fundus Images: An Extensive Validation. <https://doi.org/10.6084/m9.figshare.7613135.v1>

- Duraisamy, A., & Suganthi, M. (2021). Glaucoma based detection of cup to disc ratio from retinal fundus image: an image processing technique. *Journal of Electrical Engineering*, 21(3), 180–187. <https://doi.org/10.59168/QKPN7128>
- Ehrlich, J. R., Burke-Conte, Z., Wittenborn, J. S., Saaddine, J., Omura, J. D., Friedman, D. S., Flaxman, A. D., & Rein, D. B. (2024). Prevalence of Glaucoma Among US Adults in 2022. *JAMA Ophthalmology*, 142(11), 1046. <https://doi.org/10.1001/jamaophthalmol.2024.3884>
- Elmoufidi, A., El Hossi, A., & Nachaoui, M. (2023). Machine learning for glaucoma detection using fundus images. *Research on Biomedical Engineering*, 39(4), 819–831. <https://doi.org/10.1007/s42600-023-00305-8>
- Farhadpour, S., Warner, T. A., & Maxwell, A. E. (2024). Selecting and Interpreting Multiclass Loss and Accuracy Assessment Metrics for Classifications with Class Imbalance: Guidance and Best Practices. *Remote Sensing*, 16(3), 533. <https://doi.org/10.3390/rs16030533>
- Feng, J., & Lu, S. (2019). Performance Analysis of Various Activation Functions in Artificial Neural Networks. *Journal of Physics: Conference Series*, 1237(2), 022030. <https://doi.org/10.1088/1742-6596/1237/2/022030>
- Florek, D., & Miłosz, M. (2023). Comparison of an effectiveness of artificial neural networks for various activation functions. *Journal of Computer Sciences Institute*, 26, 7–12. <https://doi.org/10.35784/jcsi.3069>
- George, R., Panda, S., & Vijaya, L. (2022). Blindness in glaucoma: primary open-angle glaucoma versus primary angle-closure glaucoma—a meta-analysis. *Eye*, 36(11), 2099–2105. <https://doi.org/10.1038/s41433-021-01802-9>
- Gould, D. S. W., Yang, J., & Clifton, D. A. (2024). *Deep Learning for Multi-Label Disease Classification of Retinal Images: Insights from Brazilian Data for AI Development in Lower-Middle Income Countries*. <https://doi.org/10.1101/2024.02.12.24302676>
- Guedes, R. A. P. (2021). Glaucoma, collective health and social impact. *Revista Brasileira de Oftalmologia*, 80(1). <https://doi.org/10.5935/0034-7280.20210001>
- Hindarto, D. (2023). Battle Models: Inception ResNet vs. Extreme Inception for Marine Fish Object Detection. *Sinkron*, 8(4), 2819–2826. <https://doi.org/10.33395/sinkron.v8i4.13130>
- Hussain, N. Y. (2024). Deep Learning Architectures Enabling Sophisticated Feature Extraction and Representation for Complex Data Analysis. *International Journal of Innovative Science and Research Technology (IJISRT)*, 2290–2300. <https://doi.org/10.38124/ijisrt/IJISRT24OCT1521>
- Hussein, B. M., & Shareef, S. M. (2024). An Empirical Study on the Correlation between Early Stopping Patience and Epochs in Deep Learning. *ITM Web of Conferences*, 64, 01003. <https://doi.org/10.1051/itmconf/20246401003>

- Inayat, H., Abdul-Nabi, M., Leung, B., Jiang, J., Robertson, S., & Malvankar-Mehta, M. S. (2024). Detrimental impact on work productivity in patients with glaucoma: a systematic review. *JFO Open Ophthalmology*, 8, 100142. <https://doi.org/10.1016/j.jfop.2024.100142>
- Jain, S. T. D., & Panneer, D. L. (2024). Glaucoma detection based on fundus images using machine learning techniques. *I-Manager's Journal on Information Technology*, 13(4), 1. <https://doi.org/10.26634/jit.13.4.21516>
- Jiang, T., & Cheng, J. (2019). Target Recognition Based on CNN with LeakyReLU and PReLU Activation Functions. *Proceedings - 2019 International Conference on Sensing, Diagnostics, Prognostics, and Control, SDPC 2019*, 718–722. <https://doi.org/10.1109/SDPC.2019.00136>
- Kang, J. M., & Tanna, A. P. (2021). Glaucoma. *Medical Clinics of North America*, 105(3), 493–510. <https://doi.org/10.1016/j.mcna.2021.01.004>
- Kebaili, A., Lapuyade-Lahorgue, J., & Ruan, S. (2023). Deep Learning Approaches for Data Augmentation in Medical Imaging: A Review. *Journal of Imaging*, 9(4), 81. <https://doi.org/10.3390/jimaging9040081>
- Khan, S., Rahmani, H., Shah, S. A. A., & Bennamoun, M. (2018). *A Guide to Convolutional Neural Networks for Computer Vision*. Springer International Publishing. <https://doi.org/10.1007/978-3-031-01821-3>
- Kilian, J., & Siegelmann, H. T. (1996). The Dynamic Universality of Sigmoidal Neural Networks. *Information and Computation*, 128(1), 48–56. <https://doi.org/10.1006/inco.1996.0062>
- Kim, J., Tran, L., Peto, T., & Chew, E. Y. (2022). Deep Learning and Ensemble Method for Optic Disc and Cup Segmentation. *2022 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB)*, 1–8. <https://doi.org/10.1109/CIBCB55180.2022.9863022>
- Kühl, N., Schemmer, M., Goutier, M., & Satzger, G. (2022). Artificial intelligence and machine learning. *Electronic Markets*, 32(4), 2235–2244. <https://doi.org/10.1007/s12525-022-00598-0>
- Lavric, A., Petrariu, A. I., Havriliuc, S., & Coca, E. (2021). Glaucoma Detection by Artificial Intelligence: GlauNet A Deep Learning Framework. *2021 International Conference on E-Health and Bioengineering (EHB)*, 1–4. <https://doi.org/10.1109/EHB52898.2021.9657622>
- Li, H., Rajbahadur, G. K., Lin, D., Bezemer, C.-P., & Jiang, Z. M. (2024). Keeping Deep Learning Models in Check: A History-Based Approach to Mitigate Overfitting. *IEEE Access*, 12, 70676–70689. <https://doi.org/10.1109/ACCESS.2024.3402543>
- Li, Q., Yan, M., & Xu, J. (2021). Optimizing Convolutional Neural Network Performance by Mitigating Underfitting and Overfitting. *2021 IEEE/ACIS 19th International Conference on Computer and Information Science (ICIS)*, 126–131. <https://doi.org/10.1109/ICIS51600.2021.9516868>

- Lin, Y., Jiang, B., Cai, Y., Luo, W., Zhu, X., Lin, Q., Tang, M., Li, X., & Xie, L. (2023). The Global Burden of Glaucoma: Findings from the Global Burden of Disease 2019 Study and Predictions by Bayesian Age–Period–Cohort Analysis. *Journal of Clinical Medicine*, 12(5), 1828. <https://doi.org/10.3390/jcm12051828>
- Liu, Y., Wu, J., Zhu, Y., & Zhou, X. (2024). Combined Optic Disc and Optic Cup Segmentation Network Based on Adversarial Learning. *IEEE Access*, 12, 104898–104908. <https://doi.org/10.1109/ACCESS.2024.3435552>
- Manohar, G., & O'Reilly, R. (2023). InceptionCaps: A Performant Glaucoma Classification Model for Data-Scarce Environment. *2023 31st Irish Conference on Artificial Intelligence and Cognitive Science (AICS)*, 1–8. <https://doi.org/10.1109/AICS60730.2023.10470926>
- Marciniak, T., & Stankiewicz, A. (2024). Impact of Histogram Equalization on the Classification of Retina Lesions from OCT B-Scans. *Electronics*, 13(24), 4996. <https://doi.org/10.3390/electronics13244996>
- Masruroh, F., Surarso, B., & Warsito, B. (2023). Perbandingan Kinerja Inception-Resnetv2, Xception, Inception-v3, dan Resnet50 pada Gambar Bentuk Wajah. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 10(1), 11–20. <https://doi.org/10.25126/jtiik.20231014941>
- Mehmood, Y., & Bajwa, U. I. (2024). Brain tumor grade classification using the ConvNext architecture. *Digital Health*, 10. <https://doi.org/10.1177/20552076241284920>
- Murugan, K. S., Karthik, G. L., Latha, R., Navaneethakrishnan, S. R., Kirubakaran, J., & Babu, T. R. G. (2024). Analysis of Cup to Disc Ratio Using Fundus and Optical Coherence Tomography Images. *2024 9th International Conference on Communication and Electronics Systems (ICCES)*, 1421–1426. <https://doi.org/10.1109/ICCES63552.2024.10860263>
- Mustapha, M. T., & Ozsahin, D. U. (2025). Morphological Analysis and Subtype Detection of Acute Myeloid Leukemia in High-Resolution Blood Smears Using ConvNeXT. *AI*, 6(3), 45. <https://doi.org/10.3390/ai6030045>
- Neto, A., Camara, J., & Cunha, A. (2022). Evaluations of Deep Learning Approaches for Glaucoma Screening Using Retinal Images from Mobile Device. *Sensors*, 22(4), 1449. <https://doi.org/10.3390/s22041449>
- Owler, J., & Rockett, P. (2021). Influence of background preprocessing on the performance of deep learning retinal vessel detection. *Journal of Medical Imaging*, 8(06). <https://doi.org/10.1117/1.JMI.8.6.064001>
- Panthakkan, A., Anzar, S. M., & Mansoor, W. (2023). Unleashing the Power of EfficientNet-ConvNeXt Concatenation for Brain Tumor Classification. *2023 15th Biomedical Engineering International Conference (BMEiCON)*, 1–5. <https://doi.org/10.1109/BMEiCON60347.2023.10322070>

- Pishnamaz, S. M. (2021). *Retinal Fundus image processing and ensemble learning: optic disc and optic cup detection*. <https://doi.org/10.32920/ryerson.14643936.v1>
- Pratiwi, H., Windarto, A. P., Susliansyah, S., Aria, R. R., Susilowati, S., Rahayu, L. K., Fitriani, Y., Merdekawati, A., & Rahadjeng, I. R. (2020). Sigmoid Activation Function in Selecting the Best Model of Artificial Neural Networks. *Journal of Physics: Conference Series*, 1471(1), 012010. <https://doi.org/10.1088/1742-6596/1471/1/012010>
- Prsath, R. H., Prasanth, S., Hanumanth, T. S., Mohanarathinam, A., & Subramaniam, K. (2023). Classification of Glaucoma using Deep Learning Techniques. *2023 5th International Conference on Inventive Research in Computing Applications (ICIRCA)*, 840–847. <https://doi.org/10.1109/ICIRCA57980.2023.10220932>
- Puchaicela-Lozano, M. S., Zhinin-Vera, L., Andrade-Reyes, A. J., Baque-Arteaga, D. M., Cadena-Morejón, C., Tirado-Espín, A., Ramírez-Cando, L., Almeida-Galárraga, D., Cruz-Varela, J., & Meneses, F. V. (2023). Deep Learning for Glaucoma Detection: R-CNN ResNet-50 and Image Segmentation. *Journal of Advances in Information Technology*, 14(6), 1186–1197. <https://doi.org/10.12720/jait.14.6.1186-1197>
- Qiao, S., Yang, J., Zhang, T., & Zhao, C. (2022). Layered input GradiNet for image denoising. *Knowledge-Based Systems*, 254, 109587. <https://doi.org/10.1016/j.knosys.2022.109587>
- R. Geethalakshmi, E. al. (2023). A Comparison of Deep Learning Techniques for Glaucoma Diagnosis on Retinal Fundus Images. *International Journal on Recent and Innovation Trends in Computing and Communication*, 11(9), 3382–3387. <https://doi.org/10.17762/ijritcc.v11i9.9545>
- Rasamoelina, A. D., Adjailia, F., & Sincak, P. (2020). A Review of Activation Function for Artificial Neural Network. *2020 IEEE 18th World Symposium on Applied Machine Intelligence and Informatics (SAMI)*, 281–286. <https://doi.org/10.1109/SAMI48414.2020.9108717>
- Rezaeezade, A., & Batina, L. (2024). Regularizers to the rescue: fighting overfitting in deep learning-based side-channel analysis. *Journal of Cryptographic Engineering*, 14(4), 609–629. <https://doi.org/10.1007/s13389-024-00361-5>
- Riyanto, S., Sitanggang, I. S., Djatna, T., & Atikah, T. D. (2023). Comparative Analysis using Various Performance Metrics in Imbalanced Data for Multi-class Text Classification. *International Journal of Advanced Computer Science and Applications*, 14(6). <https://doi.org/10.14569/IJACSA.2023.01406116>
- Sandoval-Cuellar, H. J., Alfonso-Francia, G., Vázquez-Membrillo, M. Á., Ramos-Arreguín, J. M., & Tovar Arriaga, S. (2021). Image-based Glaucoma Classification Using Fundus Images and Deep Learning. *Revista Mexicana de Ingeniería Biomedica*, 42(3), 28–41. <https://doi.org/10.17488/RMIB.42.3.2>

- Shaveta. (2023). A review on machine learning. *International Journal of Science and Research Archive*, 9(1), 281–285. <https://doi.org/10.30574/ijjsra.2023.9.1.0410>
- Shoukat, A., Akbar, S., Hassan, S. A., Iqbal, S., Mehmood, A., & Ilyas, Q. M. (2023). Automatic Diagnosis of Glaucoma from Retinal Images Using Deep Learning Approach. *Diagnostics*, 13(10), 1738. <https://doi.org/10.3390/diagnostics13101738>
- Shoukat, A., Akbar, S., & Safdar, K. (2021). A Deep Learning-based Automatic Method for Early Detection of the Glaucoma using Fundus Images. *2021 International Conference on Innovative Computing (ICIC)*, 1–6. <https://doi.org/10.1109/ICIC53490.2021.9693078>
- Sharma, S., Sharma, S., & Athaiya, A. (2020). Activation functions in neural networks. *International Journal of Engineering Applied Sciences and Technology*, 4(12), 310–316.
- Sidhu, Z., & Mansoori, T. (2024). Artificial intelligence in glaucoma detection using color fundus photographs. *Indian Journal of Ophthalmology*, 72(3), 408–411. https://doi.org/10.4103/IJO.IJO_613_23
- Singh, H., Saini, S. S., & Lakshminarayanan, V. (2021). Rapid classification of glaucomatous fundus images. *Journal of the Optical Society of America A*, 38(6), 765. <https://doi.org/10.1364/JOSAA.415395>
- Sri Varshan V, Y., Sahayam, S., & Jayaraman, Dr. U. (2023). An Algorithm to Calculate Retinal Vessel Diameter in Fundus Images. *Proceedings of the Fourteenth Indian Conference on Computer Vision, Graphics and Image Processing*, 1–9. <https://doi.org/10.1145/3627631.3627653>
- Subbarayudu, Y., Vijendar Reddy, G., Raj Kumar, M., Aravind Naik, M., Nagini, R. V. S. S., & Singh, B. (2024). An efficient novel approach for glaucoma classification on retinal fundus images through machine learning paradigm. *MATEC Web of Conferences*, 392, 01108. <https://doi.org/10.1051/mateconf/202439201108>
- Subha, K. J., Rajavel, R., & Paulchamy, B. (2024). An improved ensemble deep learning framework for glaucoma detection. *Multimedia Tools and Applications*. <https://doi.org/10.1007/s11042-024-20088-z>
- Sumitha, S., & Gokila, S. (2023). Experimental Approach to Identify the Optimal Deep CNN Models to Early Detection of Glaucoma from Fundus CT-Scan Images. *2023 7th International Conference on Intelligent Computing and Control Systems (ICICCS)*, 511–515. <https://doi.org/10.1109/ICICCS56967.2023.10142248>
- Sun, J. A., Yuan, M., Johnson, G. E., Pasquale, L. R., Boland, M. V., Friedman, D. S., Elze, T., Shen, L. Q., & Wang, M. (2024). Comparison of Structural and Functional Features in Primary Angle Closure and Open Angle Glaucomas. *Journal of Glaucoma*, 33(4), 254–261. <https://doi.org/10.1097/IJG.0000000000002341>

- Sun, Y., Chen, A., Zou, M., Zhang, Y., Jin, L., Li, Y., Zheng, D., Jin, G., & Congdon, N. (2022). Time trends, associations and prevalence of blindness and vision loss due to glaucoma: an analysis of observational data from the Global Burden of Disease Study 2017. *BMJ Open*, 12(1), e053805. <https://doi.org/10.1136/bmjopen-2021-053805>
- Thakur, N., & Juneja, M. (2021). Early-stage prediction of glaucoma disease to reduce surgical requirements using deep-learning. *Materials Today: Proceedings*, 45, 5660–5664. <https://doi.org/10.1016/j.matpr.2021.02.458>
- Ther, A., Kumar Pandit, B., Ganguly, A., Chakraborty, A., & Banerjee, A. (2023). Resource-efficient VLSI Architecture of Softmax Activation Function for Real-time Inference in Deep Learning Applications. *2023 International Symposium on Devices, Circuits and Systems (ISDCS)*, 01–05. <https://doi.org/10.1109/ISDCS58735.2023.10153520>
- Todi, A., Narula, N., Sharma, M., & Gupta, U. (2023). ConvNext: A Contemporary Architecture for Convolutional Neural Networks for Image Classification. *2023 3rd International Conference on Innovative Sustainable Computational Technologies (CISCT)*, 1–6. <https://doi.org/10.1109/CISCT57197.2023.10351320>
- Tripathi, R. P., Khatri, S. K., Van Greunen, D., & Ather, D. (2023). Unleashing the Power of Machine Learning: A Precision Paradigm for Breast Cancer Subtype Classification Using Open-Source Data, with Caution on Dataset Size and Interpretability. *2023 6th International Conference on Contemporary Computing and Informatics (IC3I)*, 1004–1008. <https://doi.org/10.1109/IC3I59117.2023.10397969>
- Varghese, R. E., & Pandian, I. A. (2023). Inception-Resnet V2 Based Eye Disease Classification Using Retinal Images. *2023 3rd International Conference on Mobile Networks and Wireless Communications (ICMNWC)*, 1–5. <https://doi.org/10.1109/ICMNWC60182.2023.10435893>
- Victo, V., S., Geetha., & G., V. S. George. (2025). Extracting the Trustworthy Glaucoma Features using WGMO based EvoTransform: Advanced Vision Transformer from Fundus Images. *Fusion: Practice and Applications*, 19(2), 151–169. <https://doi.org/10.54216/FPA.190212>
- Wang, Y., Li, Y., Song, Y., & Rong, X. (2020). The Influence of the Activation Function in a Convolution Neural Network Model of Facial Expression Recognition. *Applied Sciences*, 10(5), 1897. <https://doi.org/10.3390/app10051897>
- Wang, Y., Guo, Y., Zhang, Y., Huang, S., & Zhong, Y. (2024). Differences and Similarities Between Primary Open Angle Glaucoma and Primary Angle-Closure Glaucoma. *Eye and Brain*, Volume 16, 39–54. <https://doi.org/10.2147/EB.S472920>
- Wu, M., Lu, Y., Hong, X., Zhang, J., Zheng, B., Zhu, S., Chen, N., Zhu, Z., & Yang, W. (2022). Classification of dry and wet macular degeneration based on the

- ConvNeXT model. *Frontiers in Computational Neuroscience*, 16. <https://doi.org/10.3389/fncom.2022.1079155>
- Xu, J., Tian, H., Wang, Z., Wang, Y., Kang, W., & Chen, F. (2021). Joint Input and Output Space Learning for Multi-Label Image Classification. *IEEE Transactions on Multimedia*, 23, 1696–1707. <https://doi.org/10.1109/TMM.2020.3002185>
- Yermukhanova, L. S., Taushanova, M. K., Baisugurova, V. Y., Balmagambetova, S. K., Tazhbenova, S. T., Aitmagambet, P. Zh., Turdalina, K. B., Kurganbekova, M. B., Bekbauova, A. U., & Kuspangaliyeva, G. S. (2024). Creation of An Electronic Register in the Healthcare System: Improving The Effectiveness Of Glaucoma Management and Treatment. *Научно — Практический Журнал Фтизиопульмонология*, 1, 63–69. <https://doi.org/10.26212/2227-1937.2024.41.67.008>
- Yunitasari, D. A., Sigit, R., & Harsono, T. (2021). Glaucoma Detection Based on Cup-to-Disc Ratio in Retinal Fundus Image Using Support Vector Machine. *2021 International Electronics Symposium (IES)*, 368–373. <https://doi.org/10.1109/IES53407.2021.9593943>