

**DETEKSI *DIABETIC RETINOPATHY* MENGGUNAKAN
CONVOLUTIONAL NEURAL NETWORK BERBASIS
EFFICIENTNET DAN *GRAD-CAM* PADA CITRA FUNDUS
RETINA**

LAPORAN TUGAS AKHIR

Laporan ini disusun guna memenuhi salah satu syarat untuk menyelesaikan program studi S1 Teknik Informatika pada Fakultas Teknologi Industri Universitas Islam Sultan Agung Semarang



DISUSUN OLEH :

HENDRA IRAWAN WIJAYA KUSUMA

32602100049

PROGRAM STUDI TEKNIK INFORMATIKA

FAKULTAS TEKNOLOGI INDUSTRI

UNIVERSITAS ISLAM SULTAN AGUNG


SEMARANG

2025

***DETECTION OF DIABETIC RETINOPATHY USING
CONVOLUTIONAL NEURAL NETWORK BASED ON
EFFICIENTNET AND GRAD-CAM ON RETINAL FUNDUS
IMAGE***

FINAL PROJECT

*Proposed to complete the requirement to obtain a bachelor's degree (S1) at
Informatics Engineering Departement of Industrial Technology Faculty Sultan
Agung Islamic University*



ARRANGED BY:

HENDRA IRAWAN WIJAYA KUSUMA

32602100049

***MAJORING OF INFORMATICS ENGINEERING
INDUSTRIAL TECHNOLOGY FACULTY
SULTAN AGUNG ISLAMIC UNIVERSITY
SEMARANG***

2025

LEMBAR PENGESAHAN TUGAS AKHIR

**DETEKSI *DIABETIC RETINOPATHY* MENGGUNAKAN
CONVOLUTIONAL NEURAL NETWORK BERBASIS *EFFICIENTNET*
DAN *GRAD-CAM* PADA CITRA FUNDUS RETINA**

**HENDRA IRAWAN WIJAYA KUSUMA
NIM 32602100049**

Telah dipertahankan di depan tim penguji ujian sarjana tugas akhir
Program Studi Teknik Informatika
Universitas Islam Sultan Agung
Pada tanggal : 4 Agustus 2025

TIM PENGUJI UJIAN SARJANA:

Prof. Dr. Sri Attini Dwi P., M.Si

NIK. 210695009

(Penguji 1)

Sam Farisa Chaerul H., ST, M.Kom

NIK. 210615046

(Penguji 2)

Bagus SWP, S.Kom, M.Cs

NIK. 210616051

(Pembimbing)

Semarang, 21 Agustus 2025

Mengetahui,

Kapredi Teknik Informatika

Universitas Islam Sultan Agung



Moeh Taufik., ST, MIT

NIK. 210604034

SURAT PERNYATAAN KEASLIAN TUGAS AKHIR

Yang bertanda tangan dibawah ini :

Nama : Hendra Irawan Wijaya Kusuma

NIM : 32602100049

Judul Tugas Akhir : *DETEKSI DIABETIC RETINOPATHY MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK BERBASIS EFFICIENTNET DAN GRAD-CAM PADA CITRA FUNDUS RETINA*

Dengan bahwa ini saya menyatakan bahwa judul dan isi Tugas Akhir yang saya buat dalam rangka menyelesaikan Pendidikan Strata Satu (S1) Teknik Informatika tersebut adalah asli dan belum pernah diangkat, ditulis ataupun dipublikasikan oleh siapapun baik keseluruhan maupun sebagian, kecuali yang secara tertulis diacu dalam naskah ini dan disebutkan dalam daftar pustaka, dan apabila di kemudian hari ternyata terbukti bahwa judul Tugas Akhir tersebut pernah diangkat, ditulis ataupun dipublikasikan, maka saya bersedia dikenakan sanksi akademis. Demikian surat pernyataan ini saya buat dengan sadar dan penuh tanggung jawab.

Semarang, 21 Agustus 2025

Yang Menyatakan,



Hendra Irawan Wijaya Kusuma

PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH

Saya yang bertanda tangan dibawah ini :

Nama : Hendra Irawan Wijaya Kusuma

NIM : 32602100049

Program Studi : Teknik Informatika

Fakultas : Teknologi industri

Alamat Asal : Desa Mangunlegi, Kec. Batangan, Kab. Pati

Dengan ini menyatakan Karya Ilmiah berupa Tugas akhir dengan Judul :

**DETEKSI *DIABETIC* *RETINOPATHY* MENGGUNAKAN
CONVOLUTIONAL NEURAL NETWORK BERBASIS *EFFICIENTNET*
DAN *GRAD-CAM* PADA CITRA FUNDUS RETINA.**

Menyetujui menjadi hak milik Universitas Islam Sultan Agung serta memberikan Hak bebas Royalti Non-Eksklusif untuk disimpan, dialihmediakan, dikelola dan pangkalan data dan dipublikasikan diinternet dan media lain untuk kepentingan akademis selama tetap menyantumkan nama penulis sebagai pemilik hak cipta. Pernyataan ini saya buat dengan sungguh-sungguh. Apabila dikemudian hari terbukti ada pelanggaran Hak Cipta/Plagiarisme dalam karya ilmiah ini, maka segala bentuk tuntutan hukum yang timbul akan saya tanggung secara pribadi tanpa melibatkan Universitas Islam Sultan agung.

Semarang, 21 Agustus 2025

Yang menyatakan,



Hendra Irawan Wijaya Kusuma

KATA PENGANTAR


Dengan mengucapkan syukur alhamdulillah atas kehadiran Allah SWT yang telah memberikan rahmat dan karunianya kepada penulis, sehingga dapat menyelesaikan Tugas Akhir dengan judul “Deteksi *Diabetic Retinopathy* Menggunakan *Convolutional Neural Network* Berbasis *EfficientNet* dan *Grad-CAM* pada Citra Fundus Retina” ini untuk memenuhi salah satu syarat menyelesaikan studi serta dalam rangka memperoleh gelar sarjana (S-1) pada Program Studi Teknik Informatika Fakultas Teknologi Industri Universitas Islam Sultan Agung Semarang.

Tugas Akhir ini disusun dan dibuat dengan adanya bantuan dari berbagai pihak, materi maupun teknis, oleh karena itu saya selaku penulis mengucapkan terima kasih kepada:

1. Rektor UNISSULA Bapak Prof. Dr. H. Gunarto, S.H., M.H yang mengizinkan penulis menimba ilmu di kampus ini.
2. Dekan Fakultas Teknologi Industri Ibu Dr. Novi Marlyana, S.T., M.T.
3. Dosen pembimbing penulis Bapak Bagus SWP, S.Kom, M.Cs yang telah meluangkan waktu dan memberi ilmu. Serta memberikan nasehat dan saran.
4. Orang tua penulis yang telah mengizinkan untuk menyelesaikan laporan ini,
5. Dan kepada semua pihak yang tidak dapat saya sebutkan satu persatu.

Dengan segala kerendahan hati, penulis menyadari masih terdapat banyak kekurangan dari segi kualitas atau kuantitas maupun dari ilmu pengetahuan dalam penyusunan laporan, sehingga penulis mengharapkan adanya saran dan kritikan yang bersifat membangun demi kesempurnaan laporan ini dan masa mendatang.

Semarang, 27 Agustus 2025



Hendra Irawan Wijaya Kusuma

DAFTAR ISI

COVER	i
LEMBAR PENGESAHAN TUGAS AKHIR	iii
SURAT PERNYATAAN KEASLIAN TUGAS AKHIR.....	iv
PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH	v
KATA PENGANTAR.....	vi
DAFTAR ISI.....	vii
DAFTAR GAMBAR	ix
DAFTAR TABEL	x
ABSTRAK	xi
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	3
1.3 Batasan Masalah.....	3
1.4 Tujuan.....	3
1.5 Manfaat	4
1.6 Sistematika Penulisan.....	4
BAB II TINJAUAN PUSTAKA DAN DASAR TEORI.....	6
2.1 Tinjauan Pustaka	6
2.2 Dasar Teori.....	7
2.2.1 Retinopati Diabetik	7
2.2.2 <i>Convolutional Neural Network (CNN)</i>	9
2.2.3 <i>EfficientNet</i>	11
2.2.4 Grad-CAM (<i>Gradient-weighted Class Activation Mapping</i>).....	15
BAB III METODE PENELITIAN	17
3.1 Metode Penelitian.....	17
3.1.1 Studi Literatur	18
3.1.2 Pengumpulan Data	18
3.1.3 <i>Preprocessing Data</i>	18
3.1.4 Pelatihan Model	19
3.1.5 Evaluasi Model.....	22

3.1.6	<i>Deployment Model</i>	23
3.2	<i>Software Yang Digunakan</i>	24
3.3	Perancangan sistem.....	27
3.4	Perancangan <i>User Interface</i>	28
3.4.1	Halaman Awal Sistem.....	28
3.4.2	Tampilan Hasil Sistem.....	29
BAB IV HASIL DAN ANALISIS PENELITIAN.....		31
4.1	Hasil Pengumpulan Data.....	31
4.2	Hasil <i>Preprocessing</i> Data.....	33
4.3	Implementasi Pelatihan Model.....	35
4.4	Evaluasi Model.....	36
4.4.1	Evaluasi Akurasi dan <i>Loss</i>	36
4.4.2	Visualisasi Akurasi dan <i>Loss</i>	36
4.4.3	<i>Confusion Matrix</i>	38
4.4.4	<i>Classification Report</i>	39
4.4.5	Evaluasi <i>Grad-CAM</i>	41
4.5	Hasil Implementasi.....	41
4.5.1	Implementasi Kelas 0 (Normal).....	43
4.5.2	Implementasi Kelas 1 (Ringan).....	44
4.5.3	Implementasi Kelas 2 (Sedang).....	46
4.5.4	Implementasi Kelas 3 (Berat).....	49
4.5.5	Implementasi Kelas 4 (Sangat Berat).....	51
BAB V KESIMPULAN DAN SARAN.....		53
5.1	Kesimpulan.....	53
5.2	Saran.....	54
DAFTAR PUSTAKA		
LAMPIRAN		

DAFTAR GAMBAR

Gambar 2. 1 Retina normal dan retina yang terkena retinopati diabetik	8
Gambar 2. 2 Lapisan pada CNN	9
Gambar 2. 3 Model Arsitektur <i>EfficientNet</i>	12
Gambar 3. 1 Alur Penelitian.....	17
Gambar 3. 2 Pengumpulan Data	18
Gambar 3. 3 Arsitektur Model <i>EfficientNetB3</i>	19
Gambar 3. 4 Proses Training CNN <i>EfficientNet</i>	21
Gambar 3. 5 Flowchart Alur Sistem.....	27
Gambar 3. 6 Tampilan halaman awal sistem.....	28
Gambar 3. 7 Tampilan Hasil sistem	29
Gambar 4. 1 Contoh citra dari masing-masing kelas	31
Gambar 4. 2 Jumlah data kelas sebelum <i>upsampling</i>	33
Gambar 4. 3 jumlah data kelas setelah <i>upsampling</i>	34
Gambar 4. 4 Grafik akurasi dan <i>loss</i> dari pelatihan	37
Gambar 4. 5 <i>Confusion Matrix</i>	38
Gambar 4. 6 Tampilan awal sistem	42
Gambar 4. 7 Implementasi hasil dari kelas 0 (normal)	43
Gambar 4. 8 Implementasi hasil dari kelas 1 (ringan)	45
Gambar 4. 9 Implementasi hasil dari kelas 2 (sedang)	47
Gambar 4. 10 Implementasi hasil dari kelas 3 (berat)	49
Gambar 4. 11 Implementasi hasil dari kelas 4 (sangat berat)	51



DAFTAR TABEL

Tabel 4. 1 <i>Labelling</i> pada dataset diabeik retinopati.....	31
Tabel 4. 2 <i>Classification Report</i>	39



ABSTRAK

Retinopati diabetik merupakan salah satu komplikasi utama diabetes yang dapat menyebabkan kebutaan permanen apabila tidak dideteksi sejak dini. Penelitian ini bertujuan mengembangkan sistem deteksi otomatis retinopati diabetik menggunakan algoritma *Convolutional Neural Network* (CNN) berbasis arsitektur *EfficientNet* dan visualisasi *Grad-CAM* pada citra fundus retina. Dataset yang digunakan adalah *APTOS 2019 Blindness Detection* dengan lima tingkat klasifikasi keparahan retinopati. Tahapan penelitian meliputi *preprocessing data*, augmentasi citra, pelatihan model dengan *transfer learning* pada *EfficientNet*, evaluasi model melalui *confusion matrix* dan *classification report*, serta *deployment* menggunakan aplikasi Streamlit. Hasil evaluasi menunjukkan bahwa model mampu mencapai akurasi validasi sebesar 96%. Performa terbaik ditunjukkan pada kelas normal (kelas 0) dan kelas berat (kelas 3–4) dengan tingkat kesalahan prediksi yang sangat rendah. Integrasi *Grad-CAM* memberikan visualisasi *heatmap* yang menyoroti area penting pada retina, sehingga meningkatkan interpretabilitas hasil prediksi.

Kata Kunci: CNN, *EfficientNet*, Fundus Retina, *Grad-CAM*, Retinopati Diabetik.

ABSTRACT

Diabetic retinopathy is one of the main complications of diabetes that can cause permanent blindness if not detected early. This study aims to develop an automatic detection system for diabetic retinopathy using a Convolutional Neural Network (CNN) algorithm based on the EfficientNet architecture and Grad-CAM visualization on retinal fundus images. The dataset used is APTOS 2019 Blindness Detection with five severity classification levels of retinopathy. The research stages include data preprocessing, image augmentation, model training using transfer learning on EfficientNet, model evaluation through a confusion matrix and classification report, and deployment using the Streamlit application. Evaluation results show that the model achieves a validation accuracy of 96%. The best performance was observed in the normal class (class 0) and severe classes (classes 3–4) with very low prediction error rates. The integration of Grad-CAM provides heatmap visualizations highlighting important areas on the retina, thereby enhancing the interpretability of prediction results.

Keywords: CNN, Diabetic Retinopathy, EfficientNet, Grad-CAM, Retinal Fundus.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Diabetic Retinopathy (DR) adalah penyebab utama kebutaan yang bisa dicegah di seluruh dunia. Risiko perkembangan *DR* sangat bervariasi di antara individu yang berbeda, sehingga sulit untuk memprediksi risiko dan mempersonalisasi skrining interval (Dai dkk., 2024). Deteksi dini dan interpretasi yang akurat sangat penting untuk mencegah progresi penyakit ini (Zahir & Adi Saputra, 2024). Menurut data dari *World Health Organization* (WHO), diabetes menempati peringkat ketujuh sebagai penyebab kematian pada tahun 2016. Deteksi dini retinopati diabetik sangat penting untuk mencegah perkembangan penyakit dan kehilangan penglihatan yang lebih parah.

Retinopati diabetik merupakan salah satu penyebab utama kebutaan pada populasi usia produktif di seluruh dunia. Penyakit ini terjadi sebagai akibat dari kerusakan mikro-pembuluh darah akibat kadar glukosa darah yang tinggi dan tidak terkontrol dalam jangka panjang. Gejala awal retinopati diabetik sering kali tidak disadari oleh pasien, sehingga penyakit ini sering terdeteksi dalam stadium lanjut ketika kerusakan penglihatan sudah terjadi secara signifikan. Oleh karena itu, pendekatan berbasis teknologi untuk mendeteksi penyakit ini secara dini menjadi sangat penting dalam upaya preventif dan kuratif.

Di era digital saat ini, pemanfaatan kecerdasan buatan dalam bidang medis semakin berkembang, terutama dalam analisis citra diagnostik. Dalam konteks retinopati diabetik, citra fundus retina yang diperoleh melalui fundus kamera menjadi sumber informasi utama untuk analisis kondisi retina. Namun, interpretasi citra tersebut secara manual oleh dokter spesialis memerlukan waktu dan keahlian khusus serta rentan terhadap subjektivitas. Oleh karena itu, dibutuhkan sistem berbasis komputer yang

mampu memberikan hasil analisis yang cepat, akurat, dan dapat diandalkan.

Selain itu, meningkatnya jumlah penderita diabetes secara global juga memberikan tekanan pada sistem pelayanan kesehatan, terutama di wilayah dengan keterbatasan tenaga ahli. Implementasi sistem deteksi otomatis berbasis *deep learning* seperti *Convolutional Neural Network* (CNN) menjadi solusi yang menjanjikan dalam meningkatkan kapasitas skrining massal. Sistem ini dapat digunakan sebagai alat bantu bagi dokter dalam menilai tingkat keparahan retinopati diabetik, sehingga mempercepat proses diagnosis dan perencanaan pengobatan.

Dalam bidang pengolahan citra medis, *Convolutional Neural Network* (CNN) telah digunakan secara luas untuk menganalisis citra fundus retina dalam mendeteksi retinopati diabetik. Misalnya, sebuah penelitian mengembangkan sistem deteksi level retinopati diabetik menggunakan metode CNN pada citra fundus mata, menunjukkan potensi CNN dalam klasifikasi penyakit retinopati diabetik (Abdullah dkk., 2022).

EfficientNet, sebuah arsitektur CNN yang efisien, telah terbukti meningkatkan akurasi dalam klasifikasi retinopati diabetik. Penelitian menunjukkan bahwa model *EfficientNet* dapat meningkatkan akurasi dalam mengklasifikasikan lima stadium retinopati diabetik dibandingkan dengan model lainnya (Zahir & Adi Saputra, 2024).

Untuk meningkatkan interpretabilitas model CNN, teknik seperti *Gradient-weighted Class Activation Mapping* (Grad-CAM) digunakan. *Grad-CAM* menciptakan penjelasan visual untuk keputusan yang dibuat oleh model berbasis CNN, menyoroti area penting dalam gambar yang mempengaruhi prediksi model. Misalnya, *Grad-CAM* dapat menunjukkan posisi lesi pada citra retina, memberikan pemahaman yang lebih baik tentang dasar prediksi model (Daanouni dkk., 2021).

Dengan menggabungkan arsitektur *EfficientNet* dan teknik *Grad-CAM*, sistem deteksi dan interpretasi retinopati diabetik dapat mencapai akurasi tinggi sekaligus memberikan interpretasi visual yang jelas, yang penting

untuk kepercayaan dan adopsi klinis (Abdullah dkk., 2022). Implementasi metode ini diharapkan dapat membantu tenaga medis dalam pengambilan keputusan yang lebih akurat dan cepat, sehingga mendukung deteksi dini dan perawatan yang lebih efektif bagi pasien dengan risiko retinopati diabetik.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dijelaskan, rumusan masalah dalam penelitian ini adalah:

- 1) Bagaimana mengembangkan dan melatih model *Convolutional Neural Network* (CNN) berbasis arsitektur *EfficientNetB3* untuk mengklasifikasikan lima tingkat keparahan *Diabetic Retinopathy* pada dataset APTOS 2019 *Blindness Detection* ?
- 2) Bagaimana mengimplementasikan teknik visualisasi *Grad-CAM* untuk menampilkan area citra retina yang menjadi dasar prediksi model, sehingga meningkatkan interpretabilitas dan transparansi hasil klasifikasi?

1.3 Batasan Masalah

Adapun batasan masalah dari penulisan proposal sebagai berikut :

1. Dataset yang digunakan adalah *APTOS 2019 Blindness Detection* dari Kaggle.
2. Model yang digunakan adalah *EfficientNet* sebagai arsitektur CNN.
3. *Grad-CAM* digunakan untuk memberikan visual pada hasil prediksi model.

1.4 Tujuan

Tujuan dari penelitian ini adalah:

1. Mengembangkan dan melatih model CNN berbasis arsitektur *EfficientNetB3* untuk klasifikasi lima tingkat keparahan *Diabetic*

Retinopathy pada citra fundus retina dari dataset APTOS 2019 *Blindness Detection*

2. Menerapkan teknik *Grad-CAM* untuk menghasilkan visualisasi heatmap pada citra fundus yang menyoroti area retina yang berkontribusi terhadap prediksi model.

1.5 Manfaat

Penelitian ini diharapkan dapat memberikan manfaat bagi pengembang teknologi pemrosesan citra dalam deteksi diabetik retinopati. Dengan menerapkan model *Convolutional Neural Network* (CNN) khususnya *EfficientNet*, sistem yang dikembangkan mampu mendeteksi citra retina yang lebih akurat serta visualisasi *Grad-CAM* untuk melihat bagian retina yang mempengaruhi hasil prediksi, sehingga dapat mendukung berbagai kebutuhan untuk penyakit diabetik retinopati.

1.6 Sistematika Penulisan

Sistematika penulisan yang akan digunakan oleh penulis dalam sebuah pembuatan laporan tugas akhir adalah sebagai berikut :

- BAB I : Pada bab 1 penulis mengutarakan latar belakang pemilihan judul, rumusan masalah, batasan masalah, tujuan penelitian, metodologi penelitian dan sistematika penulisan.
- BAB II : Pada bab II memuat penelitian – penelitian sebelumnya dan dasar teori untuk membantu penulis untuk memahami teori yang berhubungan dengan algoritma *Convolutional Neural Network* dengan arsitektur *EfficientNet* sehingga dapat menyelesaikan penelitian ini.
- BAB III : Pada bab III mengungkapkan proses tahapan – tahapan penelitian yang dimulai dari mendapatkan data hingga proses klasifikasi data yang ada.
- BAB IV : Pada bab IV penulis mengungkapkan hasil klasifikasi dari penelitian yang menggunakan model *Convolutional Neural*

Network dengan arsitektur *EfficientNet*, serta melakukan evaluasi dan pengujian klasifikasinya. Kemudian dilanjutkan dengan *Grad-CAM* dan pengujian streamlit.

BAB V : Pada bab V penulis memaparkan kesimpulan dari keseluruhan proses penelitian dari awal hingga akhir serta memberikan saran pengembangan untuk penelitian selanjutnya.



BAB II

TINJAUAN PUSTAKA DAN DASAR TEORI

2.1 Tinjauan Pustaka

Diabetic Retinopathy (DR) merupakan salah satu penyebab utama kebutaan yang dapat dicegah secara global. Risiko perkembangan DR sangat bervariasi antar individu, sehingga diperlukan pendekatan skrining yang efisien dan presisi untuk mendeteksi penyakit ini sejak dini (Dai dkk., 2024). Seiring dengan kemajuan teknologi pencitraan dan pengobatan, adopsi sistem klasifikasi seperti *Early Treatment of Diabetic Retinopathy Study* (ETDRS) dan *International Classification of Diabetic Retinopathy* (ICDR) telah meningkatkan akurasi diagnosis dan intervensi dini (Tan & Wong, 2023).

Untuk mengatasi keterbatasan skrining manual oleh dokter mata yang memerlukan waktu, keahlian, dan rentan terhadap subjektivitas berbagai penelitian mulai mengembangkan sistem deteksi otomatis berbasis kecerdasan buatan *Artificial Intelligence* (AI). Salah satu pendekatan yang paling banyak digunakan adalah *Convolutional Neural Network* (CNN) karena kemampuannya mengenali pola visual secara akurat, meskipun dalam data beresolusi tinggi Schielein dkk. (2023). CNN memungkinkan model untuk mengekstraksi fitur spasial dari citra fundus retina dan melakukan klasifikasi berdasarkan tingkat keparahan DR.

Beberapa penelitian terdahulu telah mengadopsi arsitektur CNN populer seperti *VGGNet*, *ResNet*, dan *DenseNet* untuk mendeteksi dan mengklasifikasikan DR, dengan berbagai tingkat keberhasilan. Namun, pendekatan terkini mengarah pada penggunaan *EfficientNet*, arsitektur CNN yang menggabungkan efisiensi dan akurasi melalui teknik *compound scaling*. *EfficientNet* membuktikan bahwa penskalaan kedalaman, lebar, dan resolusi gambar secara terkoordinasi dapat menghasilkan model yang ringan namun tetap akurat (Luo dkk., 2021). Dalam studi (Nayak dkk., 2022), penerapan *EfficientNet* untuk klasifikasi DR menghasilkan

performa yang signifikan dengan kompleksitas komputasi yang rendah, terutama dalam pengklasifikasian lima tingkatan *DR*.

Di sisi lain, salah satu tantangan utama dari sistem berbasis *deep learning* dalam bidang medis adalah kurangnya interpretabilitas. Dalam konteks klinis, tidak cukup hanya mengandalkan akurasi; hasil prediksi harus dapat dijelaskan dan divisualisasikan. Oleh karena itu, teknik *Gradient-weighted Class Activation Mapping (Grad-CAM)* digunakan untuk memberikan visualisasi *heatmap* dari area citra yang menjadi fokus model dalam melakukan klasifikasi. *Grad-CAM* dapat meningkatkan transparansi prediksi, membantu dokter dalam memahami dasar klasifikasi model, serta meningkatkan kepercayaan dalam penggunaan sistem *AI* di praktik medis (Daanouni dkk., 2021)(Swaminathan, 2025)

Penelitian terbaru juga menunjukkan bahwa integrasi *EfficientNet* dengan *Grad-CAM* dapat memberikan sistem deteksi *DR* yang tidak hanya akurat, tetapi juga *interpretable*. Model ini memungkinkan identifikasi struktur penting seperti mikroaneurisma, perdarahan, dan neovaskularisasi, yang dapat membantu diagnosis yang lebih tepat (Zahir & Adi Saputra, 2024)


Dengan melihat keterbatasan dan potensi dari studi sebelumnya, penelitian ini diarahkan untuk mengembangkan sistem deteksi *DR* otomatis berbasis CNN dengan arsitektur *EfficientNetB3* dan visual *Grad-CAM*, guna meningkatkan baik akurasi klasifikasi maupun interpretabilitas hasil, sehingga mendukung skrining yang lebih efektif di lingkungan klinis maupun komunitas.

2.2 Dasar Teori

2.2.1 Retinopati Diabetik

Diabetic Retinopathy (DR) adalah penyebab utama gangguan penglihatan dan kebutaan di seluruh dunia. Sejak *DR* pertama kali dikenali sebagai komplikasi penting dari diabetes, telah ada banyak upaya untuk mengklasifikasikan tingkat keparahan dan tahapan penyakit. Sistem klasifikasi historis ini berkembang seiring dengan pemahaman tentang

patofisiologi penyakit meningkat, metode pencitraan dan menilai *DR* berubah, dan pengobatan yang efektif dikembangkan (Yang dkk., 2022). *Diabetic Retinopathy* (DR) adalah komplikasi mikrovaskuler yang penting, dan terjadi pada sekitar 30% dari individu dengan diabetes. Oleh karena itu, *DR* merupakan penyebab utama gangguan penglihatan dan kebutaan yang dapat dicegah di antara orang dewasa, terutama di negara-negara berpenghasilan tinggi. Dengan keseluruhan kejadian diabetes yang meningkat dengan cepat, jumlah orang dewasa di seluruh dunia dengan *DR*, *DR* yang mengancam penglihatan, dan *diabetic macular edema* (DME) diproyeksikan akan meningkat menjadi sekitar 161 juta, 45 juta, dan 29 juta, masing-masing pada tahun 2045 (Yang dkk., 2022).




Gambar 2. 1 Retina normal dan retina yang terkena retinopati diabetik

Diabetes merupakan salah satu jenis penyakit yang paling umum terjadi di Indonesia. Salah satu penyebab utama terjadinya penyakit ini yaitu meningkatnya kadar gula darah atau glukosa. Perawatan yang tepat pada penyakit ini dapat dilakukan salah satunya dengan deteksi dini. Klasifikasi diabetes merupakan proses yang sangat penting dalam melakukan deteksi pada penyakit ini (Zahir & Adi Saputra, 2024). Pada pasien diabetes, pankreas tidak dapat memproduksi insulin yang dibutuhkan tubuh. Hormon insulin menstimulasi penyerapan dan memproses glukosa menjadi energi. Glukosa yang tidak terserap ini dapat menyebabkan berbagai gangguan pada organ tubuh. Berbagai komplikasi timbul akibat diabetes, salah satunya adalah *diabetic retinopathy* (DR) atau

dikenal dengan penyakit mata diabetes, yaitu kerusakan pada retina yang menyebabkan kebutaan. *DR* banyak terjadi di kalangan lansia dan menjadi masalah medis global selama beberapa dekade terakhir. Diagnosis retinopati diabetik dilakukan dengan cara pemeriksaan fundus mata yang biasa dilakukan oleh dokter spesialis mata, namun proses ini rumit dan membutuhkan waktu yang tidak sedikit (Wibowo & Alamsyah, 2023).

2.2.2 *Convolutional Neural Network (CNN)*

Metode *Convolutional Neural Network (CNN)* adalah jenis kerangka kerja jaringan saraf tiruan yang dimaksudkan untuk mengolah dan menganalisis data berbentuk grid. CNN memiliki kemampuan untuk mengenali pola dan fitur dalam data melalui lapisan konvolusi, yang memungkinkan model untuk belajar secara efektif tentang struktur dan detail visual (Satrio dkk., 2024.). Metode tersebut telah menunjukkan kinerja yang konsisten dalam pencitraan medis di mana pelokalan fitur sangat penting (W. Zhang dkk., 2025). Setiap neuron dalam lapisan CNN terhubung hanya pada wilayah kecil dari input, yang dikenal sebagai *receptive field*, memungkinkan jaringan untuk belajar dan mengenali fitur-fitur lokal seperti tepi, sudut, atau tekstur. Pendekatan ini meningkatkan efisiensi dan akurasi dalam tugas-tugas pengenalan pola dan klasifikasi citra (Pratama, 2024).



Gambar 2. 2 Lapisan pada CNN

Convolution layer adalah lapisan utama yang mendasari CNN untuk melakukan operasi konvolusi. Tujuannya adalah untuk mengekstraksi fitur dari citra input, seperti tepi, tekstur, warna, atau pola kompleks lainnya,

yang merupakan karakteristik penting dalam klasifikasi gambar. Secara fundamental, operasi konvolusi merupakan bentuk dari perkalian matriks antara kernel (filter) dan bagian lokal dari citra, yang menghasilkan peta fitur (*feature map*). Proses ini terinspirasi dari mekanisme kerja otak manusia, khususnya pada visual *cortex*, di mana neuron-neuron tertentu merespons area spesifik dalam bidang pandang (dikenal sebagai *receptive field*). Kernel sendiri merupakan matriks bobot berukuran kecil (misalnya 3x3 atau 5x5) yang secara bergeser (*sliding*) dari sudut kiri atas ke kanan bawah citra, melakukan kalkulasi nilai *dot product* antara elemen-elemen dalam *patch* gambar dan nilai kernel. Proses ini memperkuat informasi penting dan menekan informasi yang tidak relevan, sehingga CNN dapat mempelajari hierarki fitur mulai dari yang sederhana hingga kompleks secara bertahap melalui beberapa lapisan.

Lapisan selanjutnya adalah *pooling layer*, yang bertugas untuk mereduksi dimensi (spasial) *feature map* dari hasil konvolusi. Hal ini dilakukan untuk mengurangi jumlah parameter, menekan biaya komputasi, serta mengurangi risiko *overfitting*. *Pooling layer* bukan mengurangi nilai, tapi mengurangi ukuran dimensi spasial dari peta fitur (*feature map*), dengan tetap mempertahankan informasi penting dari fitur yang sudah diekstrak oleh *convolution layer*. *Pooling* juga membantu mempertahankan fitur utama sambil mengurangi sensitivitas terhadap posisi objek dalam gambar, sehingga mendukung invarian translasi (*translation invariance*) sebuah konsep penting dalam visi komputer. Ada dua teknik *pooling* yang umum digunakan, yaitu *max pooling*, yang mengambil nilai maksimum dari setiap *patch* citra (menekankan fitur yang paling dominan), dan *average pooling*, yang mengambil rata-rata nilai dari *patch* tersebut (lebih merata dalam representasi fitur). Dari sudut pandang teori sinyal dan pengolahan citra digital, *pooling* dapat dianggap sebagai bentuk *downsampling* yang mempertahankan esensi sinyal visual sambil mengurangi *noise* spasial.


Lapisan terakhir dalam CNN adalah *fully connected layer* (FC), yang pada dasarnya merupakan jaringan saraf tiruan *multilayer perceptron* (MLP) klasik. Tujuan dari FC adalah melakukan transformasi akhir dari fitur-fitur hasil ekstraksi sebelumnya menjadi representasi yang dapat dipetakan ke kelas keluaran. Dalam hal ini, setiap neuron pada layer FC terhubung dengan semua neuron di layer sebelumnya, mirip seperti dalam jaringan saraf *feedforward*. Teori dasarnya berasal dari *universal approximation theorem*, yang menyatakan bahwa jaringan saraf dengan minimal satu *hidden layer* dan fungsi aktivasi non-linear dapat mendekati fungsi apa pun dengan akurasi tertentu. Dalam praktiknya, FC layer mencakup komponen penting seperti *hidden layer* (untuk pemrosesan), *activation function* (seperti ReLU, *sigmoid*, *softmax*), dan *loss function* (seperti *categorical crossentropy*) yang digunakan sebagai pengukur seberapa jauh hasil prediksi dibandingkan label asli. Fungsi aktivasi sendiri berperan penting dalam membuat jaringan mampu memodelkan hubungan non-linier antar fitur, sementara *loss function* menjadi dasar dalam proses optimasi bobot selama pelatihan.

Dalam konteks pengenalan objek, CNN telah terbukti efektif dalam melakukan proses pembelajaran mandiri untuk pengenalan objek, ekstraksi fitur, dan klasifikasi, serta dapat diterapkan pada citra resolusi tinggi dengan model distribusi *nonparametric* (Romario dkk., 2020). Selain itu, CNN juga telah berhasil diterapkan dalam pengenalan isyarat tangan untuk komunikasi tuna wicara, menunjukkan kemampuan jaringan ini dalam mengenali dan mengklasifikasikan pola isyarat tangan menjadi teks dengan akurasi yang tinggi (Pratama, 2024). Secara keseluruhan, CNN menawarkan pendekatan yang efisien dan akurat untuk berbagai aplikasi pengenalan pola dan klasifikasi citra, menjadikannya alat yang sangat berguna dalam bidang pengolahan citra dan visi komputer.

2.2.3 *EfficientNet*

EfficientNet adalah model jaringan saraf konvolusional (CNN) yang sangat inovatif dan efisien (Tan & Wong, 2023). Dibandingkan dengan

arsitektur CNN konvensional seperti *VGGNet* atau *ResNet*, *EfficientNet* menawarkan keseimbangan optimal antara akurasi dan efisiensi komputasi. Pada tingkat tinggi, arsitektur *EfficientNet* terdiri dari serangkaian blok yang diulang beberapa kali. Blok-blok ini biasanya terdiri dari lapisan konvolusi, fungsi aktivasi (*such as Swish*), dan lapisan normalisasi (*such as batch normalization*) (Abbas dkk., 2023). Salah satu keunggulan utama dari *EfficientNet* adalah pendekatan *compound scaling*-nya, yaitu metode penskalaan terkoordinasi terhadap tiga aspek utama jaringan: kedalaman (*depth*), lebar (*width*), dan resolusi input gambar (*resolution*) (Arora dkk., 2024). Dalam arsitektur ini, ketiga elemen tersebut tidak ditingkatkan secara acak, melainkan dikombinasikan secara sistematis menggunakan koefisien skala yang telah dioptimalkan sebelumnya. Hal ini memungkinkan peningkatan performa model tanpa menyebabkan pertumbuhan kompleksitas yang tidak terkendali (Luo dkk., 2021).



Gambar 2. 3 Model Arsitektur *EfficientNet*

Arsitektur *EfficientNet-B3* merupakan model *convolutional neural network* (CNN) yang dirancang dengan fokus pada efisiensi dan akurasi tinggi menggunakan pendekatan yang disebut *compound scaling*. Model ini dimulai dengan sebuah lapisan konvolusi standar berukuran 3x3 yang bertugas mengekstraksi fitur awal dari gambar masukan. Setelah itu, model terdiri dari serangkaian blok yang disebut MBConv (*Mobile Inverted Bottleneck Convolution*), yang merupakan blok konvolusi efisien

yang diadopsi dari MobileNetV2. MBConv mengandalkan *depthwise separable convolution* dan ekspansi saluran fitur (biasanya dengan faktor 6) untuk menghasilkan fitur yang kaya namun tetap hemat parameter. *Depthwise Separable Convolution* adalah teknik *EfficientNet* yang dirancang untuk mengurangi jumlah parameter dan perhitungan tanpa mengorbankan terlalu banyak akurasi. Teknik ini memisahkannya menjadi dua tahap: *depthwise convolution* (yang menerapkan satu filter untuk setiap channel input secara terpisah), dan *pointwise convolution* (yang menggunakan konvolusi 1×1 untuk menggabungkan hasil dari *depthwise*). Dengan pendekatan ini, model menjadi lebih ringan dan efisien, sehingga sangat berguna untuk aplikasi real-time atau perangkat dengan keterbatasan sumber daya, seperti smartphone.

Struktur utama *EfficientNet-B3* dibagi menjadi tujuh blok. Blok pertama menggunakan MBConv dengan ekspansi 1 dan kernel 3×3 . Blok-blok berikutnya menggunakan MBConv6 (dengan ekspansi 6), dengan variasi pada ukuran kernel (3×3 atau 5×5) dan jumlah pengulangan blok. Blok 2 hingga 6 secara bertahap memperdalam jaringan, memperbesar cakupan spasial fitur, dan meningkatkan kapasitas representasi model. Blok terakhir (Blok 7) menyempurnakan fitur dengan satu MBConv6 3×3 sebelum hasilnya diubah menjadi *feature map* untuk keperluan klasifikasi atau tugas lain. Pendekatan desain *EfficientNet* ini memungkinkan pencapaian kinerja tinggi dengan jumlah parameter dan komputasi yang jauh lebih rendah dibandingkan arsitektur CNN konvensional lainnya.

EfficientNet menggunakan pendekatan *compound scaling* untuk mengatur skala *depth* (kedalaman), *width* (lebar), dan *resolution* (resolusi gambar input) secara seimbang. Berikut rumusnya:

$$\text{depth} : d = \alpha^\phi, \text{width} : w = \beta^\phi, \text{resolution} : r = \gamma^\phi \quad (1)$$

Dengan syarat:

$$\alpha \cdot \beta^2 \cdot \gamma^2 \approx 2 \quad (2)$$

Dimana:

- $\emptyset$ adalah *compound coefficient* yang menentukan seberapa besar model akan diskalakan.
- α, β , dan γ adalah konstanta yang ditentukan melalui pencarian grid untuk menentukan rasio terbaik dalam peningkatan *depth*, *width*, dan *resolution*.

Secara teknis, *EfficientNet* memanfaatkan *mobile inverted bottleneck convolution* (MBConv), yang merupakan jenis lapisan konvolusi efisien dengan pemisahan kedalaman (*depthwise separable convolution*). Struktur ini secara signifikan mengurangi jumlah parameter dan kebutuhan komputasi, sehingga model tetap ringan namun tetap memiliki akurasi tinggi. Selain itu, penggunaan teknik seperti *swish activation function* dan *dropout regularization* turut meningkatkan kemampuan generalisasi model terhadap data baru.

Tujuan dari penelitian ini adalah untuk menetapkan model CNN sepenuhnya otomatis dengan normalisasi min-max untuk multi-klasifikasi menggunakan dataset yang tersedia untuk umum. Dengan hal tersebut, penelitian ini mengusulkan jaringan *EfficientNet* yang padat untuk klasifikasi *retinopathy diabetic* menjadi lima kelas untuk mendapatkan akurasi yang lebih baik. Ini difokuskan pada augmentasi data dengan normalisasi min-max yang dikombinasikan dengan *EfficientNet* padat untuk meningkatkan akurasi pelatihan yang lebih cepat dengan kedalaman yang lebih tinggi jaringan. Ini berisi lapisan konvolusi yang dapat dipisahkan secara mendalam untuk mengurangi ke tingkat yang lebih kecil parameter dan komputasi (Nayak dkk., 2022). Penelitian terbaru menunjukkan bahwa penggunaan *EfficientNet* dalam klasifikasi retinopati diabetik memberikan hasil yang sangat menjanjikan. Model ini telah diuji dalam berbagai skenario pengujian, dan hasilnya menunjukkan peningkatan akurasi yang signifikan dalam membedakan lima stadium penyakit dibandingkan dengan arsitektur CNN lainnya. Hal ini sangat penting untuk menghindari kesalahan klasifikasi, yang dapat berdampak

pada keputusan medis dan pengobatan pasien. Dengan demikian, penerapan *EfficientNet* tidak hanya meningkatkan performa sistem, tetapi juga berkontribusi dalam mendukung sistem skrining otomatis yang lebih akurat dan andal untuk retinopati diabetik (Zahir & Adi Saputra, 2024).

2.2.4 Grad-CAM (*Gradient-weighted Class Activation Mapping*)

Dalam *Explainable Artificial Intelligence* (XAI), *Gradient-weighted Class Activation Mapping* (Grad-CAM) merupakan teknik untuk mengeksplorasi transparansi model dan kemampuan interpretasi, salah satu metode visualisasi yang paling populer dan banyak digunakan dalam bidang visi komputer (Swaminathan, 2025). *Grad-CAM* berfungsi untuk memberikan penjelasan atas prediksi yang dilakukan oleh model *deep learning*, khususnya *Convolutional Neural Network* (CNN), dengan menyoroti bagian-bagian penting dalam citra masukan yang memengaruhi keputusan model. Teknik tersebut memanfaatkan informasi gradien dengan sehubungan dengan kelas target dan menyebarkannya ke lapisan konvolusi akhir model, menghasilkan peta panas yang menyoroti wilayah gambar yang dianggap paling penting untuk keputusan klasifikasi (Long dkk., 2025). Output dari *Grad-CAM* berupa peta panas (*heatmap*) yang ditumpangkan di atas gambar asli, sehingga area yang memiliki kontribusi besar terhadap keputusan model ditampilkan dengan warna yang lebih terang (H. Zhang & Ogasawara, 2023).

Tidak seperti metode *Class Activation Mapping* (CAM) konvensional yang membutuhkan modifikasi khusus pada arsitektur CNN (misalnya mengganti lapisan *fully connected* menjadi *global average pooling*), *Grad-CAM* bersifat lebih fleksibel karena dapat diterapkan pada berbagai jenis CNN tanpa memerlukan perubahan struktur jaringan. Hal ini menjadikan *Grad-CAM* sangat praktis untuk diterapkan pada model-model CNN modern, seperti *EfficientNet*, *ResNet*, dan *DenseNet*, dalam berbagai tugas klasifikasi dan deteksi objek. *Grad-CAM* bekerja dengan cara menghitung gradien dari skor kelas target terhadap fitur-fitur peta aktivasi (*feature map*) pada lapisan konvolusi terakhir dari model CNN. Gradien tersebut

digunakan untuk memberikan bobot pada setiap peta fitur, sehingga hasil akhir berupa peta aktivasi kelas berbobot gradien yang menggambarkan area paling relevan terhadap prediksi.

Dalam konteks klasifikasi retinopati diabetik, interpretabilitas model menjadi sangat penting karena berhubungan langsung dengan keputusan medis. Model yang mampu memberikan akurasi tinggi saja tidak cukup dokter dan tenaga medis memerlukan penjelasan visual mengenai area retina yang menjadi dasar klasifikasi stadium penyakit. Oleh karena itu, *Grad-CAM* menjadi alat bantu yang krusial dalam meningkatkan kepercayaan terhadap sistem berbasis *AI*. Dengan menggunakan *Grad-CAM*, model dapat menunjukkan bagian retina seperti makula, pembuluh darah abnormal, atau bercak mikroaneurisma yang relevan dengan masing-masing tingkat keparahan penyakit.

Penelitian-penelitian terbaru menunjukkan bahwa integrasi *Grad-CAM* ke dalam sistem klasifikasi retinopati diabetik tidak hanya meningkatkan transparansi model, tetapi juga dapat dimanfaatkan sebagai alat edukatif untuk membantu dokter umum memahami tanda-tanda visual dari penyakit ini. Dalam beberapa kasus, visualisasi dari *Grad-CAM* bahkan mengungkapkan pola atau anomali yang sebelumnya tidak diperhatikan secara manual oleh ahli mata, sehingga memperluas potensi pemanfaatannya dalam skrining massal dan pendampingan diagnosis klinis.


Dengan demikian, penerapan *Grad-CAM* dalam penelitian ini tidak hanya bertujuan untuk meningkatkan interpretabilitas model CNN yang digunakan, tetapi juga untuk mendorong adopsi sistem klasifikasi otomatis yang bertanggung jawab dan dapat dipercaya oleh tenaga kesehatan. *Grad-CAM* diharapkan dapat berperan penting sebagai jembatan antara kecerdasan buatan dan penalaran klinis manusia dalam pengambilan keputusan medis berbasis citra retina.

BAB III

METODE PENELITIAN

3.1 Metode Penelitian

Metode penelitian yang digunakan dalam penelitian ini adalah menggunakan algoritma *convolutional neural network* (CNN) dengan model arsitektur *EfficientNet*. Adapun langkah – langkah yang harus dilakukan dalam penelitian ini adalah sebagai berikut :




Gambar 3. 1 Alur Penelitian

3.1.1 Studi Literatur

Teori yang dipelajari pada penelitian ini adalah mengenai *image classification*, *deep learning*, *convolutional neural network*, *EfficientNet*, dan *Grad-CAM* yang bersumber dari berbagai macam artikel, jurnal, penelitian terdahulu, dan situs website yang tersedia di *google*.

3.1.2 Pengumpulan Data

Pada tahap ini, penulis mengumpulkan data yang diperlukan terkait penelitian yang akan dilakukan dengan menggunakan dataset yang berasal dari penelitian sebelumnya.



Gambar 3. 2 Pengumpulan Data

Dataset tersebut diambil dari salah satu *platform online* yaitu Kaggle yang kemudian datasetnya disimpan dalam *google drive* sebagai berikut:
<https://drive.google.com/file/d/1IKpDaiETKYssLy4WRkeq-qYHZwnOX1R/view?usp=sharing>.

Adapun jumlah data citra pada dataset sebanyak 1928 untuk *test_images* dan 3662 untuk *train_images*.


3.1.3 Preprocessing Data

Pada tahap perancangan model, proses *preprocessing* data memegang peranan penting dalam memastikan kualitas input yang diterima oleh model *Convolutional Neural Network* (CNN). Dataset yang digunakan berupa citra fundus retina dari kompetisi APTOS 2019 *Blindness Detection*, yang memerlukan penyesuaian format dan dimensi agar sesuai dengan kebutuhan arsitektur *EfficientNet*. Sebelum melakukan klasifikasi,

harus dilakukan implementasi dengan beberapa teknik *preprocessing* termasuk ekstraksi dan seleksi fitur (Akhtar dkk., 2025). Proses *preprocessing* diawali dengan membaca dan memuat citra berformat .png dari direktori dataset. Selanjutnya, setiap citra diubah ukurannya menjadi 224x224 piksel untuk menyesuaikan dengan input layer dari model *EfficientNetB3*. Warna citra juga dikonversi ke format RGB. Selain itu, dilakukan augmentasi data menggunakan teknik rotasi, *zoom*, dan *flip horizontal*. Augmentasi ini bertujuan untuk meningkatkan keragaman data pelatihan dan mengurangi risiko *overfitting*, sehingga model dapat mengenali fitur penting dari berbagai variasi gambar (Navaneethan dkk., 2024). Serta menggunakan *class weights* agar model lebih sensitif terhadap kelas minoritas.

3.1.4 Pelatihan Model

Proses selanjutnya adalah pengembangan dan pelatihan model (*model development and training*) menggunakan arsitektur *Convolutional Neural Network* (CNN) berbasis *EfficientNetB3*. Tahap ini diawali dengan pengembangan model, yaitu memilih dan memodifikasi arsitektur *EfficientNetB3* sebagai arsitektur utama. *EfficientNetB3* merupakan model yang telah dipra-latih (*pretrained*) pada dataset *ImageNet*, sehingga memungkinkan penerapan *transfer learning*. Modifikasi dilakukan dengan menambahkan lapisan *Global Average Pooling*, dilanjutkan dengan *Dense layer*, serta *Dropout layer* untuk mengurangi risiko *overfitting*. Lapisan *output* berupa *Dense layer*, masing-masing merepresentasikan lima tingkat keparahan *diabetic retinopathy*, menggunakan fungsi aktivasi *softmax* untuk klasifikasi multikelas.



Gambar 3. 3 Arsitektur Model *EfficientNetB3*


Gambar 3.3 menunjukkan arsitektur sistem deteksi *diabetic retinopathy* menggunakan model *Convolutional Neural Network* (CNN) berbasis *EfficientNetB3* dengan tambahan visualisasi *Grad-CAM*. Sistem ini dimulai dari masukan berupa citra retina fundus berukuran 224x224 piksel dengan tiga kanal warna (RGB). Ukuran ini merupakan standar input untuk arsitektur *EfficientNetB3* agar model dapat membaca dan memproses fitur visual secara optimal. Setelah melalui proses *preprocessing* seperti *resize* dan normalisasi, gambar dimasukkan ke dalam *EfficientNetB3* yang telah dilatih sebelumnya (*pretrained*) pada dataset ImageNet. Arsitektur *EfficientNetB3* berperan sebagai ekstraktor fitur visual dengan efisiensi tinggi, dan pada tahap ini berbagai informasi penting dari citra seperti tekstur pembuluh darah dan anomali retina diekstraksi melalui lapisan-lapisan konvolusional dan blok MBConv.

Hasil dari ekstraksi fitur ini kemudian diteruskan ke lapisan *Global Average Pooling*, yaitu sebuah metode untuk mereduksi dimensi spasial dari *feature map* menjadi vektor satu dimensi. Lapisan ini menghitung rata-rata dari seluruh nilai aktivasi pada setiap *channel*, yang bertujuan untuk merangkum informasi penting tanpa menambahkan parameter baru, sekaligus mengurangi risiko *overfitting*. Setelah proses *pooling*, data dilanjutkan ke *layer fully connected* yang terdiri dari 256 *neuron* (*Dense*) dan dilengkapi dengan mekanisme *Dropout*. *Dropout* digunakan untuk menonaktifkan sejumlah *neuron* secara acak selama pelatihan, sehingga mencegah model terlalu bergantung pada fitur tertentu dan meningkatkan generalisasi.

Selanjutnya, output dari *layer Dense* diteruskan ke lapisan klasifikasi akhir, yaitu output layer dengan fungsi aktivasi *Softmax*. Layer ini menghasilkan lima nilai probabilitas, masing-masing merepresentasikan tingkat keparahan *diabetic retinopathy*, mulai dari kelas 0 (normal) hingga kelas 4 (sangat berat). Probabilitas tertinggi menjadi hasil prediksi utama model. Sebagai pelengkap interpretasi hasil klasifikasi, sistem ini mengintegrasikan metode *Grad-CAM* (*Gradient-weighted Class Activation*

Mapping) untuk menghasilkan visualisasi *heatmap*. *Grad-CAM* bekerja dengan menggunakan gradien dari *layer* konvolusi terakhir untuk menyoroti area pada citra yang paling berkontribusi terhadap prediksi model. Hasil visualisasi ini sangat berguna bagi tenaga medis untuk memahami keputusan model dan meningkatkan kepercayaan terhadap sistem deteksi otomatis berbasis *deep learning*.

Pada tahap pelatihan model (*training*), bobot dari seluruh *layer EfficientNetB3* dibekukan (*frozen*) agar hanya bagian klasifikasi yang dilatih, sehingga proses konvergensi lebih cepat dan stabil. Model kemudian dilatih menggunakan data latih, dengan pemantauan kinerja melalui data validasi. *Optimizer* seperti Adam digunakan untuk mengatur pembaruan bobot, dan *loss function* yang digunakan adalah *categorical cross-entropy*, sesuai dengan klasifikasi multikelas. Selain itu, dilakukan juga *early stopping* untuk mencegah *overfitting* dan memilih model terbaik berdasarkan performa validasi.



Gambar 3. 4 Proses *Training CNN EfficientNet*

Flowchart pada gambar 3.4 menggambarkan proses pelatihan model *Convolutional Neural Network (CNN)* menggunakan arsitektur *EfficientNetB3* dalam lima tahapan utama. Proses dimulai dari langkah *Load Dataset*, di mana data gambar dikumpulkan dan disiapkan untuk

pelatihan. Setelah itu, data menjalani tahap *Preprocess Data*, yang meliputi *resize* gambar ke ukuran yang sesuai (224x224 piksel untuk *EfficientNetB3*), normalisasi nilai piksel, serta augmentasi data untuk meningkatkan generalisasi model. Tahap berikutnya adalah *Load EfficientNetB3*, yaitu memuat arsitektur *EfficientNetB3*, biasanya dengan bobot awal dari *ImageNet* dan menyesuaikannya dengan jumlah kelas pada dataset kita. Setelah arsitektur siap, proses masuk ke tahap *Train Model*. Terakhir, model yang telah terlatih disimpan pada tahap *Save Model*, agar bisa digunakan untuk prediksi atau *deployment* ke sistem produksi. Seluruh proses berjalan secara berurutan dan sistematis untuk membangun model klasifikasi gambar yang efisien dan akurat.

3.1.5 Evaluasi Model

Setelah proses pelatihan model selesai, tahap evaluasi model dilakukan untuk mengukur kinerja dan generalisasi model dalam mendeteksi *diabetic retinopathy* pada citra fundus retina. Parameter evaluasi utama yang digunakan meliputi nilai akurasi, *loss* (fungsi kerugian), serta analisis lebih mendalam melalui *confusion matrix* dan *classification report*. *Confusion matrix* digunakan untuk melihat distribusi prediksi model terhadap kelas yang sebenarnya, sehingga dapat dianalisis sejauh mana model berhasil membedakan berbagai tingkat keparahan *diabetic retinopathy*. Selain itu, *classification report* menghasilkan metrik seperti *precision*, *recall*, dan *F1-score* untuk masing-masing kelas, yang sangat penting untuk memahami kekuatan dan kelemahan model terhadap setiap kategori.

Untuk mengukur *Accuracy*, *Precision*, *Recall*, dan *F1-Score* berdasarkan data *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN), digunakan metode *confusion matrix*. Persamaan pertama digunakan untuk menghitung permutasi *accuracy*, persamaan kedua untuk menghitung permutasi *precision*, persamaan ketiga untuk menghitung permutasi *recall*, dan persamaan keempat untuk menghitung permutasi *F1-Score* dengan lebih dari dua kelas keluaran.

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN} \times 100\% \quad (3)$$

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (4)$$

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (5)$$

$$F1-Score = \frac{2 \times Precision \times Recall}{Precision+Recall} \times 100\% \quad (6)$$

Keterangan :

TP : Jumlah data *actual* yang sebenarnya benar dan diprediksi benar

TN : Jumlah data *actual* yang sebenarnya salah dan diprediksi salah

FP : Jumlah data *actual* yang sebenarnya benar dan diprediksi salah

FN : Jumlah data *actual* yang sebenarnya salah dan diprediksi benar

Sedangkan tiga jenis *Confusion matrix* yang digunakan dalam menghitung prediksi antara lain :

1. *Precision* adalah rasio prediksi benar dengan jumlah hasil prediksi positif dan negatif.
2. *Recall* adalah rasio prediksi benar dengan jumlah nilai aktual positif atau negatif.
3. *F1 Score* adalah perbandingan rata – rata *precision* dan *recall* yang dibobotkan.

Untuk meningkatkan interpretabilitas hasil, digunakan metode visualisasi *Grad-CAM* (*Gradient-weighted Class Activation Mapping*) yang menunjukkan area citra mana yang paling berkontribusi terhadap keputusan model. Dengan demikian, tahap evaluasi ini tidak hanya menilai akurasi prediksi secara numerik, tetapi juga mengkaji visual dari prediksi model untuk memastikan kehandalan dan transparansi sistem deteksi *diabetic retinopathy* yang dikembangkan.

3.1.6 Deployment Model

Setelah model CNN berbasis *EfficientNetB3* berhasil dilatih dan di evaluasi, tahap selanjutnya adalah *deployment model* ke dalam bentuk aplikasi interaktif berbasis web. Proses ini dilakukan menggunakan *framework* Streamlit, yang memungkinkan integrasi antara antarmuka

pengguna dan logika prediksi model secara efisien. Aplikasi dibangun sedemikian rupa agar pengguna dapat mengunggah citra fundus retina, yang kemudian diproses dan dianalisis oleh model untuk mengidentifikasi tingkat keparahan *diabetic retinopathy*. Gambar yang diunggah akan melalui proses *preprocessing* serupa seperti pada tahap pelatihan model, kemudian hasil prediksi ditampilkan secara *real-time*. Selain memberikan hasil klasifikasi, aplikasi juga menyertakan visual berbasis *Grad-CAM* (*Gradient-weighted Class Activation Mapping*), yang menyoroti area penting pada citra yang mempengaruhi keputusan model. Hal ini bertujuan untuk meningkatkan transparansi dan kepercayaan pengguna terhadap sistem yang dikembangkan. Seluruh proses implementasi aplikasi dilakukan secara modular, sehingga mudah dipelihara dan dapat dikembangkan lebih lanjut untuk kebutuhan diagnosis klinis berbasis citra retina.

3.2 Software Yang Digunakan

1. Bahasa Pemrograman

a. Python

Python merupakan bahasa pemrograman utama yang digunakan dalam pengembangan sistem ini. Python dipilih karena memiliki sintaks yang sederhana dan didukung oleh berbagai pustaka *Deep Learning* yang sangat powerful. Dengan fitur-fitur seperti kemudahan dalam pemrograman berorientasi objek, dukungan untuk pengolahan data, serta kemampuan untuk bekerja dengan data besar, Python adalah bahasa yang sangat ideal untuk pengembangan sistem berbasis *Deep Learning*.

2. Perangkat Lunak (*software*)

a. Google Colab

Google Colaboratory (Colab) dimanfaatkan sebagai lingkungan pemrograman interaktif yang berbasis *cloud* untuk menulis, menjalankan, dan menguji kode secara langsung.

Platform ini sangat mendukung proses pengembangan dan eksperimen dalam penelitian karena memungkinkan integrasi dengan berbagai pustaka Python serta 32 penyimpanan di *Google Drive*. Dengan antarmuka yang ramah pengguna dan dukungan terhadap eksekusi berbasis GPU, *Colab* mempermudah peneliti dalam memodifikasi kode, mencatat hasil eksperimen, serta mendokumentasikan proses pengujian secara terstruktur dalam satu dokumen yang interaktif.

b. *Visual Studio Code*

Visual Studio Code dipilih sebagai text editor pada pengembangan aplikasi dalam penelitian ini, *Visual Studio Code* dipilih dikarenakan mendukung banyak bahasa pemrograman dan *framework*, multi platform, performa yang sangat cepat, dan mempunyai banyak *extensions* yang dapat mempermudah proses pengembangan *website*.

c. *Streamlit*

Streamlit adalah *framework Python* yang sangat berguna untuk membangun aplikasi web interaktif secara cepat, terutama dalam proyek *machine learning* dan *deep learning* seperti CNN (*Convolutional Neural Network*). Dengan menggunakan *EfficientNet* untuk klasifikasi gambar, *Streamlit* memungkinkan untuk membuat antarmuka sederhana.

3. *Library dan Framework*

a. *TensorFlow/Keras*

TensorFlow merupakan *framework* utama untuk *deep learning* dalam program ini. Submodul Keras dari *TensorFlow* digunakan untuk membangun dan melatih model CNN. Misalnya, *EfficientNetB3* digunakan sebagai model dasar *pre-trained*, lalu ditambahkan layer tambahan untuk klasifikasi. Komponen seperti *ImageDataGenerator*, *ModelCheckpoint*, *EarlyStopping*, dan *ReduceLROnPlateau* sangat penting dalam pelatihan karena

membantu memperkuat performa model dan mencegah *overfitting*.

b. *Pandas*

Pandas digunakan untuk memuat dan memproses file CSV (*train.csv*) yang berisi data label gambar. *Library* ini juga digunakan untuk manipulasi *DataFrame*, seperti menggabungkan *path* gambar dengan nama *file* dan menangani *undersampling* data agar distribusi kelas menjadi seimbang.

c. *OpenCV*

OpenCV digunakan untuk membaca, menampilkan, dan memproses gambar. Fungsinya termasuk membaca gambar dari direktori, mengubah format warna, dan melakukan *resize* sebelum digunakan untuk visualisasi.

d. *NumPy*

NumPy digunakan untuk operasi *array* numerik, termasuk normalisasi dan konversi label. Selain itu, *library* ini juga berperan dalam pengolahan label untuk menghitung *class weight* agar pelatihan model lebih adil terhadap kelas minoritas.

e. *Matplotlib & Seaborn*

Kedua *library* visualisasi ini digunakan untuk menampilkan berbagai grafik, termasuk distribusi kelas (dengan *Seaborn*), contoh gambar tiap kelas, grafik akurasi dan *loss* selama pelatihan, serta *confusion matrix* dan visualisasi prediksi hasil model.

f. *Scikit-learn*


Library ini digunakan dalam beberapa bagian penting, seperti *train_test_split* untuk membagi data, *resample* untuk *undersampling*, *compute_class_weight* untuk menangani ketidakseimbangan kelas, dan *classification_report* serta *confusion_matrix* untuk mengevaluasi performa model.

g. *TQDM*

TQDM menyediakan progress bar saat melakukan iterasi, seperti saat menyalin gambar ke folder berdasarkan label. Ini membantu memantau proses yang membutuhkan waktu lama.

3.3 Perancangan sistem

Pada tahap ini akan menentukan alur kerja system berupa *flowchart* yang akan memberikan gambaran dari alur sistem nantinya. Di mana metode ini nantinya akan melakukan klasifikasi citra fundus retina, dan ada beberapa tahapan yang perlu dilakukan dalam penelitian ini, seperti yang terlihat pada gambar 3.5 :



Gambar 3. 5 Flowchart Alur Sistem

Gambar 3.5 merupakan *flowchart* streamlit yang menerangkan alur kerja aplikasi web dalam mengklasifikasikan gambar retina yang terkategori *class* normal, ringan, sedang, parah, atau sangat parah. Tahapan alur kerja streamlit tersebut dijelaskan sebagai berikut :

- a) Pertama *user* mengakses link streamlit dari kreator aplikasi web.
- b) Pada fitur *upload* gambar, *user* memasukkan gambar retina yang ingin diklasifikasikan.
- c) Setelah gambar retina terproses maka hasil prediksi akan mengklasifikasikan apakah gambar tersebut terkategori *class* normal, ringan, sedang, parah, atau sangat parah, selain itu terdapat probabilitas hasil dari setiap kelas.

Setelah prediksi berhasil, akan muncul visualisasi *Grad-CAM* pada bagian bawah hasil prediksi.

3.4 Perancangan *User Interface*

3.4.1 Halaman Awal Sistem




Gambar 3. 6 Tampilan halaman awal sistem

Gambar 3.6 menampilkan rancangan antarmuka pengguna (*user interface*) pada halaman awal sistem deteksi diabetik retinopati. Pada halaman ini, pengguna diminta untuk mengunggah citra yang akan dideteksi dengan menekan tombol *Browse Files*, yang kemudian akan membuka direktori penyimpanan lokal untuk memilih berkas citra. Setelah citra berhasil diunggah, sistem secara otomatis akan memproses citra tersebut menggunakan model *Deep Learning CNN EfficientNetB3*, dan

menghasilkan keluaran berupa keterangan dari hasil citra yang di *upload*. Proses ini dirancang agar berjalan secara otomatis tanpa memerlukan intervensi manual dari pengguna, sehingga meningkatkan efisiensi dan kemudahan dalam penggunaan sistem.

3.4.2 Tampilan Hasil Sistem



Gambar 3. 7 Tampilan Hasil sistem

Gambar 3.7 menampilkan antarmuka sistem setelah pengguna berhasil mengunggah citra retina untuk memulai proses deteksi diabetik retinopati. Pada tahap ini, sistem secara otomatis menampilkan citra retina yang sudah di upload, kemudian di bawahnya terdapat keterangan hasil dari prediksi model CNN *EfficientNetB3* dan visualisasi *Grad-CAM* dari citra fundus retina. Tampilan *Grad-CAM* memungkinkan pengguna untuk melihat bagian kondisi citra retina yang mempengaruhi hasil prediksi.

model, sehingga meyakinkan pengguna dalam melihat hasil prediksi yang diperoleh. Selain itu, sistem menyediakan fitur probabilitas dari semua kelas untuk melihat presentase dari hasil prediksi. Antarmuka ini dirancang untuk memberikan pengalaman pengguna yang intuitif dan efisien, serta mendukung alur kerja yang terotomatisasi dalam proses deteksi citra retina berbasis kecerdasan buatan.



BAB IV

HASIL DAN ANALISIS PENELITIAN

4.1 Hasil Pengumpulan Data

Dataset yang diperoleh dalam format zip memiliki dua komponen utama, yaitu file *train.csv* yang berisi label dan metadata gambar, serta folder *train_images* yang berisi citra retina dalam format .png. File csv mengandung dua kolom, yaitu *id_code* sebagai nama file gambar, dan *diagnosis* sebagai label kelas (dari 0 hingga 4). Untuk keperluan *preprocessing* dan pelatihan, setiap gambar dihubungkan kembali dengan labelnya, dan *path* gambar dibentuk secara dinamis menggunakan *Python* dan *library Pandas*.



Gambar 4. 1 Contoh citra dari masing-masing kelas

Pada gambar 4.1 menunjukkan dataset yang digunakan dalam penelitian ini berasal dari *APTOS 2019 Blindness Detection* dari platform Kaggle. Dataset ini berisi gambar retina (fundus) yang diambil melalui pemeriksaan funduskopi, dan bertujuan untuk mengklasifikasikan tingkat keparahan *diabetic retinopathy* (DR) berdasarkan lima kategori, yaitu:

Tabel 4. 1 *Labelling* pada dataset diabeik retinopati

Kode Kelas	Tingkat DR	Keterangan
0	<i>NO DR</i>	Retina tidak menunjukkan tanda-tanda retinopati diabetik. Tidak ada kelainan pada pembuluh darah mata. Kondisi ini dianggap normal.
1	<i>Mild DR</i> (Ringan)	Terdapat sedikit mikroaneurisma (pelebaran kecil pada pembuluh darah retina), tanda awal dari DR.

		Tidak ada perdarahan atau eksudat keras.
2	<i>Moderate DR</i> (Sedang)	Ditemukan lebih banyak mikroaneurisma dan mungkin disertai perdarahan ringan atau eksudat keras. Tanda-tanda kerusakan pembuluh darah mulai terlihat.
3	<i>Severe DR</i> (Parah)	Perdarahan retina yang luas, banyak mikroaneurisma, dan kerusakan pembuluh darah yang signifikan. Risiko tinggi berkembang ke retinopati proliferatif.
4	<i>Poliferative DR</i> (Sangat Parah)	Tahap paling lanjut. Terdapat pertumbuhan pembuluh darah abnormal di retina (neovaskularisasi), yang dapat menyebabkan perdarahan vitreous, jaringan parut, atau bahkan kebutaan permanen.

Setelah data berhasil diekstrak, analisis awal menunjukkan bahwa dataset memiliki distribusi kelas yang tidak seimbang (*imbalanced dataset*), di mana kelas 0 (tidak ada retinopati) mendominasi sebagian besar sampel. Hal ini berpotensi menimbulkan bias saat pelatihan model jika tidak ditangani. Oleh karena itu, dilakukan proses *undersampling* terhadap kelas mayoritas, yaitu dengan membatasi jumlah maksimum sampel per kelas menjadi 1000 gambar. Langkah ini bertujuan untuk menciptakan distribusi kelas yang lebih seimbang dan meningkatkan performa model dalam mengenali kelas minoritas.

Gambar-gambar yang telah diproses kemudian disalin ke dalam struktur folder baru berdasarkan label masing-masing kelas. Struktur ini dibuat agar sesuai dengan format input `flow_from_directory` pada *TensorFlow*, yang secara otomatis membaca gambar berdasarkan struktur folder sebagai kelas label. Proses pengelompokan ini juga mempermudah proses augmentasi dan validasi data selanjutnya.

Secara keseluruhan, hasil pengumpulan dan pemrosesan awal data menunjukkan bahwa dataset APTOS 2019 sangat representatif untuk

mendeteksi *diabetic retinopathy* melalui citra fundus retina, dan telah berhasil dipersiapkan dalam format yang optimal untuk proses pelatihan model menggunakan arsitektur CNN *EfficientNetB3*.

4.2 Hasil *Preprocessing* Data

Proses *preprocessing* data dilakukan untuk mempersiapkan dataset agar dapat digunakan dalam pelatihan model CNN berbasis arsitektur *EfficientNetB3*. Tahapan ini dimulai dengan membaca file label train.csv yang berisi dua kolom utama: id_code (nama file gambar retina) dan diagnosis (label kelas tingkat *diabetic retinopathy*). Setiap nilai dalam id_code kemudian dikonversi menjadi *path* absolut ke gambar terkait di folder train_images, sehingga gambar dapat diakses langsung melalui *Pandas DataFrame*.

Selanjutnya, dilakukan penyalinan nilai diagnosis ke kolom baru bernama label, dengan tetap mempertahankan tipe data numerik (integer). Label ini digunakan untuk kebutuhan pelabelan selama pelatihan model dan proses *one-hot encoding*. Hal ini bertujuan untuk memudahkan pengelompokan gambar berdasarkan kelas selama proses augmentasi dengan *ImageDataGenerator*.

```
Jumlah data per kelas (sebelum upsampling):
label
0      1805
2       999
1       370
4       295
3       193
Name: count, dtype: int64
```

Gambar 4. 2 Jumlah data kelas sebelum *upsampling*

Dataset APTOS 2019 memiliki ketidakseimbangan distribusi kelas (*imbalance*). Distribusi awal jumlah sampel per kelas dihitung menggunakan `value_counts()`. Untuk mengatasi masalah ini, dilakukan *upsampling* terhadap kelas minoritas dengan menggandakan sampel secara acak (resampling dengan `replacement=True`) hingga jumlah setiap kelas

sama dengan kelas mayoritas. Setelah *upsampling*, *DataFrame* diacak kembali dan dibagi menjadi *train set* dan *validation set* menggunakan `train_test_split` dengan `stratify` agar proporsi kelas tetap terjaga.

```
Jumlah data per kelas (sesudah upsampling):
label
2    1805
4    1805
3    1805
1    1805
0    1805
Name: count, dtype: int64
```

Gambar 4. 3 jumlah data kelas setelah *upsampling*

Setelah data diseimbangkan, jalur absolut ke setiap gambar disimpan dalam kolom `id_code` pada *DataFrame*, dan label kelas disertakan dalam kolom `label`. Dengan struktur ini, gambar tidak perlu dipindahkan ke folder terpisah per kelas. Sebaliknya, data dikelola langsung melalui *DataFrame*, sehingga proses pembacaan dan pelabelan gambar dapat dikontrol secara fleksibel dalam class data generator kustom, tanpa mengandalkan struktur direktori atau metode `flow_from_directory()`.

Proses *preprocessing* ini juga mencakup pembacaan citra retina menggunakan OpenCV, di-*resize* ke ukuran 224×224 piksel, dikonversi ke format RGB, dan dinormalisasi ke rentang nilai 0–1 untuk memastikan konsistensi warna. Maksudnya adalah data warna (misalnya nilai RGB) diubah skalanya supaya berada di antara 0 dan 1, bukan di antara 0 dan 255 seperti aslinya. Augmentasi data diterapkan secara opsional melalui *ImageDataGenerator*, meliputi rotasi $\pm 10^\circ$, *zoom* hingga 10%, dan *flip horizontal*. Hal ini membantu meningkatkan keragaman data dan mencegah *overfitting* selama pelatihan.

Tahap akhir dari *preprocessing* adalah augmentasi data menggunakan *ImageDataGenerator*, yang diterapkan pada citra retina dengan rotasi, *zoom*, dan *flip horizontal*. Augmentasi ini membantu meningkatkan keragaman data dan mencegah *overfitting* selama pelatihan. Secara keseluruhan, hasil *preprocessing* ini memastikan bahwa dataset telah

dibersihkan, diseimbangkan, disusun ulang, dan diperkuat secara visual untuk mendukung pelatihan model *deep learning* dengan cara yang optimal dan efisien.

4.3 Implementasi Pelatihan Model

Setelah proses *preprocessing* selesai, tahap selanjutnya adalah melakukan pelatihan model *Convolutional Neural Network* (CNN) dengan arsitektur *EfficientNetB3*. Model ini dipilih karena memiliki performa tinggi dan efisiensi parameter yang baik untuk klasifikasi citra retina, seperti pada kasus deteksi *diabetic retinopathy*.

Output dari *EfficientNetB3* kemudian dilewatkan ke dalam `GlobalAveragePooling2D`, yang berfungsi mengubah fitur spasial menjadi vektor satu dimensi tanpa parameter tambahan, diikuti oleh `Dropout(0.4)` untuk mengurangi risiko *overfitting* dengan menonaktifkan 40% neuron secara acak saat proses pelatihan. Setelah itu, model memiliki output layer berupa `Dense(5, activation='softmax')`, yang menghasilkan lima skor probabilitas masing-masing untuk satu dari lima kelas tingkat keparahan *diabetic retinopathy* (kelas 0: normal hingga kelas 4: sangat berat). Model akhir dikompilasi menggunakan *optimizer Adam*, yang merupakan algoritma efisien untuk mengatur bobot model, dengan fungsi kerugian *categorical_crossentropy* yang sesuai untuk klasifikasi multi-kelas, serta metrik akurasi untuk mengevaluasi performa model selama pelatihan.

Secara keseluruhan, model ini dirancang untuk mengoptimalkan klasifikasi citra retina ke dalam lima tingkat retinopati diabetik dengan memanfaatkan kekuatan arsitektur *EfficientNetB3* dan strategi regulasi *overfitting* melalui *dropout*. Model inilah yang kemudian dilatih pada dataset APTOS 2019, dan menjadi dasar dari sistem deteksi otomatis yang dilaporkan dalam penelitian.

4.4 Evaluasi Model

Setelah model CNN berbasis *EfficientNetB3* selesai dilatih, tahap selanjutnya adalah melakukan evaluasi performa model pada data validasi. Tujuan dari evaluasi ini adalah untuk mengetahui sejauh mana model mampu mengklasifikasikan gambar retina ke dalam lima kelas *diabetic retinopathy* dengan benar, serta mengidentifikasi potensi kesalahan klasifikasi yang terjadi.

4.4.1 Evaluasi Akurasi dan Loss


Model terbaik disimpan dalam format (model.h5) dimuat ulang menggunakan `load_model()` dari *Keras*. Evaluasi dilakukan terhadap generator validasi (`val_gen`) yang berisi 20% dari data hasil *preprocessing*. Hasil evaluasi menunjukkan nilai akurasi validasi akhir (*final validation accuracy*) dan loss validasi, yang menjadi indikator utama keberhasilan pelatihan model.

Dari hasil evaluasi, model menghasilkan akurasi sebesar 0.96, berarti 96% prediksi model terhadap data uji sesuai dengan label aslinya. Nilai ini menunjukkan bahwa model memiliki tingkat ketepatan yang tinggi dalam mengklasifikasikan data.

Akurasi yang diperoleh ini menunjukkan bahwa model sudah mampu mengenali pola dari citra retina dengan cukup baik, meskipun belum sempurna. Perlu juga dipahami bahwa akurasi saja tidak cukup untuk menilai kinerja model secara menyeluruh, terutama karena model ini digunakan untuk klasifikasi multi-kelas dengan tingkat keparahan retinopati diabetik yang berbeda-beda.

4.4.2 Visualisasi Akurasi dan Loss

Untuk memahami perkembangan model selama proses pelatihan, dilakukan visualisasi grafik akurasi dan *loss* untuk data pelatihan dan validasi. Grafik ini memperlihatkan apakah model mengalami *overfitting* (akurasi validasi menurun sementara akurasi pelatihan meningkat) atau *underfitting* (kedua akurasi rendah secara konsisten).



Gambar 4. 4 Grafik akurasi dan *loss* dari pelatihan

Dari gambar grafik 4.4 menunjukkan bahwa nilai *train accuracy* meningkat secara konsisten dari sekitar 0,63 pada *epoch* pertama hingga mendekati 1,00 pada *epoch* ke-10, dan kemudian stabil hingga akhir pelatihan. *Validation accuracy* pada awalnya berada di kisaran 0,20–0,65 dengan fluktuasi pada *epoch* ke-2 hingga ke-5, sebelum akhirnya meningkat signifikan pada *epoch* ke-6 dan stabil di kisaran 0,94–0,96 hingga *epoch* terakhir. Pola ini mengindikasikan bahwa model membutuhkan beberapa *epoch* awal untuk menyesuaikan bobot dan mempelajari representasi yang baik dari data, sebelum akhirnya mencapai performa yang stabil baik pada data latih maupun data validasi.


Pada grafik *loss*, *train loss* berada pada nilai yang sangat rendah sejak awal dan terus stabil mendekati nol, sedangkan *validation loss* mengalami lonjakan yang sangat tinggi pada *epoch* awal (lebih dari 5000) sebelum turun drastis mendekati nol mulai *epoch* ke-3 dan stabil hingga akhir pelatihan. Lonjakan ekstrem pada *validation loss* di awal pelatihan ini kemungkinan disebabkan oleh *batch* awal data validasi yang tidak representatif atau kombinasi inisialisasi bobot dan *learning rate* yang menyebabkan prediksi awal jauh dari label sebenarnya. Setelah proses optimisasi berlangsung, *validation loss* menurun tajam dan stabil, selaras dengan meningkatnya *validation accuracy*.

Secara keseluruhan, meskipun terdapat anomali pada *validation loss* di awal pelatihan, tren akurasi yang stabil tinggi dan *loss* yang rendah pada akhir pelatihan menunjukkan bahwa model telah mampu mempelajari pola

data dengan baik dan menghasilkan kinerja yang konsisten pada data latih maupun data validasi.

4.4.3 *Confusion Matrix*

Confusion matrix divisualisasikan menggunakan `ConfusionMatrixDisplay` dari *Scikit-learn*, sehingga lebih mudah dalam mengamati pola kesalahan model. Hal ini penting untuk melihat apakah model kesulitan dalam membedakan kelas-kelas yang berdekatan secara visual. Untuk analisis yang lebih mendalam, digunakan *confusion matrix* guna mengevaluasi jumlah prediksi yang benar dan salah pada masing-masing kelas. Matrix ini menyajikan informasi sebagai berikut:



Gambar 4. 5 *Confusion Matrix*

Dari gambar 4.5 menunjukkan distribusi prediksi model terhadap label sebenarnya untuk lima kelas tingkat keparahan *diabetic retinopathy*. Secara umum, model mampu mengklasifikasikan sebagian besar citra dengan benar, terlihat dari dominasi angka pada diagonal utama matriks. Untuk kelas 0, terdapat 219 prediksi benar dari total 222 sampel, dengan hanya sedikit kesalahan klasifikasi ke kelas 1 dan 2. Kelas 1 juga memiliki

kinerja yang tinggi dengan 209 prediksi benar dari 216 sampel, walaupun terdapat sebagian kecil citra yang salah diklasifikasikan ke kelas 0, 2, 3, dan 4.

Kinerja pada kelas 2 relatif baik dengan 188 prediksi benar dari 218 sampel, meskipun terdapat kesalahan klasifikasi ke kelas 1, 3, dan 4, dengan jumlah tertinggi salah ke kelas 1 (19 kasus). Hal ini menunjukkan bahwa citra pada kelas 2 memiliki kemiripan visual dengan kelas 1 sehingga model kadang mengalami kebingungan dalam membedakannya. Untuk kelas 3, model menunjukkan akurasi yang hampir sempurna dengan 221 prediksi benar dari 222 sampel, dan hanya 1 kesalahan ke kelas 4. Demikian pula pada kelas 4, model berhasil memprediksi 223 dari 226 sampel dengan benar, dengan kesalahan hanya pada kelas 3.

Secara keseluruhan, *confusion matrix* ini menunjukkan bahwa model memiliki performa klasifikasi yang sangat baik di semua kelas, dengan tingkat kesalahan relatif rendah. Kesalahan yang terjadi sebagian besar merupakan *misclassification* ke kelas yang berdekatan tingkat keparahannya, yang dapat dimaklumi mengingat kemiripan karakteristik visual pada citra retina antar kelas tersebut.

4.4.4 Classification Report

Selain *confusion matrix*, ditampilkan juga *classification report* yang berisi metrik evaluasi penting lainnya:

- *Precision*: proporsi prediksi benar dibanding seluruh prediksi pada kelas tertentu.
- *Recall*: proporsi prediksi benar dibanding jumlah aktual pada kelas tersebut.
- *F1-Score*: harmonisasi antara *precision* dan *recall*.

Tabel 4. 2 *Classification Report*

Kelas	Deskripsi	Precision	Recall	F1-Score
0	Tidak ada DR	1.00	0.99	0.99
1	DR ringan (<i>Mild</i>)	0.91	0.97	0.94
2	DR sedang (<i>Moderate</i>)	0.97	0.86	0.91

3	DR berat (<i>Severe</i>)	0.96	1.00	0.98
4	DR sangat berat	0.97	0.99	0.98
<i>Accuracy</i>				0.96
<i>Macro avg</i>		0.96	0.96	0.96
<i>Weighted avg</i>		0.96	0.96	0.96

Dari tabel 4.2 menunjukkan bahwa model memiliki kinerja klasifikasi yang sangat baik pada semua kelas *diabetic retinopathy*. Pada kelas 0, model mencapai nilai *precision* sempurna sebesar 1,00 dan *recall* sebesar 0,99, menghasilkan *f1-score* 0,99 yang menunjukkan kemampuan mendeteksi kasus tanpa retinopati secara hampir sempurna tanpa banyak kesalahan prediksi positif palsu. Kelas 1 memiliki *precision* 0,91 dan *recall* 0,97 dengan *f1-score* 0,94, yang mengindikasikan bahwa meskipun kemampuan model dalam menemukan semua kasus kelas ini sangat baik, terdapat sebagian prediksi yang keliru mengklasifikasikan citra dari kelas lain sebagai kelas 1.

Pada kelas 2, *precision* tinggi sebesar 0,97 menunjukkan bahwa prediksi kelas ini jarang salah, namun *recall* lebih rendah di angka 0,86, yang berarti masih ada sejumlah kasus kelas 2 yang tidak terdeteksi dan diklasifikasikan ke kelas lain. Kelas 3 dan kelas 4 menunjukkan performa yang sangat baik dengan *precision* di atas 0,96 dan *recall* hampir sempurna (1,00 untuk kelas 3 dan 0,99 untuk kelas 4), menghasilkan *f1-score* 0,98 untuk keduanya.

Secara keseluruhan, model memperoleh akurasi total sebesar 0,96, dengan nilai *macro average* dan *weighted average* yang sama, yaitu *precision*, *recall*, dan *f1-score* masing-masing sebesar 0,96. Nilai *macro average* yang tinggi menunjukkan bahwa performa model konsisten di semua kelas tanpa bias signifikan terhadap kelas tertentu, sementara *weighted average* yang sama menunjukkan bahwa model juga mempertahankan kinerja tinggi meskipun mempertimbangkan distribusi jumlah sampel di tiap kelas. Hasil ini membuktikan bahwa model mampu

mengklasifikasikan citra retina secara akurat dan konsisten pada semua tingkat keparahan *diabetic retinopathy*.

4.4.5 Evaluasi *Grad-CAM*

Selain evaluasi berbasis metrik numerik seperti akurasi, *precision*, *recall*, dan *f1-score*, penelitian ini juga mengevaluasi interpretabilitas model menggunakan visualisasi *Grad-CAM*. *Grad-CAM* menghasilkan *heatmap* yang menyoroti area citra retina yang paling berkontribusi terhadap prediksi model. Pada kelas 0 (normal), *Grad-CAM* menunjukkan area fokus yang tersebar merata tanpa titik terang signifikan, sesuai dengan kondisi retina yang sehat. Untuk kelas 1 (*mild*) dan kelas 2 (*moderate*), area sorotan cenderung mengarah pada titik-titik kecil atau bercak merah yang mengindikasikan mikroaneurisma atau perdarahan ringan.

Pada kelas 3 (*severe*) dan kelas 4 (*proliferative*), *heatmap Grad-CAM* memperlihatkan sorotan intens di sekitar pembuluh darah yang abnormal dan area dengan perdarahan luas atau neovaskularisasi. Hasil ini konsisten dengan karakteristik visual tiap tingkat keparahan *DR* dan mendukung validitas prediksi model. Evaluasi ini menunjukkan bahwa *Grad-CAM* tidak hanya meningkatkan transparansi model, tetapi juga dapat menjadi alat bantu interpretasi medis dengan memberikan petunjuk visual yang relevan untuk diagnosis klinis.

4.5 Hasil Implementasi

Setelah tahap pemodelan dan pelatihan selesai, selanjutnya implementasi sistem deteksi diabetik retinopati ke dalam *platform website* dengan menggunakan *framework* streamlit. Berikut ini merupakan hasil implementasi sistem :



Gambar 4. 6 Tampilan awal sistem


Pada gambar 4.6 menunjukkan tampilan awal dari antarmuka aplikasi deteksi Retinopati Diabetik (*Diabetic Retinopathy*) yang dikembangkan menggunakan *framework* Streamlit. Pada tampilan ini, pengguna disambut dengan judul aplikasi “Deteksi Retinopati Diabetik (DR)”. Tepat di bawah judul, terdapat deskripsi singkat yang memberikan informasi kepada pengguna mengenai tujuan dari aplikasi ini, yaitu untuk mengunggah gambar retina fundus dan mendapatkan hasil prediksi beserta hasil visual secara otomatis.

Aplikasi ini menyediakan fitur unggah gambar retina dalam format .jpg atau .png yang dapat dilakukan dengan dua cara, yaitu melalui mekanisme *drag and drop* atau dengan menelusuri file menggunakan tombol "*Browse files*". Selain itu, terdapat informasi tambahan mengenai batas maksimal ukuran *file* yang diunggah, yaitu sebesar 200MB per gambar. Desain antarmuka aplikasi ini dibuat dengan tampilan yang minimalis, terpusat, dan responsif agar pengguna dapat berinteraksi dengan mudah dan nyaman.

Tampilan awal ini merupakan langkah awal dalam proses kerja aplikasi sebelum pengguna mendapatkan hasil klasifikasi kondisi retina dan visualisasi area penting yang dianalisis oleh model melalui metode *Grad-CAM*.

4.5.1 Implementasi Kelas 0 (Normal)

Tampilan hasil implementasi sistem deteksi Retinopati Diabetik berbasis *Convolutional Neural Network* (CNN) dengan dukungan visualisasi *Grad-CAM*. Setelah pengguna mengunggah citra retina fundus melalui antarmuka aplikasi, sistem secara otomatis menampilkan hasil analisis yang terdiri dari visualisasi gambar retina asli, peta panas (*heatmap*) *Grad-CAM*, prediksi klasifikasi, serta probabilitas dari masing-masing kelas.



Gambar 4. 7 Implementasi hasil dari kelas 0 (normal)

Pada gambar 4.7 menunjukkan dua gambar retina yang diletakkan berdampingan. Gambar sebelah kiri adalah citra retina fundus yang diunggah oleh pengguna, sementara gambar di sebelah kanan merupakan hasil visualisasi *Grad-CAM* yang menunjukkan area fokus model saat melakukan prediksi. Warna-warna dalam *heatmap Grad-CAM* mengindikasikan area yang paling berkontribusi terhadap keputusan


model, tetapi warna biru pada gambar tersebut terlihat tanpa bercak-bercak putih, sehingga hasil menunjukkan tidak ada *DR*. Di bawah visualisasi tersebut, terdapat hasil klasifikasi model yang menyatakan bahwa gambar retina tidak menunjukkan tanda-tanda Retinopati Diabetik, yang ditandai dengan label "Prediksi: Tidak ada *DR*" disertai deskripsi tambahan "Retina normal".

Selanjutnya, pada sisi kanan bawah ditampilkan grafik batang horizontal yang merepresentasikan probabilitas dari setiap kelas diagnosis. Grafik ini memperlihatkan bahwa nilai probabilitas tertinggi berada pada kelas "Tidak ada *DR*", sementara empat kelas lainnya (*DR* Ringan, *DR* Sedang, *DR* Berat, dan *DR Proliferasif*) memiliki nilai yang sangat rendah atau mendekati nol. Hal ini mengonfirmasi bahwa model memiliki tingkat keyakinan yang tinggi terhadap klasifikasi yang diberikan.

Keseluruhan tampilan ini menunjukkan bahwa sistem mampu memberikan hasil deteksi yang komprehensif dan mudah diinterpretasikan, tidak hanya dalam bentuk teks klasifikasi, tetapi juga dalam bentuk visual yang informatif, sehingga mempermudah proses validasi hasil oleh pengguna atau tenaga medis.

4.5.2 Implementasi Kelas 1 (Ringan)

Hasil implementasi sistem deteksi *Diabetic Retinopathy* (DR) dengan menggunakan model *deep learning* berbasis CNN dan interpretasi visual *Grad-CAM*. Setelah pengguna mengunggah gambar retina fundus, sistem menampilkan output berupa hasil klasifikasi, visualisasi citra dan *Grad-CAM*, serta probabilitas dari setiap kelas.



Gambar 4. 8 Implementasi hasil dari kelas 1 (ringan)


Pada gambar 4.8 menunjukkan dua visualisasi berdampingan: citra retina asli di sebelah kiri dan peta *Grad-CAM* di sebelah kanan. *Grad-CAM* (*Gradient-weighted Class Activation Mapping*) berfungsi untuk menyoroti area-area yang paling berkontribusi terhadap keputusan model. Dalam visualisasi *Grad-CAM*, warna biru dan hijau tanpa bercak-bercak putih menunjukkan area dengan perhatian tinggi, sedangkan warna merah dan kuning menunjukkan perhatian rendah. Terlihat bahwa model memberikan fokus pada bagian bawah retina, yang kemungkinan mengindikasikan adanya mikroaneurisma atau kelainan kecil yang menjadi ciri awal *DR* ringan. Di bagian bawah, hasil klasifikasi ditampilkan dengan prediksi utama yaitu "*DR* Ringan". Informasi tambahan "Mikroaneurisma kecil" diberikan sebagai indikator karakteristik dari kelas ini. Hal ini menunjukkan bahwa sistem berhasil mendeteksi adanya perubahan awal pada retina yang sesuai dengan kategori *DR* ringan.

Pada grafik batang “Probabilitas Tiap Kelas”, ditampilkan nilai probabilitas dari setiap kategori. Kelas “*DR Ringan*” memiliki nilai probabilitas tertinggi di antara lima kelas lainnya, disusul oleh “Tidak ada *DR*”, sementara kategori *DR Sedang*, *Berat*, dan *Proliferatif* memiliki nilai probabilitas yang sangat kecil. Grafik ini mendukung keputusan prediksi yang dibuat oleh model, dan menunjukkan keyakinan relatif dari sistem terhadap hasil yang diberikan.

Secara keseluruhan, hasil ini memperlihatkan kemampuan sistem dalam mengenali indikasi awal Retinopati Diabetik serta memberikan penjelasan visual melalui *Grad-CAM* yang memperkuat interpretasi medis. Hal ini berguna bagi tenaga medis untuk memahami dan memverifikasi hasil deteksi secara lebih informatif dan akurat.

4.5.3 Implementasi Kelas 2 (Sedang)

Tampilan hasil implementasi sistem deteksi *Diabetic Retinopathy* (DR) terhadap salah satu citra retina fundus pasien. Setelah gambar retina diunggah, sistem secara otomatis melakukan analisis dan menghasilkan tiga jenis output utama: visualisasi citra & *Grad-CAM*, prediksi kelas, serta probabilitas dari masing-masing tingkat keparahan *DR*.



Gambar 4. 9 Implementasi hasil dari kelas 2 (sedang)

Pada gambar 4.9 menunjukkan dua gambar berdampingan: sebelah kiri merupakan citra retina asli, sementara sebelah kanan adalah visualisasi *Grad-CAM* (*Gradient-weighted Class Activation Mapping*). Gambar *Grad-CAM* menunjukkan area yang menjadi fokus perhatian model saat melakukan prediksi. Tampak bahwa area berwarna biru tua hingga ungu serta bercak putih pada bagian tengah retina menjadi pusat perhatian model, menandakan keberadaan fitur penting seperti perdarahan atau kerusakan pembuluh darah yang khas pada tingkat *DR* sedang. Berdasarkan hasil analisis model, sistem memberikan prediksi utama yaitu "*DR* Sedang", dengan keterangan tambahan "Perdarahan & pembuluh rusak". Ini menunjukkan bahwa model mendeteksi adanya kelainan pada retina yang mengindikasikan kerusakan vaskular lebih lanjut dari *DR* ringan, namun belum mencapai kondisi berat atau proliferaatif.


Visualisasi probabilitas tiap kelas ditampilkan dalam bentuk grafik batang di kanan bawah. Terlihat bahwa probabilitas tertinggi berada pada kelas "*DR Sedang*", diikuti oleh kelas "*DR Ringan*" dan "*DR Berat*" dalam jumlah kecil, sedangkan kelas "*Tidak ada DR*" dan "*DR Proliferaatif*" memiliki probabilitas yang sangat rendah. Hal ini menunjukkan keyakinan tinggi model terhadap prediksi kelas "*DR Sedang*".

Secara keseluruhan, implementasi ini menunjukkan bahwa sistem mampu memberikan hasil diagnosis yang cukup detail dan informatif, tidak hanya melalui klasifikasi otomatis, tetapi juga melalui interpretasi visual (*Grad-CAM*) yang membantu tenaga medis dalam memahami area-area penting pada citra retina yang menjadi dasar pengambilan keputusan oleh model.



4.5.4 Implementasi Kelas 3 (Berat)

Tampilan hasil implementasi sistem deteksi Retinopati Diabetik berbasis *Convolutional Neural Network* (CNN) dengan dukungan visualisasi *Grad-CAM*. Setelah pengguna mengunggah citra retina fundus melalui antarmuka aplikasi, sistem secara otomatis menampilkan hasil analisis yang terdiri dari visualisasi gambar retina asli, peta panas (*heatmap*) *Grad-CAM*, prediksi klasifikasi, serta probabilitas dari masing-masing kelas.




Gambar 4. 10 Implementasi hasil dari kelas 3 (berat)

Pada gambar 4.10 menunjukkan citra retina fundus pasien, di mana tampak banyak bercak putih dan kekuningan yang tersebar cukup luas. Ini menunjukkan adanya eksudat keras, pendarahan mikro, atau kerusakan retina yang cukup signifikan. Sementara pada gambar kanan atas adalah visualisasi *Grad-CAM*, yang menunjukkan area fokus model saat mengambil keputusan. Wilayah berwarna biru keunguan di tengah retina menandakan bahwa area tersebut sangat memengaruhi klasifikasi oleh

model. Berdasarkan analisis citra tersebut, sistem memberikan hasil prediksi: "*DR Berat*", yang disertai dengan deskripsi "Kerusakan retina signifikan". Hal ini menunjukkan bahwa model mendeteksi tanda-tanda jelas dari kerusakan retina tingkat lanjut, termasuk eksudat dan hemoragi yang lebih luas dibandingkan kondisi sebelumnya.


Dukungan terhadap hasil prediksi ini diperkuat oleh grafik probabilitas kelas di bagian kanan bawah. Grafik menunjukkan bahwa probabilitas tertinggi berada pada kelas *DR Berat*, disusul oleh kelas *DR Sedang* dan *DR Proliferaatif* dalam jumlah kecil, sedangkan kelas *DR Ringan* dan Tidak ada *DR* nyaris mendekati nol. Ini mengindikasikan bahwa model sangat yakin terhadap klasifikasi yang diberikan.

Dengan demikian, implementasi ini membuktikan bahwa sistem mampu mendeteksi tingkat keparahan *DR* dengan cukup baik, serta menyediakan interpretasi visual (*Grad-CAM*) untuk memudahkan pemahaman dokter atau tenaga medis dalam meninjau bagian retina yang terkena dampak paling parah.



4.5.5 Implementasi Kelas 4 (Sangat Berat)

Tampilan hasil implementasi sistem deteksi Retinopati Diabetik berbasis *Convolutional Neural Network* (CNN) dengan dukungan visualisasi *Grad-CAM*. Setelah pengguna mengunggah citra retina fundus melalui antarmuka aplikasi, sistem secara otomatis menampilkan hasil analisis yang terdiri dari visualisasi gambar retina asli, peta panas (*heatmap*) *Grad-CAM*, prediksi klasifikasi, serta probabilitas dari masing-masing kelas.



Gambar 4. 11 Implementasi hasil dari kelas 4 (sangat berat)

Pada gambar 4.11 menunjukkan citra retina, di mana terlihat struktur pembuluh darah dan adanya beberapa kelainan seperti bercak-bercak yang dapat mengindikasikan pembentukan pembuluh darah baru yang tidak normal. Gambar di sebelah kanannya merupakan visualisasi

Grad-CAM, yang menunjukkan area yang paling berkontribusi terhadap keputusan model. Warna biru-ungu serta banyak bercak-bercak di bagian kanan retina menunjukkan area yang sangat memengaruhi klasifikasi, mengindikasikan kemungkinan adanya pembuluh darah abnormal atau jaringan baru yang menjadi ciri khas *DR* stadium lanjut. Model memberikan hasil prediksi: *DR Proliferasif*, dengan deskripsi "Pembuluh abnormal, risiko tinggi kebutaan". Ini merupakan tingkat keparahan tertinggi dalam klasifikasi Retinopati Diabetik, di mana terjadi pertumbuhan pembuluh darah baru yang rapuh dan mudah pecah, sehingga sangat berisiko menyebabkan perdarahan hebat dalam retina dan bahkan lepasnya retina dari dinding mata.

Hasil prediksi ini didukung oleh grafik probabilitas kelas, di mana kelas *DR Proliferasif* memiliki probabilitas tertinggi secara signifikan, mendekati angka 1.0. Kelas-kelas lainnya seperti *DR Berat*, *Sedang*, dan *Ringan* hanya menunjukkan probabilitas yang sangat kecil, menandakan keyakinan tinggi dari model terhadap prediksi tersebut.

Dengan demikian, implementasi sistem ini menunjukkan bahwa model tidak hanya mampu mendeteksi keberadaan *DR*, tetapi juga mengklasifikasikan tingkat keparahannya secara detail dan dapat diandalkan. Interpretasi visual *Grad-CAM* juga membantu memberikan penjelasan tambahan mengenai area retina yang menjadi fokus perhatian model, mendukung pengambilan keputusan oleh dokter secara lebih akurat dan cepat.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penggunaan arsitektur *EfficientNetB3* dalam pengembangan model klasifikasi *diabetic retinopathy* pada citra fundus retina memberikan hasil yang cukup memuaskan. Model mampu mengklasifikasikan lima tingkat keparahan penyakit dengan akurasi mencapai 96%, serta memberikan visualisasi prediksi melalui *Grad-CAM* yang memperjelas area citra yang berpengaruh terhadap hasil klasifikasi.

Visualisasi *Grad-CAM* yang diterapkan pada sistem ini terbukti efektif dalam membantu memahami dasar keputusan model, ditunjukkan dengan konsistensi area sorotan heatmap terhadap lokasi kelainan pada citra retina sesuai dengan karakteristik tiap tingkat keparahan *diabetic retinopathy*. Pada kelas ringan hingga sedang, *Grad-CAM* menyoroti area yang mengandung mikroaneurisma atau perdarahan kecil, sedangkan pada kelas berat hingga *proliferasif*, sorotan terlihat jelas di sekitar pembuluh darah abnormal dan area perdarahan luas. Hal ini membuktikan bahwa model fokus pada fitur visual yang relevan secara medis, sehingga meningkatkan interpretabilitas dan kepercayaan pengguna. Meskipun demikian, terdapat beberapa kasus di mana sorotan *Grad-CAM* kurang terpusat pada area kelainan, yang menunjukkan ruang perbaikan pada tahap pelatihan atau *preprocessing*. Selain itu, implementasi model dalam bentuk aplikasi berbasis Streamlit berhasil mempermudah penggunaan sistem deteksi ini secara langsung oleh pengguna dengan antarmuka yang sederhana dan interaktif.

Kinerja model menunjukkan hasil yang sangat baik terutama pada kelas “tidak ada DR” (kelas 0) dengan *precision* sempurna (1,00) dan *recall* tinggi (0,99). Namun, tantangan masih terlihat pada kelas yang memiliki kemiripan visual, seperti kelas *mild* (kelas 1) dan *moderate*

(kelas 2), di mana meskipun kelas 1 memiliki *recall* tinggi (0,97), nilai *precision*-nya lebih rendah (0,91), dan kelas 2 memiliki *recall* yang relatif lebih rendah (0,86) meskipun *precision*-nya tinggi (0,97). Sementara itu, kelas *severe* (kelas 3) dan *proliferative* (kelas 4) menunjukkan performa hampir sempurna dengan *recall* masing-masing 1,00 dan 0,99 serta *precision* di atas 0,96. Hal ini menandakan bahwa peningkatan akurasi pada kelas dengan perbedaan visual yang lebih halus masih menjadi ruang pengembangan yang penting untuk ke depan.

5.2 Saran

Berdasarkan hasil yang telah diperoleh, terdapat beberapa hal yang dapat disarankan untuk pengembangan sistem deteksi *diabetic retinopathy*. Pertama, meskipun distribusi data sudah relatif seimbang, peningkatan variasi data terutama untuk kelas dengan perbedaan visual yang halus seperti *mild* dan *moderate* akan membantu model belajar lebih baik dan mengurangi potensi kesalahan klasifikasi. Kedua, penerapan metode *fine-tuning* pada seluruh lapisan arsitektur *EfficientNetB3*, bukan hanya pada bagian klasifikasi akhir, berpotensi meningkatkan kemampuan model dalam menangkap detail karakteristik citra fundus retina secara lebih menyeluruh. Selain itu, teknik augmentasi yang lebih beragam seperti penguatan kontras lokal, color jitter, atau transformasi spektral dapat membantu memperjelas fitur penting pada gambar. Ke depannya, sistem ini juga dapat diintegrasikan ke dalam platform berbasis mobile atau telemedis agar dapat diakses secara luas, terutama di wilayah dengan keterbatasan tenaga medis spesialis mata.

DAFTAR PUSTAKA

- Abbas, Q., Daadaa, Y., Rashid, U., Sajid, M. Z., & Ibrahim, M. E. A. (2023). HDR-EfficientNet: A Classification of Hypertensive and Diabetic Retinopathy Using Optimize EfficientNet Architecture. *Diagnostics*, 13(20). <https://doi.org/10.3390/diagnostics13203236>
- Abdullah, S. H., Magdalena, R., & Fu'adah, R. Y. N. (2022). Klasifikasi Diabetic Retinopathy Berbasis Pengolahan Citra Fundus Dan Deep Learning. *Journal of Electrical and System Control Engineering*, 5(2), 84–90. <https://doi.org/10.31289/jesce.v5i2.5659>
- Akhtar, S., Aftab, S., Ali, O., Ahmad, M., Khan, M. A., Abbas, S., & Ghazal, T. M. (2025). A deep learning based model for diabetic retinopathy grading. *Scientific reports*, 15(1), 3763. <https://doi.org/10.1038/s41598-025-87171-9>
- Arora, L., Singh, S. K., Kumar, S., Gupta, H., Alhalabi, W., Arya, V., Bansal, S., Chui, K. T., & Gupta, B. B. (2024). Ensemble deep learning and EfficientNet for accurate diagnosis of diabetic retinopathy. *Scientific Reports*, 14(1), 1–16. <https://doi.org/10.1038/s41598-024-81132-4>
- Daanouni, O., Cherradi, B., & Tmiri, A. (2021). Automatic Detection of Diabetic Retinopathy Using Custom CNN and Grad-CAM. *Advances in Intelligent Systems and Computing*, 1188(January), 15–26. https://doi.org/10.1007/978-981-15-6048-4_2
- Dai, L., Sheng, B., Chen, T., Wu, Q., Liu, R., Cai, C., Wu, L., Yang, D., Hamzah, H., Liu, Y., Wang, X., Guan, Z., Yu, S., Li, T., Tang, Z., Ran, A., Che, H., Chen, H., Zheng, Y., ... Jia, W. (2024). A deep learning system for predicting time to progression of diabetic retinopathy. *Nature Medicine*, 30(2), 584–594. <https://doi.org/10.1038/s41591-023-02702-z>
- Long, X., Gan, F., Fan, H., Qin, W., Li, X., Ma, R., Wang, L., Hu, R., Xie, Y., Chen, L., Cao, J., Shao, Y., Liu, K., & You, Z. (2025). EfficientNetB0-Based End-to-End Diagnostic System for Diabetic Retinopathy Grading and Macular Edema Detection. *Diabetes, Metabolic Syndrome and Obesity*, 18(April), 1311–1321. <https://doi.org/10.2147/DMSO.S506494>

- Luo, C. Y., Cheng, S. Y., Xu, H., & Li, P. (2021). Human behavior recognition model based on improved EfficientNet. *Procedia Computer Science*, 199, 369–376. <https://doi.org/10.1016/j.procs.2022.01.045>
- Navaneethan, S., Pardhiv, A., & Teja, K. (2024). Automated Diabetic Retinopathy Detection and Multi-Stage Classification Using Convolutional Neural Networks. *Proceedings of the 2024 International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems, ICSES 2024*, 6(5), 1–24. <https://doi.org/10.1109/ICSES63760.2024.10910687>
- Nayak, D. R., Padhy, N., Mallick, P. K., Zymbler, M., & Kumar, S. (2022). Brain Tumor Classification Using Dense Efficient-Net. *Axioms*, 11(1). <https://doi.org/10.3390/axioms11010034>
- Pratama, H. A. (2024). Implementasi convolutional neural network pada pengenalan isyarat tangan untuk komunikasi tuna wicara. *Jurnal Komputer Dan Teknologi Informasi*, 2(2), 65–71. <https://doi.org/10.26714/jkti.v2i2.13931>
- Romario, M. H., Ihsanto, E., & Kadarina, T. M. (2020). Sistem Hitung dan Klasifikasi Objek dengan Metode Convolutional Neural Network. *Jurnal Teknologi Elektro*, 11(2), 108. <https://doi.org/10.22441/jte.2020.v11i2.007>
- Satrio, B., Poetro, W., Mulyono, S., & Pramesti, V. A. (2024). *Prediksi Penyakit Batu Ginjal dengan Menerapkan Convolutional Neural Network*. 153–162.
- Schielein, M. C., Christl, J., Sitaru, S., Pilz, A. C., Kaczmarczyk, R., Biedermann, T., Lasser, T., & Zink, A. (2023). Outlier detection in dermatology: Performance of different convolutional neural networks for binary classification of inflammatory skin diseases. *Journal of the European Academy of Dermatology and Venereology*, 37(5), 1071–1079. <https://doi.org/10.1111/jdv.18853>
- Swaminathan, R. (2025). *An Attention Infused Deep Learning System with Grad-CAM Visualization for Early Screening of Glaucoma*. <http://arxiv.org/abs/2505.17808>

- Tan, T. E., & Wong, T. Y. (2023). Diabetic retinopathy: Looking forward to 2030. *Frontiers in Endocrinology*, 13(January), 1–8. <https://doi.org/10.3389/fendo.2022.1077669>
- Wibowo, K. A. H., & Alamsyah, A. (2023). Klasifikasi Diabetic Retinopathy Menggunakan CNN dengan Arsitektur yang Dimodifikasi. *Indonesian Journal of Mathematics and Natural Sciences*, 46(1), 45–52. <https://doi.org/10.15294/ijmns.v46i1.46172>
- Yang, Z., Tan, T. E., Shao, Y., Wong, T. Y., & Li, X. (2022). Classification of diabetic retinopathy: Past, present and future. *Frontiers in Endocrinology*, 13(December), 1–18. <https://doi.org/10.3389/fendo.2022.1079217>
- Zahir, M., & Adi Saputra, R. (2024). Deteksi Penyakit Retinopati Diabetes Menggunakan Citra Mata Dengan Implementasi Deep Learning Cnn. *Jurnal Teknoinfo*, 18(1), 121–132.
- Zhang, H., & Ogasawara, K. (2023). Grad-CAM-Based Explainable Artificial Intelligence Related to Medical Text Processing. *Bioengineering*, 10(9). <https://doi.org/10.3390/bioengineering10091070>
- Zhang, W., Belcheva, V., & Ermakova, T. (2025). Interpretable Deep Learning for Diabetic Retinopathy: A Comparative Study of CNN, ViT, and Hybrid Architectures. *Computers*, 14(5). <https://doi.org/10.3390/computers14050187>