

**TESIS**

**DETEKSI PENYAKIT DIABETIC RETINOPATHY  
MENGUNAKAN CONVOLUTIONAL NEURAL NETWORK  
BERBASIS ARSITEKTUR EFFICIENTNETV2**



disusun oleh

**AIMAN MUKHLISHAH**

**23.51.2532**

**Konsentrasi : Digital Transformation Intellgence**

**FAKULTAS ILMU KOMPUTER  
UNIVERSITAS AMIKOM YOGYAKARTA  
YOGYAKARTA**

**2025**

**TESIS**  
**DETEKSI PENYAKIT DIABETIC RETINOPATHY**  
**MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK**  
**BERBASIS ARSITEKTUR EFFICIENTNETV2**

**DIABETIC RETINOPATHY DETECTION USING**  
**CONVOLUTIONAL NEURAL NETWORK BASED ON**  
**EFFICIENTNETV2 ARCHITECTURE**

Diajukan untuk memenuhi salah satu syarat mencapai derajat Pascasarjana  
Program Studi Informatika



disusun oleh

**AIMAN MUKHLISHAH**

**23.51.2532**

**Konsentrasi : Digital Transformation Intelligence**

**FAKULTAS ILMU KOMPUTER**  
**UNIVERSITAS AMIKOM YOGYAKARTA**  
**YOGYAKARTA**

**2025**

**HALAMAN PERSETUJUAN**

**DETEKSI PENYAKIT DIABETIC RETINOPATHY MENGGUNAKAN  
CONVOLUTIONAL NEURAL NETWORK BERBASIS ARSITEKTUR  
EFFICIENTNETV2**

**DIABETIC RETINOPATHY DETECTION USING CONVOLUTIONAL  
NEURAL NETWORK BASED ON EFFICIENTNETV2  
ARCHITECTURE**

yang disusun dan diajukan oleh

**Aiman Mukhlisah**

**23.51.2532**

telah disetujui oleh Dosen Pembimbing Tesis  
pada tanggal 03 Oktober 2025

**Dosen Pembimbing,**



**Prof. Dr. Ema Utomi, S.Si., M.Kom**  
**NIK/190302037**

**HALAMAN PENGESAHAN**

**DETEKSI PENYAKIT DIABETIC RETINOPATHY MENGGUNAKAN  
CONVOLUTIONAL NEURAL NETWORK BERBASIS ARSITEKTUR  
EFFICIENTNETV2**

**DIABETIC RETINOPATHY DETECTION USING CONVOLUTIONAL  
NEURAL NETWORK BASED ON EFFICIENTNETV2  
ARCHITECTURE**

yang disusun dan diajukan oleh

**Aiman Mukhlislah**

**23.51.2532**

Telah dipertahankan di depan Dewan Penguji  
pada tanggal 03 Oktober 2025

**Susunan Dewan Penguji**

**Nama Penguji**

Alva Hendi Muhammad, S.T., M.Eng., Ph.D.  
NIK. 190302493

I Made Artha Agastva, S.T., M.Eng., PhD  
NIK. 190302352

Prof. Dr. Ema Utami, S.Si., M.Kom.  
NIK. 190302037

**Tanda Tangan**



Tesis ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Magister Komputer  
Tanggal 03 Oktober 2025

**DEKAN FAKULTAS ILMU KOMPUTER**



Prof. Dr. Kusriani, M.Kom.  
NIK. 190302106

## HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Aiman Mukhlisah  
NIM : 23.51.2532

Menyatakan bahwa Tesis dengan judul berikut:

**Deteksi Penyakit Diabetic Retinopathy Menggunakan Convolutional Neural Network Berbasis Arsitektur EfficientnetV2**

Dosen Pembimbing : Prof. Dr. Ema Utami, S.Si., M.Kom.

1. Karya tulis ini adalah benar-benar **ASLI** dan **BELUM PERNAH** diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya.
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian **SAYA** sendiri, tanpa bantuan pihak lain kecuali arahan dari Dosen Pembimbing.
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini.
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab **SAYA**, bukan tanggung jawab Universitas AMIKOM Yogyakarta.
5. Pernyataan ini **SAYA** buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka **SAYA** bersedia menerima **SANKSI AKADEMIK** dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi.

Yogyakarta, 03 Oktober 2025

Yang Menyatakan,



Aiman Mukhlisah

## HALAMAN PERSEMBAHAN

Dengan segala puji syukur kepada Allah SWT yang telah memberikan Rahmat dan Hidayah-Nya juga atas dukung serta doa dari orang-orang tercinta dan terkasih, akhirnya tesis ini mampu terselesaikan dengan baik. Dengan rasa bangga dan bahagia, tesis ini saya persembahkan untuk :

1. Kedua orang tua saya bapak Muhammad, S.Pd.i dan ibu Anisah, S.Pd. yang senantiasa memberikan semangat, dukungan moral maupun materi serta doa, motivasi dan kesabaran kepada saya.
2. Kepada adik dan kakak saya yang senantiasa memberikan semangat serta dukungan kepada saya.
3. Prof. Dr. Ema Utami, S.Si., M.Kom., selaku pembimbing saya yang selalu memberikan arahan, saran, motivasi serta bimbingan positif dalam menyelesaikan tesis ini sehingga dapat terselesaikan dengan baik.
4. Kepada teman teman tongkrongan yang saya hormati dan sayangi yang tidak dapat disebutkan satu satu.
5. Keluarga besar MTI AMIKOM Angkatan 31, yang telah menjadi teman-teman saya semasa kuliah pascasarjana serta kenangan yang tidak dapat saya rasakan dikesempatan lain.

## KATA PENGANTAR

Dengan memanjatkan puji syukur kepada kehadiran Allah SWT atas limpahan rahmat dan hidayah-Nya sehingga mampu menyelesaikan tesis yang berjudul "Deteksi Penyakit Diabetic Retinopathy Menggunakan Convolutional Neural Network Berbasis Arsitektur EfficientnetV2". Dalam penyusunan dan penulisan tesis ini, tidak terlepas dari bantuan dan bimbingan serta dukungan dari beberapa pihak. Oleh karena itu dalam kesempatan ini, penulis dengan senang hati menyampaikan terima kasih yang sebesar- sebesarnya kepada:

1. Prof. Dr. M. Suyanto, MM. selaku Rektor Universitas AMIKOM Yogyakarta.
2. Robert Marco, M.T., Ph.D. selaku Direktur Program Pascasarjana Universitas AMIKOM Yogyakarta
3. Prof. Dr. Ema Utami, S.Si., M.Kom. selaku dosen pembimbing yang telah sabar memberikan arahan, masukan, dan saran dalam menyelesaikan tesis ini.
4. Kepada kedua orangtua saya yang selalu memberikan support dan doa kepada saya.
5. Teman-teman Magister Informatika angkatan 31 Kelas A.

Yogyakarta, 28 Oktober 2025


Penulis

## DAFTAR ISI

HALAMAN JUDUL .....	ii
HALAMAN PERSETUJUAN.....	iii
HALAMAN PENGESAHAN .....	iv
HALAMAN PERNYATAAN KEASLIAN TESIS .....	v
HALAMAN PERSEMBAHAN .....	vi
KATA PENGANTAR .....	vii
DAFTAR ISI.....	viii
DAFTAR TABEL .....	xi
DAFTAR GAMBAR .....	xii
DAFTAR LAMPIRAN.....	xiii
DAFTAR LAMBANG DAN SINGKATAN .....	xiv
DAFTAR ISTILAH.....	xv
INTISARI .....	xvii
ABSTRACT.....	xviii
<b>BAB 1 PENDAHULUAN</b> .....	<b>1</b>
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	5
1.3 Batasan Masalah.....	5
1.4 Tujuan Penelitian.....	6
1.5 Manfaat Penelitian.....	6
<b>BAB 2 TINJAUAN PUSTAKA</b> .....	<b>7</b>
2.1 Tjauan Pustaka.....	7
2.2 Keaslian Penelitian .....	11
2.3 Landasan Teori .....	15
2.3.1. Diabetic Retinopathy .....	15
2.3.2. Deep Learning.....	17
2.3.3. Convolutional Neural Network (CNN).....	18
2.3.4. EfficientnetV2.....	22

2.3.5.	Peningkatan Pada EfficientNetV2 .....	24
2.3.6.	Peningkatan Pada EfficientNetV2 .....	26
2.3.7.	Evaluasi Confusion Matrix .....	28
2.3.8.	Pengukuran Performance .....	29
<b>BAB 3</b>	<b>METODE PENELITIAN</b> .....	<b>31</b>
3.1	Jenis, Sifat, dan Pendekatan Penelitian.....	31
3.2	Metode Pengumpulan Data .....	32
3.3	Metode Analisis Data.....	32
3.4	Alur Penelitian .....	33
<b>BAB 4</b>	<b>HASIL PENELITIAN DAN PEMBAHASAN</b> .....	<b>34</b>
4.1.	Dan Pengumpulan Data .....	34
4.1.1	Studi Literatur .....	34
4.1.2	Pengumpulan Data .....	34
4.2.	Preprocessing dan Split data.....	36
4.2.1	Preprocessing .....	36
4.2.2	Split Data .....	37
4.3.	Skenario Pengujian .....	38
4.3.1	Pemodelan Algoritma EfficientNetV2.....	38
4.3.2	Integrasi Dilation Layer .....	39
4.4.3	Pelatihan Model .....	41
4.4.4	EfficientnetV2.....	42
4.4.	Evaluasi Model .....	45
4.4.1	Analisis Hasil Klasifikasi.....	45
4.4.2	Analisis Hasil EfficientNetV2-B0 .....	46
4.4.3	Analisis Hasil EfficientNetV2-B3 .....	52
4.4.4	Analisis Hasil EfficientNetV2-B3 .....	58
4.5.	Analisis Hasil Klasifikasi.....	64

4.6. Analisis Imbalance Data .....	70
4.7. Analisis Penerapan preprocessing CLAHE .....	72
4.8. Kontribusi Penelitian .....	75
<b>BAB 5 PENUTUP</b> .....	<b>79</b>
5.1 Kesimpulan .....	79
5.2 Saran .....	80
<b>DAFTAR PUSTAKA</b> .....	<b>81</b>



## DAFTAR TABEL

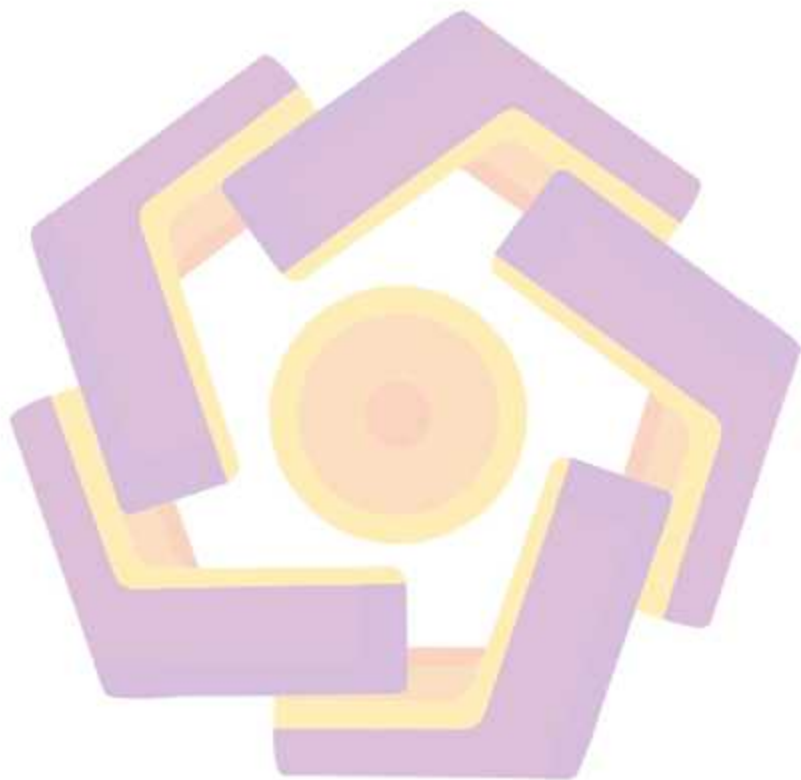
Tabel 2.1. Matriks literatur review dan posisi penelitian.....	11
Tabel 2.1. Confusion Matrix .....	28
Tabel 4.1 Distribusi Data .....	35
Tabel 4.2 Pembagian Data .....	37
Tabel 4.3 Skenario Penelitian dengan hyperparameter.....	41
Tabel 4.4 Hasil Eksperimen.....	64
Tabel 4.5 Perbandingan Penelitian .....	76



## DAFTAR GAMBAR

Gambar 2.1. Perbedaan Retina Normal dan Retinopathy .....	15
Gambar 2.2. Klasifikasi DR.....	16
Gambar 2.3. Arsitektur CNN .....	19
Gambar 2.4. Contoh Penerapan Aktivasi ReLu (Sumber: Rosebrock, Adrian). ...	20
Gambar 2.5. Perhitungan pada Pooling layer .....	21
Gambar 2.6. Proses Fully Connected Layer .....	22
Gambar 2.4 Convolutional Neural Network dengan $d = 1$ (kiri); Dilated .....	27
Convolutional Neural Network dengan $d = 2$ (Kanan).....	27
Gambar 4.1 Dataset DR .....	34
Gambar 4.4 Gambar Retina Setelah CLAHE .....	37
Gambar 4.5 Model Arsitektur EfficientnetV2 + Dilation Layer.....	43
Gambar 4.6 Plot Akurasi dan Loss Metode EfficientNetV2-B0 + Dilation Layer	46
Gambar 4.8 Plot Confusion Matrix Metode EfficientNetV2-B0 + Dilation Layer .....	47
Gambar 4.11 Plot Confusion Matrix Metode EfficientNetV2-B3 + Dilation Layer .....	53
Gambar 4.14 Plot Confusion Matrix Metode EfficientNetV2-S + Dilation Layer	59
Gambar 4.15 Classification Report EfficientNetV2-S.....	63
Gambar 4.16 Grafik akurasi, presisi recall dan F1-Score Train .....	69
Gambar 4.16 Grafik akurasi, presisi recall dan F1-Score Train .....	69

## DAFTAR LAMPIRAN



## DAFTAR LAMBANG DAN SINGKATAN



DR	Diabetic Retinopathy
CNN	Convolutional Neural Network
AI	Artificial Intelligence
DL	Deep Learning
ML	Machine Learning
CLAHE	Contrast Limited Adaptive Histogram Equalization
ReLU	Rectified Linear Unit
SVM	Support Vector Machine
GLCM	Gray Level Co-occurrence Matrix
DeepDR	Deep Diabetic Retinopathy Detection System
AUC	Area Under Curve
VGG19	Visual Geometry Group 19 Layers
ResNet50	Residual Network 50 Layers
DenseNet121	Densely Connected Convolutional Network 121 Layers
MRI	Magnetic Resonance Imaging
ELM	Extreme Learning Machine
MLP	Multi-Layer Perceptron
AE	Autoencoder
CA-EfficientNetV2	Coordinate Attention EfficientNetV2
NPDR	Non-Proliferative Diabetic Retinopathy
PDR	Proliferative Diabetic Retinopathy
AAO	American Academy of Ophthalmology
ETDRS	Early Treatment Diabetic Retinopathy Study
GPU	Graphics Processing Unit
ROC	Receiver Operating Characteristic
AUC	Area Under Curve
ReLU	Rectified Linear Unit

## DAFTAR ISTILAH

EfficientNetV2	Arsitektur CNN efisien dengan kecepatan pelatihan tinggi dan parameter sedikit.
Dataset	Kumpulan data yang digunakan untuk melatih, memvalidasi, dan menguji model.
Accuracy	Persentase prediksi benar dibanding total data.
Precision	Perbandingan antara prediksi positif benar dan total prediksi positif.
Recall	Rasio prediksi positif benar terhadap data positif sebenarnya.
F1-Score	Nilai harmonis antara precision dan recall.
Confusion Matrix	Tabel evaluasi prediksi benar dan salah per kelas.
Overfitting	Kondisi ketika model terlalu menyesuaikan data latih, menyebabkan performa buruk di data uji.
Validation	Proses pengujian model pada data yang tidak digunakan untuk pelatihan.
Transfer Learning	Teknik memanfaatkan model pra-latih untuk mempercepat pelatihan model baru.
MATLAB	Lingkungan komputasi numerik untuk pemrosesan citra dan analisis data.
Sensitivity	Kemampuan model dalam mendeteksi kasus positif dengan benar.
Specificity	Kemampuan model dalam mengidentifikasi kasus negatif dengan benar.
Ensemble Learning	Teknik menggabungkan beberapa model untuk meningkatkan kinerja prediksi.
Epoch	Satu kali iterasi penuh dari seluruh dataset selama pelatihan.

Batch Size	Jumlah sampel data yang diproses dalam satu langkah pelatihan.
Learning Rate	Parameter yang mengontrol kecepatan pembaruan bobot model.
Adam	Algoritma optimisasi berbasis adaptif untuk pembaruan bobot.
SGD	Algoritma optimisasi dengan pembaruan berdasarkan sampel acak.
Kaggle	Platform penyedia dataset publik dan kompetisi <i>machine learning</i> .
Messidor	Dataset publik berisi citra retina untuk penelitian DR.
Scottish Grading Protocol	Sistem penilaian tingkat keparahan DR yang digunakan di Skotlandia.
RGB	Model warna aditif <i>Red, Green, Blue</i> yang digunakan dalam citra digital.
Softmax	Fungsi aktivasi untuk klasifikasi multi-kelas yang menghasilkan probabilitas total 1.

## INTISARI

Diabetic Retinopathy (DR) merupakan salah satu komplikasi serius akibat diabetes mellitus yang menjadi penyebab utama kebutaan di dunia. Seiring meningkatnya jumlah penderita diabetes, kebutuhan akan sistem deteksi otomatis yang akurat semakin mendesak guna mendukung diagnosis dini serta mencegah risiko kehilangan penglihatan permanen. Namun, klasifikasi DR masih menghadapi tantangan, seperti variasi tingkat keparahan, distribusi data yang tidak seimbang, serta keterbatasan model dalam mengenali pola spasial citra retina. Untuk menjawab permasalahan tersebut, penelitian ini mengusulkan integrasi *dilation layer* pada arsitektur EfficientNetV2 yang efisien dalam ekstraksi fitur, dengan dukungan *preprocessing* Contrast Limited Adaptive Histogram Equalization (CLAHE) untuk meningkatkan kualitas citra retina. Penambahan *dilation layer* memungkinkan perluasan *receptive field* tanpa meningkatkan jumlah parameter maupun menurunkan resolusi spasial, sehingga jaringan lebih optimal dalam menangkap fitur patologis. Penelitian ini menguji tiga varian model, yaitu EfficientNetV2-B0, B3, dan S. Hasil eksperimen menunjukkan bahwa EfficientNetV2-B0 dengan *dilation layer* memberikan performa terbaik dengan akurasi 96,54% serta *precision* dan *recall* yang seimbang. Sementara itu, arsitektur lebih kompleks tidak selalu lebih unggul, bahkan menurun pada kelas minoritas seperti *Proliferative DR*. Temuan ini mengindikasikan bahwa integrasi *dilation layer* pada arsitektur EfficientNetV2 berpotensi meningkatkan stabilitas dan konsistensi klasifikasi DR.

Kata kunci: *Diabetic Retinopathy*, *EfficientNetV2*, *dilated convolution*, klasifikasi citra, CNN

## ABSTRACT

*Diabetic Retinopathy (DR) is one of the most severe complications of diabetes mellitus and remains a leading cause of blindness worldwide. With the increasing prevalence of diabetes, the demand for accurate automated detection systems has become more urgent to support early diagnosis and prevent the risk of permanent vision loss. However, DR classification still faces several challenges, including varying severity levels, imbalanced data distribution, and limitations of existing models in comprehensively capturing spatial patterns within retinal images. To address these issues, this study proposes the integration of a dilation layer into the EfficientNetV2 architecture, which is recognized for its efficiency and strong feature extraction capabilities, supported by preprocessing using Contrast Limited Adaptive Histogram Equalization (CLAHE) to enhance retinal image quality. The inclusion of the dilation layer enables an expanded receptive field without increasing the number of parameters or reducing spatial resolution, thereby allowing the network to capture pathological features more effectively. Three model variants—EfficientNetV2-B0, B3, and S—were evaluated in this study. Experimental results demonstrate that EfficientNetV2-B0 with the integrated dilation layer achieved the best performance, reaching an accuracy of 96.54% with balanced precision and recall. In contrast, more complex architectures such as EfficientNetV2-B3 and S did not consistently yield superior results and exhibited reduced sensitivity in minority classes, such as Proliferative DR. These findings suggest that integrating a dilation layer into EfficientNetV2 can enhance the stability and consistency of DR classification.*

**Keywords:** *Diabetic Retinopathy, EfficientNetV2, dilated convolution, image classification, CNN*

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

Deteksi dini penyakit adalah hal yang sangat penting untuk dilakukan. Semakin cepat penyakit ditemukan, semakin besar peluang kesembuhan dan memungkinkan pengobatan yang lebih efektif. Diabetes adalah gangguan metabolik kronis ditandai oleh peningkatan kadar gula darah (glukosa darah) diatas batas normal ( $\geq 126$  mg/dL), yang seiring waktu dapat menyebabkan kerusakan serius pada jantung, pembuluh darah, mata, ginjal, dan saraf [1]. Diabetes adalah salah satu penyakit yang terus meningkat diseluruh dunia, dengan Asia menyumbang lebih dari 60% populasi diabetes global. Pada tahun 2021, Indonesia berada di peringkat kelima dengan jumlah penderita diabetes terbanyak, yaitu 19,5 juta orang [2][3].

Diabetic Retinopathy (DR) adalah salah satu komplikasi yang sering terjadi pada penderita Diabetes Mellitus (DM). DR merupakan kondisi medis yang dapat merusak pembuluh darah di retina atau menyebabkan sejumlah luka pada mata yang bisa merusak retina, sehingga dapat mengakibatkan kebutaan jika tidak ditangani dengan benar. Kondisi ini terjadi akibat tingginya kadar gula darah yang dapat memengaruhi struktur dan fungsi retina [4]. Dalam proses diagnosis pasien yang diduga mengidap DR, terdapat empat tahap penilaian, ditandai oleh gejala klinis yang berbeda yaitu Mild Non-Proliferative Diabetic Retinopathy (NPDR), Moderate Non-Proliferative Diabetic Retinopathy (NPDR), Severe Non-

Proliferative Diabetic Retinopathy (NPDR), dan Proliferative Diabetic Retinopathy (PDR)[5], [6].

Dengan berbagai kemajuan teknologi, DR dapat dideteksi secara efisien menggunakan Deep Learning. Deep Learning adalah metode pembelajaran mesin yang meniru cara kerja otak manusia, dengan mempelajari pola dari banyak contoh [7], [8]. Pendekatan deep learning yang umum diterapkan untuk mengklasifikasikan tahap-tahap retinopati diabetik (DR) adalah Convolutional Neural Network (CNN) [9]. CNN dipilih karena kemampuannya yang luar biasa dalam mengekstraksi fitur-fitur kompleks untuk pengenalan pola gambar yang tersembunyi dan meningkatkan akurasi secara keseluruhan [10]. Ada berbagai jenis arsitektur CNN yang dapat digunakan dalam penelitian, seperti AlexNet, ResNet, VGG, DenseNet, Efficientnet dan EfficientnetV2.

Penelitian yang dilakukan oleh Aryan dkk, 2024[11] berhasil mengidentifikasi diabetic retinopathy (DR) dengan menganalisis citra fundus menggunakan metode deep learning. Teknik R-CNN digunakan untuk deteksi, sedangkan GAN) diterapkan untuk meningkatkan kualitas citra fundus. Penelitian ini mencapai tingkat akurasi bounding box rata-rata sebesar 75,20% untuk eksudasi dan 67,20% untuk microaneurysm, sedangkan akurasi segmentasi wilayah rata-rata mencapai 62,36% untuk eksudasi dan 57,69% untuk microaneurysm. Selain itu, penelitian yang juga dilakukan oleh [12] dan [13] untuk deteksi diabetic retinopathy menggunakan metode EfficientNet. Namun, hasil penelitian tersebut menunjukkan bahwa masih terdapat ruang untuk peningkatan akurasi deteksi.

Penelitian, [14] Melakukan deteksi citra gambar untuk klasifikasi DR menggunakan model EfficientnetV2 dengan teknik ensemble pada EfficientnetV2-S, L dan M yang diterapkan pada 2000 gambar fundus DeepDRiD. Uji data yang dilakukan menghasilkan nilai 75% dengan AUC sebesar 74,9% dari teknik ensemble. Penelitian lain juga dilakukan oleh [15] menerapkan Penggunaan Variasi Model pada Arsitektur EfficientNetV2 untuk Prediksi Sel Kanker Serviks dengan beberapa variasi (B0, B1, B2, Small, Medium, dan Large) untuk memprediksi jenis sel kanker. Hasil penelitian menunjukkan Model EfficientNetV2-Large mencapai akurasi tertinggi sekitar 99,9%, sedangkan model lain memiliki akurasi di atas 99%. Hal ini menunjukkan bahwa model ini dapat diterapkan untuk klasifikasi diabetic retinopathy.

Meskipun teknologi deep learning telah banyak dilakukan menggunakan arsitektur modern seperti efficientNet untuk klasifikasi Diabetic Retinopathy (DR) [16]. Namun demikian, sebagian besar model masih mengandalkan convolution standar yang memiliki receptive field terbatas. Hal ini dapat membatasi kemampuan model dalam menangkap fitur penting yang bersifat halus dan tersebar, seperti mikroaneurisma dan lesi kecil, yang merupakan penanda awal DR. Fitur-fitur ini sering kali tidak terdeteksi secara optimal oleh jaringan konvolusional standar karena keterbatasan receptive field [17]. Akibatnya, informasi kontekstual yang krusial dapat hilang. Kondisi ini diperparah oleh kualitas citra fundus retina memiliki perbedaan pencahayaan dan kontras yang signifikan, [18]. Tingkat pencahayaan yang tidak konsisten antar citra serta Kontras pembuluh darah retina yang lemah mengakibatkan fitur patologis seperti microaneurysm dan hemorrhage

sulit terlihat. Masalah tersebut dapat memberikan pengaruh yang besar terhadap ketepatan hasil analisis.

Berdasarkan penelitian sebelumnya tentang deteksi DR, seiring dengan meningkatnya kesadaran masyarakat akan pentingnya kesehatan, menunjukkan perlunya upaya lebih lanjut untuk mengklasifikasikan jenis penyakit ini secara akurat. Penelitian ini berkontribusi dengan mengintegrasikan dilation layer ke dalam arsitektur EfficientNetV2, yang dikenal efisien dan kuat sebagai feature extractor, serta menggabungkan metode CLAHE sebagai tahapan preprocessing untuk meningkatkan kualitas citra. Dengan menggunakan filter konvolusional berdilatasi, jaringan memperoleh kemampuan untuk memperluas receptive field secara signifikan tanpa menambah jumlah parameter atau mengurangi resolusi spasial [19]. Sejumlah penelitian terdahulu telah membuktikan bahwa penggunaan dilation layer efektif dalam meningkatkan performa klasifikasi, sebagaimana ditunjukkan dalam studi [20] [21] Sebagai contoh [22] melakukan komparasi metode Context-Gated Dilated Convolution Network (CGDCN) dengan ResNet50 dan akurasi tertinggi dicapai CGDCN 98,178%. Model ini akan dianalisa berdasarkan matrix evaluasi nilai Confusion matrix. Penelitian ini Diharapkan dapat membantu dokter dalam mendiagnosis penyakit DR pada penderita diabetes secara lebih akurat, serta mengurangi beban pada sistem kesehatan, sehingga memberikan dampak signifikan dalam pengembangan penelitian.

## 1.2 Rumusan Masalah

Dari permasalahan yang terjadi, rumusan masalah pada penelitian ini antara lain:

- a. Bagaimana performa yang dihasilkan metode Convolutional Neural Networks EfficientnetV2 berdasarkan evaluasi akurasi, presisi, recall, f1 score dari Rancangan Penelitian?
- b. Bagaimana pengaruh ekstraksi fitur pada performa metode Convolutional Neural Networks EfficientnetV2 dalam mengidentifikasi diabetic retinopathy pada retina?
- c. Bagaimana pengaruh kombinasi metode CLAHE dan EfficientNetV2 terhadap akurasi dan kemampuan generalisasi model dalam mendeteksi tingkat keparahan *Diabetic Retinopathy*?

## 1.3 Batasan Masalah

Melihat dari permasalahan yang sangat luas penulis menetapkan Batasan Batasan masalah dalam penelitian sehingga lebih terarah dan tidak menyimpang jauh diuraikan Sebagai berikut:

- a. Penelitian ini mengidentifikasi penyakit diabetic retinopathy berdasarkan gambar fundus retina.
- b. Metode yang digunakan pada penelitian ini menggunakan Convolutional Neural Networks EfficientnetV2 B0, B3, dan S.
- c. Gambar retina terbagi menjadi 5 kelas yaitu No DR, Mild NPDR, Moderate NPDR, Severe NPDR, dan PDR.

- d. Data gambar retina yang digunakan dalam penelitian ini bersifat public yang diambil dari website Kaggle.com
- e. Target penelitian ini hanya dalam bentuk uji akurasi presisi, recall, f1 score dengan bahasa python
- f. Penelitian ini tidak sampai kepada tahap pembuatan aplikasi.

#### **1.4 Tujuan Penelitian**

Tujuan dari penelitian diuraikan berdasarkan rumusan masalah meliputi:

- a. Untuk mengetahui bagaimana penerapan metode yang dihasilkan Convolutional Neural Networks EfficientnetV2 berdasarkan evaluasi akurasi, presisi, recall, f1 score dan waktu training dari Rancangan Penelitian?
- b. Untuk mengetahui pengaruh ekstraksi fitur pada performa metode Convolutional Neural Networks EfficientnetV2 dalam mengidentifikasi diabetic retinopathy pada retina?

#### **1.5 Manfaat Penelitian**

- a. Dapat bermanfaat sebagai pedoman pengembangan aplikasi yang digunakan untuk mendeteksi DR secara automatic.
- b. Dapat dijadikan referensi rekomendasi algoritma untuk pengembangan sistem klasifikasi DR pada citra retina.
- c. Sebagai syarat kelulusan Magister Teknik Informatika Universitas Amikom Yogyakarta.

## BAB 2

### TINJAUAN PUSTAKA

#### 2.1 Tinjauan Pustaka

Penelitian terdahulu yang menjadi acuan untuk mendukung deteksi dan klasifikasi DR seperti penelitian yang telah dilakukan [23] untuk mendeteksi eksudat dan penelitian [24] dalam hal deteksi lesi merah. Penelitian sebelumnya [25] yang juga melakukan deteksi penyakit Diabetic Retinopathy dengan menggunakan MATLAB untuk proses pembuatan system. Algoritma Support Vector Machine (SVM) untuk melakukan klasifikasi antara gambar retina dengan DR dan tanpa DR. Ekstraksi fitur dilakukan menggunakan metode Gray Level Co-occurrence Matrix (GLCM), dengan fitur korelasi dan energi sebagai fitur utama yang diekstraksi dari citra retina. Penelitian ini menghasilkan tingkat akurasi sebesar 89% untuk data pelatihan dan 100% untuk data pengujian dalam mendeteksi Diabetic Retinopathy.

Penelitian beberapa tahun terakhir juga mengalami perkembangan pesat dalam bidang pembelajaran mesin terkhusus metode Convolutional Neural Networks (CNN). Berdasarkan penelitian yang dilakukan oleh [26], mengusulkan metode deep learning untuk ekstraksi fitur dan klasifikasi menggunakan mesin vektor dukungan. Kami menggunakan fitur tingkat tinggi dari lapisan fully connected terakhir berdasarkan transfer learning dari Convolutional Neural Network (CNN) sebagai fitur input untuk klasifikasi menggunakan mesin vektor dukungan (SVM). Metode ini mengurangi waktu komputasi yang dibutuhkan oleh proses klasifikasi menggunakan CNN dengan fine-tuning. Metode yang diusulkan diuji menggunakan 77 dan 70 gambar retina dari basis data Messidor masing-

masing untuk base 12 dan base 13. Dari hasil eksperimen, nilai akurasi tertinggi adalah 95,83% dan 95,24% untuk base 12 dan base 13 masing-masing. Namun, hanya berjumlah 70 gambar untuk membedakan retina normal dan retina DR.

Penelitian lain juga dilakukan oleh [27] dalam rangka memperlambat perkembangan penyakit DR diusulkan sistem identifikasi dan penilaian DR otomatis yang disebut DeepDR. DeepDR secara langsung mendeteksi keberadaan dan tingkat keparahan DR dari gambar fundus melalui transfer learning dan ansambel learning yang terdiri dari Neural Network. Hasil penelitian menunjukkan bahwa model identifikasi memiliki kinerja terbaik dengan sensitivitas 97,5%, spesifisitas 97,7%, dan area di bawah kurva 97,7%. Sedangkan model grading mencapai sensitivitas 98,1% dan spesifisitas 98,9%. Dimana persentase tersebut memberikan hasil deteksi yang dapat dapat direproduksi dan konsisten dengan sensitivitas dan spesifisitas tinggi secara instan

[28] mengusulkan sebuah metode untuk pengenalan Diabetic Retinopathy berdasarkan pembelajaran transfer. Pertama, unduh data dari situs web resmi Kaggle, lalu melakukan peningkatan data, termasuk amplifikasi data, pembalikan, pelipatan, dan penyesuaian kontras. Kemudian, gunakan model yang sudah terlatih seperti VGG19, InceptionV3, Resnet50. Penelitian ini melakukan klasifikasi DR dalam 5 kelas. Hasil percobaan menunjukkan bahwa akurasi klasifikasi metode ini dapat mencapai 0,60, yang lebih baik daripada metode tradisional dan memiliki ketahanan dan generalisasi yang lebih baik.

Penelitian lain yang dilakukan oleh [29]. tentang Diabetic retinopathy melalui citra retina mata sudah pernah diteliti menggunakan proses peningkatan

kualitas citra maupun teknik filtering. Dalam penelitian ini, algoritma Convolutional Neural Network (CNN) telah digunakan untuk mengoptimalkan klasifikasi gambar retina mata dengan diagnosis retinopati (DR). Selain itu, algoritma ini juga telah digunakan untuk mengidentifikasi pembuluh darah pada retina mata yang mengalami DR. Fokus penelitian ini adalah untuk menguji kemampuan CNN dalam proses klasifikasi citra DR pada data yang cukup besar tanpa menggunakan preprosesing. Tujuan dari penelitian ini adalah untuk memastikan bahwa CNN saja mampu mengklasifikasi objek dengan baik. Citra berasal dari Kaggle database dengan total 88702 citra yang di sortir menjadi 88000 data. Hasil klasifikasi citra benar yaitu 82445 dengan prosentse 93,68% sedangkan citra salah klasifikasi yaitu 5555 citra dengan prosentase kegagalan yaitu 6,32%.

Penelitian [30] mengembangkan system diagnosis tumor otak menggunakan arsitektur transfer learning terdiri dari Enam arsitektur transfer learning yang berbeda, termasuk ResNet-50, MobileNet, VGG16, Inception-V3, DenseNet-121, dan EfficientNetV2-M, digunakan dalam penelitian ini. Dataset MRI publik digunakan untuk validasi model dan perbandingan dengan studi serupa. Untuk mengatasi ketidakseimbangan jumlah gambar antar kelas dalam dataset, teknik augmentasi data seperti rotasi acak diterapkan selama pra-pemrosesan data. Eksperimen menunjukkan bahwa model EfficientNetV2-M memiliki kinerja lebih baik dibandingkan arsitektur lainnya dengan tingkat akurasi 98,01%

[31] melakukan penelitian sistem deteksi dan klasifikasi kanker serviks menggunakan arsitektur deep learning berbasis convolutional neural networks (CNNs) yang dikombinasikan dengan Extreme Learning Machine (ELM) sebagai

classifier. Beberapa model CNN dengan pendekatan transfer learning digunakan dalam penelitian ini, sementara database publik Herlev dimanfaatkan untuk validasi sistem serta perbandingan dengan metode serupa. Selain ELM, penelitian ini juga mengeksplorasi alternatif classifier lain seperti multi-layer perceptron (MLP) dan autoencoder (AE). Hasil eksperimen menunjukkan bahwa sistem berbasis CNN-ELM mencapai kinerja terbaik dengan akurasi 99,5% pada deteksi (2 kelas) dan 91,2% pada klasifikasi (7 kelas), sekaligus menjadi salah satu penelitian awal yang mengintegrasikan ELM dan AE setelah CNN dalam diagnosis kanker serviks.

[32] menggunakan tiga varian arsitektur EfficientNetV2 untuk melakukan klasifikasi pemandangan yang telah dioptimalkan menunjukkan hasil akurasi yang mengesankan. Model CA-EfficientNetV2-S mencapai akurasi sebesar 99,55%, diikuti oleh CA-EfficientNetV2-M dengan akurasi 97,49%, dan CA-EfficientNetV2-L dengan akurasi 97,08%. EfficientNetV2 memiliki keunggulan dalam hal kecepatan pelatihan yang lebih tinggi dan efisiensi parameter yang lebih baik dibandingkan dengan model sebelumnya yaitu training-aware neural architecture search dan scaling[33].

## 2.2 Keaslian Penelitian

Tabel 2.1. Matriks literatur review dan posisi penelitian

Deteksi Penyakit Diabetic Retinopathy Menggunakan Convolutional Neural Network Berbasis Arsitektur Efficientnetv2

No	Judul Penelitian	Nama Peneliti, Tahun, Index	Metode Penelitian	Hasil	Keunggulan dan Kelemahan	Perbandingan
1	Application of the Support Vector Machine (SVM) Algorithm for the Diagnosis of Diabetic Retinopathy	Fadhli Dzil Ikram, Yuliadi, M. Julkarnain, Fahri Hamdani, Halid Nuryadi, (Brilliance: Research of Artificial Intelligence, 2023)	Penelitian ini melakukan deteksi diabetic retinopathy menggunakan metode SVM dengan ekstraksi fitur menggunakan GLCM (Gray Level Co-occurrence Matrix)	Penelitian ini menghasilkan Algoritma SVM dapat mengklasifikasikan retinopati diabetik menggunakan gambar retina dengan akurasi pelatihan sebesar 89% dan akurasi pengujian sebesar 100%.	Informasi mengenai ukuran dan kualitas dataset yang digunakan dalam penelitian ini tidak disertakan.	Penelitian yang akan dilakukan menggunakan preprocessing CLAHE dengan arsitektur EfficientnetV2 yang diintegrasikan dilation layer untuk klasifikasi 5 kelas DR
2	Classification of Diabetic Retinopathy and Normal Retinal Images using CNN and SVM	Dinial Utami Nurul Qomariah; Handayani Tjandrasa; Chastine Faticah, (ICTS, 2019)	Klasifikasi 2 kelas DR menggunakan metode kombinasi CNN dan SVM. Dengan ekstraksi fitur menggunakan pembelajaran transfer dari Alexnet, VGGnet, InceptionNet, GoogleNet, dan Densenet. Menggunakan dataset Messidor dengan jumlah 77 gambar.	Kombinasi transfer learning ResNet 50 SVM memberikan hasil akurasi tertinggi 95,83%. Penelitian ini menyimpulkan bahwa menggunakan kombinasi fitur yang diekstrak dari pembelajaran transfer CNN dan SVM dapat memberikan hasil yang baik untuk klasifikasi 2 kelas DR.	Dataset citra yang digunakan berjumlah 70 citra untuk membedakan Normal dan DR	Penelitian yang akan dilakukan mengklasifikasikan 5 kelas DR menggunakan kombinasi model EfficientnetV2 dengan dilation layer pada layer konvolusi

Tabel 2.1 (Lanjutan)

No	Judul Penelitian	Nama Peneliti, Tahun, Index	Metode Penelitian	Hasil	Keunggulan dan Kelemahan	Perbandingan
3	Convolutional Neural Network (CNN) Untuk Klasifikasi Citra Penyakit Diabetes Retinopathy	Muslib, Eko Hari Rachmawanto (SKANIKA: Sistem Komputer dan Teknik Informatika, 2019)	menguji kemampuan CNN dalam proses klasifikasi citra DR pada data yang cukup besar tanpa menggunakan preprocessing. Tujuan dari penelitian ini adalah untuk memastikan bahwa CNN saja mampu mengklasifikasi objek dengan baik	Hasil klasifikasi citra benar yaitu 82445 dengan prosentase 93,68% sedangkan citra salah klasifikasi yaitu 5555 citra dengan prosentase kegagalan yaitu 6,32%.	Masih terdapat salah klasifikasi pada data Sebanyak yaitu 16,26%	Penelitian yang akan dilakukan menggunakan tahapan preprocessing klaha drgan arsitektur yang lebih canggih daripada CNN biasa yaitu arsitektur EfficientnetV2 untuk klasifikasi Diabetic Retinopathy
4	Recognition of Diabetic Retinopathy Basedon Transfer Learning	Yuchen Wu, Ze Hu, IEEE 2019	Penelitian ini menggunakan Metode CNN untuk mengklasifikasikan 5 kelas DR menggunakan model transfer Resnet50, VGG19, dan InceptionV3. Ini dilakukan menggunakan dataset Kaggle yang berisi 126 gambar dan data augmentasi.	jaringan inception V3 menghasilkan akurasi terbaik mencapai 61%.	Nilai akurasi yang diperoleh masih terbilang kecil.	Penelitian yang akan dilakukan menggunakan menggunakan citra retina sebanyak 3662 citra dengan jumlah kelas sebanyak 5 kelas metode yang digunakan yaitu EfficientnetV2 dikombinasikan melalui penambahan dilation layer.

Tabel 2.1 (Lanjutan)

No	Judul Penelitian	Nama Peneliti, Tahun, Index	Metode Penelitian	Hasil	Keunggulan dan Kelemahan	Perbandingan
5	Automated identification and grading system of diabetic retinopathy using deep neural networks	Wei Zhang, Jie Zhong, Shijun Yang, Zhentao Gao, Junjie Hu, Yuanyuan Chen, Zhang Yi (Knowledge-Based Systems, 2019)	Penelitian ini bertujuan untuk mengembangkan sistem otomatis bernama DeepDR guna mengidentifikasi dan mengklasifikasikan retinopati diabetik (Diabetic Retinopathy/DR) dari gambar fundus mata	Model identifikasi (binary classification) mencapai sensitivitas 97,5% dan spesifisitas 97,7%, sedangkan model grading (multi-class classification) mencapai sensitivitas 98,1% dan spesifisitas 98,9%	Model deep learning berfungsi sebagai "black box," sehingga sulit untuk memahami fitur-fitur spesifik yang dipelajari model dari data.e	Penelitian ini menggunakan pendekatan multi-class classification dengan <i>loss function</i> Sparse Categorical Crossentropy dan fungsi aktivasi Softmax pada layer output memastikan bahwa model dapat menghasilkan distribusi probabilitas yang akurat serta memiliki tingkat keyakinan yang tinggi terhadap kelas yang diprediksi dengan benar.
6	Improving braintumor classification with combined convolutional neural networks and transfer learning	Ramazan Incira, Ferhat Bozkurt (Knowledge-Based Systems, 2024)	untuk meningkatkan akurasi klasifikasi tumor otak dengan menggabungkan arsitektur CNN (Convolutional Neural Network) dan teknik transfer learning.	Hasil menunjukkan bahwa kombinasi model EfficientNetV2-M dengan Inception-V3 memberikan akurasi tertinggi sebesar 98,41%, yang lebih baik dibandingkan hasil penelitian sebelumnya pada dataset yang sama.	Tidak terdapat pengolahan citra yang lebih mendalam memperjelas batas-batas tumor.	Penelitian yang akan dilakukan menggunakan tahapan preprocessing CLAHE serta penggunaan arsitektur yang lebih advance yaitu EfficientnetV2 dengan integrasi dilation layer untuk klasifikasi 5 kelas DR


Tabel 2.1 (Lanjutan)

No	Judul Penelitian	Nama Peneliti, Tahun, Index	Metode Penelitian	Hasil	Keunggulan dan Kelemahan	Perbandingan
7	Cervical cancer classification using convolutional neural networks and extreme learning machines	Ahmed Ghoncim, Ghulam Muhammad, M. Shamim Hossain	Mengembangkan sistem deteksi dan klasifikasi menggunakan CNNs yang dikombinasikan dengan Extreme Learning Machine (ELM)	sistem berbasis CNN-ELM mencapai kinerja terbaik dengan akurasi 99,5% pada deteksi (2 kelas) dan 91,2% pada klasifikasi (7 kelas), sekaligus menjadi salah satu penelitian awal yang mengintegrasikan ELM dan AE setelah CNN dalam diagnosis kanker serviks.	Hanya fitur keseluruhan citra yang diekstraksi, tanpa fokus pada fitur lokal dari area fokus;	penelitian yang dilakukan saat ini menggunakan arsitektur EfficientNetV2 yang diintegrasikan dengan Dilation Layer untuk klasifikasi 5 kelas DR, sehingga mampu mengekstraksi fitur spasial secara mendalam dan memperluas area reseptif tanpa menambah jumlah parameter

Source: Author (2007). Gunakan style Citation for Table AMIKOM

## 2.3 Landasan Teori

### 2.3.1. Diabetic Retinopathy




Gambar 2.1. Perbedaan Retina Normal dan Retinopathy

Retinopati Diabetik adalah penyakit yang dapat menyebabkan kebutaan pada penderita. Penyakit ini terjadi karena adanya banyak luka pada mata yang dapat merusak retina. Pada tahap awal, terdapat pembuluh darah yang melebar di mata, dan jika tidak diobati, pembuluh darah baru akan tumbuh dan menutupi retina, menyebabkan kebutaan. Retinopati Diabetik dibagi menjadi dua jenis yaitu Retinopati Diabetik Non-Proliferatif (NPDR) dan Retinopati Diabetik Proliferatif (PDR). NPDR adalah tahap awal dari Retinopati Diabetik yang ditandai dengan terbentuknya mikroaneurisma. PDR adalah tahap lanjut dari Retinopati Diabetik yang berarti kerusakan pada mata sudah parah dan dapat menyebabkan pecahnya pembuluh darah di mata. (RIZAL et al., 2020).

Diabetic Retinopathy Retinopati Diabetik adalah suatu mikroangiopati progresif yang ditandai oleh kerusakan dan penyumbatan pada pembuluh-

pembuluh halus, mencakup arteriol prekapiler retina, kapiler, dan vena. Berkaitan dengan prediksi dan pengobatan, maka DR dibagi menjadi 4 kategori.



Gambar 2.2. Klasifikasi DR

Berdasarkan Tingkat keparahannya, menurut [5] tanda tanda DR pada citra fundus dapat dibagi menjadi beberapa kelas diantaranya:

1) Mild Non-Proliferative Diabetic Retinopathy (NPDR)

Ini adalah tahap awal retinopati diabetik, yang ditandai dengan area kecil pembengkakan pada pembuluh darah retina. Area pembengkakan ini dikenal sebagai aneurisma mikro. Sejumlah kecil cairan dapat bocor ke dalam retina pada tahap ini, sehingga memicu pembengkakan makula. Makula adalah area di dekat pusat retina.

2) Moderate Non-Proliferative Diabetic Retinopathy (NPDR)

Pembengkakan pembuluh darah kecil yang meningkat mulai mengganggu aliran darah ke retina, sehingga mencegah nutrisi yang tepat. Hal ini menyebabkan penumpukan darah dan cairan lain di makula.

3) Severe Non-Proliferative Diabetic Retinopathy (NPDR)

Sebagian besar pembuluh darah di retina tersumbat, sehingga menyebabkan penurunan aliran darah yang signifikan ke area ini. Pada tahap ini, tubuh menerima sinyal untuk mulai menumbuhkan pembuluh darah baru di retina.

#### 4) Proliferative Diabetic Retinopathy (PDR)

Ini adalah stadium lanjut dari penyakit ini, di mana pembuluh darah baru terbentuk di retina. Karena pembuluh darah ini sering kali rapuh, maka ada risiko kebocoran cairan yang lebih tinggi. Hal ini memicu berbagai masalah penglihatan, seperti pandangan kabur, berkurangnya lapang pandang, dan bahkan kebutaan.

Ada beberapa sistem untuk menilai tingkat keparahan DR, seperti American Academy of Ophthalmology (AAO), Early Treatment of Diabetic Retinopathy Study (ETDRS), dan protokol penilaian Scottish. Dalam penelitian ini, DR diklasifikasikan menjadi lima kelas yaitu tidak ada DR, DR ringan, DR sedang, DR parah, dan PDR, berdasarkan protokol penilaian Scottish.

### 2.3.2. Deep Learning

Deep Learning merupakan salah satu cabang dalam Machine Learning yang bertugas untuk mengolah data dalam lapisan-lapisan bertingkat agar menghasilkan interpretasi yang lebih berarti. Kata "Deep" pada Deep Learning merujuk pada lapisan representasi yang tersusun secara bertahap. Umumnya, model Deep Learning saat ini terdiri dari puluhan hingga ratusan lapisan yang diatur berurutan dan mampu belajar dari data pelatihan secara mandiri. Dalam konsep ini, lapisan-

lapisan tersebut dikenal dengan sebutan Neural Networks, yaitu struktur bertingkat di mana satu lapisan berada di atas lapisan lainnya. Neural Networks mengadopsi prinsip neurobiologi, terinspirasi dari kemampuan otak manusia dalam memahami informasi. Meskipun inspirasi awalnya berasal dari otak manusia, model Deep Learning tidak serta-merta meniru cara kerja otak, karena belum ada bukti yang menunjukkan bahwa otak berfungsi seperti model Deep Learning yang digunakan saat ini[35] [36].

### **2.3.3. Convolutional Neural Network (CNN)**

Convolutional Neural Network (CNN) adalah jenis arsitektur jaringan saraf tiruan yang sering digunakan untuk tugas-tugas pengenalan dan pemrosesan citra. CNN merupakan pengembangan dari Multilayer Perceptron (MLP) yang dirancang untuk mengolah data berskala besar dan diaplikasikan pada citra tiga dimensi.[37]. Menurut Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, dan L. D. Jackel dalam paper "Backpropagation Applied to Handwritten Zip Code Recognition" (1989), CNN adalah "sebuah arsitektur neural network yang terdiri dari layer-layer konvolusi dan pooling yang digunakan untuk memproses data berupa gambar atau citra". Metode CNN banyak digunakan untuk klasifikasi dan pengenalan citra yang sudah diberi label melalui metode pembelajaran terawasi (supervised learning). Dengan data yang dilatih dan variabel target, metode pembelajaran terawasi bertujuan untuk mengelompokkan data baru sesuai dengan data yang sudah ada. Gambar 2 menunjukkan arsitektur umum CNN. Arsitektur ini memungkinkan CNN untuk menangkap informasi kontekstual yang terdapat dalam

data, seperti piksel yang berdekatan dalam gambar. Ini menunjukkan bahwa model CNN dapat melakukan ekstraksi fitur dari gambar secara mandiri.



Gambar 2.3. Arsitektur CNN

Berikut adalah beberapa layer yang digunakan untuk proses klasifikasi dalam Convolutional Neural Network:

### 1. Layer Input

Pada lapisan layer ini merupakan dimana citra yang akan digunakan Sebagai dataset dimasukkan untuk proses klasifikasi ke dalam model klasifikasi.

### 2. Layer Convolutional

Layer Convolution melakukan pekerjaan untuk mengurangi kompleksitas perhitungan sesuai dengan prinsip sliding window dan pembagian berat[38]. Dengan melakukan konvolusi pada data gambar, tujuan adalah untuk mendapatkan lebih banyak fitur dari gambar input. Pada lapisan awal, fitur yang diekstraksi memiliki sifat low-level, seperti warna pada gambar. Namun, ketika gambar bergerak ke lapisan yang lebih dalam, fitur yang terdeteksi menjadi high-level, seperti tekstur (Liu, Shen, dan Van Den Hengel, n.d.).

Dibidang pembelajaran mesin, gambar input direpresentasikan sebagai array 2D, sementara kernel adalah parameter berbentuk array multidimensi yang disesuaikan dengan algoritma model yang digunakan. Operasi konvolusi dapat diterapkan dalam berbagai dimensi. Sebagai ilustrasi, jika citra 2D  $J$  digunakan sebagai masukan,  $K$  juga akan membentuk 2D.

$$T(j, k) = (J \times K)(j, k) = \sum_b \sum_c J(b, c)K(j - b, k - c) \quad (2.2)$$

Ket:

$T(j, k)$  = Fungsi hasil konvolusi

$J$  = Input

$K$  = Kernel atau Filter

$(j, k)$  = Pixel input

$(b, c)$  = Pixel Kernel

Lapisan convolutional kemudian diikuti oleh Rectified Linear Unit (ReLU), berfungsi untuk mengubah nilai negatif pada feature map menjadi positif, seperti ditampilkan pada Gambar 4. ReLU yang bertugas menyesuaikan piksel non-linear setelah melalui konvolusi dengan menerapkan fungsi 2.1. [39].


Input			ReLU		
-249	-91	-37	0	0	0
250	-134	101	250	0	101
27	61	-153	27	61	0

Gambar 2.4. Contoh Penerapan Aktivasi ReLU (Sumber: Rosebrock, Adrian).

$$f(x) = \text{Max}(0, x) \quad (2.1)$$

### 3. Layer Pooling

Lapisan Pooling adalah lapisan yang ditempatkan diantara lapisan konvolusi untuk mengurangi volume output peta fitur, yang membantu mengendalikan overfitting. Lapisan pooling digunakan untuk mengambil nilai maksimum (max-pooling) atau nilai rata-rata (average pooling) dari area piksel dalam sebuah citra. Fungsi utama lapisan ini adalah untuk mengurangi ukuran citra sehingga lebih mudah digantikan dengan lapisan konvolusi yang memiliki stride yang sama dengan lapisan pooling yang digunakan (Gholamalizhad & Khosravi, n.d.).




Gambar 2.5. Perhitungan pada Pooling layer

### 4. Layer Full Connected

Fully Connected Layer adalah lapisan dalam jaringan saraf di mana setiap neuron terhubung dengan semua neuron di lapisan sebelumnya. Lapisan ini biasanya terletak di bagian akhir jaringan, setelah beberapa lapisan konvolusi dan pooling dalam CNN, dan bertugas untuk keputusan akhir atau klasifikasi. Fully Connected Layer digunakan dalam penerapan Multi-Layer Perceptron

(MLP) dengan tujuan melakukan transformasi pada dimensi data sehingga dapat diklasifikasikan secara linear.



Gambar 2.6. Proses Fully Connected Layer

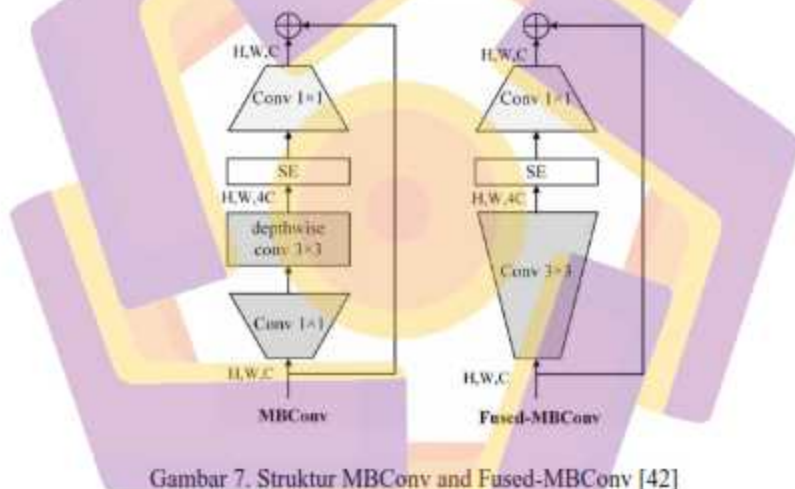
Matriks peta fitur akan diubah menjadi vektor ( $x_1, x_2, x_3, \dots$ ). Dengan lapisan yang sepenuhnya terhubung, vektor diproses Fully Connected Layer yang menggabungkan fitur-fitur ini untuk membuat model. Tahap terakhir, proses ini memiliki fungsi aktivasi seperti softmax atau sigmoid untuk mengklasifikasikan keluaran Sebagai pengenalan objek[41].

#### 2.3.4. EfficientnetV2

EfficientNet-V2 adalah model terkini dari seri EfficientNet yang diperkenalkan oleh Google Research pada 2021, EfficientNet mewakili sebuah arsitektur Convolutional Neural Network (CNN) yang sangat efisien, yang mengoptimalkan kinerja jaringan melalui pendekatan sistematis terhadap scaling (penyesuaian ukuran). Pendekatan ini melibatkan penyesuaian secara bersamaan pada kedalaman (depth), lebar (width), dan resolusi (resolution). EfficientNetV2

dikembangkan berdasarkan fondasi dari EfficientNet, dengan mengintegrasikan tiga teknik inovatif untuk meningkatkan efisiensi dan efektivitasnya lebih lanjut.

Efficientnetv2 memiliki keunggulan dalam efisiensi parameter yang lebih baik. Model ini mengkombinasikan dua blok konvolusi, yaitu MBCConv dan Fused MBCConv, yang keduanya dilengkapi dengan lapisan pemerasan dan eksitasi. Blok MBCConv menggunakan depth-wise convolutional layer dengan ukuran  $3 \times 3$ , sementara blok Fused MBCConv menggunakan lapisan konvolusi biasa  $3 \times 3$ .



EfficientNetV2 mengintegrasikan Fused-MBCConv untuk mengatasi kelemahan layer MBCConv yang terdapat pada tahap awal EfficientNet-B0, walaupun layer tersebut efektif di tahap-tahap akhir. Layer MBCConv memiliki jumlah parameter dan FLOP yang lebih sedikit dibandingkan layer deep learning lainnya, tetapi sering kali tidak dapat memanfaatkan akselerator modern akibat kompleksitasnya.

Strategi scaling pada EfficientNet melibatkan penyesuaian kedalaman (depth), lebar (width), dan resolusi input jaringan secara bersamaan, yang dikendalikan oleh koefisien komposit  $\phi$ . Strategi ini memungkinkan peningkatan kapasitas dan kinerja jaringan secara sistematis. Rumus yang digunakan dalam scaling ini adalah sebagai berikut [43]:

1. Penyesuaian Kedalaman:

$$d = d_0 \times \alpha^\phi$$

Di mana  $d_0$  adalah jumlah lapisan dalam jaringan dasar, dan  $\alpha$  alpha adalah faktor scaling kedalaman.

2. Penyesuaian Lebar:

$$w = w_0 \times \beta^\phi$$

Di mana  $w_0$  adalah lebar jaringan awal, dan  $\beta$  adalah faktor scaling lebar.

3. Penyesuaian Resolusi:

$$r = r_0 \times \gamma^\phi$$

Di mana  $r_0$  adalah resolusi awal, dan  $\gamma$  gamma adalah faktor scaling resolusi.

Koefisien komposit  $\phi$  memungkinkan pengguna untuk menyesuaikan nilai ini guna memperbesar seluruh jaringan sesuai kebutuhan.

### 2.3.5. Peningkatan Pada EfficientNetV2

EfficientNetV2 menyempurnakan metode scaling dasar yang digunakan oleh EfficientNet, membuatnya lebih adaptif terhadap berbagai kondisi pelatihan dan

kebutuhan aplikasi. Optimalisasi ini memberikan keseimbangan yang lebih baik antara efisiensi komputasi dan kinerja model. Hasilnya, EfficientNetV2 mampu menangani berbagai jenis dataset dan ukuran gambar dengan lebih efisien.

Keunggulan EfficientNetV2:

1. Kemampuan untuk Mengolah Gambar dengan Resolusi Beragam:

Efisien dalam memproses gambar beresolusi tinggi untuk tugas yang membutuhkan detail presisi, sekaligus mampu menangani gambar sederhana dengan cepat.

2. Optimalisasi untuk Beragam Dataset:

Strategi scaling yang canggih memungkinkan penyesuaian pada kedalaman, lebar, dan resolusi sesuai dengan kebutuhan spesifik aplikasi. Dengan demikian, model ini sangat fleksibel untuk diterapkan pada berbagai skenario pemrosesan gambar di dunia nyata.

EfficientNetV2 tidak hanya meningkatkan performa tetapi juga memperluas jangkauan penggunaannya, menjadikannya pilihan yang unggul untuk tugas-tugas pemrosesan gambar yang menuntut efisiensi tinggi tanpa mengorbankan kualitas hasil.


EfficientNetV2 dipilih dalam penelitian ini karena arsitektur ini dirancang untuk memberikan efisiensi yang lebih tinggi dibandingkan model sebelumnya (EfficientNet). Dengan memanfaatkan teknik seperti progressive learning (progresif peningkatan resolusi gambar) dan arsitektur yang lebih optimal untuk

hardware modern, EfficientNetV2 mampu mencapai akurasi tinggi dengan waktu inferensi yang lebih cepat dan kebutuhan komputasi yang lebih rendah. Hal ini sangat relevan untuk deteksi diabetic retinopathy yang membutuhkan klasifikasi akurat pada data gambar dengan resolusi tinggi.

### 2.3.6. Peningkatan Pada EfficientNetV2

Dilation layer (atau dilated convolution layer) adalah lapisan konvolusi yang memperlebar jangkauan filter dengan menyisipkan celah (dilasi) antar elemen kernel. Hal ini memungkinkan model menangkap informasi spasial yang lebih luas tanpa meningkatkan jumlah parameter atau kehilangan resolusi spasial, sangat berguna untuk tugas-tugas seperti segmentasi citra dan deteksi objek [44].

Prinsip dasar dari dilated convolutional neural network adalah memberikan lubang/ruang diantara titik satu dengan yang lain pada proses perkalian matriks input dengan kernel. Metode ini terbukti pada beberapa penelitian dapat membuat kernel konvolusi memperoleh lebih banyak informasi dari matriks input tanpa meningkatkan proses komputasi [45]. Proses pada dilated convolutional neural network dapat dilakukan menggunakan Persamaan 2.8. Jika metode convolutional neural network menggunakan nilai  $d = 1$ , maka metode dilated convolutional neural network menggunakan nilai  $d > 1$ . Ilustrasi dari metode dilated convolutional neural network dapat dilihat pada gambar 2.



Gambar 2.4 Convolutional Neural Network dengan  $d = 1$  (kiri); Dilated Convolutional Neural Network dengan  $d = 2$  (Kanan)

Manfaat Dilated Convolution dapat dilihat dari beberapa aspek penting. Pertama, dilated convolution mampu memperluas receptive field secara efisien, sehingga model dapat menangkap konteks yang lebih luas tanpa harus menambah jumlah parameter atau menurunkan resolusi feature map (GeeksforGeeks; Analytics Vidhya). Kedua, metode ini mendukung kemampuan multi-skala, karena dengan menggunakan beragam nilai dilation rate dalam satu layer atau blok, model dapat memproses informasi lokal maupun global secara bersamaan, sehingga representasi fitur yang diperoleh menjadi lebih kaya (Analytics Vidhya; DevChunk). Selain itu, dilated convolution juga memberikan efisiensi komputasi sekaligus menjaga detail, sebab operasi ini tidak membutuhkan pooling sehingga resolusi citra tetap terpelihara, sementara cakupan model menjadi lebih luas

### 2.3.7. Evaluasi Confusion Matrix

Confusion Matrix merupakan tool yang diterapkan dalam melakukan kinerja algoritme klasifikasi. Confusion Matrix dibangun dengan tujuan menemukan jumlah perkiraan yang benar dan salah. Kemudian, perkiraan ini dirangkum dan dipisahkan ke dalam setiap kelas. Hal ini menyelesaikan semua masalah yang timbul mengenai bagaimana model klasifikasi bekerja. Confusion Matrix yaitu metode yang bekerja melakukan perhitungan akurasi pada data mining [46]. Berikut menunjukkan jumlah istilah yang digunakan dengan metode Confusion Matrix:[47]

Tabel 2.1. Confusion Matrix

		True Value	
		FALSE	TRUE
Prediction	FALSE	TN	FP
	TRUE	FN	TP

Deskripsi:

1. " True Positive" (TP), adalah jumlah data positif yang diklasifikasikan dengan benar oleh sistem.
2. Jumlah data negatif yang diklasifikasikan dengan benar oleh sistem disebut sebagai True Negative (TN).
3. Jumlah data negatif yang diklasifikasikan sebagai positif oleh sistem disebut sebagai False Positive (FP).
4. umlah data positif yang diklasifikasikan sebagai negatif oleh sistem dikenal sebagai false negative (FN).

### 2.3.8. Pengukuran Performance

Untuk memudahkan pemahaman mengenai Accuracy, Precision, Recall, dan F1 Score.

#### Accuracy

Akurasi adalah rasio jumlah prediksi yang benar (baik positif maupun negatif) terhadap seluruh data. Akurasi dihitung dengan rumus:

$$\text{Akurasi} = (TP + TN) / (TP+FP+FN+TN)$$

Pada contoh kasus di atas, Akurasi =  $(4+3) / (4+2+1+3) = 7/10 = 70\%$

#### Precision

Presisi adalah rasio perkiraan benar positif jika comparasi dengan keseluruhan hasil yang diperkirakan positif."

$$\text{Precision} = (TP) / (TP+FP)$$

Pada contoh kasus di atas, Precision =  $4 / (4+2) = 4/6 = 67\%$ .

#### Recall (Sensitifitas)

Recall adalah rasio perkiraan benar positif dibandingkan dengan semua data yang mencakup True positif. Recall menjawab pertanyaan

$$\text{Recall} = (TP) / (TP + FN)$$

$$4 = 4 / (4+1) = 4/5 = 80\%.$$

#### F1 Score


F1 Score merupakan perbandingan average recall dan presisi yang dibobotkan

$$\text{F1 Score} = 2 * (\text{Recall} * \text{Precision}) / (\text{Recall} + \text{Precision})$$

Waktu Training (Times)

Merupakan rasio pengukuran waktu dimulainya trainin hingga selesai. Waktu training mengukur performa seberapa cepat algoritma dapat menyelesaikan masalah perhitungan.

$$\text{Waktu Training} = \text{Start (t start)} - \text{Finish (t end)}$$



## **BAB 3**

### **METODE PENELITIAN**

#### **3.1 Jenis, Sifat, dan Pendekatan Penelitian**

Jenis penelitian yang dilakukan merupakan penelitian eksperimental, Dimana penelitian ini menerapkan beberapa scenario percobaan untuk mendapatkan hasil akurasi yang paling baik. Eksperimen yang dimaksud yaitu dengan membandingkan beberapa metode klasifikasi untuk mengidentifikasi diabetic retinopathy memanfaatkan arsitektur EfficientNetV2 sebagai ekstraksi fitur dengan menggunakan metode Convolutional Neural Network (CNN). Metode ini akan dilakukan beberapa pengujian untuk mengetahui model yang lebih akurat dalam mengidentifikasi diabetic retinopathy.

Penelitian ini merupakan penelitian yang bersifat deskriptif yang digunakan untuk mengetahui tingkat keakuratan model dalam mengidentifikasi penyakit diabetic retinopathy dengan parameter uji confusion matrix, yaitu akurasi, presisi, recall, F1 score menggunakan metode CNN EfficientnetV2. Penelitian ini menggunakan pendekatan penelitian kuantitatif yang hasilnya berupa informasi nilai angka serta plot diagram dari eksperimen yang telah dilakukan. Data pada penelitian ini diambil dari hasil eksperimen Dimana data data tersebut dianalisis untuk menemukan hasil terbaik.

### 3.2 Metode Pengumpulan Data

Data yang digunakan dalam penelitian ini diperoleh dari layanan penyedia data bersifat publik sehingga setiap orang dapat mengakses dan melakukan penelitian dari sumber tersebut. Situs [www.kaggle.com](http://www.kaggle.com) yang memungkinkan akses ke kumpulan data dalam berbagai ukuran. Data yang digunakan berupa gambar atau citra digital retina, yang dikontribusikan oleh APTOS 2019 Blindness Detection. Dataset gambar retina diabetic retinopathy adalah gambar retina dari penderita diabetes. Data pada penelitian ini telah digunakan pada beberapa penelitian sebelumnya yaitu (RIZAL et al., 2020), berjudul "Deep Learning untuk Klasifikasi Diabetic Retinopathy menggunakan Model EfficientNet" dan [48] dengan judul "A Lightweight Robust Deep Learning Model Gained High Accuracy in Classifying a Wide Range of Diabetic Retinopathy Image". Data citra retina yang digunakan terbagi dalam 5 kelas yaitu Mild, Moderate, No\_DR, Proliferate\_DR, dan Severe

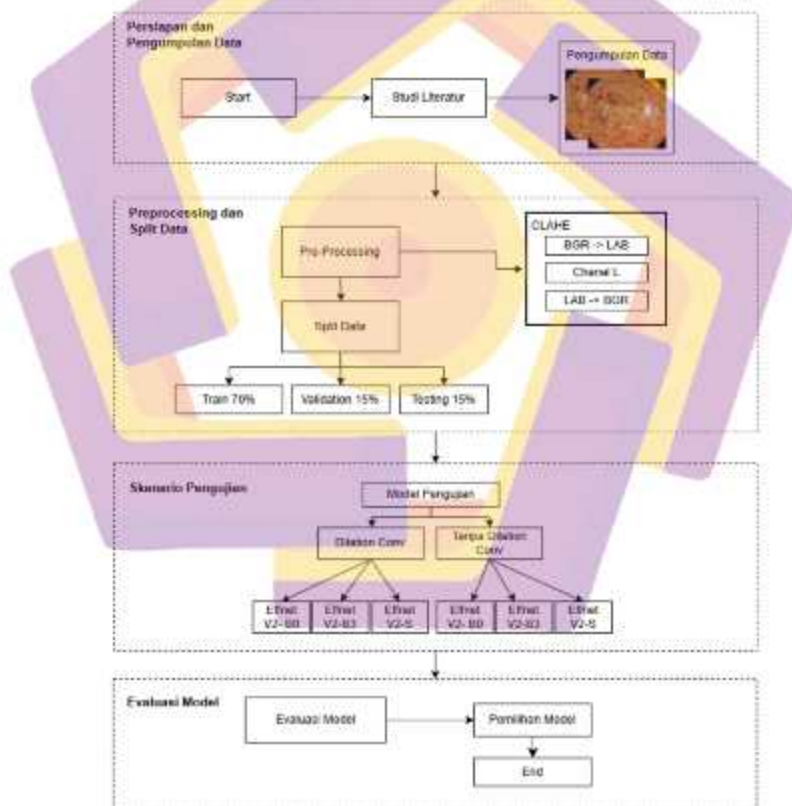
### 3.3 Metode Analisis Data

Metode analisis data yaitu tahapan pengolahan data untuk mendapatkan hasil yang optimal dengan menghitung akurasi, presisi, recall dan F1-Score metode EfficientnetV2 dalam melakukan deteksi DR. Sebelum data citra retina diklasifikasikan maka dilakukan preprocessing terlebih dahulu seperti resize dan menaikkan kosntras menggunakan teknik Contrast Limited Adaptive Histogram Equalization (CLAHE). Penelitian ini akan menerapkan scenario yaitu penerapan citra yang sudah dilakukan preprocessing, menggunakan model EfficientNetV2 berbagai ukuran. Pada percobaan scenario penelitian ini menempatkan data traning

sebanyak 70%, data validasi sebanyak 15% dan data testing 15%. Selanjutnya mengukur Tingkat keakuratan model yang telah dihasilkan

### 3.4 Alur Penelitian

Alur penelitian pada penelitian ini adalah sebagai berikut, dan dijelaskan melalui bagan alur penelitian pada gambar 3.1.



Gambar 3.1 Alur Penelitian

## BAB 4 HASIL PENELITIAN DAN PEMBAHASAN

### 4.1. Dan Pengumpulan Data

#### 4.1.1 Studi Literatur

Dalam penyusunan laporan penelitian ini, langkah-langkah yang dilakukan harus selaras dengan metode penelitian yang telah dirancang sebelumnya. Tahap awal yang ditempuh adalah studi literatur, yakni dengan menelaah berbagai sumber seperti arsip, buku, jurnal, artikel ilmiah, serta laporan penelitian terdahulu yang dijadikan sebagai acuan maupun dasar dalam penelitian ini. Studi literatur ditempatkan pada BAB II Landasan Teori, yang berisi uraian mengenai teori-teori dan konsep relevan yang mendukung serta memperkuat penyelesaian penelitian ini.

#### 4.1.2 Pengumpulan Data



Gambar 4.1 Dataset DR

Pada penelitian ini digunakan data yang bersifat sekunder, yaitu data yang diperoleh dari situs penyedia data publik Kaggle yang dapat diakses oleh semua

orang. Data yang digunakan berupa citra digital retina yang bersumber dari dataset APTOS 2019 Blindness Detection yang dikontribusikan oleh Asia Pacific Tele-Ophthalmology Society (APTOS) dan dapat diakses melalui tautan <https://www.kaggle.com/datasets/mariaherrerot/aptos2019>. Dataset ini telah digunakan pada beberapa penelitian sebelumnya, salah satunya oleh [48].

Citra retina pada dataset ini merupakan gambar retina penderita diabetic retinopathy, yaitu komplikasi pada mata yang disebabkan oleh penyakit diabetes. Total data yang digunakan dalam penelitian ini berjumlah 3.665 citra retina yang terbagi ke dalam lima kelas, yaitu Mild, Moderate, No\_DR, Proliferative\_DR, dan Severe. Setiap kelas mewakili tingkat keparahan penyakit yang berbeda, mulai dari tidak adanya tanda penyakit hingga kondisi yang sudah parah. Pembagian jumlah citra berdasarkan setiap kelasnya dapat dilihat pada Tabel 4.1 berikut.

Tabel 4.1 Distribusi Data

<b>Kelas</b>	<b>Jumlah</b>
<i>Mild</i>	370
<i>Moderate</i>	999
<i>No_DR</i>	1805
<i>Severe</i>	193
<i>Proliferative_DR</i>	295
<b>Jumlah</b>	<b>3662</b>

Berdasarkan Tabel 4.1, dapat diamati bahwa distribusi jumlah citra pada setiap kelas tidak merata atau bersifat imbalanced. Kelas No\_DR memiliki jumlah citra yang paling dominan yaitu 1.805 citra (sekitar 49% dari total dataset),

sedangkan kelas Severe dan Proliferative\_DR memiliki jumlah data yang jauh lebih sedikit, masing-masing hanya 193 dan 295 citra. Ketidakseimbangan ini berpotensi menimbulkan bias dalam proses pelatihan model, di mana jaringan saraf cenderung lebih sering belajar mengenali pola dari kelas dengan jumlah data yang besar dan mengabaikan kelas minoritas. Akibatnya, model dapat memperoleh nilai akurasi keseluruhan (overall accuracy) yang tinggi, tetapi memiliki performa yang buruk pada kelas dengan jumlah data yang sedikit, khususnya pada kelas dengan tingkat keparahan tinggi seperti Severe dan Proliferative\_DR.


## **4.2. Preprocessing dan Split data**

### **4.2.1 Preprocessing**


Tahapan preprocessing pada penelitian ini bertujuan untuk meningkatkan kualitas citra retina sehingga lebih optimal digunakan dalam proses pelatihan model. Langkah pertama adalah resizing citra ke dalam ukuran tertentu (misalnya 224×224 piksel) agar sesuai dengan input arsitektur EfficientNetV2 dan mengurangi beban komputasi. Selanjutnya dilakukan normalisasi piksel dengan skala 0–1 untuk menstabilkan distribusi data sehingga proses pelatihan jaringan saraf lebih cepat konvergen.

Untuk memperbaiki kualitas kontras dan memperjelas detail pembuluh darah retina, digunakan Contrast Limited Adaptive Histogram Equalization (CLAHE). Metode ini mampu menyesuaikan kontras secara lokal pada area citra, sehingga bagian retina yang gelap atau terlalu terang tetap dapat terdeteksi dengan

baik tanpa menyebabkan distorsi warna berlebih Gambar 4.2 dan 4.3 menunjukkan proses sebelum dan sesudah clahe diterapkan.



Gambar 4.2 Proses Load data sebelum CLAHE



Gambar 4.4 Gambar Retina Setelah CLAHE

#### 4.2.2 Split Data

Tabel 4.2 Pembagian Data

Kelas	Jumlah	Presentase (%)
<i>Data Training</i>	2563	70%
Data Validation	549	15%
Data Testing	550	15%
<b>Jumlah</b>	<b>3662</b>	<b>100%</b>

Dataset pada penelitian ini dibagi menjadi 3 bagian terdiri data latih sebanyak 70% Sebagai untuk melatih model agar dapat mempelajari pola dari data yang ada., data validasi 15% untuk mengevaluasi kinerja model selama proses

pelatihan dan membantu dalam pemilihan parameter terbaik. dan data uji 15% yang difungsikan untuk mengukur performa akhir model pada data yang belum pernah dilihat sebelumnya, sehingga memberikan gambaran akurasi model di kondisi nyata. Pembagian dilakukan menggunakan fungsi `train_test_split` dari library Python, yang memungkinkan pemisahan data secara acak namun terkontrol berdasarkan persentase yang telah ditentukan.

### **4.3. Skenario Pengujian**

#### **4.3.1 Pemodelan Algoritma EfficientNetV2**

Pada penelitian ini, pemodelan dilakukan dengan menggunakan algoritma EfficientNetV2 sebagai arsitektur utama dalam proses klasifikasi citra. EfficientNetV2 dipilih karena memiliki efisiensi tinggi dalam hal jumlah parameter sekaligus mampu menghasilkan performa yang baik pada permasalahan klasifikasi citra medis. Arsitektur model dibangun dengan EfficientNetV2B0, B3 dan S sebagai base model yang dilatih menggunakan bobot awal ImageNet. Lapisan akhir bawaan (`include_top=False`) dihilangkan dan digantikan dengan beberapa lapisan tambahan, yaitu:

Arsitektur model yang digunakan pada penelitian ini dibangun dengan menambahkan beberapa lapisan setelah base model EfficientNetV2. Lapisan pertama adalah Conv2D dengan dilation rate yang berfungsi untuk mengekstraksi fitur spasial lebih luas dari citra retina. Selanjutnya ditambahkan Batch Normalization guna menstabilkan distribusi data selama proses pelatihan, sehingga konvergensi model menjadi lebih cepat dan stabil.

Setelah itu digunakan Global Average Pooling untuk mereduksi dimensi fitur sekaligus mempertahankan informasi penting yang telah diekstraksi. Tahap berikutnya adalah penambahan lapisan Dense dan Dropout yang berperan dalam mencegah overfitting serta meningkatkan kemampuan generalisasi model. Sebagai lapisan akhir digunakan Dense dengan aktivasi Softmax yang memiliki jumlah neuron sesuai dengan banyaknya kelas, yaitu lima kelas: No\_DR, Mild, Moderate, Severe, dan Proliferative\_DR.

Model yang telah dibangun kemudian dikompilasi dengan menggunakan optimizer Adam, loss function dan metric accuracy. Setelah proses pelatihan selesai, model dievaluasi menggunakan data latih, validasi, dan uji dengan mengukur beberapa metrik performa, yaitu akurasi, presisi, recall, dan F1-score. Selain itu, kinerja model juga divisualisasikan melalui kurva ROC-AUC untuk mengukur kemampuan diskriminasi antar kelas serta confusion matrix untuk melihat distribusi hasil klasifikasi pada masing-masing kelas.

#### **4.3.2 Integrasi Dilation Layer**

Pada penelitian ini, dilation layer atau atrous convolution diterapkan setelah ekstraksi fitur dari arsitektur EfficientNetV2 dengan tujuan memperluas receptive field tanpa menambah jumlah parameter model. Secara prinsip, dilation layer bekerja dengan memberikan jarak tertentu antar elemen kernel konvolusi. Jika pada konvolusi standar setiap elemen kernel berdekatan satu sama lain, maka pada dilated convolution terdapat ruang kosong di antara elemen-elemen tersebut sesuai dengan nilai dilation rate yang digunakan. Dalam penelitian ini, nilai dilation\_rate

= 2 digunakan, yang berarti terdapat satu piksel jarak di antara setiap elemen kernel. Mekanisme ini memungkinkan filter berukuran  $3 \times 3$  untuk mencakup area yang lebih luas secara efektif (setara dengan  $5 \times 5$ ), sehingga neuron dapat mengenali pola yang tersebar pada citra retina tanpa kehilangan resolusi spasial aslinya.

Dengan perluasan area pengamatan tersebut, *dilation layer* membantu model memahami hubungan antar fitur yang terletak pada jarak yang lebih jauh, seperti distribusi *microaneurysm*, *hemorrhage*, atau pola neovaskularisasi pada citra retina. Hal ini sangat penting karena tanda-tanda awal *Diabetic Retinopathy (DR)* tidak hanya muncul secara lokal, tetapi juga dalam bentuk pola yang menyebar di seluruh permukaan retina. Dengan memanfaatkan *dilated convolution*, model memperoleh kemampuan untuk menangkap konteks spasial global sekaligus mempertahankan detail lokal, menghasilkan representasi fitur yang lebih informatif dan mendalam.

Selain itu, pendekatan ini memiliki keunggulan efisiensi karena tidak menambah jumlah parameter secara signifikan. Dengan kata lain, *dilation layer* memperluas jangkauan persepsi model tanpa menambah kompleksitas komputasi secara drastis. Pada implementasinya, *dilation layer* ini diikuti oleh proses *batch normalization* untuk menstabilkan distribusi aktivasi, dan dilanjutkan dengan *global average pooling* serta beberapa lapisan *dense* untuk melakukan klasifikasi akhir ke dalam lima kelas tingkat keparahan *Diabetic Retinopathy*. Secara keseluruhan, penambahan *dilation layer* berperan penting dalam meningkatkan kemampuan model untuk mengenali variasi pola penyakit retina, yang pada akhirnya berkontribusi terhadap peningkatan akurasi klasifikasi menjadi 96,54%.

lebih tinggi dibandingkan dengan penelitian terdahulu yang tidak menerapkan mekanisme dilasi pada arsitekturnya.

#### 4.4.3 Pelatihan Model

Langkah selanjutnya adalah menentukan skenario pelatihan model yang akan digunakan pada proses klasifikasi citra retina. Pada penelitian ini, citra retina yang berasal dari dataset APTOS 2019 akan dikelompokkan ke dalam lima kelas sesuai label yang telah ditentukan, yaitu No\_DR, Mild, Moderate, Severe, dan Proliferative\_DR. Untuk menghasilkan model klasifikasi yang optimal, penelitian ini dirancang dengan membandingkan 3 Varian Model arsitektur, yaitu EfficientNetV2. Perbandingan ini dilakukan untuk mengetahui pengaruh penggunaan dilation terhadap akurasi, presisi, recall, dan F1-score dalam mendeteksi tingkat keparahan diabetic retinopathy.

Tabel 4.3 Skenario Penelitian dengan hyperparameter

SP	Varian	Optimizer	BatchSize	Loss Funclon	Epoch
S1	EfficientNet V2 -B0	Adam(learning rate=0.0001)	32	sparse_categorical _crossentropy	50
S2	EfficientNet V2 -B3	Adam(learning rate=0.0001)	32	sparse_categorical _crossentropy	50
S3	EfficientNet V2 -S	Adam(learning rate=0.0001)	32	sparse_categorical _crossentropy	50

Skenario penelitian ini dilakukan untuk mengetahui performa arsitektur EfficientNetV2 pada klasifikasi Diabetic Retinopathy dengan mengintegrasikan dilation layer. penelitian ini dilakukan tiga skenario percobaan (S1, S2, dan S3) dengan menggunakan varian arsitektur EfficientNetV2 yang berbeda, yaitu EfficientNetV2-B0, EfficientNetV2-B3, dan EfficientNetV2-S. Setiap skenario menggunakan konfigurasi hyperparameter yang sama untuk menjaga konsistensi perbandingan performa antar model yang ditunjukkan pada tabel 4.3. Proses pelatihan dijalankan dengan mekanisme early stopping untuk mencegah overfitting. Melalui pengaturan ini, setiap varian EfficientNetV2 diuji kemampuannya dalam mendeteksi tingkat keparahan diabetic retinopathy secara optimal.

#### 4.4.4 EfficientnetV2

Pada skenario penelitian ini, metode EfficientNetV2 diterapkan dengan preprocessing citra menggunakan Contrast Limited Adaptive Histogram Equalization (CLAHE) pada ruang warna LAB untuk meningkatkan kontras dan visibilitas detail pada citra retina. Peningkatan kualitas citra ini memungkinkan model menangkap fitur penting seperti pembuluh darah, mikroaneurisma, pendarahan, dan eksudat secara lebih jelas, sehingga pola-pola yang relevan untuk klasifikasi Diabetic Retinopathy (DR) dapat diekstraksi dengan akurat.

EfficientNetV2 dipilih karena kemampuannya dalam mengekstraksi fitur secara efisien dari level global hingga detail halus pada citra medis. Dalam arsitektur penelitian ini, base model diinisialisasi dengan bobot pretrained ImageNet dan `include_top=False`, sehingga lapisan klasifikasi bawaan diganti

dengan lapisan kustom. Penambahan utama pada arsitektur adalah dilated convolution layer, yang memperluas receptive field tanpa menambah jumlah parameter secara signifikan. Dilation layer memungkinkan model menangkap lesi kecil pada retina yang tersebar dengan jarak spasial tertentu, sehingga fitur kritis untuk diagnosis DR dapat diperoleh lebih lengkap dan akurat.

Selain dilation layer, arsitektur juga dilengkapi dengan Batch Normalization, Global Average Pooling, beberapa lapisan Fully Connected Layer, dan lapisan output dengan aktivasi Softmax sesuai lima kelas DR (No\_DR, Mild, Moderate, Severe, Proliferative\_DR). Kombinasi ini memastikan model tidak hanya mengekstraksi fitur penting secara efisien, tetapi juga mempertahankan informasi spasial yang kritis pada citra retina, sehingga mendukung deteksi dini dan klasifikasi DR dengan performa yang lebih baik.



Total param:	8,324,388	(35.56 MB)
Trainable param:	3,809,809	(12.90 MB)
Non-trainable param:	4,514,579	(22.58 MB)

Gambar 4.5 Model Arsitektur EfficientnetV2 + Dilation Layer

Pada gambar 4.12, terlihat struktur arsitektur CNN yang dibangun menggunakan arsitektur EfficientNetV2B0 sebagai feature extractor. Model ini diawali dengan input layer berukuran 224x224 piksel dengan 3 kanal warna (RGB). Seluruh bobot pada EfficientNetV2B0 yang digunakan telah dilatih sebelumnya (pre-trained) dengan dataset ImageNet, namun pada tahap awal penelitian ini

lapisan bawaan EfficientNet difreeze sehingga tidak ikut dilatih, sehingga hanya lapisan tambahan yang diperbarui selama proses training.

Selanjutnya, setelah keluaran dari EfficientNetV2B0, ditambahkan sebuah Convolutional Layer (Conv2D) dengan 256 unit kernel, ukuran kernel 3x3, serta dilengkapi dengan dilation rate = 2. Fungsi dari lapisan dilated convolution ini adalah memperluas receptive field sehingga model mampu menangkap informasi spasial yang lebih luas tanpa menambah jumlah parameter secara signifikan. Setelah itu, digunakan BatchNormalization untuk menstabilkan distribusi data agar proses pelatihan lebih cepat dan stabil.

Lapisan berikutnya adalah GlobalAveragePooling2D, yang bertugas mereduksi dimensi fitur dengan cara merata-ratakan setiap peta fitur. Tahapan ini juga berfungsi untuk menghubungkan lapisan konvolusional dengan lapisan fully connected tanpa menambah terlalu banyak parameter. Selanjutnya, ditambahkan Dense layer dengan 64 unit dan aktivasi ReLU yang dilengkapi regularisasi L2 untuk mencegah overfitting. Setelah itu digunakan Dropout sebesar 0.5 yang secara acak menonaktifkan sebagian neuron guna meningkatkan generalisasi model.

Pada tahap akhir, model menggunakan Dense layer output dengan jumlah unit sesuai banyaknya kelas (NUM\_CLASSES) dan aktivasi softmax untuk menghasilkan probabilitas klasifikasi pada masing-masing kelas target. Proses pelatihan (training) dilakukan dengan 50 epoch, di mana satu epoch merepresentasikan satu kali siklus penuh proses forward pass dan backpropagation

terhadap seluruh data latih. Dengan jumlah epoch ini, model mampu mempelajari pola-pola fitur secara optimal dari data citra.

#### **4.4. Evaluasi Model**

##### **4.4.1 Analisis Hasil Klasifikasi**


Dalam penelitian ini, proses deteksi Diabetic Retinopathy dilakukan dengan menerapkan arsitektur EfficientNetV2 yang dimodifikasi melalui penambahan dilation layer sebagai pendekatan utama. Analisis dilakukan pada citra fundus mata untuk mengidentifikasi adanya indikasi retinopati diabetik. Penelitian ini melibatkan beberapa skenario pengujian yang dirancang untuk mengevaluasi kinerja model, meliputi variasi parameter pelatihan, tingkat dilasi pada convolution layer, serta metode augmentasi data yang digunakan.

Penilaian hasil klasifikasi dilakukan untuk mengukur tingkat kemampuan model dalam mendeteksi dan memisahkan setiap kelas diabetic retinopathy secara tepat. Melalui penggunaan metrik akurasi, precision, recall, dan F1-score, diperoleh gambaran menyeluruh mengenai performa model, baik dari segi kemampuan dalam mengenali kasus positif maupun menghindari kesalahan prediksi. Confusion matrix dimanfaatkan untuk memberikan informasi yang lebih detail mengenai distribusi prediksi pada setiap kelas sehingga dapat diidentifikasi kelebihan dan kekurangan yang dimiliki model. Setiap nilai pada matriks menunjukkan jumlah prediksi model terhadap kelas tertentu dibandingkan dengan label sebenarnya. Pada kasus multi-kelas, konsep True Positive (TP) mengacu pada jumlah citra fundus yang diprediksi dengan benar sesuai kelas aslinya. False Positive (FP) terjadi ketika model salah memprediksi suatu citra ke dalam kelas tertentu padahal label aslinya berbeda.

Sebaliknya, False Negative (FN) menggambarkan kondisi ketika model gagal mengenali citra yang sebenarnya termasuk dalam suatu kelas, sehingga terklasifikasi ke kelas lain. Sedangkan True Negative (TN) menunjukkan jumlah citra dari kelas lain yang berhasil dikenali dengan benar sebagai bukan bagian dari kelas yang sedang diuji. Analisis ini juga menjadi dasar untuk membandingkan efektivitas skenario penelitian yang telah dirancang sebelumnya, yaitu EfficientNetV2-B0, B3, dan S dengan integrasi dilation layer, yang masing-masing diuji menggunakan 25 epoch serta penerapan early stopping guna memperoleh model yang paling optimal dalam mendeteksi diabetic retinopathy.

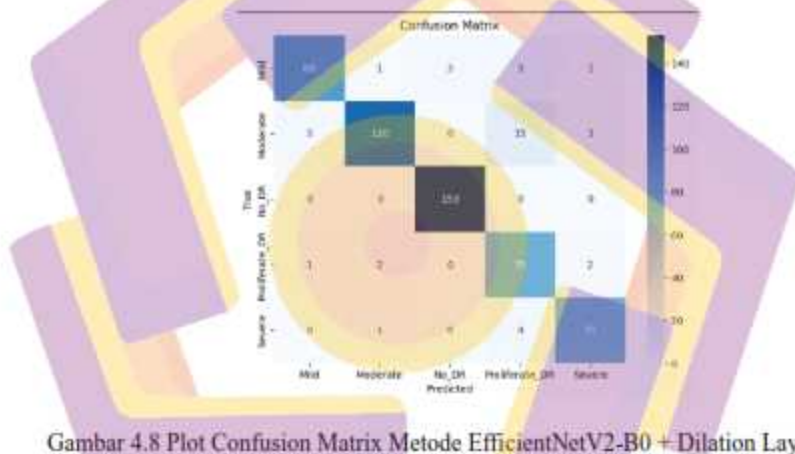
#### 4.4.2 Analisis Hasil EfficientNetV2-B0

Skenario pertama pada penelitian ini merapkan metode EfficientnetV2-B0 dengan dilation layer menggunakan dataset yang sudah diterapkan peningkatan kontras pada datasetnya. Hasil dari pengujian training dan testing ditampilkan pada grafik loss dan akurasi pada gambar 4.6.



Gambar 4.6 Plot Akurasi dan Loss Metode EfficientNetV2-B0 + Dilation Layer

Pada Gambar 4.6 ditampilkan hasil proses training dan validation selama 25. Proses training menghasilkan akurasi sebesar 96,54% dengan nilai loss 0.1426, sedangkan pada proses validation diperoleh akurasi sebesar 84,27% dengan nilai loss 0.6128. Hasil ini menunjukkan bahwa meskipun terdapat selisih antara akurasi training dan validation, performa model masih berada pada kategori baik. Dari model yang telah terbentuk, selanjutnya dilakukan evaluasi lanjutan menggunakan confusion matrix untuk menganalisis kemampuan klasifikasi pada setiap kelas.



Gambar 4.8 Plot Confusion Matrix Metode EfficientNetV2-B0 +Dilation Layer

Gambar 4.8 adalah representasi hasil klasifikasi menggunakan model EfficientNetV2-B0 dengan penambahan dilation layer memperlihatkan distribusi prediksi pada masing-masing kelas. Pada kelas Mild, model berhasil mengklasifikasikan 88 dari 96 citra dengan benar, dengan kesalahan prediksi, yaitu 1 citra ke Moderate, 3 citra ke No\_DR, 3 citra ke Proliferasi\_DR, dan 1 citra ke Severe. Kelas Moderate, terdapat 141 citra, 120 citra diklasifikasikan dengan benar. 3 citra diklasifikasikan sebagai Mild, 15 citra sebagai Proliferasi\_DR, dan 3 citra

sebagai Severe. Untuk kelas No\_DR, model menunjukkan performa sempurna, di mana 153 dari 153 citra berhasil diprediksi dengan benar tanpa ada kesalahan klasifikasi. Sementara itu, pada kelas Prolifera<sub>te</sub>\_DR, dari total 80 citra, sebanyak 75 citra diklasifikasikan dengan benar. Sisanya Mild (1 citra), Moderate (2 citra), dan Severe (2 citra). Kelas Severe, model mampu mengenali 75 dari 79 citra dengan benar, 4 lainnya salah terklasifikasi sebagai Prolifera<sub>te</sub>\_DR. Berikut proses perhitungan manual akurasi, presisi, Recall, dan F1-Score.

### 1. Akurasi

Menunjukkan seberapa banyak prediksi model yang benar dibandingkan dengan keseluruhan data uji. Nilai akurasi dihitung dengan menjumlahkan seluruh *true positive* dari setiap kelas, kemudian dibagi dengan total seluruh data pada confusion matrix.

$$Accuracy = \frac{88 + 120 + 153 + 75 + 75}{550} \times 100\% = 92,91\%$$

### 2. Presisi

Rasio antara jumlah *true positive* dengan jumlah *true positive* ditambahkan *false positive*. Precision menunjukkan seberapa tepat model dalam mengklasifikasikan suatu kelas dibandingkan dengan prediksi yang dibuat. Nilai ini diambil untuk setiap kelas pada confusion matrix.

$$No\_DR\ Precision = \frac{153}{153 + 3} \times 100\% = 98,08\%$$

$$Mild\ Precision = \frac{88}{88 + 4} \times 100\% = 95,65\%$$

$$Moderate\ Precision = \frac{120}{120 + 4} \times 100\% = 96,77\%$$

$$Severe\ Precision = \frac{75}{75 + 6} \times 100\% = 92,59\%$$

$$PDR\ Precision = \frac{75}{75 + 22} \times 100\% = 77,32\%$$

Kemudian untuk memperoleh nilai recall keseluruhan dengan menjumlahkan semua nilai Presisi pada masing-masing kelas, kemudian dibagi dengan jumlah kelas. Maka perhitungan nilai precision keseluruhan sebagai berikut.

$$P\ overall = \frac{95.65 + 96.77 + 98.08 + 77.32 + 92.59}{5} = 92.08\%$$

Nilai precision keseluruhan pada model EfficientNetV2-B0 diperoleh rata-rata precision sebesar 92,08%, yang menunjukkan bahwa model memiliki tingkat ketepatan yang cukup tinggi dalam memprediksi kelas diabetic retinopathy.

### 3. Recall

Recall adalah perbandingan antara jumlah *true positive* dengan jumlah *true positive* ditambahkan *false negative*. Recall mengukur kemampuan model dalam mengenali seluruh data aktual dari suatu kelas. Nilai recall juga dihitung untuk setiap kelas dari confusion matrix.

$$No\_DR\ Recall = \frac{153}{153 + 0} \times 100\% = 100\%$$

$$Mild\ Recall = \frac{88}{88 + 8} \times 100\% = 91,67\%$$

$$Moderate\ Recall = \frac{120}{120 + 21} \times 100\% = 85,11\%$$

$$Severe\ Recall = \frac{75}{75 + 5} \times 100\% = 93,75\%$$

$$PDR\ Recall = \frac{75}{75 + 22} \times 100\% = 93,75\%$$

Kemudian untuk memperoleh nilai recall keseluruhan dengan menjumlahkan semua nilai recall pada masing-masing kelas, kemudian dibagi dengan jumlah kelas. Maka perhitungan nilai recall sebagai berikut.

$$R_{overall} = \frac{91,67 + 85,11 + 100 + 93,75 + 93,75}{5} \times 100\% = 92,86\%$$

Nilai recall keseluruhan diperoleh rata-rata recall sebesar 92,86%, yang menggambarkan kemampuan model dalam mengenali seluruh kasus positif masih berada pada kategori baik, meskipun terdapat beberapa kelas yang lebih sulit dikenali dengan optimal.

#### 4. F1-Score

Rata-rata harmonis dari precision dan recall. Nilai ini digunakan untuk menyeimbangkan antara ketepatan prediksi (precision) dan kelengkapan prediksi (recall), sehingga lebih objektif dalam menilai performa model, terutama pada data yang tidak seimbang.

$$No\_DR\ F1 - Score = \frac{2,153}{2,153 + 3 + 0} \times 100\% = 99,03\%$$

$$Mild\ F1 - Score = \frac{2,88}{2,88 + 4 + 8} \times 100\% = 93,62\%$$

$$Moderate\ F1 - Score = \frac{2,120}{2,120 + 4 + 21} \times 100\% = 90,57\%$$

$$Severe\ F1 - Score = \frac{2,75}{2,75 + 22 + 5} \times 100\% = 84,75\%$$

$$PDR\ F1 - Score = \frac{2,75}{2,75 + 6 + 22} \times 100\% = 93,17\%$$

Perolehan nilai F1-Score keseluruhan dilakukan dengan menjumlahkan nilai F1-Score pada masing-masing kelas, kemudian dibagi dengan jumlah kelas. Maka perhitungan nilai F1-Score adalah sebagai berikut:

$$F1 \text{ overall} = \frac{93.62 + 90.57 + 99.03 + 84.75 + 93.17}{5} \times 100\% = 92.63\%$$

Nilai F1-Score keseluruhan diperoleh rata-rata F1-Score sebesar 92,63%, yang menunjukkan bahwa model memiliki keseimbangan yang baik antara nilai precision dan recall dalam melakukan klasifikasi pada seluruh kelas.


	precision	recall	f1-score	support
Mild	0.96	0.92	0.94	96
Moderate	0.97	0.85	0.91	141
No_DR	0.98	1.00	0.99	153
Proliferate_DR	0.77	0.94	0.85	80
Severe	0.93	0.54	0.73	80
accuracy			0.93	550
macro avg	0.92	0.93	0.92	550
weighted avg	0.94	0.93	0.93	550

Gambar 4.9 Classification Report EfficientNetV2-B0

Berdasarkan perhitungan manual yang dilakukan terhadap nilai accuracy, precision, dan recall dan F1-Score pada metode confusion matrix multi-kelas, diperoleh hasil yang konsisten dengan perhitungan menggunakan program Python. Kesamaan hasil tersebut memperkuat validitas analisis dan dapat dilihat pada Gambar 4.9.

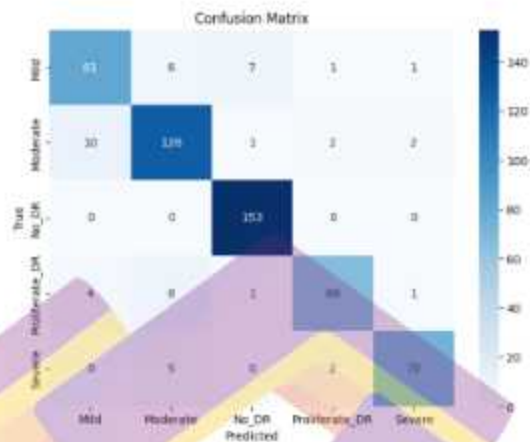
#### 4.4.3 Analisis Hasil EfficientNetV2-B3

Skenario pertama pada penelitian ini merupakan metode EfficientNetV2-B3 dengan dilation layer menggunakan dataset yang sudah diterapkan peningkatan kontras pada datasetnya. Hasil dari pengujian training dan testing ditampilkan pada grafik loss dan akurasi pada gambar 4.6.



Gambar 4.10 Plot Akurasi dan Loss Metode EfficientNetV2-B3 + Dilation Layer

Pada Gambar 4.x ditampilkan hasil proses training dan validation selama 25 epoch pada model EfficientNetV2-B3 dengan penambahan dilation layer. Proses training menghasilkan akurasi tertinggi sebesar 95,67% dengan nilai loss sekitar 0.3217, sedangkan pada proses validation diperoleh akurasi tertinggi sebesar 90.73% dengan nilai loss sekitar 0.65. Hasil ini menunjukkan bahwa meskipun terdapat gap antara akurasi training dan validation, performa model masih dapat dikategorikan baik. Selain itu, grafik loss memperlihatkan penurunan yang konsisten pada data training, sementara pada data validation cenderung stabil setelah epoch ke-10, sehingga menunjukkan bahwa model relatif stabil



Gambar 4.11 Plot Confusion Matrix Metode EfficientNetV2-B3 + Dilation Layer

Gambar 4.11 merupakan hasil klasifikasi menggunakan model EfficientNetV2-B3 dengan penambahan dilation layer yang memperlihatkan distribusi prediksi pada setiap kelas. Pada kelas Mild, model berhasil mengklasifikasikan 81 citra dengan benar dari 96 citra. Kesalahan prediksi terjadi pada 6 citra sebagai Moderate, 7 citra sebagai No\_DR, 1 citra sebagai Proliferate\_DR, dan 1 citra sebagai Severe. Kelas Moderate, terdapat 139 citra dengan 126 citra terklasifikasi benar, 10 citra salah diprediksi sebagai Mild, 1 citra sebagai No\_DR, 2 citra sebagai Proliferate\_DR, dan 2 citra sebagai Severe. Untuk kelas No\_DR, model menunjukkan performa sempurna dengan 153 dari 153 citra berhasil diprediksi dengan benar tanpa adanya kesalahan klasifikasi. Kelas Proliferate\_DR, dari total 80 citra, 66 citra berhasil diklasifikasikan dengan benar, kesalahan prediksi ke kelas Mild (4 citra), Moderate (8 citra), No\_DR (1 citra), dan Severe (1 citra). Terakhir, pada kelas Severe, dari 80 citra, 73 citra terklasifikasi dengan benar, sedangkan 5 citra salah diprediksi sebagai Moderate dan 2 citra

sebagai Prolifera<sub>te</sub>\_DR. Hasil ini menunjukkan bahwa model mampu mengenali kelas No\_DR dengan sangat baik, namun masih terdapat kesalahan klasifikasi pada kelas Mild dan Prolifera<sub>te</sub>\_DR yang lebih sulit dibedakan. Selanjutnya, dilakukan perhitungan manual akurasi, presisi, recall, dan F1-Score untuk mengetahui performa model secara keseluruhan

### 1. Akurasi

Menunjukkan seberapa banyak prediksi model yang benar dibandingkan dengan keseluruhan data uji. Nilai akurasi dihitung dengan menjumlahkan seluruh *true positive* dari setiap kelas, kemudian dibagi dengan total seluruh data pada confusion matrix.

$$Accuracy = \frac{81 + 126 + 153 + 66 + 73}{550} \times 100\% = 90,73\%$$

### 2. Presisi

Rasio antara jumlah *true positive* dengan jumlah *true positive* ditambahkan *false positive*. Precision menunjukkan seberapa tepat model dalam mengklasifikasikan suatu kelas dibandingkan dengan prediksi yang dibuat. Nilai ini diambil untuk setiap kelas pada confusion matrix.

$$No\_DR\ Precision = \frac{153}{153 + 9} \times 100\% = 94,44\%$$

$$Mild\ Precision = \frac{81}{81 + 14} \times 100\% = 85,26\%$$

$$Moderate\ Precision = \frac{126}{126 + 19} \times 100\% = 86,90\%$$

$$Severe\ Precision = \frac{73}{73 + 4} \times 100\% = 94,81\%$$

$$PDR\ Precision = \frac{66}{66 + 5} \times 100\% = 92,96\%$$

Kemudian untuk memperoleh nilai recall keseluruhan dengan menjumlahkan semua nilai Presisi pada masing-masing kelas, kemudian dibagi dengan jumlah kelas. Maka perhitungan nilai precision keseluruhan sebagai berikut.

$$P\ overall = \frac{85,26 + 86,90 + 94,44 + 92,96 + 94,81}{5} = 90,87\%$$

Nilai precision keseluruhan pada model EfficientNetV2-B0 diperoleh rata-rata precision sebesar 90,87%, yang menunjukkan bahwa model memiliki tingkat ketepatan yang cukup tinggi dalam memprediksi kelas diabetic retinopathy.

### 3. Recall

Recall adalah perbandingan antara jumlah *true positive* dengan jumlah *true positive* ditambahkan *false negative*. Recall mengukur kemampuan model dalam mengenali seluruh data aktual dari suatu kelas. Nilai recall juga dihitung untuk setiap kelas dari confusion matrix.

$$No\_DR\ Recall = \frac{153}{153 + 0} \times 100\% = 100\%$$

$$Mild\ Recall = \frac{88}{88 + 15} \times 100\% = 84,38\%$$

$$Moderate\ Recall = \frac{126}{126 + 15} \times 100\% = 89,39\%$$

$$Severe\ Recall = \frac{73}{73 + 7} \times 100\% = 91,25\%$$

$$PDR\ Recall = \frac{66}{66 + 14} \times 100\% = 82,50\%$$

Kemudian untuk memperoleh nilai recall keseluruhan dengan menjumlahkan semua nilai recall pada masing-masing kelas, kemudian dibagi dengan jumlah kelas. Maka perhitungan nilai recall sebagai berikut.

$$R_{overall} = \frac{984,38 + 89,36 + 100,00 + 82,50 + 91,25}{5} \times 100\% = 89,50\%$$

Nilai recall keseluruhan diperoleh rata-rata recall sebesar 89,50% yang menggambarkan kemampuan model dalam mengenali seluruh kasus positif masih berada pada kategori baik, meskipun terdapat beberapa kelas yang lebih sulit dikenali dengan optimal.

#### 4. F1-Score

Rata-rata harmonis dari precision dan recall. Nilai ini digunakan untuk menyeimbangkan antara ketepatan prediksi (precision) dan kelengkapan prediksi (recall), sehingga lebih objektif dalam menilai performa model, terutama pada data yang tidak seimbang.

$$No\_DR\ F1 - Score = \frac{2.153}{2.153 + 9 + 0} \times 100\% = 97,14\%$$

$$Mild\ F1 - Score = \frac{2.81}{2.81 + 14 + 15} \times 100\% = 84,82\%$$

$$Moderate\ F1 - Score = \frac{2.126}{2.126 + 19 + 15} \times 100\% = 88,11\%$$

$$Severe\ F1 - Score = \frac{2.73}{2.73 + 4 + 7} \times 100\% = 92,99\%$$

$$PDR\ F1 - Score = \frac{2.66}{2.66 + 5 + 14} \times 100\% = 87,42\%$$

Perolehan nilai F1-Score keseluruhan dilakukan dengan menjumlahkan nilai F1-Score pada masing-masing kelas, kemudian dibagi dengan jumlah kelas. Maka perhitungan nilai F1-Score adalah sebagai berikut:

$$F1 \text{ overall} = \frac{84,82 + 88,11 + 97,14 + 87,42 + 92,99}{5} \times 100\% = 90,10\%$$

Nilai F1-Score keseluruhan diperoleh rata-rata F1-Score sebesar 90,10%, yang menunjukkan bahwa model memiliki keseimbangan yang baik antara nilai precision dan recall dalam melakukan klasifikasi pada seluruh kelas.


	precision	recall	f1-score	support
Mild	0.85	0.84	0.85	96
Moderate	0.87	0.89	0.88	141
No. DF	0.94	1.00	0.97	253
Proliferata. DF	0.93	0.82	0.87	80
Severe	0.95	0.91	0.93	80
accuracy			0.91	550
macro avg	0.91	0.89	0.90	550
weighted avg	0.91	0.91	0.91	550

Gambar 4.12 Classification Report EfficientNetV2-B3

Berdasarkan perhitungan manual yang dilakukan terhadap nilai accuracy, precision, dan recall dan F1-Score pada metode confusion matrix multi-kelas, diperoleh hasil yang konsisten dengan perhitungan menggunakan program Python. Kesamaan hasil tersebut memperkuat validitas analisis dan dapat dilihat pada Gambar 4.12.

#### 4.4.4 Analisis Hasil EfficientNetV2-B3


Skenario selanjutnya pada penelitian ini menggunakan CNN dengan varian arsitektur efficientNetV2-S. Hasil hasil dari pengujian training dan testing ditunjukkan pada gambar 4.13.



Gambar 4.13 Plot Akurasi dan Loss Metode EfficientNetV2-S + Dilation Layer

Gambar 4.13 menunjukkan hasil proses training dan validation metode EfficientNetV2-S + Dilation Layer hingga 25 epoch. Pada proses training diperoleh akurasi yang terus meningkat hingga mencapai sekitar 93,99% dengan nilai loss akhir mendekati 0.3152. Sementara itu, proses validation menghasilkan akurasi maksimum sekitar 80-85% dengan nilai loss yang cenderung stabil di sekitar 0.6299 - 0.7702. Hasil ini mengindikasikan bahwa penambahan Dilation Layer pada arsitektur EfficientNetV2-S mampu meningkatkan kemampuan generalisasi model, meskipun akurasi validation belum menyamai akurasi training.

Dari model yang telah terbentuk, langkah selanjutnya adalah melakukan evaluasi lebih lanjut menggunakan confusion matrix untuk melihat distribusi prediksi antar kelas serta tingkat kesalahan klasifikasi yang masih terjadi.



Gambar 4.14 Plot Confusion Matrix Metode EfficientNetV2-S + Dilation Layer

Confusion matrix pada Gambar 4.14 menunjukkan bahwa model EfficientNetV2-S dengan Dilation Layer memiliki performa terbaik pada kelas *No\_DR* dengan 152 prediksi benar dan hanya 1 kesalahan, diikuti oleh kelas *Moderate* dengan 136 prediksi benar. Kelas *Mild* terdeteksi cukup baik meskipun masih terdapat 14 kasus salah ke *Moderate*. Sementara itu, kelas *Proliferate\_DR* menunjukkan kelemahan karena 20 kasus salah diprediksi sebagai *Moderate*. Untuk kelas *Severe*, model berhasil mengenali 68 kasus dengan benar namun masih terdapat 9 kesalahan ke *Moderate*. Hasil ini mengindikasikan bahwa meskipun EfficientNetV2-S cukup andal dalam membedakan kelas *No\_DR* dan *Moderate*, model masih menghadapi kesulitan dalam mengenali kelas *Proliferate\_DR* dan *Severe*, yang kemungkinan dipengaruhi oleh keterbatasan jumlah data serta kemiripan karakteristik visual antar kelas. Berikut proses perhitungan manual akurasi, presisi, Recall, dan F1-Score.

### 1. Akurasi

Menunjukkan seberapa banyak prediksi model yang benar dibandingkan dengan keseluruhan data uji. Nilai akurasi dihitung dengan menjumlahkan seluruh *true positive* dari setiap kelas, kemudian dibagi dengan total seluruh data pada confusion matrix.

$$\text{Accuracy} = \frac{80 + 136 + 152 + 56 + 68}{550} = 89,45\%$$

### 2. Presisi

Rasio antara jumlah *true positive* dengan jumlah *true positive* ditambahkan *false positive*. Precision menunjukkan seberapa tepat model dalam mengklasifikasikan suatu kelas dibandingkan dengan prediksi yang dibuat. Nilai ini diambil untuk setiap kelas pada confusion matrix.

$$\text{No\_DR Precision} = \frac{152}{152 + 3} \times 100\% = 98,06\%$$

$$\text{Mild Precision} = \frac{80}{80 + 7} \times 100\% = 91,95\%$$

$$\text{Moderate Precision} = \frac{136}{136 + 44} \times 100\% = 75,5\%$$

$$\text{Severe Precision} = \frac{68}{68 + 2} \times 100\% = 97,14\%$$

$$\text{PDR Precision} = \frac{56}{56 + 2} \times 100\% = 96,55\%$$

Kemudian untuk memperoleh nilai recall keseluruhan dengan menjumlahkan semua nilai Presisi pada masing-masing kelas, kemudian dibagi

dengan jumlah kelas. Maka perhitungan nilai precision keseluruhan sebagai berikut.

$$P_{overall} = \frac{91.95 + 75.56 + 98.06 + 96.55 + 97.14}{5} = 91,85\%$$

Nilai precision keseluruhan pada model EfficientNetV2-B0 diperoleh rata-rata precision sebesar 91,85%, yang menunjukkan bahwa model memiliki tingkat ketepatan yang cukup tinggi dalam memprediksi kelas diabetic retinopathy.

### 3. Recall

Recall adalah perbandingan antara jumlah *true positive* dengan jumlah *true positive* ditambahkan *false negative*. Recall mengukur kemampuan model dalam mengenali seluruh data aktual dari suatu kelas. Nilai recall juga dihitung untuk setiap kelas dari confusion matrix.

$$No\_DR\ Recall = \frac{152}{152 + 1} \times 100\% = 99,35\%$$

$$Mild\ Recall = \frac{80}{80 + 16} \times 100\% = 83,33\%$$

$$Moderate\ Recall = \frac{136}{136 + 5} \times 100\% = 96,45\%$$

$$Severe\ Recall = \frac{68}{68 + 12} \times 100\% = 85,00\%$$

$$PDR\ Recall = \frac{56}{56 + 24} \times 100\% = 70,00\%$$

Kemudian untuk memperoleh nilai recall keseluruhan dengan menjumlahkan semua nilai recall pada masing-masing kelas, kemudian dibagi dengan jumlah kelas. Maka perhitungan nilai recall sebagai berikut.

$$R_{overall} = \frac{83.33 + 96.45 + 99.35 + 70.00 + 85.00}{5} \times 100\% = 86,83\%$$

Nilai recall keseluruhan diperoleh rata-rata recall sebesar 86,83% yang menggambarkan kemampuan model dalam mengenali seluruh kasus positif masih berada pada kategori baik, meskipun terdapat beberapa kelas yang lebih sulit dikenali dengan optimal.

#### 4. F1-Score

Rata-rata harmonis dari precision dan recall. Nilai ini digunakan untuk menyeimbangkan antara ketepatan prediksi (precision) dan kelengkapan prediksi (recall), sehingga lebih objektif dalam menilai performa model, terutama pada data yang tidak seimbang.

$$Mild\ F1 - Score = \frac{2.80}{2.80 + 7 + 16} \times 100\% = 87,4\%$$

$$Moderate\ F1 - Score = \frac{2.136}{2.136 + 44 + 5} \times 100\% = 84,7\%$$

$$No\_DR\ F1 - Score = \frac{2.152}{2.152 + 3 + 1} \times 100\% = 98,7\%$$

$$Severe\ F1 - Score = \frac{2.68}{2.68 + 2 + 12} \times 100\% = 90,7\%$$

$$PDR\ F1 - Score = \frac{2.56}{2.56 + 2 + 24} \times 100\% = 81,2\%$$

Perolehan nilai F1-Score keseluruhan dilakukan dengan menjumlahkan nilai F1-Score pada masing-masing kelas, kemudian dibagi dengan jumlah kelas. Maka perhitungan nilai F1-Score adalah sebagai berikut:

$$F1\ overall = \frac{87.4 + 84.7 + 98.7 + 81.2 + 90.7}{5} \times 100\% = 88.5\%$$

Nilai F1-Score keseluruhan diperoleh rata-rata F1-Score sebesar 88,50%, yang menunjukkan bahwa model memiliki keseimbangan yang baik antara nilai precision dan recall dalam melakukan klasifikasi pada seluruh kelas.

	precision	recall	f1-score	support
Nilid	0.92	0.83	0.87	96
Moderata	0.76	0.96	0.85	141
No_D0	0.98	0.99	0.99	153
Proliferate_D0	0.92	0.70	0.81	80
Severe	0.87	0.85	0.91	80
accuracy			0.89	550
macro avg	0.90	0.87	0.89	550
weighted avg	0.91	0.89	0.89	550

Gambar 4.15 Classification Report EfficientNetV2-S

Berdasarkan perhitungan manual yang dilakukan terhadap nilai accuracy, precision, dan recall dan F1-Score pada metode confusion matrix multi-kelas, diperoleh hasil yang konsisten dengan perhitungan menggunakan program Python. Kesamaan hasil tersebut memperkuat validitas analisis dan dapat dilihat pada Gambar 4.15.

#### 4.5. Analisis Hasil Klasifikasi

Setelah melalui tahapan eksperimen serta proses pengujian dengan memanfaatkan arsitektur EfficientNetV2 yang telah dimodifikasi menggunakan dilation layer untuk tugas deteksi penyakit Diabetic Retinopathy (DR), penelitian ini kemudian melakukan evaluasi menyeluruh terhadap kinerja model. Evaluasi dilakukan dengan mempertimbangkan beberapa skenario pengujian yang dirancang untuk mengukur sejauh mana model mampu mengenali pola-pola citra retina pada tingkat keparahan yang berbeda. Untuk memberikan gambaran yang lebih komprehensif, hasil pengujian tersebut disajikan dalam bentuk Tabel 4.4 yang menampilkan metrik evaluasi utama, yaitu akurasi, presisi, dan recall pada masing-masing skenario.

Tabel 4.4 Hasil Eksperimen

No	Skenario	Class	Accuracy	Precision	Recall	F1-Score
1	EfficientNetV 2-B0 + DLayer	No_DR	96,54%	98%	100%	99%
		Mild		96%	85%	94%
		Moderate		97%	92%	91%
		Severe		77%	94%	93%
		PDR		93%	94%	85%
2	EfficientNetV 2-B3 + DLayer	No_DR	95,67%	94%	100%	94%
		Mild		85%	84%	94%
		Moderate		87%	89%	92%
		Severe		95%	91%	93%
		PDR		93%	82%	87%
3	EfficientNetV 2-S + DLayer	No_DR	93,99%	98%	99%	99%

Tabel 4.4 (Lanjutan)

		Mild		92%	83%	87%
		Moderate		76%	96%	85%
		Severe		96%	85%	91%
		PDR		96%	70%	81%
<b>EfficientnetV2 No Dilation Layer</b>						
4	EfficientNetV2-B0	No_DR	82,67%	94%	99%	96%
		Mild		76%	70%	73%
		Moderate		71%	89%	79%
		Severe		78%	68%	72%
		PDR		83%	60%	70%
5	EfficientNetV2-B3	No_DR	77,65%	93%	98%	96%
		Mild		79%	57%	66%
		Moderate		62%	91%	74%
		Severe		86%	53%	65%
		PDR		66%	51%	58%
6	EfficientNetV2-S	No_DR	79,58%	93%5	98%	95%
		Mild		71%	57%	63%
		Moderate		65%	87%	75%
		Severe		87%	65%	74%
		PDR		74%	57%	74%
<b>EfficientnetV2 No CLAHE</b>						
7	NO CLAHE Efficientnetv2-B0	No_DR	28,37%	29%	100%	44%
		Mild		00	00	00
		Moderate		00	00	00
		Severe		00	00	00

Tabel 4.4 (Lanjutan)

		PDR		00	00	00
8	NO CLAHE Efficientnetv2 -B3	No_DR	30.08%	28%	22%	25%
		Mild		00	00	00
		Moderate		27%	76%	40%
		Severe		100%	35	5%
		PDR		00	00	00
9	NO CLAHE Efficientnetv2 -S	No_DR	55.11%	83%	82%	83%
		Mild		48%	27%	35%
		Moderate		41%	89%	41%
		Severe		72%	29%	41%
		PDR		86%	7%	14%

Skenario pertama dengan EfficientNetV2-B0 + DLayer menghasilkan akurasi tertinggi sebesar 96,54%, dengan performa yang cukup seimbang di setiap kelas. Nilai precision dan recall relatif tinggi terutama pada kelas *No DR* (98% dan 100%) serta kelas *Moderate* (97% dan 92%). Namun, kelas *Severe* menunjukkan precision yang lebih rendah (77%), meskipun recall masih tinggi (94%). Hal ini menandakan bahwa model lebih baik dalam mendeteksi keberadaan *Severe DR* dibanding ketepatannya dalam klasifikasi.

Skenario kedua dengan EfficientNetV2-B3 + DLayer menghasilkan akurasi 95,67%. Pada skenario ini, kelas *Severe* menunjukkan performa yang lebih baik dibanding B0, dengan precision mencapai 95% dan recall 91%. Namun, pada kelas *Mild* dan *PDR*, nilai recall lebih rendah (84% dan 82%) meskipun precision relatif

tinggi. Secara keseluruhan, B3 memberikan keseimbangan performa antar kelas, terutama dalam mendeteksi *Severe DR*.

Skenario ketiga dengan EfficientNetV2-S + DLayer memiliki akurasi terendah, yaitu 93,99%. Nilai precision pada kelas *Moderate* cukup rendah (76%), sedangkan recall kelas *PDR* hanya 70%, yang menunjukkan kelemahan model dalam mendeteksi kasus *Proliferative DR*. Meski demikian, performa pada kelas *No DR* masih stabil dengan precision 98% dan recall 99%.

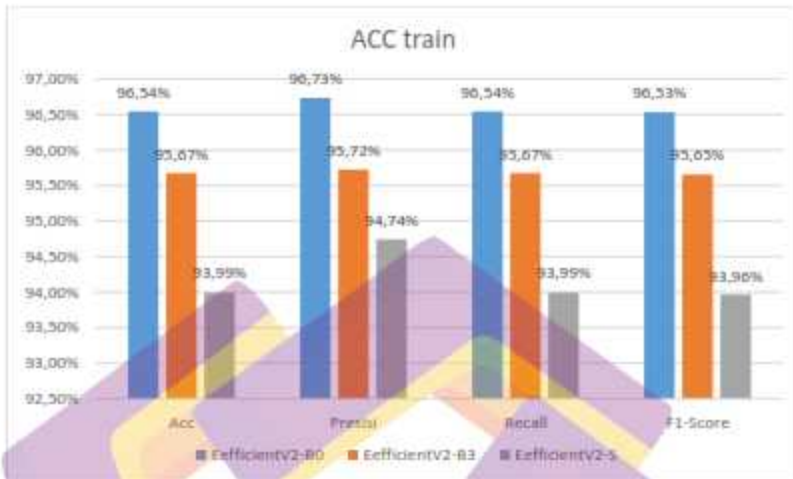
Secara keseluruhan, skenario EfficientNetV2-B0 + DLayer memberikan hasil terbaik dengan akurasi dan keseimbangan metrik yang lebih stabil, meskipun masih terdapat kelemahan pada kelas *Severe*. Temuan ini sejalan dengan penelitian (Zhang et al., 2023), yang menunjukkan bahwa arsitektur EfficientNetV2 dengan modifikasi ringan dapat memberikan performa tinggi pada klasifikasi diabetic retinopathy. Sementara itu, hasil pada EfficientNetV2-B3 dan S menunjukkan bahwa peningkatan kompleksitas model tidak selalu menjamin peningkatan performa, bahkan bisa menurunkan sensitivitas pada kelas minoritas.

Pada skenario EfficientNetV2 tanpa Dilation Layer, performa model menurun cukup signifikan dibandingkan dengan versi +DLayer. EfficientNetV2-B0 hanya mencapai akurasi 82,67%, dengan penurunan ketajaman terutama pada kelas *Mild* (precision 76%, recall 70%, F1 73%). Begitu juga pada EfficientNetV2-B3 yang hanya memperoleh akurasi 77,65%, dengan recall sangat rendah pada kelas *PDR* (51%). EfficientNetV2-S mencatat akurasi 79,58%, dengan distribusi metrik yang tidak stabil, di mana kelas *Moderate* hanya mencapai precision 65% dan recall 87%, sementara kelas *Mild* jatuh pada precision 71% dan recall 57%. Hal

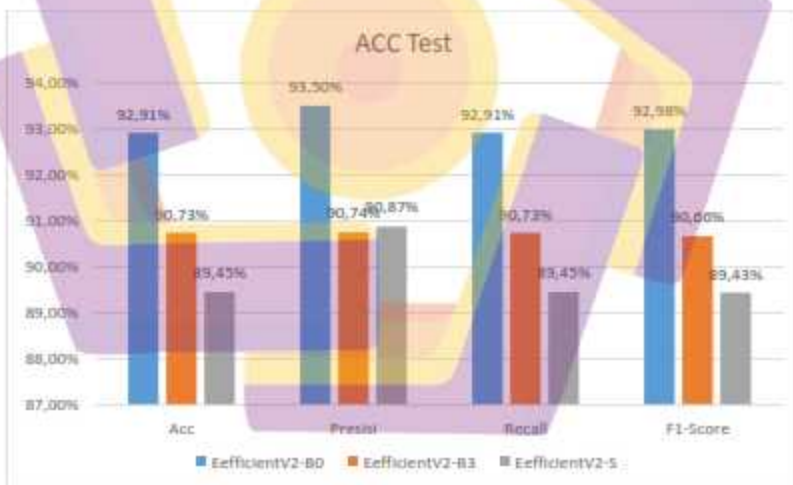
ini menunjukkan bahwa penambahan Dilation Layer berperan penting dalam memperluas receptive field sehingga model lebih mampu menangkap pola retinopati yang bervariasi pada citra retina.

Pada skenario EfficientNetV2 tanpa CLAHE, performa model anjlok drastis, khususnya pada B0 dengan akurasi hanya 28,37%, di mana hampir semua kelas selain No DR gagal dikenali (precision dan recall 0%). B3 juga rendah dengan akurasi 30,08%, meskipun sedikit lebih baik dalam mengenali kelas Moderate (recall 76%) dan Severe (precision 86%). Sementara itu, EfficientNetV2-S lebih unggul dengan akurasi 55,11%, namun tetap jauh lebih rendah dibandingkan hasil dengan CLAHE. Hasil ini memperkuat bahwa preprocessing menggunakan CLAHE sangat penting dalam meningkatkan kontras dan detail citra retina, sehingga memudahkan model dalam membedakan tingkat keparahan DR.

Dalam proses pengujian metode klasifikasi dengan penerapan CLAHE dan penggunaan dilation layer, dilakukan analisis perbandingan performa model menggunakan confusion matrix dengan mengacu pada perhitungan nilai accuracy, precision, dan recall dari arsitektur EfficientNetV2-B0, B3, dan S. Hasil perbandingan tersebut kemudian divisualisasikan dalam bentuk grafik yang menampilkan nilai accuracy, precision, dan recall untuk masing-masing metode klasifikasi, seperti ditunjukkan pada Gambar 4.16 dan 4.17.



Gambar 4.16 Grafik akurasi, presisi recall dan F1-Score Train



Gambar 4.16 Grafik akurasi, presisi recall dan F1-Score Train

Pada Gambar 4.16 memperlihatkan perbandingan nilai persentase dari accuracy, precision, recall, dan F1-score pada proses pelatihan (train) dan pengujian

(test) untuk setiap skenario penelitian yang menggunakan model EfficientNetV2 dengan penambahan Dilation Layer. Berdasarkan grafik di atas terlihat bahwa metode EfficientNetV2-B0 menghasilkan nilai accuracy, precision, recall, dan F1-score tertinggi, baik pada tahap pelatihan maupun pengujian. Hal ini menunjukkan bahwa arsitektur EfficientNetV2-B0 mampu memberikan performa klasifikasi yang lebih stabil dan konsisten dibandingkan varian lainnya. Sementara itu, metode EfficientNetV2-B3 menempati posisi kedua dengan capaian nilai yang cukup baik, meskipun masih lebih rendah dibandingkan EfficientNetV2-B0, terutama pada aspek precision dan recall. Adapun metode EfficientNetV2-S memperlihatkan performa terendah di antara ketiga model.

Hasil penelitian menunjukkan bahwa semakin besar arsitektur EfficientNetV2 tidak selalu menghasilkan akurasi yang lebih baik. Hal ini dapat disebabkan oleh beberapa faktor. Pertama, model dengan arsitektur yang lebih besar memiliki jumlah parameter yang jauh lebih banyak. Kedua, kompleksitas model yang tinggi membutuhkan data pelatihan dalam jumlah besar agar representasi fitur dapat dipelajari dengan optimal, sehingga jika data tidak cukup banyak atau distribusinya tidak seimbang, kinerja model bisa menurun. Ketiga, penambahan kompleksitas juga meningkatkan risiko vanishing gradient atau sulitnya proses optimasi, sehingga bobot model tidak ter-update secara maksimal.

#### **4.6. Analisis Imbalance Data**

Dari Tabel 4.1 distribusi kelas pada citra teridentifikasi tidak seimbang (imbalanced) dimana kelas No\_DR mendominasi (1.805 citra), sedangkan kelas

Severe dan Proliferative\_DR memiliki representasi yang relatif kecil (193 dan 295 citra). Ketidakeimbangan ini memberi implikasi penting pada pengembangan model. Secara teoretis dan empiris, model cenderung meminimalkan loss total dengan menyesuaikan parameter untuk performa optimal pada kelas mayoritas, sehingga akurasi global yang tinggi dapat tercapai walaupun performa pada kelas minoritas buruk. Oleh karena itu, evaluasi model harus difokuskan pada metrik yang sensitif terhadap distribusi kelas, seperti per-class recall, macro-F1, dan balanced accuracy, bukan hanya akurasi keseluruhan.

Hasil learning curves (Gambar 4.6, Gambar 4.10 dan Gambar 4.13) menunjukkan adanya gap yang signifikan antara training loss dan validation loss, yang mengindikasikan kecenderungan overfitting. Kondisi ini membuat model EfficientNetV2 lebih sering terpapar pada pola citra kelas mayoritas (No\_DR dan Moderate), sehingga bobot jaringan lebih berfokus untuk mengoptimalkan prediksi pada kelas-kelas tersebut. Akibatnya, saat menghadapi kelas dengan jumlah data kecil, model tidak memiliki cukup variasi contoh untuk membangun representasi fitur yang kuat, dan akhirnya hanya “menghafal” pola spesifik dari data pelatihan (memorization).

Overfitting juga dapat dipicu oleh kompleksitas arsitektur EfficientNetV2 itu sendiri, yang memiliki jumlah parameter besar dan kapasitas representasi tinggi. Dengan jumlah data pelatihan yang relatif terbatas, parameter-parameter tersebut dapat menyesuaikan secara berlebihan terhadap noise atau fitur yang tidak relevan dari data pelatihan. Hal ini terlihat dari pola validation loss yang berfluktuasi setelah

mencapai titik minimum, menunjukkan bahwa model tidak mampu mempertahankan kestabilan kinerja pada data validasi.

#### **4.7. Analisis Penerapan preprocessing CLAHE**

Citra retina pada umumnya memiliki permasalahan kualitas, seperti tingkat pencahayaan yang tidak merata, kontras rendah, serta adanya bayangan atau noise akibat proses akuisisi menggunakan fundus kamera seperti yang ditunjukkan pada gambar 4.2. Kondisi ini menyebabkan struktur penting pada retina, seperti pembuluh darah halus, makula, dan microaneurysm, menjadi kurang jelas terlihat. Padahal, struktur-struktur inilah yang sangat krusial dalam proses deteksi dini penyakit retinopati diabetik. Sebelum dilakukan preprocessing, gambar retina yang kontrasnya rendah sering tampak “pucat” dengan detail pembuluh darah yang samar dan sulit dibedakan dari jaringan sekitarnya. Hal ini dapat mengurangi akurasi sistem klasifikasi otomatis karena fitur yang dipelajari model menjadi kurang representatif.

Berbagai penelitian menunjukkan bahwa Contrast Limited Adaptive Histogram Equalization (CLAHE) efektif dalam meningkatkan kualitas citra retina untuk mendukung deteksi dan analisis retinopati diabetik (DR). Integrasi CLAHE dengan CNN kustom terbukti meningkatkan akurasi deteksi multi-tahap DR dari 97,69% menjadi 99,69%, menegaskan perannya dalam memperjelas fitur penting retina seperti microaneurysm dan pembuluh darah halus [49]. Studi lain yang menggabungkan CLAHE dengan model VGG16, InceptionV3, dan EfficientNet juga melaporkan peningkatan akurasi klasifikasi, dengan capaian masing-masing 91%, 95%, dan 97%. dibandingkan dengan citra asli yang masing-masing hanya

87%, 90%, dan 95%. Hal ini menunjukkan bahwa metode CLAHE mampu menonjolkan detail retina secara signifikan sehingga mempermudah proses klasifikasi berbasis deep learning [50].

Selain pada klasifikasi, efektivitas CLAHE juga terlihat dalam segmentasi struktur vaskular retina. Penelitian yang menggabungkan CLAHE dengan metode berbasis Hessian dan transformasi intensitas berhasil meningkatkan akurasi segmentasi hingga 95,05% pada CHASE\_DB1 dan 95,59% pada DRIVE. Hasil ini konsisten menunjukkan bahwa CLAHE dapat memperbaiki distribusi pencahayaan lokal dan meningkatkan detail kontras tanpa menimbulkan over-enhancement, sehingga struktur penting retina lebih mudah dideteksi. Dengan demikian, CLAHE merupakan teknik peningkatan citra yang relevan dan banyak direkomendasikan untuk sistem diagnosis berbantuan komputer pada citra retina.

Selain CLAHE, terdapat beberapa metode peningkatan kualitas citra yang sering digunakan dalam literatur, seperti Global Histogram Equalization (HE), Adaptive Histogram Equalization (AHE), dan Gamma Correction. Histogram Equalization standar memang mampu meningkatkan kontras, tetapi sering menimbulkan efek noise pada citra retina. Adaptive Histogram Equalization lebih baik karena bekerja secara lokal, tetapi berpotensi menghasilkan amplifikasi noise pada area tertentu. Gamma Correction digunakan untuk memperbaiki tingkat kecerahan, tetapi tidak cukup efektif dalam menonjolkan detail halus pada pembuluh darah. Dibandingkan metode-metode tersebut, CLAHE memiliki keunggulan karena secara khusus dirancang untuk membatasi amplifikasi kontras

berlebih (melalui clip limit), sehingga lebih stabil untuk diaplikasikan pada citra medis seperti retina.

Berdasarkan temuan dalam literatur, CLAHE telah terbukti banyak digunakan dalam penelitian terkait deteksi retinopati diabetik dan analisis fundus mata karena mampu menghasilkan citra dengan detail vaskular yang lebih jelas dan distribusi kontras yang merata, sehingga meningkatkan kualitas fitur yang dipelajari oleh model deep learning. Dengan pertimbangan ini, pemilihan CLAHE dalam penelitian ini menjadi penting dan relevan sebagai tahap preprocessing yang dapat mendukung kinerja model klasifikasi retina secara optimal.

Contrast Limited Adaptive Histogram Equalization (CLAHE) dipilih dalam penelitian ini karena kemampuannya dalam meningkatkan kontras citra secara lokal. Berbeda dengan histogram equalization biasa yang menerapkan peningkatan kontras secara global (berpotensi menimbulkan over-enhancement atau noise berlebihan), CLAHE bekerja dengan cara membagi citra menjadi beberapa blok kecil (tiles) lalu melakukan equalization pada masing-masing blok. Proses ini membuat detail halus seperti cabang pembuluh darah dan lesi mikro pada retina lebih menonjol, tanpa menyebabkan peningkatan kontras yang berlebihan pada area terang. Dengan demikian, CLAHE sangat efektif untuk meningkatkan kejelasan struktur retina yang berukuran kecil namun penting secara klinis.

Dengan demikian, penelitian ini menegaskan bahwa arsitektur EfficientNetV2-B0 yang dioptimasi dengan CLAHE dan dilation layer lebih sesuai digunakan pada kasus klasifikasi citra dengan jumlah data terbatas, distribusi tidak seimbang, serta kualitas citra yang rendah. Hal ini menjadikannya relevan untuk

berbagai domain terapan, seperti diagnosis citra medis, deteksi penyakit tanaman, maupun klasifikasi citra industri, di mana kondisi keterbatasan data dan kualitas citra sering kali menjadi tantangan utama.

#### 4.8. Kontribusi Penelitian

Penelitian ini melakukan Integrasi Dilation Layer pada arsitektur EfficientNetV2. Dilation Layer pada penelitian ini di gunakan untuk Memperlebar jangkauan filter tanpa menambah parameter, memungkinkan model menangkap informasi spasial lebih luas dan fitur patologis halus.

Secara keseluruhan, skenario EfficientNetV2-B0 + DLayer memberikan hasil terbaik dengan akurasi dan keseimbangan metrik yang lebih stabil, meskipun masih terdapat kelemahan pada kelas Severe. Temuan ini sejalan dengan penelitian (Zhang et al., 2023), yang menunjukkan bahwa arsitektur EfficientNetV2 dengan modifikasi ringan dapat memberikan performa tinggi pada klasifikasi diabetic retinopathy. Sementara itu, hasil pada EfficientNetV2-B3 dan S menunjukkan bahwa peningkatan kompleksitas model tidak selalu menjamin peningkatan performa, bahkan bisa menurunkan sensitivitas pada kelas minoritas.

Hasil penelitian ini menunjukkan bahwa penggunaan arsitektur EfficientNetV2 dengan penambahan dilation layer dan preprocessing CLAHE mampu meningkatkan kinerja klasifikasi citra. Berdasarkan perbandingan performa, varian EfficientNetV2-B0 menghasilkan nilai akurasi, presisi, recall, dan F1-score tertinggi, baik pada data pelatihan maupun pengujian, sehingga terbukti lebih stabil dan konsisten dibandingkan EfficientNetV2-B3 maupun

EfficientNetV2-S. Temuan ini mengindikasikan bahwa arsitektur yang lebih besar tidak selalu memberikan performa lebih baik, terutama pada dataset yang terbatas dan tidak seimbang. Kompleksitas model yang tinggi membutuhkan jumlah data yang besar agar proses pembelajaran representasi fitur dapat berlangsung optimal. Jika kondisi tersebut tidak terpenuhi, risiko overfitting, hilangnya sensitivitas terhadap detail lokal, serta kesulitan dalam proses optimasi (misalnya vanishing gradient) akan semakin meningkat.

Penelitian ini terbukti mampu memperluas receptive field secara proporsional sehingga memperkaya representasi fitur tanpa menghilangkan detail penting. Sementara pada varian B3 dan S, receptive field yang sudah besar sejak awal justru membuat penambahan dilation layer berlebihan sehingga berdampak negatif terhadap sensitivitas detail lokal. Penerapan CLAHE sebagai metode peningkatan kontras juga terbukti efektif dalam memperbaiki kualitas citra masukan, sehingga performa model dapat meningkat secara signifikan.

Tabel 4.5 Perbandingan Penelitian

Ref	Metode	Pre-Processing	Dataset	Kompleksitas	Parameter	Akurasi Terbaik
[13]	EfficientNet	CLAHE	Aptos	5,3 juta	Optimizer SGD, loss function Categorical Cross-Entropy, LR 0,001	79,85%

Tabel 4.5 (Lanjutan)

[14]	EfficientNet V2 ensemble S, M, L.	Progressive Data Augmentation	DeepDR	±196 juta	Optimizer Adadelata, Loss Function Binary Cross-Entropy (CE), LR 0,1	75%
[48]	Retnet	Otsu Thresholding, NLMD, dan CLAHE.	APTOS, Messidor2, dan IDRiD,	39,9 juta	Optimizer Adam, loss function categorical crossentropy, LR 0,0001	98,65%
[51]	CNN	Class-specific augmentation	Aptos	143 juta	Optimizer SGD, loss function Categorical Cross-Entropy, LR 0,001	89%
Penelitian ini	EfficientNet V2-B0	CLAHE	Aptos	7,1 juta	Optimizer Adam, loss function Sparse Categorical Cross-Entropy, LR 0,001	96,54

Penelitian terdahulu dalam klasifikasi diabetic retinopathy menunjukkan variasi hasil yang cukup signifikan. Keseluruhan penelitian diatas melakukan klasifikasi terhadap 5 kelas diabetic retinopathy. Rizal et al. (2020) menggunakan EfficientNet dan memperoleh akurasi 79,85% pada klasifikasi lima kelas DR, namun performanya masih terbatas dalam menangani variasi kualitas citra.

Tummala et al. (2023) berfokus pada quality estimation citra fundus menggunakan EfficientNetV2 pada dataset DeepDRiD dengan akurasi 75%, yang bermanfaat untuk memastikan kualitas gambar, tetapi tidak secara langsung mengklasifikasikan tingkat keparahan DR. Alyoubi et al. (2021) menawarkan pendekatan berbeda dengan menggabungkan CNN512 dan YOLOv3, menghasilkan akurasi 84,1% pada dataset APTOS serta mampu melakukan lokalisasi lesi, meskipun akurasinya lebih rendah dibandingkan beberapa penelitian lain.

Sebaliknya, penelitian terbaru oleh Raiaan et al. (2023) menunjukkan performa yang sangat tinggi dengan mengusulkan model ResNet-10. Dengan memanfaatkan dataset gabungan APTOS, Messidor2, dan IDRiD serta berbagai teknik augmentasi dan fine-tuning, model ini berhasil mencapai akurasi 98,65%, melampaui banyak arsitektur CNN populer lainnya seperti MobileNetV2, VGG16, dan ResNet50. Keunggulan utama penelitian tersebut terletak pada luasnya cakupan dataset serta penggunaan metode optimisasi yang komprehensif.

Dibandingkan dengan studi-studi tersebut, penelitian ini menggunakan arsitektur EfficientNetV2-B0 yang dimodifikasi dengan CLAHE preprocessing dan Dilation Layer, menghasilkan akurasi 96,54% pada klasifikasi multi-kelas DR. Hasil ini menunjukkan peningkatan signifikan dibandingkan penelitian Rizal (2020), Tummala (2023), maupun Alyoubi (2021), serta mendekati capaian Raiaan (2023). Keunggulan penelitian ini terletak pada kombinasi teknik peningkatan kualitas citra (CLAHE) dan modifikasi arsitektur (Dilation Layer), yang tidak hanya meningkatkan akurasi keseluruhan tetapi juga memperbaiki sensitivitas model terhadap kelas minoritas seperti Severe dan PDR.

## BAB 5 PENUTUP

### 5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan maka dapat diambil Kesimpulan Sebagai berikut:

1. Setelah dilakukannya serangkaian pengujian dari masing-masing skenario penelitian pada arsitektur EfficientNetV2 dengan penerapan Dilation Layer pada varian B0, B3 dan S ditemukan bahwa arsitektur EfficientnetV2- B0 mencapai akurasi sebesar 96,54%, arsitektur EfficientnetV2- B3 menghasilkan akurasi 95,67% dan EfficientnetV2- S dengan akurasi 93,99%.
2. Performa metode CNN EfficientNetV2 dengan penambahan *Dilation Layer* dalam mendeteksi *diabetic retinopathy* menunjukkan hasil yang cukup baik berdasarkan evaluasi akurasi, presisi, recall, dan F1-score. Arsitektur EfficientNetV2-B0 terbukti memberikan performa paling stabil dengan nilai evaluasi metrik yang konsisten dibandingkan EfficientNetV2-B3 dan EfficientNetV2-S. ini menunjukkan bahwa penggunaan arsitektur yang lebih sederhana justru lebih efektif dalam penelitian ini.
3. Ekstraksi fitur menggunakan pendekatan *Dilation Layer* berpengaruh signifikan terhadap peningkatan performa model. Proses ini membantu model dalam menangkap informasi spasial pada citra retina secara lebih luas tanpa kehilangan detail penting, sehingga meningkatkan kemampuan identifikasi *diabetic retinopathy*.

4. Penerapan Contrast Limited Adaptive Histogram Equalization (CLAHE) pada tahap preprocessing terbukti berpengaruh positif terhadap hasil klasifikasi. Teknik ini berhasil meningkatkan kontras lokal pada citra retina sehingga fitur penting seperti pembuluh darah, microaneurysm, dan pendarahan halus menjadi lebih terlihat oleh model.

## 5.2 Saran

Terdapat beberapa usulan untuk pengembangan penelitian selanjutnya yang diuraikan sebagai berikut:

1. Penggunaan segmentasi citra retina, misalnya dengan U-Net atau metode semantic segmentation lainnya, dapat membantu model lebih fokus pada area pembuluh darah, makula, atau lesi yang menjadi indikator diabetic retinopathy, sehingga meningkatkan akurasi klasifikasi.
2. Perlu dilakukan pengujian dengan variasi pembagian data training, validation, dan testing yang berbeda untuk melihat pengaruh proporsi data terhadap kestabilan performa model.
3. Penelitian selanjutnya disarankan untuk memperbanyak jumlah data dan memperhatikan keseimbangan antar kelas, khususnya pada kelas dengan jumlah sampel sedikit, misalnya dengan teknik data augmentation lanjutan atau generative models (seperti GAN), sehingga model mampu melakukan generalisasi yang lebih baik.

## DAFTAR PUSTAKA

- [1] World Health Organization, "Diabetes," WHO. Accessed: Jun. 02, 2024. [Online]. Available: [https://www.who.int/health-topics/diabetes?gad\\_source=1&gclid=CjwKCAjwjqWzBhAqEiwAQmtgT5gywPuJk73veYVoD4bXIJZnjIBviXUFbUlamvAwH7juQdHd58EgnRoCQykQAvD\\_BwE#tab=tab\\_1](https://www.who.int/health-topics/diabetes?gad_source=1&gclid=CjwKCAjwjqWzBhAqEiwAQmtgT5gywPuJk73veYVoD4bXIJZnjIBviXUFbUlamvAwH7juQdHd58EgnRoCQykQAvD_BwE#tab=tab_1)
- [2] Ditjen P2P, "Saatnya Mengatur Si Manis," Kemenkes Ditjen P2P. Accessed: Jun. 13, 2024. [Online]. Available: <https://p2p.kemkes.go.id/saatnya-mengatur-si-manis/#:~:text=Menurut%20IDF%2C%20Indonesia%20menduduki%20peringkat,merupakan%20ibu%20dari%20segala%20penyakit.>
- [3] R. K. Yazid and J. Teknik Informatika, "Pendeteksian Diabetik Retinopatik Menggunakan Convolutional Neural Network (CNN)," UNIVERSITAS SRIWIJAYA, 2021.
- [4] S. Qummar *et al.*, "A Deep Learning Ensemble Approach for Diabetic Retinopathy Detection," *IEEE Access*, vol. 7, pp. 150530–150539, 2019, doi: 10.1109/ACCESS.2019.2947484.
- [5] V. Higuera, "The 4 Stages of Diabetic Retinopathy," Healthline. Accessed: Oct. 26, 2024. [Online]. Available: <https://www.healthline.com/health/diabetes/diabetic-retinopathy-stages>
- [6] C. Koetting, "The Four Stages of Diabetic Retinopathy," Modernoptometry. Accessed: Oct. 26, 2024. [Online]. Available: <https://modernod.com/articles/2019-june/the-four-stages-of-diabeticretinopathy?c4src=article:infinite-scroll>
- [7] R. M. Duwairi, S. A. Al-Zboon, R. A. Al-Dwairi, and A. Obaidi, "A Deep Learning Model and a Dataset for Diagnosing Ophthalmology Diseases," *Journal of Information & Knowledge Management*, vol. 20, no. 03, p. 2150036, Sep. 2021, doi: 10.1142/S0219649221500362.

- [8] N. Nagaraja Kumar, T. Jayachandra Prasad, and K. Satya Prasad, "Multimodal Medical Image Fusion with Improved Multi-Objective Meta-Heuristic Algorithm with Fuzzy Entropy," *Journal of Information & Knowledge Management*, vol. 22, no. 01, Feb. 2023, doi: 10.1142/S0219649222500630.
- [9] A. V. D. P. Jordi de la Torre, "A deep learning interpretable classifier for diabetic retinopathy disease grading," *Neurocomputing*, vol. 396, pp. 365–476, Jul. 2020.
- [10] Y.-D. Zhang *et al.*, "Image based fruit category classification by 13-layer deep convolutional neural network and data augmentation," *Multimed Tools Appl*, vol. 78, no. 3, pp. 3613–3632, Feb. 2019, doi: 10.1007/s11042-017-5243-3.
- [11] Aryan, R. Chaudhuri, and S. Deb, "Precise lesion analysis to detect diabetic retinopathy using Generative Adversarial Network(GAN) and Mask-RCNN," *Procedia Comput Sci*, vol. 235, pp. 520–529, 2024, doi: 10.1016/j.procs.2024.04.051.
- [12] S. H. Abdullah, R. Magdalena, and R. Y. N. Fu'adah, "KLASIFIKASI DIABETIC RETINOPATHY BERBASIS PENGOLAHAN CITRA FUNDUS DAN DEEP LEARNING," *JOURNAL OF ELECTRICAL AND SYSTEM CONTROL ENGINEERING*, vol. 5, no. 2, pp. 84–90, Feb. 2022, doi: 10.31289/jesce.v5i2.5659.
- [13] S. RIZAL, N. IBRAHIM, N. K. C. PRATIWI, S. SAIDAH, and R. Y. N. FU'ADAH, "Deep Learning untuk Klasifikasi Diabetic Retinopathy menggunakan Model EfficientNet," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 8, no. 3, p. 693, Aug. 2020, doi: 10.26760/elkomika.v8i3.693.
- [14] S. Tummala, V. S. G. Thadikemalla, S. Kadry, M. Sharaf, and H. T. Rauf, "EfficientNetV2 Based Ensemble Model for Quality Estimation of Diabetic Retinopathy Images from DeepDRiD," *Diagnostics*, vol. 13, no. 4, Feb. 2023, doi: 10.3390/diagnostics13040622.

- [15] D. P. Sidik, F. Utamingrum, and L. Muflikhah, "Penggunaan Variasi Model pada Arsitektur EfficientNetV2 untuk Prediksi Sel Kanker Serviks," 2023. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [16] Y. Fu, Y. Ju, and D. Zhang, "MSEF-Net: A multi-scale EfficientNet Fusion for Diabetic Retinopathy grading," *Biomed Signal Process Control*, vol. 98, p. 106714, Dec. 2024, doi: 10.1016/j.bspc.2024.106714.
- [17] H. Hu, C. Yu, Q. Zhou, Q. Guan, and H. Feng, "HDConv: Heterogeneous kernel-based dilated convolutions," *Neural Networks*, vol. 179, p. 106568, Nov. 2024, doi: 10.1016/j.neunet.2024.106568.
- [18] S. Roy, M. Tyagi, V. Bansal, and V. Jain, "SVD-CLAHE boosting and balanced loss function for Covid-19 detection from an imbalanced Chest X-Ray dataset," *Comput Biol Med*, vol. 150, p. 106092, Nov. 2022, doi: 10.1016/j.combiomed.2022.106092.
- [19] R. Liu, W. Cai, G. Li, X. Ning, and Y. Jiang, "Hybrid Dilated Convolution Guided Feature Filtering and Enhancement Strategy for Hyperspectral Image Classification," *IEEE Geoscience and Remote Sensing Letters*, vol. 19, pp. 1–5, 2022, doi: 10.1109/LGRS.2021.3100407.
- [20] Z. Shang, C. Yu, H. Huang, and R. Li, "DCNet: A lightweight retinal vessel segmentation network," *Digit Signal Process*, vol. 153, p. 104651, Oct. 2024, doi: 10.1016/j.dsp.2024.104651.
- [21] S. Madarapu, S. Ari, and K. Mahapatra, "A multi-resolution convolutional attention network for efficient diabetic retinopathy classification," *Computers and Electrical Engineering*, vol. 117, p. 109243, Jul. 2024, doi: 10.1016/j.compeleceng.2024.109243.
- [22] S. Das and S. K. Saha, "Diabetic retinopathy detection and classification using CNN tuned by genetic algorithm," *Multimed Tools Appl*, vol. 81, no. 6, pp. 8007–8020, Mar. 2022, doi: 10.1007/s11042-021-11824-w.
- [23] M. M. Fraz, M. Badar, A. W. Malik, and S. A. Barman, "Computational Methods for Exudates Detection and Macular Edema Estimation in Retinal

- Images: A Survey,” *Archives of Computational Methods in Engineering*, vol. 26, no. 4, pp. 1193–1220, Sep. 2019, doi: 10.1007/s11831-018-9281-4.
- [24] R. S. Biyani and B. M. Patre, “Algorithms for red lesion detection in Diabetic Retinopathy: A review,” *Biomedicine & Pharmacotherapy*, vol. 107, pp. 681–688, Nov. 2018, doi: 10.1016/j.biopha.2018.07.175.
- [25] Y. Yuliadi, F. Dzil Ikram, M. Julkarnain, F. Hamdan, and H. Nuryadi, “Application of the Support Vector Machine (SVM) Algorithm for the Diagnosis of Diabetic Retinopathy,” *Brilliance: Research of Artificial Intelligence*, vol. 3, no. 2, pp. 416–422, Jan. 2024, doi: 10.47709/brilliance.v3i2.3436.
- [26] D. U. N. Qomariah, H. Tjandra, and C. Fatichah, “Classification of Diabetic Retinopathy and Normal Retinal Images using CNN and SVM,” in *2019 12th International Conference on Information & Communication Technology and System (ICTS)*, IEEE, Jul. 2019, pp. 152–157. doi: 10.1109/ICTS.2019.8850940.
- [27] W. Zhang *et al.*, “Automated identification and grading system of diabetic retinopathy using deep neural networks,” *Knowl Based Syst*, vol. 175, pp. 12–25, Jul. 2019, doi: 10.1016/j.knosys.2019.03.016.
- [28] Y. Wu and Z. Hu, “Recognition of Diabetic Retinopathy Based on Transfer Learning,” in *2019 IEEE 4th International Conference on Cloud Computing and Big Data Analysis (ICCCBDA)*, IEEE, Apr. 2019, pp. 398–401. doi: 10.1109/ICCCBDA.2019.8725801.
- [29] M. Muslih and E. H. Rachmawanto, “CONVOLUTIONAL NEURAL NETWORK (CNN) UNTUK KLASIFIKASI CITRA PENYAKIT DIABETES RETINOPATHY,” *SKANIKA*, vol. 5, no. 2, pp. 167–176, Jul. 2022, doi: 10.36080/skanika.v5i2.2945.
- [30] R. İncir and F. Bozkurt, “Improving brain tumor classification with combined convolutional neural networks and transfer learning,” *Knowl Based Syst*, vol. 299, Sep. 2024, doi: 10.1016/j.knosys.2024.111981.

- [31] A. Ghoneim, G. Muhammad, and M. S. Hossain, "Cervical cancer classification using convolutional neural networks and extreme learning machines," *Future Generation Computer Systems*, vol. 102, pp. 643–649, Jan. 2020, doi: 10.1016/j.future.2019.09.015.
- [32] Z. Wang *et al.*, "Scene Classification of Remote Sensing Images Using EfficientNetV2 with Coordinate Attention," *J Phys Conf Ser*, vol. 2289, no. 1, p. 012026, Jun. 2022, doi: 10.1088/1742-6596/2289/1/012026.
- [33] M. Tan and Q. V. Le, "EfficientNetV2: Smaller Models and Faster Training," Apr. 2021, [Online]. Available: <http://arxiv.org/abs/2104.00298>
- [34] S. RIZAL, N. IBRAHIM, N. K. C. PRATIWI, S. SAIDAH, and R. Y. N. FU'ADAH, "Deep Learning untuk Klasifikasi Diabetic Retinopathy menggunakan Model EfficientNet," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 8, no. 3, p. 693, Aug. 2020, doi: 10.26760/elkomika.v8i3.693.
- [35] S. F. Ahmed *et al.*, "Deep learning modelling techniques: current progress, applications, advantages, and challenges," *Artif Intell Rev*, vol. 56, no. 11, pp. 13521–13617, Nov. 2023, doi: 10.1007/s10462-023-10466-8.
- [36] H. Nafi'ah, "Deep Learning," Medium. Accessed: Nov. 10, 2024. [Online]. Available: <https://medium.com/@hannnfh/deep-learning-3840922fc77b>
- [37] M. Segal-Rozenhaimer, A. Li, K. Das, and V. Chirayath, "Cloud detection algorithm for multi-modal satellite imagery using convolutional neural networks (CNN)," *Remote Sens Environ*, vol. 237, p. 111446, Feb. 2020, doi: 10.1016/j.rse.2019.111446.
- [38] J. Wira and G. Putra, "Pengenalan Konsep Pembelajaran Mesin dan Deep Learning Edisi 1.4 (17 Agustus 2020)."
- [39] A. F. Agarap, "Deep Learning using Rectified Linear Units (ReLU)," Mar. 2018, [Online]. Available: <http://arxiv.org/abs/1803.08375>
- [40] H. Gholamalinezhad and H. Khosravi, "Pooling Methods in Deep Neural Networks, a Review."

- [41] E. C. Putra and R. M. Awangga, *Tutorial Gender Classification Using the You Look Only Once (YOLO)*, vol. 1. Kreatif, 2020.
- [42] H. Mei, Q. Wang, L. Yu, and Q. Zeng, "A deep learning-based algorithm for intelligent prediction of adverse geologic bodies in tunnels," *Meas Sci Technol*, vol. 35, no. 9, p. 096119, Sep. 2024, doi: 10.1088/1361-6501/ad4c8a.
- [43] H. Liu, P. Jiang, and Z. Tao, "Google is all you need: Semi-Supervised Transfer Learning Strategy For Light Multimodal Multi-Task Classification Model," Jan. 2025, [Online]. Available: <http://arxiv.org/abs/2501.01611>
- [44] J. Jiao *et al.*, "DilateFormer: Multi-Scale Dilated Transformer for Visual Recognition," Feb. 2023, [Online]. Available: <http://arxiv.org/abs/2302.01791>
- [45] X. Lei, H. Pan, and X. Huang, "A Dilated CNN Model for Image Classification," *IEEE Access*, vol. 7, pp. 124087–124095, 2019, doi: 10.1109/ACCESS.2019.2927169.
- [46] Avinash. Navlani, Armando. Fandango, and Ivan. Idris, *Python Data Analysis: Perform Data Collection, Data Processing, Wrangling, Visualization, and Model Building Using Python*.
- [47] M. Munarsih and B. A. Ningsi, "Performance Comparison of Data Mining Classification Algorithms on Student Academic Achievement Prediction," *Indonesian Journal of Artificial Intelligence and Data Mining*, vol. 6, no. 1, p. 29, Apr. 2023, doi: 10.24014/ijaidm.v6i1.21874.
- [48] M. A. K. Raiaan *et al.*, "A Lightweight Robust Deep Learning Model Gained High Accuracy in Classifying a Wide Range of Diabetic Retinopathy Images," *IEEE Access*, vol. 11, pp. 42361–42388, 2023, doi: 10.1109/ACCESS.2023.3272228.
- [49] S. Phimphisian and N. Sriwiboon, "A Customized CNN Architecture with CLAHE for Multi-Stage Diabetic Retinopathy Classification," *Engineering*.

*Technology and Applied Science Research*, vol. 14, no. 6, pp. 18258–18263, Dec. 2024, doi: 10.48084/etasr.8932.

- [50] M. Hayati *et al.*, “Impact of CLAHE-based image enhancement for diabetic retinopathy classification through deep learning,” in *Procedia Computer Science*, Elsevier B.V., 2022, pp. 57–66. doi: 10.1016/j.procs.2022.12.111.
- [51] M. Shaban *et al.*, “A convolutional neural network for the screening and staging of diabetic retinopathy,” *PLoS One*, vol. 15, no. 6 June, Jun. 2020, doi: 10.1371/journal.pone.0233514.

