

**PENERAPAN AUGMENTASI DAN ENSEMBLE LEARNING PADA
ARSITEKTUR INCEPTIONV3, MOBILENET, DAN
VISUAL GEOMETRY GROUP 19 UNTUK KLASIFIKASI
GANGGUAN DIABETIC RETINOPATY**

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar
Sarjana di Jurusan Matematika pada Fakultas MIPA**

Oleh :

**NUR AVISA CALISTA ANDRIANI
08011281722024**



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS SRIWIJAYA
2021**

LEMBAR PENGESAHAN

**PENERAPAN AUGMENTASI DAN ENSEMBLE LEARNING PADA
ARSITEKTUR INCEPTIONV3, MOBILENET, DAN
VISUAL GEOMETRY GROUP 19 UNTUK KLASIFIKASI
GANGGUAN DIABETIC RETINOPATY**

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar
Sarjana di Jurusan Matematika pada Fakultas MIPA**

Oleh

NUR AVISA CALISTA ANDRIANI

NIM.08011281722024

Indralaya, Maret 2022

Pembimbing Kedua



Drs. Sugandi Yahdin, M.M.

NIP. 195807271986031003

Pembimbing Utama



Anita Desiani, M.Kom

NIP.197712112003122002

Mengetahui,

Ketua Jurusan Matematika



Drs. Sugandi Yahdin, M.M

NIP. 19580727 1986031003

PERNYATAAN KEASLIAN KARYA ILMIAH

Yang bertanda tangan di bawah ini:

Nama Mahasiswa : Nur Avisa Calista Andriani

NIM : 08011281722024

Fakultas/Jurusan : Matematika dan Ilmu Pengetahuan Alam/Matematika

Menyatakan bahwa skripsi ini adalah hasil karya saya sendiri dan karya ilmiah ini belum pernah diajukan sebagai pemenuhan persyaratan untuk memperoleh gelar kesarjanaan srata (S1) dari Universitas Sriwijaya maupun perguruan tinggi lain. Semua informasi yang dimuat dalam skripsi ini berasal dari penulis lain baik yang dipublikasikan atau tidak telah diberikan penghargaan dengan mengutip nama sumber penulis secara benar. Semua isi dari skripsi ini sepenuhnya menjadi tanggung jawab saya sebagai penulis.

Demikianlah surat pernyataan ini saya buat dengan sebenarnya

Indralaya, 11 April 2022

Penulis



Nur Avisa Calista Andriani
NIM.08011281722024

HALAMAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Sebagai Civitas Akademik Universitas Sriwijaya, yang bertanda tangan di bawah ini :

Nama Mahasiswa : Nur Avisa Calista Andriani
NIM : 08011281722024
Fakultas/Jurusan : Matematika dan Ilmu Pengetahuan Alam/Matematika
Jenis Karya : Skripsi

Demi pengembangan ilmu pengetahuan, saya menyetujui untuk memberikan kepada Universitas Sriwijaya “Penerapan Augmentasi dan *Ensemble Learning* pada arsitektur *InceptionV3*, *MobileNet*, dan *Visual Geometry Group 19* untuk Klasifikasi Gangguan *Diabetic Retinopathy*”. Dengan hak bebas royalty non-ekslusif ini Universitas Sriwijaya berhak menyimpan, mengalih, edit/memformatkan, mengelola dalam bentuk pangkalan data (database), merawat, dan mempublikasikan tugas akhir atau skripsi saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik hak cipta.

Demikian pernyataan ini saya buat dengan sesungguhnya.

Indralaya, 11 April 2022
Penulis



Nur Avisa Calista Andriani
NIM.08011281722024

HALAMAN PERSEMBAHAN

Kupersembahkan skripsi ini untuk :

Yang MahaKuasa Allah SubhanahuWaTa'ala

Kedua Orangtuaku Tersayang

Adikku Tercinta,

Keluarga Besarku Tersayang

Semua Guru dan Dosenku

Sahabat-sahabatku Tercinta

Almamaterku

Motto :

"Hidup ini hanya soal sudut pandang. Digeser sedikit saja cara kita memandangnya, kita bisa mengubah sesuatu yang menyebalkan menjadi hal yang berbeda"

Bartazoar

KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh

Dengan mengucapkan Alhamdulillah, segala puji bagi Allah Subhanahu Wa Ta'ala atas limpahan rahmat dan karunia-Nya, sehingga penulis dapat menyelesaikan skripsi ini sehingga berjalan dengan baik dan sebagai salah satu syarat memperoleh gelar Sarjana Sains bidang Studi Matematika di Fakultas MIPA Universitas Sriwijaya.

Dengan segala hormat dan kerendahan hati penulis mengucapkan terima kasih yang sebesar-besarnya dan perhargaan yang tulus penulis sampaikan kepada kedua orang tua tercinta, yaitu **Bapak Triandani Leogrita** dan **Ibu Tut Wuri Handayani** yang telah menuntun, mendidik, mengajari, menasehati, memberi semangat, dan tidak pernah lelah berdoa yang tebaik untuk anaknya. Penulis juga menyampaikan ucapan terima kasih dan perhargaan kepada :

1. Bapak **Drs. Sugandi Yahdin, M.M** selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya, Pembimbing Pembantu, serta Pembimbing Akademik dan Ibu **Dr. Dian Cahyawati Sukanda, M.Si** selaku Sekretaris Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya yang bersedia membimbing, memberi nasihat dan mengarahkan urusan akademik kepada penulis selama belajar di Jurusan Matematika FMIPA Universitas Sriwijaya.
2. Ibu **Anita Desiani, M.Kom** selaku Dosen Pembimbing Utama, Bapak **Dr. Bambang Suprihatin, M.Si**, dan Ibu **Endang Sri Kresnawati, M.Si** selaku dosen pembahas skripsi yang telah bersedia meluangkan waktu, tenaga, pikiran

untuk memberikan bimbingan dan pengarahan dengan penuh perhatian, pengertian, dan kesabaran sehingga skripsi ini dapat diselesaikan.

3. Seluruh **Dosen** di Jurusan Matematika Fakultas Matematika Dan Ilmu Pengetahuan Alam Universitas Sriwijaya, dan seluruh pendidik yang telah memberikan ilmu yang sangat bermanfaat kepada penulis selama menempuh pendidikan. Serta Ibu **Hamidah** dan Pak **Irwan** di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya, terima kasih atas bantuannya yang telah diberikan kepada penulis.
4. Adikku **Nur Annisa Aprilia**, serta keluarga besarku terima kasih untuk kasih sayang, motivasi, dukungan, perhatian, dan doa yang selalu dipanjatkan selama ini untuk keberhasilanku.
5. Sahabat-sahabatku di bangku SMP D'CESA (**Dina, Elin, Shara, dan Tris**) dan di bangku SMA **Hermawati, Indah, Septia, Lutfiah, Inakk, Eri, Adesti Yulia, dan Nur Fadhillah** yang telah memberi dukungan, meluangkan waktu untuk mendengarkan curhatan baik tentang skripsi maupun yang lainnya, dan selalu mengingatkan bahwa tiap orang punya proses.
6. Sahabat-sahabatku selama diperkuliahannya **ONE HEART (Ajeng Islamia Putri, Anggri Amelia, Ayu Wulandari, Elsa Agustin Putri, Enyta Yuniar, Feni Oktavia, Filda Efriliyanti, Khairanil Washilah, dan Tesya Rahmawati), TONGKONGAN (Annisa Nabilah, Fathona Nur Muzayyadah, Oktanza Tyara Dwi Haryanti, Carolina Rahman, Deasty Jesica, Fretti Nuraprilia, dan Yogi Wahyudin), Annisa Miftahul Jannah, dan Rada Pramadian** yang telah menjadi *moodbooster* selama perkuliahan, serta canda tawa, suka duka dan

kebersamaan yang telah dilalui bersama, semangat, nasehat, dukungan, dan batuan yang telah diberikan selama perkuliahan. Serta Teman online **Kak Meri**, **Kak Mik**, **Kak Jess**, dan **Naufal** yang telah menjadi *moodbooster* selama penggerjaan skripsi ini.

7. Tim Bimbingan Skripsi **Kak Fathur**, **Kak Ilham**, **Muhammad Gibran Al Filambany**, dan **Za'im Ukhrowi** atas bantuan dan kerjasamanya selama penyusunan skripsi ini. Serta Keluarga KKN Tematik Penyandingan (**Ona**, **Anabil**, **Ajeng**, **Enyta**, **Kahfi**, **Ojik**, **Susanto**, **Udin**, **Bowok**, **Tari**, **Ipul**, **Siddiq**, dan **Juli**) atas kebersamaan yang telah dilalui bersama, doa, serta telah memberikan semangat.
8. Kakak-kakak tingkat angkatan 2015, 2016, dan seluruh teman-teman angkatan 2017, serta adik-adik tingkat angkatan 2018, dan 2019 atas bantuan selama perkuliahan. Serta semua pihak yang tidak dapat penulis sebutkan satu persatu yang telah memberikan bantuan dalam menyelesaikan skripsi ini hanya ucapan terima kasih yang dapat penulis berikan. Semoga segala kebaikan yang diberikan mendapatkan balasan dari Allah *Subhanahu Wa Ta'ala*.

Semoga skripsi ini dapat menambah pengetahuan dan bermanfaat bagi mahasiswa/mahasiswi Jurusan Matematika Fakultas dan Ilmu Pengetahuan Alam Universitas Sriwijaya dan semua pihak yang memerlukan.

Wassalamu“alaikum warahmatullahi wabarakatuh.

Indralaya, Novemmmber 2021

Penulis

**AUGMENTATION APPLICATION AND ENSEMBLE LEARNING
ARCHITECTURE IN INCEPTIONV3, MOBILENET,AND
VISUAL GEOMETRY GROUP 19 FOR CLASSIFICATION OF
DISORDERS DIABETIC RETINOPATY**

By :

Nur Avisa Calista Andriani

08011281722024

ABSTRACT

Deep learning has developed rapidly and provides good performance in the image classification process in diabetic retinopathy (DR) disorders. The dataset that is often used in classification is STARE. Unfortunately, only 20 images have labels, therefore augmentation was chosen to overcome data limitations. The high-performance classification method is CNN, so the architecture used is InceptionV3, MobileNet, and VGG19. Unfortunately, in a single classification, overfitting problems often occur during the training process. In this study, the Ensemble learning method will be used to optimize the performance results of the architecture. This study aims to determine the results of the evaluation of the methods used in classifying DR. The stages carried out are data collection, pre-processing, augmentation using rotation and image flipping methods, training, testing, and evaluation of each architecture. The results of the study obtained 18000 new data from augmentation. Ensemble learning performance results outperformed single classification performance with values of accuracy, specificity, sensitivity, F1-Score, and Cohen's kappa which were obtained respectively 95.5%, 95.7%, 95.4%, 95.5%, and 0.911. From these results, it can be said that the Ensemble learning method can perform DR classification very well, which is indicated

Keywords : Diabetic retinopathy, augmentation, Ensemble learning, MobileNet, InceptionV3, VGG19

**PENERAPAN AUGMENTASI DAN ENSEMBLE LEARNING PADA
ARSITEKTUR INCEPTIONV3, MOBILENET, DAN
VISUAL GEOMETRY GROUP 19 UNTUK KLASIFIKASI
GANGGUAN DIABETIC RETINOPATY**

Oleh :

Nur Avisa Calista Andriani

08011281722024

ABSTRAK

Deep learning telah berkembang pesat dan memberikan kinerja yang baik dalam proses klasifikasi citra pada gangguan *diabetic retinopathy* (DR). Dataset yang sering digunakan pada klasifikasi yaitu STARE. Sayangnya, hanya 20 citra yang memiliki label, oleh karena itu augmentasi dipilih untuk mengatasi keterbatasan data. Metode klasifikasi kinerja tinggi adalah CNN, maka dari itu arsitektur yang digunakan adalah *InceptionV3*, *MobileNet*, dan *VGG19*. Sayangnya pada klasifikasi tunggal sering kali terjadi masalah *overfitting* saat proses *training*. Pada penelitian ini akan menggunakan metode *Ensemble learning* untuk mengoptimalkan hasil kinerja dari arsitektur. Penelitian ini bertujuan untuk mengetahui hasil evaluasi kinerja dari metode yang digunakan dalam melakukan klasifikasi penyakit DR. Adapun tahapan yang dilakukan yaitu pengumpulan data, *pre-processing*, augmentasi menggunakan metode *rotation* dan *flipping image*, *training*, *testing*, dan evaluasi pada masing-masing arsitektur. Hasil penelitian diperoleh 18000 data baru hasil dari augmentasi. Hasil kinerja *Ensemble learning* mengungguli dari kinerja klasifikasi tunggal dengan nilai akurasi, spesifitas, sensitivitas, *F1-Score*, dan *Cohen's kappa* yang diperoleh secara berturut-turut 95,5%, 95,7%, 95,4%, 95,5%, dan 0,911. Dari hasil tersebut dapat disimpulkan bahwa metode *Ensemble learning* mampu melakukan klasifikasi DR dengan sangat baik yang ditunjukkan oleh nilai akurasi, sensitivitas, dan spesifitas diatas 90%, keseimbangan antara nilai sensitivitas dan spesifistas sudah sangat baik dilihat dari nilai *F1-Score* diatas 90%, dan sangat baik dalam ukuran kesepakatan antar kelas yang diamati dan diprediksi terlihat dari nilai *Cohen's kappa* diatas 0,8. Selain itu, metode *Ensemble learning* mampu mengatasi masalah *overfitting* pada klasifikasi tunggal.

Kata kunci : *Diabetic retinopathy*, augmentasi, *Ensemble learning*, *MobileNet*, *InceptionV3*, *VGG19*.

DAFTAR ISI

LEMBAR PENGESAHAN	i
HALAMAN PERSEMPAHAN	ii
KATA PENGANTAR	iii
ABSTRACT	vi
ABSTRAK.....	vii
DAFTAR ISI.....	viii
DAFTAR TABEL.....	x
DAFTAR GAMBAR	xi
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Perumusan Masalah	5
1.3 Pembatasan Masalah.....	6
1.4 Tujuan	6
1.5 Manfaat	7
BAB II TINJAUAN PUSTAKA	8
2.1 <i>Diabetic Retinopathy</i> (DR)	8
2.2 Citra Digital	8
2.3 Pre-processing.....	8
a. Cropping Image	9
b. Green Channel Extrarction.....	9
c. Contrast Limited Adaptive Histogram Equalization (CLAHE)	9
2.4 Augmentasi	10
2.5 Klasifikasi Citra.....	10
2.6 Convolutional Neural Network (CNN).....	10
a. Convolution layer.....	10
b. Pooling Layer.....	13
c. Fungsi Aktivasi	14
d. Batch Normalization	16
f. Loss Function : Binary Cross Entropy	18
g. Depthwise Separable Convolutions	18
2.7 <i>InceptionV3</i>	19
2.8 <i>MobileNet</i>	20
2.9 VGG 19.....	21
2.10 <i>Ensemble learning</i>	22

2.11	<i>Confusion Matrix</i>	23
BAB III	METODOLOGI PENELITIAN	26
3.1	Tempat	26
3.2	Waktu	26
3.3	Alat.....	26
3.4	Metode Penelitian	26
BAB IV	HASIL DAN PEMBAHASAN	35
4.1.	Deskripsi Data.....	35
4.2.	Pre-processing.....	35
4.3.	Augmentasi	37
4.4.	Klasifikasi Citra	38
4.5.	Proses Klasifikasi.....	58
4.5	Analisis dan Interpretasi Hasil	89
BAB V	PENUTUP	93
PENUTUP	93
5.1.	Kesimpulan	93
5.2.	Saran	94

DAFTAR TABEL

Tabel 2. 1 <i>Confusion matrix</i>	23
<i>Tabel 2. 2 Kategori nilai kinerja arsitektur</i>	25
Tabel 4. 1 Contoh Dataset STARE	35
Tabel 4. 2 Contoh citra yang yang telah dilakukan augmentasi	37
Tabel 4. 3 Hasil <i>confusion matrix</i> data <i>testing</i>	73
Tabel 4. 4 Hasil <i>confusion matrix</i> data <i>testing</i>	65
Tabel 4. 5 Hasil <i>confusion matrix</i> data <i>testing</i>	80
Tabel 4. 6 Hasil <i>confusion matrix</i> data <i>testing</i>	87
Tabel 4. 7 Perbandingan hasil klasifikasi dari masing-masing model.....	90
Tabel 4. 8 Perbandingan arsitektur dengan penelitian lain	91

DAFTAR GAMBAR

Gambar 2. 1 Ilustrasi convolution layer	12
Gambar 2. 2 Representasi lapisan dalam max pooling	13
Gambar 2. 3 Representasi lapisan dalam avarage pooling.....	14
Gambar 2. 4 Representasi fungsi aktivasi ReLU	15
Gambar 2. 5 Representasifungsi aktivasi sigmoid	16
Gambar 2. 6 Ilustrasi arsitektur InceptionV3	20
Gambar 2. 7. Contoh arsitektur MobileNet.....	20
Gambar 2. 8 Contoh arsitektur VGG19	21
Gambar 4. 1 Ilustrasi arsitektur InceptionV3 yang diusulkan.....	59
Gambar 4. 2 Tahapan Stem.....	59
Gambar 4. 3 Tahapan Inception A	60
Gambar 4. 4 Tahapan Reduction A.....	61
Gambar 4. 5 Hasil Training data pada model InceptionV3	62
Gambar 4. 6 Grafik nilai akurasi pada proses training model InceptionV3.....	63
Gambar 4. 7 Grafik nilai loss pada proses training model InceptionV3	64
Gambar 4. 8 Arsitektur MobileNet yang diusulkan.....	68
Gambar 4. 9 hasil Training data pada model Mobilennet	70
Gambar 4. 10 Grafik nilai akurasi pada proses training model MobileNet	71
Gambar 4. 11 Grafik nilai loss pada proses training model MobileNet.....	72
Gambar 4. 12 Ilustrasi arsitektur VGG19 yang diusulkan	76
Gambar 4. 13 Isi dari blok A pada arsitektur VGG19	76
Gambar 4. 14 hasil Training pada model VGG19	78

Gambar 4. 15 Grafik nilai akurasi pada proses training model VGG19	79
Gambar 4. 16 Grafik nilai loss pada proses training model VGG19	79
Gambar 4. 17 Ilustrasi Ensemble learning	83
Gambar 4. 18 Hasil Training Data pada Model Ensemble Learning	84
Gambar 4. 19 Grafik nilai akurasi pada proses training model Ensemble learning	85
Gambar 4. 20 Grafik nilai loss pada proses training model Ensemble learning	86

BAB I

PENDAHULUAN

1.1 Latar Belakang

Pembelajaran fitur menggunakan *Deep Learning* (DL) telah berkembang pesat dan dapat memberikan kinerja yang sangat baik dalam proses klasifikasi citra (Alom *et al.*, 2019; Cao *et al.*, 2019). DL mampu mendeteksi pola dari data yang diberikan kepada model secara otomatis kemudian membuat keputusan atau prediksi berdasarkan data gambar (Soomro *et al.*, 2019). Metode DL sering digunakan dalam dunia medis untuk mendeteksi suatu penyakit, salah satunya adalah penyakit *Diabetic Retinopathy* (DR) (Jiang *et al.*, 2019). *Diabetic retinopathy* merupakan penyakit komplikasi dari *diabetes mellitus* yang terjadi akibat adanya kelainan pada pembuluh darah retina yang menyebabkan gangguan penglihatan dan bahkan kebutaan total jika penderitanya tidak mendapatkan penanganan dengan tepat (Qummar *et al.*, 2019). Pengenalan penyakit DR dapat melalui citra dari kamera fundus. Berbagai dataset citra retina telah tersedia dan dapat diakses secara gratis untuk berbagai keperluan, salah satunya dataset *The Structured Analysis of the Retina* (STARE) (Erwin *et al.*, 2019). Dataset STARE merupakan kumpulan dataset yang cocok untuk menganalisis struktur pada retina (Bhardwaj *et al.*, 2021; Singh *et al.*, 2015). Dataset STARE diambil menggunakan kamera fundus dengan resolusi 700 x 605 piksel, berjumlah 400 citra namun sayangnya pada dataset ini hanya 20 citra yang memiliki label (Choi *et al.*, 2017; AbdelMaksoud *et al.*, 2020). Keakuratan suatu model bergantung dari banyak data

latih (Kavzoglu, 2009). Semakin banyak data latih dan data yang seimbang pada tiap kelas atau label yang digunakan akan menghasilkan nilai akurasi yang bagus (Kavzoglu, 2009). Salah satu cara memperbanyak data yaitu dengan melakukan proses augmentasi.

Augmentasi data merupakan suatu proses dalam pengolahan data gambar yang mengubah gambar menjadi data baru tanpa menghilangkan ataupun mengubah inti dari gambar (Soomro *et al.*, 2019). Terdapat beberapa fitur metode dalam proses augmentasi yang paling sering digunakan diantaranya yaitu *rotation image* dan *flipping image*. Penelitian Perez and Wang (2017) membandingkan hasil klasifikasi yang menggunakan proses augmentasi dan tanpa proses augmentasi pada data hewan, hasil menunjukkan bahwa proses augmentasi klasifikasi yang menggunakan proses augmentasi naik sebesar 7 % dibandingkan pada klasifikasi tanpa proses augmentasi. Salah satu metode klasifikasi yang memerlukan banyak data adalah *Convolutional Neural Network* (CNN) (Nguyen *et al.*, 2019).

Convolutional Neural Network (CNN) merupakan salah satu metode DL yang paling populer dalam data gambar yang mampu mencapai hasil klasifikasi lebih efektif (Chen *et al.*, 2020). Dengan meningkatnya popularitas CNN, banyak arsitektur CNN yang muncul dan mampu mencapai hasil yang cukup baik diantaranya arsitektur *InceptionV3*, *MobileNet*, dan *VGG19*.

Arsitektur *InceptionV3* merupakan arsitektur CNN yang cukup sering digunakan dalam klasifikasi citra (Cao *et al.*, 2021). Arsitektur *InceptionV3* merupakan arsitektur yang dikembangkan oleh *google* untuk untuk membangun model diagnosis multi-kelas serta telah berhasil diterapkan ke berbagai jenis

identifikasi dan segmentasi (Hagos and Kant, 2019; Soomro *et al.*, 2019). Beberapa penelitian yang telah memanfaatkan arsitektur *InceptionV3* pada klasifikasi diantaranya Bhardwaj *et al.* (2021) menggunakan model QIY-3 dengan mengkombinasikan *InceptionV3* memperoleh hasil nilai akurasi sebesar 93,33%. Penelitian Yoo *et al.* (2021) memperoleh hasil akurasi sebesar 97% dan nilai *Cohen's kappa* sebesar 96,7%. Pada penelitian Hagos and Kant (2019) diperoleh nilai akurasi 90,9 %. Sayangnya ketiga penelitian tersebut tidak menghitung nilai sensitivitas, spesitifitas, *F1-Score*, dan *Cohen's kappa*. Arsitektur *InceptionV3* menggunakan parameter kecil dengan fitur *convolution* lebih dalam, namun semakin dalam fitur *convolution* akan menyebabkan waktu komputasi semakin lama (Cao *et al.*, 2021). Salah satu arsitektur yang menggunakan waktu komputasi yang lebih cepat adalah *MobileNet*.

Arsitektur *MobileNet* merupakan arsitektur dalam CNN yang paling ringan dan dapat digunakan dengan parameter kecil, selain itu *MobileNet* mampu mengurangi ukuran parameter, dan bekerja lebih cepat dibanding arsitektur lainnya (Patel, 2020;Gao *et al.*, 2019). Terdapat beberapa peneliti yang menerapkan arsitektur *MobileNet* untuk klasifikasi DR diantaranya Patel (2020) menghasilkan nilai akurasi sebesar 89%, Suriyal *et al.* (2018) menghasilkan nilai akurasi sebesar 73%, dan Kassani *et al.* (2019) menghasilkan nilai akurasi sebesar 79%. Dari ketiga penelitian tersebut hanya penelitian Kassani *et al.* (2019) yang menghitung spesitifitas sebesar 84% dan sensitivitas sebesar 76%, dan ketiga penelitian tersebut tidak menghitung nilai *Cohen's kappa*. *MobileNet* rentan terjadinya *overfitting* pada proses *training* yang mengakibatkan menurunnya kinerja pada model tersebut

(Gao *et al.*, 2019; Shang *et al.*, 2020).

Salah satu arsitektur CNN yang cukup bagus dalam proses klasifikasi adalah *Visual Geometry Group* 19 (VGG19). VGG19 merupakan salah satu arsitektur pada CNN yang cukup efektif untuk menghasilkan kinerja yang baik pada klasifikasi (Das *et al.*, 2019; Yang, 2021), sayangnya arsitektur VGG19 memiliki kelemahan yaitu terlalu banyak menggunakan parameter dan memori pada komputer (Kusuma *et al.*, 2019). Pada penelitian telah yang dilakukan oleh Kwasigroch *et al.* (2017) diperoleh hasil akurasi, sensitivitas, spesifikasi, dan *Cohen's kappa* berturut-turut 81,7%, 89,5%, 50,5%, dan 0,776. Pada penelitian yang dilakukan Nie *et al.* (2021) diperoleh hasil akurasi sebesar 84,44 %, sayangnya penelitian ini tidak menghitung nilai sensitivitas, spesifikasi, *F1-Score* dan *Cohen's kappa*.

Setiap arsitektur memiliki kelebihan dan kekurangan masing-masing untuk mengoptimalkan hasil kinerja dari masing-masing arsitektur dapat digunakan metode *Ensemble learning* (Gao *et al.*, 2019). *Ensemble learning* merupakan metode klasifikasi yang menggabungkan *output* dari beberapa model yang berguna untuk meningkatkan kinerja model dan membantu mengurangi masalah *overfitting* pada *training* (Soomro *et al.*, 2019 ; Reddy *et al.*, 2020). Beberapa penelitian yang menggunakan metode *Ensemble learning* (Jiang *et al.*, 2019; Mishra *et al.*, 2020; Reddy *et al.*, 2020). Jiang *et al.* (2019) menggunakan metode *Ensemble learning* dengan model *InceptionV3*, *InceptionResNetV2*, dan *ResNet152* menghasilkan nilai akurasi 88,21%, spesifikasi 85,57%, dan sensitivitas 88,41%. Pada penelitian yang dilakukan Mishra *et al.* (2020) menggunakan arsitektur VGG16 dan VGG19

menghasilkan nilai akurasi 83%, spesitifitas 80%, dan sensitivitas 82%. Pada penelitian Reddy *et al.*(2020) menggunakan *Random Forest Classifier*, *Decision Tree Classifier*, *Adaboost Classifier*, *K-Nearest Neighbor Classifier*, *Logistic Regression Classifier* menghasilkan nilai akurasi, sensitivitas, dan spesitifitas diatas 80%. Ketiga penelitian tersebut tidak menghitung nilai *F1-Score* dan *Cohen's kappa*.

Berdasarkan kelebihan dari masing-masing arsitektur penelitian ini akan meningkatkan kinerja prediksi pada klasifikasi *Diabetic Retinopathy* dengan menggabungkan augmentasi citra dan metode *Ensemble learning* pada arsitektur *MobileNet*, *InceptionV3*, dan *VGG19* dalam melakukan klasifikasi dengan pengambilan keputusan prediksi berdasarkan metode *weighted voting*. Hasil evaluasi kinerja arsitektur akan dilihat berdasarkan nilai akurasi, sensitivitas, spesifisitas, *F1-Score*, dan *Cohen's kappa*. Pada penelitian ini arsitektur yang diusulkan akan diuji menggunakan dataset STARE.

1.2 Perumusan Masalah

Permasalahan pada penelitian ini akan membahas bagaimana hasil evaluasi kinerja dari metode augmentasi dan metode *Ensemble learning* dengan arsitektur *MobileNet*, *InceptionV3*, dan *VGG19* dalam melakukan klasifikasi penyakit DR sehingga mendapatkan nilai akurasi, sensitivitas, spesifisitas, *F1-Score*, dan *Cohen's kappa*.

1.3 Pembatasan Masalah

Beberapa pembatasan masalah pada penelitian ini :

1. Penelitian ini dilakukan hanya untuk klasifikasi *Diabetic Retinopathy* menggunakan citra retina yang terdiri dari 2 kelas yaitu normal dan DR. Dalam pengambilan keputusan berdasarkan pembobotan hanya menggunakan *weighted voting*.
2. Pada penelitian ini tidak membahas segmentasi gambar yang dibutuhkan pada saat klasifikasi. Dataset yang digunakan dalam penelitian ini hanya dataset STARE.
3. Pada augmentasi hanya menggunakan metode *rotation image* dan *flipping image*.
4. Pembahasan evaluasi dari model arsitektur klasifikasi hanya akan mengukur kinerja berdasarkan akurasi, sensitivitas, spesifisitas, *F1-Score*, dan *Cohen's kappa*.

1.4 Tujuan

Tujuan dari penelitian ini adalah untuk mengetahui hasil evaluasi kinerja dari metode augmentasi dan metode *Ensemble learning* dengan arsitektur *MobileNet*, *InceptionV3*, dan *VGG19* dalam melakukan klasifikasi penyakit DR sehingga mendapatkan nilai akurasi, sensitivitas, spesifisitas, *F1-Score*, dan *Cohen's kappa*.

1.5 Manfaat

Manfaat dari hasil penelitian ini :

1. Dapat diperoleh model yang dapat mengklasifikasikan jenis gangguan DR yang lebih akurat dengan menambahkan metode augmentasi dan *Ensemble learning*.
2. Dapat digunakan sebagai referensi bagi penelitian yang akan melakukan penelitian pada bidang klasifikasi dan pengembangan *deep learning*.

DAFTAR PUSTAKA

- AbdelMaksoud, *et al.* (2020) ‘A comprehensive diagnosis system for early signs and different diabetic retinopathy grades using fundus retinal images based on pathological changes detection’, *Computers in Biology and Medicine*. Elsevier Ltd, 126, p. 104039. doi: 10.1016/j.combiomed.2020.104039.
- Alom, M. Z. *et al.* (2019) ‘Recurrent residual U-Net for medical image segmentation’, *Journal of Medical Imaging*, 6(01), p. 1. doi: 10.1117/1.jmi.6.1.014006.
- Bhardwaj, *et al.* (2021) ‘Diabetic retinopathy severity grading employing quadrant-based Inception-V3 convolution neural network architecture’, *International Journal of Imaging Systems and Technology*, 31(2), pp. 592–608. doi: 10.1002/ima.22510.
- Biswas, *et al.* (2020) ‘Dilated Deep Neural Network for Segmentation of Retinal Blood Vessels in Fundus Images’, *Iranian Journal of Science and Technology - Transactions of Electrical Engineering*. Springer International Publishing, 44(1), pp. 505–518. doi: 10.1007/s40998-019-00213-7.
- Cai, Z. (2018) ‘Cascade R-CNN : Delving into High Quality Object Detection’, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- Cao, J. *et al.* (2021) ‘Application of a modified Inception-v3 model in the dynasty-based classification of ancient murals’, *Eurasip Journal on Advances in Signal Processing*. EURASIP Journal on Advances in Signal Processing, 2021(1). doi: 10.1186/s13634-021-00740-8.
- Cao, Y. *et al.* (2019) ‘Deep Learning Methods for Cardiovascular Image’, *Journal of Artificial Intelligence and Systems*, 1(1), pp. 96–109. doi: 10.33969/ais.2019.11006.
- Chen, W. *et al.* (2020) ‘An approach to detecting diabetic retinopathy based on integrated shallow convolutional neural networks’, *IEEE Access*, 8, pp. 178552–178562. doi: 10.1109/ACCESS.2020.3027794.
- Choi, J. Y. *et al.* (2017) ‘Multi-categorical deep learning neural network to classify retinal images: A pilot study employing small database’, *PLoS ONE*, 12(11), pp. 1–16. doi: 10.1371/journal.pone.0187336.
- Das, A. *et al.* (2019) ‘Classification of Retinal Diseases Using Transfer Learning Approach’, *Proceedings of the 4th International Conference on Communication and Electronics Systems, ICCES 2019*, (Icces), pp. 2080–2084. doi: 10.1109/ICCES45898.2019.9002415.
- Dong, K. *et al.* (2020) ‘MobileNetV2 Model for Image Classification’, *Proceedings - 2020 2nd International Conference on Information Technology and Computer Application, ITCA 2020*, pp. 476–480. doi: 10.1109/ITCA52113.2020.00106.

- Erwin *et al.* (2019) ‘Improved Image Quality Retinal Fundus with Contrast Limited Adaptive Histogram Equalization and Filter Variation’, *Proceedings - 1st International Conference on Informatics, Multimedia, Cyber and Information System, ICIMCIS 2019*, pp. 49–54. doi: 10.1109/ICIMCIS48181.2019.8985198.
- Gao, J., *et al.* (2019) ‘Diabetic Retinopathy Classification Using an Efficient Convolutional Neural Network’, *Proceedings - 2019 IEEE International Conference on Agents, ICA 2019*. IEEE, pp. 80–85. doi: 10.1109/AGENTS.2019.8929191.
- Gayathri, S., *et al.* (2020) ‘Biomedical Signal Processing and Control A lightweight CNN for Diabetic Retinopathy classification from fundus images’, *Biomedical Signal Processing and Control*. Elsevier Ltd, 62(July), p. 102115. doi: 10.1016/j.bspc.2020.102115.
- Gholamalinezhad, H. and Khosravi, H. (2020) ‘Pooling Methods in Deep Neural Networks, a Review’, *arXiv preprint arXiv:2009.07485*. Available at: <http://arxiv.org/abs/2009.07485>.
- Hagos, M. T. and Kant, S. (2019) ‘Transfer Learning based Detection of Diabetic Retinopathy from Small Dataset’. Available at: <http://arxiv.org/abs/1905.07203>.
- Howard, A. G. *et al.* (2017) ‘MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications’. Available at: <http://arxiv.org/abs/1704.04861>.
- Huang, L. *et al.* (2018) ‘Decorrelated Batch Normalization’, *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 791–800. doi: 10.1109/CVPR.2018.00089.
- Id, T. J. B. *et al.* (2019) ‘Enhanced classifier training to improve precision of a convolutional neural network to identify images of skin lesions’, *PLoS ONE*, pp. 1–8.
- Jiang, H. *et al.* (2019) ‘An Interpretable Ensemble Deep Learning Model for Diabetic Retinopathy Disease Classification’, *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, pp. 2045–2048. doi: 10.1109/EMBC.2019.8857160.
- Kassani, S. H. *et al.* (2019) ‘Diabetic Retinopathy Classification Using a Modified Xception Architecture’, in *2019 IEEE 19th International Symposium on Signal Processing and Information Technology, ISSPIT 2019*, pp. 0–5. doi: 10.1109/ISSPIT47144.2019.9001846.
- Kavzoglu, T. (2009) ‘Increasing the accuracy of neural network classification using refined training data’, *Environmental Modelling and Software*. Elsevier Ltd, 24(7), pp. 850–858. doi: 10.1016/j.envsoft.2008.11.012.
- Khari, M. *et al.* (2019) ‘Gesture Recognition of RGB and RGB-D Static Images Using Convolutional Neural Networks’, *International Journal of Interactive*

- Multimedia and Artificial Intelligence*, 5(7), p. 22. doi: 10.9781/ijimai.2019.09.002.
- Kumar, S. and Kumar, B. (2018) ‘Diabetic Retinopathy Detection by Extracting Area and Number of Microaneurysm from Colour Fundus Image’, *2018 5th International Conference on Signal Processing and Integrated Networks, SPIN 2018*. IEEE, pp. 359–364. doi: 10.1109/SPIN.2018.8474264.
- Kwasigroch, A., Jarzembski, B. and Grochowski, M. (2018) ‘Deep CNN based decision support system for detection and assessing the stage of diabetic retinopathy’, *2018 International Interdisciplinary PhD Workshop (IIPhDW)*. IEEE, pp. 111–116.
- Laurensia, Y., Young, J. C. and Suryadibrata, A. (2020) ‘Early Detection of Diabetic Retinopathy Cases using Pre-trained EfficientNet and XGBoost’, *International Journal of Advances in Soft Computing and its Applications*, 12(3), pp. 101–111.
- Mishra, S. *et al.* (2016) ‘Regularized discriminant analysis for multi-sensor decision fusion and damage detection with Lamb waves’, *Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2016*, 9803(850), p. 98032H. doi: 10.1117/12.2217959.
- Mishra, S., Hanchate, S. and Saquib, Z. (2020) ‘Diabetic retinopathy detection using deep learning’, *Proceedings of the International Conference on Smart Technologies in Computing, Electrical and Electronics, ICSTCEE 2020*, pp. 515–520. doi: 10.1109/ICSTCEE49637.2020.9277506.
- Nath, S. S. *et al.* (2014) ‘A survey of image classification methods and techniques’, *2014 International Conference on Control, Instrumentation, Communication and Computational Technologies, ICCICCT 2014*, pp. 554–557. doi: 10.1109/ICCI CCT.2014.6993023.
- Nguyen, L. D. *et al.* (2019) ‘Biomedical image classification based on a feature concatenation and Ensemble of deep CNNs’, *Journal of Ambient Intelligence and Humanized Computing*. doi: 10.1007/s12652-019-01276-4.
- Nie, Y. *et al.* (2021) ‘Computer assisted grade diagnosis using feature fusion and network algorithm flow’, in *Journal of Physics: Conference Series*. doi: 10.1088/1742-6596/2033/1/012006.
- Patel, S. (2020) ‘Diabetic Retinopathy Detection and Classification using Pre-trained Convolutional Neural Networks’, *International Journal on Emerging Technologies*, 11(3), pp. 1082–1087.
- Perez, L. and Wang, J. (2017) ‘The Effectiveness of Data Augmentation in Image Classification using Deep Learning’. Available at: <http://arxiv.org/abs/1712.04621>.
- Qummar, S. *et al.* (2019) ‘A Deep Learning Ensemble Approach for Diabetic Retinopathy Detection’, *IEEE Access*. IEEE, 7, pp. 150530–150539. doi: 10.1109/ACCESS.2019.2947484.

- Reddy, G. T. *et al.* (2020) ‘An Ensemble based Machine Learning model for Diabetic Retinopathy Classification’, *International Conference on Emerging Trends in Information Technology and Engineering, ic-ETITE 2020*, pp. 1–6. doi: 10.1109/ic-ETITE47903.2020.9235.
- Shang, R. *et al.* (2020) ‘Dense connection and depthwise separable convolution based CNN for polarimetric SAR image classification’, *Knowledge-Based Systems*. Elsevier B.V., 194, p. 105542. doi: 10.1016/j.knosys.2020.105542.
- Shelda Mohan, M. R. (2013) ‘Optimized Histogram Based Contrast Limited\nEnhancement for Mammogram Images\n’, *ACEEE Int. J. on Information Technology*, 3(1), pp. 66–71. Available at: doi.searchdl.org/01.IJIT.3.1.1115%5Cn.
- Shi, J. *et al.* (2021) ‘Improvement of damage segmentation based on pixel-level data balance using vgg-unet’, *Applied Sciences (Switzerland)*, 11(2), pp. 1–17. doi: 10.3390/app11020518.
- Shorten, C. and Khoshgoftaar, T. M. (2019) ‘A survey on Image Data Augmentation for Deep Learning’, *Journal of Big Data*. Springer International Publishing, 6(1). doi: 10.1186/s40537-019-0197-0.
- Shu, L., Xu, H. and Liu, B. (2016) ‘DOC: Deep Open Classification of Text Documents’, *arXiv preprint arXiv:2009.07485*, (2013).
- Singh, D., Dharmveer and Singh, B. (2015) ‘A new morphology based approach for blood vessel segmentation in retinal images’, in *11th IEEE India Conference: Emerging Trends and Innovation in Technology, INDICON 2014*, pp. 1–6. doi: 10.1109/INDICON.2014.7030686.
- Soomro, T. A. *et al.* (2019) ‘Deep Learning Models for Retinal Blood Vessels Segmentation: A Review’, *IEEE Access*. IEEE, 7, pp. 71696–71717. doi: 10.1109/ACCESS.2019.2920616.
- Wang, J. *et al.* (2020) ‘Multi-Label Classification of Fundus Images with EfficientNet’, *IEEE Access*, 8, pp. 212499–212508. doi: 10.1109/ACCESS.2020.3040275.
- Wang, W. *et al.* (2020) ‘A novel image classification approach via dense-MobileNet models’, *Mobile Information Systems*, 2020. doi: 10.1155/2020/7602384.
- Yang, Z. (2021) ‘Classification of picture art style based on VGGNET’, *Journal of Physics: Conference Series*, 1774(1). doi: 10.1088/1742-6596/1774/1/012043.
- Zhang, W. *et al.* (2019) ‘Automated identification and grading system of diabetic retinopathy using deep neural networks’, *Knowledge-Based Systems*. Elsevier B.V., 175, pp. 12–25. doi: 10.1016/j.knosys.2019.03.016.