

**METODE *ENSEMBLE* PADA ARSITEKTUR *RESNET-50*,
MOBILENET, DAN *EFFICIENT NET* DALAM PENENTUAN
PENYAKIT *DIABETIC RETINOPATHY* PADA RETINA**

SKRIPSI

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

Oleh:

MUHAMMAD GIBRAN AL-FILAMBANY

08011281722048



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

2022

HALAMAN PENGESAHAN

**METODE ENSEMBLE PADA ARSITEKTUR RESNET-50, MOBILENET,
DAN EFFICIENT NET DALAM PENENTUAN PENYAKIT DIABETIC
RETINOPATHY PADA RETINA**

SKRIPSI

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

Oleh:

MUHAMMAD GIBRAN AL-FILAMBANY

08011281722048

Pembimbing Kedua




Dr. Bambang Suprihatin. S.Si., M.Si.
NIP. 197101261994121001

**Indralaya, Januari 2022
Pembimbing Utama**



Anita Desiani. M.Kom
NIP.197712112003122002

**Mengetahui,
Ketua Jurusan Matematika**



Drs. Sugandi Yahdin. M.M
NIP.19580727198603 1003

PERNYATAAN KEASLIAN KARYA ILMIAH

Yang bertanda tangan di bawah ini:

Nama Mahasiswa : Muhammad Gibran Al-Filambany

NIM : 08011281722048

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.

Demikian pernyataan ini saya buat dengan sesungguhnya.

Indralaya, 11 April 2022

Penulis



Muhammad Gibran Al-Filambany

NIM.08011281722048

**HALAMAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK
KEPENTINGAN AKADEMIS**

Sebagai Civitas Akademik Universitas Sriwijaya, yang bertanda tangan dibawah ini:

Nama Mahasiswa : Muhammad Gibran Al-Filambany
NIM : 08011281722048
Fakultas/Jurusan : Matematika dan Ilmu Pengetahuan Alam/Matematika
Jenis Karya : Skripsi

Demi pengembangan ilmu pengetahuan, saya menyetujui untuk memberikan kepada Universitas Sriwijaya “Metode *Ensemble* pada arsitektur *Resnet-50*, *MobileNet*, dan *Efficient Net* dalam Penentuan Penyakit *Diabetic Retinopathy* pada Retina”. Dengan hak bebas royalti non-eksklusif ini Universitas Sriwijaya berhak menyimpan, mengalihkan, 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



Muhammad Gibran Al-Filambany

NIM.08011281722048

HALAMAN PERSEMBAHAN

Kupersembahkan skripsi ini untuk :

Yang MahaKuasa Allah SubhanahuWaTa'ala

Orangtuaku Tersayang

Adikku ,

Keluarga Besarku Tersayang

Semua Guru dan Dosenku

Teman baik yang Kubanggakan

Almamaterku

Motto :

*" Bangunlah suatu dunia di mana semua bangsanya hidup dalam damai dan
persaudaraan "*

-Soekarno

KATA PENGANTAR

Assalaamu'alaikum Warohmatulloohi Wabarokaatuh

Alhamdulillahirobbil'aalamiin, segala puji atas kehadiran Allah *Subhanahu Wa Ta'ala* dengan segala rahmat dan karunia-Nya. Shalawat beserta salam selalu tercurahkan kepada suri tauladan umat manusia, Nabi Muhammad *Shalallahu Alaihi Wassalam* beserta para sahabat, keluarga, dan pengikutnya hingga akhir zaman. Penulis bersyukur atas segala berkah-Nya karena dapat menyelesaikan skripsi berjudul “**METODE ENSEMBLE PADA ARSITEKTUR RESNET-50, MOBILENET, DAN EFFICIENT NET DALAM PENENTUAN PENYAKIT DIABETIC RETINOPATHY PADA RETINA**” sebagai salah satu syarat untuk memperoleh gelar Sarjana di Jurusan Matematika pada Fakultas MIPA.

Dengan segala hormat dan kerendahan hati mengucapkan terima kasih yang sedalam-dalamnya kepada kedua orang tua tercinta, yaitu **Bapak Zulkarnain** dan **Ibu Kenis Wulan Sari** yang telah merawat, mendidik, menuntun, memberi nasehat, dan semangat serta do'a yang tiada henti untuk penulis dengan penuh rasa cinta dan kasih sayang. Penulis juga ingin menyampaikan ucapan terima kasih kepada :

1. Bapak **Drs. Sugandi Yahdin, M.M** dan Ibu **Dr. Dian Cahyawati Sukanda, M.Si** selaku Ketua dan Sekretaris Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya yang telah membimbing dan mengarahkan dalam urusan akademik selama menempuh perkuliahan di Jurusan Matematika FMIPA Universitas Sriwijaya.

2. Ibu **Anita Desiani, M.Kom** dan Bapak **Dr. Bambang Suprihatin, S.Si., M.Si.** selaku Dosen Pembimbing Utama dan Dosen Pembimbing Kedua yang telah bersedia meluangkan waktu, tenaga, dan pikiran untuk memberikan bimbingan dengan penuh perhatian dan kesabaran sehingga skripsi ini dapat diselesaikan.
3. Ibu **Dr. Evi Yuliza, M.Si** dan Ibu **Irmeilyana, M.Si** selaku Dosen Pembahas yang telah meluangkan waktunya dalam memberikan tanggapan, saran, masukan, dan kritik yang sangat bermanfaat untuk perbaikan dan penyelesaian skripsi ini.
4. Ibu **Oki Dwipurwani, M.Si** selaku Dosen Pembimbing Akademik yang telah membimbing, membantu, mengarahkan, dan memberi saran untuk urusan akademik penulis pada setiap semester.
5. **Seluruh Dosen di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya** yang telah memberikan ilmu yang sangat bermanfaat bagi penulis selama menempuh pendidikan.
6. Bapak **Irwansyah** selaku admin dan Ibu **Hamidah** selaku Pegawai tata usaha di Jurusan Matematika FMIPA Universitas Sriwijaya yang telah membantu urusan administrasi penulis selama perkuliahan.
7. Semua teman, adik dan kakak saya di Jurusan Matematik FMIPA Universitas Sriwijaya yang telah memberikan saya semangat dan bantuan dalam mengerjakan skripsi ini.

8. Semua pihak yang terlibat dalam memberikan bantuan untuk menyelesaikan skripsi ini. Semoga semua kebaikan yang telah diberikan kepada penulis mendapatkan balasan dari-Nya.

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

Wassalaamu'alaikum Warohmatulloohi Wabarokaatuh

Indralaya, Januari 2022

Penulis

**ENSEMBLE METHOD WITH RESNET-50, MOBILENET, AND
EFFICIENTNET ARCHITECTURE FOR DIABETIC RETHINOPATHY
CLASSIFICATION IN RETINAL**

By :

Muhammad Gibran Al-Filambany

08011281722048

ABSTRACT

Diabetic rethinopathy (DR) is a diabetic that affects the retinal of eye and can be identified through retinal images. Retinal image identification process can be done by applying deep learning-based methods, one of which is Convolutional Neural Network (CNN). CNN has an architecture that can perform the images classification process, namely ResNet-50, MobileNet, and EfficientNet. The weaknesses possessed by each architecture can be overcome through the ensemble learning method which can combine the performance results of each single classification methods. This research applies ensemble learning method to improve performance results of the ResNet-50, MobileNet, and EfficientNet architectures in determining retinal DR disease. APTOS and EyEPACS is used in this research. The method used is data collection, training, *testing*, and evaluation in each architecture and ensemble learning. The result of ensemble learning evaluation outperform the other architecture in term of accuracy, F1-Score and cohen kappa with value of 93,3%, 93,42%, and 0.866 respectively. The best result for specificity are achieved by Resnet with 99,78% and EfficientNet achieved the best result for sensitivity with 96,2%. Based on the result, it can be concluded that the ensemble learning method proposed perform very well.

Keyword : Diabetic Retinopathy, Ensemble Learning, MobileNet, ResNet-50, EfficientNet.

**METODE ENSEMBLE PADA ARSITEKTUR *RESNET-50*, *MOBILENET*
DAN *EFFICIENT NET* DALAM PENENTUAN PENYAKIT *DIABETIC*
RETINOPATHY PADA RETINA**

Oleh :

Muhammad Gibran Al-Filambany

08011281722048

ABSTRAK

Penyakit *Diabetic Retinopathy* (DR) merupakan penyakit diabetes yang memengaruhi retina mata dan dapat diidentifikasi melalui citra retina. Proses identifikasi citra retina dapat dilakukan dengan menerapkan metode berbasis *deep learning*, dimana salah satunya adalah *Convolutional Neural Network* (CNN). CNN memiliki arsitektur yang dapat melakukan proses klasifikasi citra yaitu *ResNet-50*, *MobileNet*, dan *EfficientNet*. Kelemahan yang dimiliki oleh masing-masing arsitektur dapat diatasi melalui metode *ensemble learning* yang dapat menggabungkan hasil kinerja pada setiap metode klasifikasi tunggal. Penelitian ini menerapkan metode *ensemble learning* untuk meningkatkan hasil kinerja dari arsitektur *ResNet-50*, *MobileNet*, dan *EfficientNet* dalam penentuan penyakit DR pada retina. Data yang digunakan pada penelitian ini yaitu dataset APTOS dan EyePACS. Metode yang digunakan pada penelitian ini adalah pengumpulan data, *training*, *testing*, dan evaluasi pada setiap arsitektur dan *ensemble learning*. Hasil kinerja *ensemble learning* unggul pada nilai akurasi, *F1-Score*, dan *Cohens Kappa* yang diperoleh secara berturut-turut 93,3%, 93,42%, dan 0.866. Nilai spesifisitas terbaik diperoleh oleh *Resnet-50* sebesar 99,78% dan nilai sensitivitas tertinggi diperoleh *EfficientNet* sebesar 96,2%. Berdasarkan hasil klasifikasi dari setiap arsitektur dan *ensemble learning*, dapat disimpulkan bahwa metode *ensemble learning* yang diusulkan mampu melakukan klasifikasi citra dengan sangat baik.

Kata Kunci: *Diabetic retinopathy*, *Ensemble Learning*, *MobileNet*, *ResNet-50*, *EfficientNet*.

DAFTAR ISI

HALAMAN PENGESAHAN	ii
HALAMAN PERSEMBAHAN	iii
KATA PENGANTAR	iv
ABSTRACT	vii
ABSTRAK	viii
DAFTAR TABEL	xi
DAFTAR GAMBAR	xi
BAB I PENDAHULUAN	14
1.1 Latar Belakang.....	14
1.2 Rumusan Masalah.....	18
1.3 Batasan Masalah.....	18
1.4 Tujuan.....	18
1.5 Manfaat.....	19
BAB II TINJAUAN PUSTAKA	20
2.1 <i>Diabetic Retinopathy (DR)</i>	20
2.2 <i>Pre-Processing Citra</i>	20
a. <i>Green Channel</i>	20
b. <i>Contrast Limited Adaptive Histogram Equalization (CLAHE)</i>	21
2.3 <i>Klasifikasi Citra</i>	21
2.4 <i>Ensemble Learning</i>	21
2.5 <i>Convolutional Neural Network (CNN)</i>	22
a. <i>Convolutional layer</i>	22
b. <i>Batch Normalization</i>	25
c. <i>Fungsi Aktivasi</i>	26
d. <i>Max Pooling Layer</i>	27
e. <i>Concatenate Layer</i>	29
f. <i>Loss Function</i>	29
g. <i>Depthwise Separable Convolution</i>	29
2.6 <i>MobileNet</i>	31
2.7 <i>ResNet-50</i>	32

2.8	<i>EfficientNet</i>	32
2.9	<i>Weighted Voting</i>	33
2.10	<i>Confusion Matrix</i>	34
BAB III		37
3.	Testing Data.....	42
BAB IV		44
4.1.	Deskripsi Data.....	44
4.2.	Klasifikasi Citra	45
4.	Depthwise separable convolution.....	49
5.	ReLU	50
6.	Fungsi Aktivasi Sigmoid	51
7.	Batch Normalization.....	51
8.	Max Pooling	55
9.	Concatenate	56
10.	Average Pooling.....	57
11.	Global Average Pooling.....	59
12.	Softmax	59
13.	Weighted Voting.....	60
14.	Loss Function Binary Cross Entropy	61
4.3.	Proses Klasifikasi	62
4.4.	Analisis dan Hasil	93
BAB V		97
DAFTAR PUSTAKA		99

DAFTAR TABEL

Tabel 2.1 <i>Confusion Matrix</i>	18
Tabel 2.2 Kategori Kinerja	19
Tabel 4.1 Sampel Data <i>Training</i> (EyePACS) dan Data <i>Testing</i> (APTOS)	28
Tabel 4.2 Hasil <i>Confusion Matrix</i> Arsitektur <i>MobileNet</i>	32
Tabel 4.3 Hasil <i>Confusion Matrix</i> Arsitektur <i>ResNet-50</i>	36
Tabel 4.4 Hasil <i>Confusion Matrix</i> Arsitektur <i>EfficientNet</i>	43
Tabel 4.5 Hasil <i>Confusion Matrix Ensemble Learning</i>	46
Tabel 4.6 Perbandingan Hasil Klasifikasi Setiap Model	47
Tabel 4.7 Perbandingan Hasil Klasifikasi dengan Penelitian Lain	47

DAFTAR GAMBAR

Gambar 2.1 Ilustrasi Proses Konvolusi.....	8
Gambar 2.2 Fungsi Aktivasi <i>ReLU</i>	11
Gambar 2.3 Fungsi Aktivasi <i>Sigmoid</i>	12
Gambar 2.4 Fungsi Aktivasi <i>Softmax</i>	12

Gambar 2.5 Ilustrasi <i>Max Pooling</i>	13
Gambar 2.6 Ilustrasi <i>Depthwise Separable Convolution</i>	14
Gambar 2.7 Arsitektur <i>MobileNet</i>	15
Gambar 2.8 Arsitektur <i>ResNet-50</i>	16
Gambar 2.9 Arsitektur <i>EfficientNet</i>	17
Gambar 4.1 Arsitektur <i>MobileNet</i> yang diusulkan	29
Gambar 4.2 Grafik nilai akurasi pada proses <i>training</i> model <i>MobileNet</i>	30
Gambar 4.3 Grafik nilai <i>loss</i> pada proses <i>training</i> model <i>MobileNet</i>	31
Gambar 4.4 Arsitektur <i>ResNet-50</i> yang diusulkan.....	32
Gambar 4.5 Ilustrasi <i>ConvBlock</i>	33
Gambar 4.6 Ilustrasi <i>Identity Block</i>	33
Gambar 4.7 Grafik nilai akurasi pada proses <i>training</i> model <i>ResNet-50</i>	35
Gambar 4.8 Grafik nilai <i>loss</i> pada proses <i>training</i> model <i>ResNet-50</i>	36
Gambar 4.9 Arsitektur <i>EfficientNet</i> yang diusulkan	37
Gambar 4.10 Ilustrasi <i>first module</i>	38
Gambar 4.11 Ilustrasi <i>Module 1</i>	38
Gambar 4.12 Ilustrasi <i>Module 3</i>	38
Gambar 4.13 Ilustrasi <i>Module 4</i>	39
Gambar 4.14 Ilustrasi <i>Module 5</i>	39
Gambar 4.15 Ilustrasi <i>Module 2</i>	39
Gambar 4.16 Grafik nilai akurasi pada proses <i>training</i> model <i>EfficientNet</i>	41
Gambar 4.17 Grafik nilai <i>loss</i> pada proses <i>training</i> model <i>EfficientNet</i>	42

Gambar 4.18 Arsitektur <i>ensemble learning</i> yang diusulkan.....	44
Gambar 4.19 Grafik nilai akurasi pada proses <i>training</i> model <i>ensemble learning</i>	44
Gambar 4.20 Grafik nilai <i>loss</i> pada proses <i>training</i> model <i>ensemble learning</i>	45

BAB I

PENDAHULUAN

1.1 Latar Belakang

Penyakit *Diabetic Rethinopathy* (DR) merupakan penyakit diabetes yang memengaruhi retina mata. Penyakit DR dapat diidentifikasi melalui citra retina mata (Kwasigroch, Jarzembinski and Grochowski, 2018). Metode berbasis *deep learning* telah digunakan untuk klasifikasi citra di berbagai bidang terutama dalam mengidentifikasi penyakit DR pada citra retina (Erdem *et al.*, 2020). Salah satu metode berbasis *deep learning* yang mampu untuk mengatasi permasalahan ini adalah *Convolutional Neural Network* (CNN). CNN terdiri dari *convolutional layer* dan *pooling layer* yang saling terhubung satu sama lain sehingga dapat melakukan ekstraksi fitur dan pengenalan objek pada citra (Erdem *et al.*, 2020). Pada beberapa kasus, penggunaan CNN untuk melatih bobot jaringan dari awal membutuhkan waktu yang lama dan kumpulan data yang besar. Penggunaan arsitektur CNN menjadi solusi untuk mempercepat kinerja klasifikasi sehingga proses penentuan penyakit DR menjadi lebih efisien (Kandel and Castelli, 2020).

Salah satu permasalahan yang terjadi ketika CNN melatih jaringannya adalah *gradien* yang menghilang sehingga jaringan menjadi mati ketika sedang melatih datanya (Kilic *et al.*, 2020). Permasalahan *gradien* yang meledak dapat diatasi dengan menerapkan arsitektur *Residual Network-50* (*ResNet-50*). *ResNet-50* dapat mengatasi permasalahan *gradien* yang menghilang selama proses *training* data (Shehab *et al.*, 2020). Penelitian DR yang menggunakan arsitektur *ResNet-50* telah

banyak dilakukan, diantaranya oleh *Heisler et al.* (2020) yang menerapkan arsitektur *ResNet-50* pada dataset OCTA dengan nilai akurasi dan spesifisitas yang diperoleh sebesar 90,71% dan 87,74%. Selain itu, *Qummar et al.* (2019) menerapkan arsitektur *ResNet-50* pada dataset EyePACS dengan nilai akurasi dan spesifisitas yang diperoleh sebesar 80,8% dan 86,72%. *Jinfeng et al.* (2020) juga menerapkan arsitektur *ResNet-50* pada dataset EyePACS dengan nilai akurasi dan spesifisitas yang diperoleh sebesar 77,28% dan 84,8%. *ResNet-50* menggunakan jaringan *residual* untuk mengatasi permasalahan gradien yang menghilang, namun jaringan residual memiliki kelemahan yaitu dapat menurunkan kinerja pembelajaran arsitektur (*Elsawah et al.*, 2020).

Permasalahan lain yang sering terjadi pada CNN dalam melatih jaringannya adalah kualitas dataset yang masih rendah (*Pan et al.*, 2020). Salah satu arsitektur CNN yang dapat melakukan ekstraksi fitur pada dataset berkualitas rendah adalah *Mobile Neural Network (MobileNet)* (*Wang et al.*, 2020). *MobileNet* memiliki struktur yang lebih kecil, perhitungan yang lebih sedikit, dan dapat melakukan ekstraksi fitur dengan menerapkan *depthwise separable convolutions* sehingga dapat menjaga keseimbangan antara efisiensi dan akurasi (*Wang et al.*, 2020). *Srinivasu et al.* (2021) menerapkan *MobileNet* untuk klasifikasi penyakit kulit dengan memperoleh nilai akurasi sebesar 85,34%. Penelitian lain juga dilakukan oleh *Souid et al.* (2021) yang melakukan klasifikasi penyakit paru-paru dengan menerapkan arsitektur *MobileNet* sehingga memperoleh nilai akurasi 90,2% namun nilai sensitivitas dan *F1-Score* yang diperoleh masih rendah yaitu sebesar 45,3%

dan 55,6%. Sedikitnya parameter yang dimiliki *MobileNet* menyebabkan beberapa fitur bagian pada dataset tidak dipelajari (Suriyal *et al.*, 2018). Hasil klasifikasi citra seringkali ditentukan hanya dari bagian tertentu pada citra dan keberadaan fitur yang tidak terlalu penting pada citra seringkali membingungkan algoritma dalam melakukan klasifikasi (Alhichri *et al.*, 2021).

Permasalahan hasil klasifikasi yang tidak optimal dapat diatasi dengan menyederhanakan CNN dalam melakukan klasifikasi citra sehingga arsitektur *Efficient Network (EfficientNet)* sangat relevan untuk diterapkan. *EfficientNet* bekerja dengan menggunakan koefisien gabungan yang sederhana dan efisien untuk menskalakan semua dimensi kedalaman, lebar, dan resolusi secara seragam sehingga dapat digunakan untuk melakukan ekstraksi fitur (Wang *et al.*, 2020). Beberapa penelitian telah menerapkan arsitektur *EfficientNet* untuk melakukan proses klasifikasi DR diantaranya Liu *et al.* (2020) dengan menggunakan dataset EyePACS dan APTOS memperoleh nilai akurasi sebesar 85,44%. Momeni Pour *et al.* (2020) juga menerapkan arsitektur *EfficientNet* untuk melakukan klasifikasi DR pada dataset Messidor dan IDRiD dengan nilai akurasi dan sensitivitas yang diperoleh sebesar 94,5% dan 92%. *EfficientNet* memiliki kekurangan pada kompleksitas jaringan yang tinggi dan dapat menyebabkan terjadinya *overfitting* pada hasil pelatihan arsitektur (Wang *et al.*, 2020; Lawrence and Zhang, 2019).

Kemampuan yang dimiliki oleh masing-masing arsitektur dapat diterapkan dengan menggunakan metode *ensemble learning*. *Ensemble learning* merupakan proses penggabungan nilai *output* dari beberapa model klasifikasi menjadi satu

model prediktif (Qummar *et al.*, 2019). *Ensemble learning* mampu menghasilkan model prediksi yang lebih baik daripada metode klasifikasi tunggal. Salah satu metode *ensemble learning* yang paling umum digunakan adalah teknik *weighted voting*. *Weighted voting* bekerja dengan memilih suara terbanyak dari prediksi akhir yang dihasilkan oleh masing-masing metode klasifikasi (Deepa *et al.*, 2021). Beberapa penelitian yang menggunakan *ensemble learning* diantaranya Antal and Hajdu (2014) yang menggunakan *forward and backward search* menghasilkan nilai akurasi sebesar 87%, sensitifitas sebesar 90%, dan *Cohen Kappa* sebesar 0,89. Jiang *et al.* (2019) menggunakan metode *Ensemble learning* dengan arsitektur *InceptionV3*, *InceptionResNetV2*, dan *ResNet152* menghasilkan nilai akurasi sebesar 88,21%, spesitifitas 85,57%, dan sensitivitas 88,41%. Saleh *et al.*, (2018) menggunakan *fuzzy random forest and dominance-based rough set* menghasilkan nilai akurasi sebesar 80,05%, spesifisitas 79,58%, dan sensitivitas 81,78%.

Berdasarkan kelebihan dan kekurangan dari masing-masing arsitektur serta kemampuan yang dimiliki oleh *ensemble learning*, maka pada penelitian ini akan menerapkan metode *ensemble learning* pada hasil kinerja dari arsitektur *ResNet-50*, *MobileNet*, dan *EfficientNet* dengan pengambilan keputusan menggunakan teknik *wighted voting*. Hasil evaluasi kinerja arsitektur dapat diukur berdasarkan nilai akurasi, sensitifitas, spesifisitas, *F1-Score*, dan *Cohens Kappa*.

1.2 Rumusan Masalah

Rumusan masalah dari penelitian ini adalah bagaimana penerapan metode *ensemble learning* pada hasil kinerja dari arsitektur *ResNet-50*, *MobileNet*, dan *EfficientNet* dalam penentuan penyakit DR berdasarkan nilai akurasi, sensitifitas, spesifisitas, *F1-Score*, dan *Cohens Kappa*.

1.3 Batasan Masalah

Batasan masalah dalam penelitian ini adalah :

- a. Penelitian ini hanya melakukan klasifikasi DR menggunakan citra retina yang terdiri dari 2 kelas yaitu normal dan DR.
- b. Penelitian ini tidak membahas perbaikan citra dan segmentasi citra.
- c. Kriteria penilaian yang dilakukan dalam klasifikasi DR berdasarkan nilai akurasi, sensitifitas, spesifisitas, *F1-Score*, dan *Cohens Kappa*.

1.4 Tujuan

Tujuan dari penelitian ini adalah menerapkan metode *ensemble learning* untuk meningkatkan hasil kinerja dari arsitektur *ResNet-50*, *MobileNet*, dan *EfficientNet* dalam penentuan penyakit DR pada retina berdasarkan nilai akurasi, sensitifitas, spesifisitas, *F1-Score*, dan *Cohens Kappa*.

1.5 Manfaat

Manfaat dari hasil penelitian ini sebagai berikut :

- a. Memperoleh hasil yang cepat dan tepat dalam menentukan penyakit DR pada retina dengan menerapkan metode *ensemble learning* (*ResNet-50*, *MobileNet*, dan *EfficientNet*).
- b. Dapat digunakan sebagai rujukan untuk melakukan penelitian terkait klasifikasi citra retina

DAFTAR PUSTAKA

- Albawi, S., Mohammed, T. A. M. and Alzawi, S. (2017) 'Understanding of a Convolutional Neural Network', *International Conference on Engineering and Technology, ICET 2017*, pp. 1–6. doi: 10.1109/ICEngTechnol.2017.8308186.
- Alhichri, H. *et al.* (2021) 'Classification of Remote Sensing Images Using EfficientNet-B3 CNN Model with Attention', *IEEE Access*, 9, pp. 14078–14094. doi: 10.1109/ACCESS.2021.3051085.
- Antal, B. and Hajdu, A. (2014) 'An ensemble-based system for automatic screening of diabetic retinopathy', *Knowledge-Based Systems*, 60(January), pp. 20–27. doi: 10.1016/j.knosys.2013.12.023.
- Bharati, S. *et al.* (2020) *Comparative Performance Analysis of Different Classification Algorithm for the Purpose of Prediction of Lung Cancer, Advances in Intelligent Systems and Computing*. Springer International Publishing. doi: 10.1007/978-3-030-16660-1_44.
- Chicco, D., Warrens, M. J. and Jurman, G. (2021) 'The Matthews Correlation Coefficient (MCC) is More Informative Than Cohen's Kappa and Brier Score in Binary Classification Assessment', *IEEE Access*, 9, pp. 78368–78381. doi: 10.1109/ACCESS.2021.3084050.
- da Costa, R. F. *et al.* (2019) 'A Brief Didactic Theoretical Review on Convolutional Neural Networks, Deep Belief Networks and Stacked Auto-Encoders', *International Journal of Engineering and Technical Research (IJETR)*, 9(12). doi: 10.31873/ijetr.9.12.35.
- Deepa, V., Kumar, C. S. and Cherian, T. (2021) 'Ensemble of Multi-Stage Deep Convolutional Neural Networks for Automated Grading of Diabetic Retinopathy using Image Patches', *Journal of King Saud University - Computer and Information Sciences*. The Authors, pp. 1–11. doi: 10.1016/j.jksuci.2021.05.009.
- Desiani, A. *et al.* (2021) 'Variasi Thresholding untuk Segmentasi Pembuluh Darah Citra Retina', *Jurnal Edukasi dan Penelitian Informatika*, 7(2), pp. 255–262. doi: <http://dx.doi.org/10.26418/jp.v7i2.47205>.
- Elsawah, D. K., Elnakib, A. A. and El-Din Moustafa, H. (2020) 'Automated Diabetic Retinopathy Grading using Resnet', *National Radio Science Conference, NRSC, Proceedings, 2020-Septe(Nrsc)*, pp. 248–254. doi: 10.1109/NRSC49500.2020.9235098.

- Erdem, D., Beke, A. and Kumbasar, T. (2020) ‘A Deep Learning-Based Pipeline for Teaching Control Theory : Transforming Feedback Control Systems on Whiteboard Into MATLAB’, *IEEE Access*, 8, pp. 84631–84641. doi: 10.1109/ACCESS.2020.2992614.
- Guo, Y. *et al.* (2019) ‘Depthwise convolution is all you need for learning multiple visual domains’, *33rd AAAI Conference on Artificial Intelligence, AAAI 2019, 31st Innovative Applications of Artificial Intelligence Conference, IAAI 2019 and the 9th AAAI Symposium on Educational Advances in Artificial Intelligence, EAAI 2019*, pp. 8368–8375. doi: 10.1609/aaai.v33i01.33018368.
- 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>.
- Hattiya, T., Dittakan, K. and Musikasuwan, S. (2021) ‘Diabetic Retinopathy Detection Using Convolutional Neural Network: A Comparative Study on Different Architectures’, *MAHASARAKHAM INTERNATIONAL JOURNAL OF ENGINEERING TECHNOLOGY*, 70(1). doi: 10.1007/978-981-15-5309-7_13.
- He, K. *et al.* (2016) ‘Deep Residual Learning for Image Recognition’, in *Proc. of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR2016)*, pp. 770–778. doi: 10.1002/chin.200650130.
- Heisler, M. *et al.* (2020) ‘Ensemble Deep Learning for Diabetic Retinopathy Detection Using Optical Coherence Tomography Angiography’, *Translational Vision Science & Technology*, 9(2), pp. 1–11. doi: <https://doi.org/10.1167/tvst.9.2.20>.
- Howard, A. G. *et al.* (2017) ‘MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications’.
- Islam, M. M. *et al.* (2020) ‘Artificial Intelligence in Ophthalmology: A Meta-Analysis of Deep Learning Models for Retinal Vessels Segmentation’, *Journal of Clinical Medicine*, 9(4), p. 1018. doi: 10.3390/jcm9041018.
- Jadon, S. (2020) ‘A survey of loss functions for semantic segmentation’, *2020 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology, CIBCB 2020*. doi: 10.1109/CIBCB48159.2020.9277638.
- 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.
- Jinfeng, G. *et al.* (2020) ‘Ensemble Framework of Deep CNNs for Diabetic

- Retinopathy Detection’, *Computational Intelligence and Neuroscience*, 2020, pp. 1–11. doi: 10.1155/2020/8864698.
- Kandel, I. and Castelli, M. (2020) ‘Transfer Learning with Convolutional Neural Networks for Diabetic Retinopathy Image Classification. A Review’, *Applied Sciences*, 10(6), pp. 1–24. doi: 10.3390/app10062021.
- Kassani, S. H. *et al.* (2019) ‘Diabetic Retinopathy Classification Using a Modified Xception Architecture’, *2019 IEEE 19th International Symposium on Signal Processing and Information Technology, ISSPIT 2019*, pp. 0–5. doi: 10.1109/ISSPIT47144.2019.9001846.
- Khan, A. *et al.* (2020) ‘A survey of the recent architectures of deep convolutional neural networks’, *Artificial Intelligence Review*. Springer Netherlands, 53(8), pp. 5455–5516. doi: 10.1007/s10462-020-09825-6.
- Kilic, S., Askerzade, I. and Kaya, Y. (2020) ‘Using ResNet Transfer Deep Learning Methods in Person Identification According to Physical Actions’, *IEEE Access*, 8, pp. 220364–220373. doi: 10.1109/ACCESS.2020.3040649.
- 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., Jarzembinski, 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 2018*. IEEE, pp. 111–116. doi: 10.1109/IIPHDW.2018.8388337.
- Lawrence, T. and Zhang, L. (2019) ‘IoTNet: An efficient and accurate convolutional neural network for IoT devices’, *Sensors (Switzerland)*, 19(24). doi: 10.3390/s19245541.
- Li, Q. *et al.* (2014) ‘Medical image classification with convolutional neural network’, *2014 13th International Conference on Control Automation Robotics and Vision, ICARCV 2014*, 2014(December), pp. 844–848. doi: 10.1109/ICARCV.2014.7064414.
- Li, Q. *et al.* (2018) ‘Tumor Segmentation in Contrast-Enhanced Magnetic Resonance Imaging for Nasopharyngeal Carcinoma: Deep learning with Convolutional Neural Network’, *BioMed Research International*, 2018, pp. 1–8. doi: 10.1155/2018/9128527.
- Liu, H. *et al.* (2020) ‘Hybrid Model Structure for Diabetic Retinopathy Classification’, *Journal of Healthcare Engineering*, 2020, pp. 1–9. doi: 10.1155/2020/8840174.
- Luo, D. and Kamata, S. I. (2020) ‘Diabetic retinopathy grading based on Lesion

- correlation graph’, *2020 Joint 9th International Conference on Informatics, Electronics and Vision and 2020 4th International Conference on Imaging, Vision and Pattern Recognition, ICIEV and icIVPR 2020*. doi: 10.1109/ICIEVicIVPR48672.2020.9306664.
- Mapayi, T., Viriri, S. and Tapamo, J. R. (2015) ‘Comparative study of retinal vessel segmentation based on global thresholding techniques’, *Computational and Mathematical Methods in Medicine*, 2015. doi: 10.1155/2015/895267.
- Marques, G., Agarwal, D. and de la Torre Díez, I. (2020) ‘Automated medical diagnosis of COVID-19 through EfficientNet convolutional neural network’, *Applied Soft Computing Journal*. Elsevier B.V., 96, p. 106691. doi: 10.1016/j.asoc.2020.106691.
- Momeni Pour, A. *et al.* (2020) ‘Automatic Detection and Monitoring of Diabetic Retinopathy using Efficient Convolutional Neural Networks and Contrast Limited Adaptive Histogram Equalization’, *IEEE Access*, 8, pp. 136668–136673. doi: 10.1109/ACCESS.2020.3005044.
- 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/ICCICCT.2014.6993023.
- O’Shea, K. and Nash, R. (2015) ‘An Introduction to Convolutional Neural Networks’, pp. 1–11.
- Pan, H. *et al.* (2020) ‘A New Image Recognition and Classification Method Combining Transfer Learning Algorithm and MobileNet Model for Welding Defects’, *IEEE Access*, 8, pp. 119951–119960. doi: 10.1109/ACCESS.2020.3005450.
- Phiphatphaisit, S. and Surinta, O. (2020) ‘Food Image Classification with Improved MobileNet Architecture and Data Augmentation’, in *ACM International Conference Proceeding Series*, pp. 51–56. doi: 10.1145/3388176.3388179.
- Putra, R. E., Tjandrasa, H. and Suciati, N. (2020) ‘Severity classification of non-proliferative diabetic retinopathy using convolutional support vector machine’, *International Journal of Intelligent Engineering and Systems*, 13(4), pp. 156–170. doi: 10.22266/IJIES2020.0831.14.
- Putra, T. A., Rufaida, S. I. and Leu, J. S. (2020) ‘Enhanced Skin Condition Prediction through Machine Learning Using Dynamic Training and Testing Augmentation’, *IEEE Access*. IEEE, 8, pp. 40536–40546. doi: 10.1109/ACCESS.2020.2976045.
- Qomariah, D. U. N., Tjandrasa, H. and Fatichah, C. (2019) ‘Classification of

- diabetic retinopathy and normal retinal images using CNN and SVM’, *Proceedings of 2019 International Conference on Information and Communication Technology and Systems, ICTS 2019*. IEEE, pp. 152–157. doi: 10.1109/ICTS.2019.8850940.
- 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.
- Sae-Lim, W., Wettayaprasit, W. and Aiyarak, P. (2019) ‘Convolutional Neural Networks Using MobileNet for Skin Lesion Classification’, in *JCSSE 2019 - 16th International Joint Conference on Computer Science and Software Engineering: Knowledge Evolution Towards Singularity of Man-Machine Intelligence*. IEEE, pp. 242–247. doi: 10.1109/JCSSE.2019.8864155.
- Saleh, E. *et al.* (2018) ‘Learning ensemble classifiers for diabetic retinopathy assessment’, *Artificial Intelligence in Medicine*, 85, pp. 50–63. doi: 10.1016/j.artmed.2017.09.006.
- Shehab, L. H. *et al.* (2020) ‘An Efficient Brain Tumor Image Segmentation Based on Deep Residual Networks (ResNets)’, *Journal of King Saud University - Engineering Sciences*. King Saud University, 33(6), pp. 404–412. doi: 10.1016/j.jksues.2020.06.001.
- Soomro, T. A., Afifi, Ahmed J., *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.
- Soomro, T. A., Afifi, Ahmed J, *et al.* (2019) ‘Impact of Image Enhancement Technique on CNN Model for Retinal Blood Vessels Segmentation’, *IEEE Access*, pp. 158183–158197. doi: 10.1109/ACCESS.2019.2950228.
- Soud, A., Sakli, N. and Sakli, H. (2021) ‘Classification and Predictions of Lung Diseases from Chest X-rays Using MobileNet V2’, *Applied Sciences (Switzerland)*, 11(6), pp. 1–16. doi: 10.3390/app11062751.
- Srinivasu, P. N. *et al.* (2021) ‘Classification of Skin Disease Using Deep Learning Neural Networks with MobileNet V2 and LSTM’, *Sensors*, 21(8), pp. 1–27. doi: 10.3390/s21082852.
- Suriyal, S., Druzgalski, C. and Gautam, K. (2018) ‘Mobile assisted diabetic retinopathy detection using deep neural network’, *2018 Global Medical Engineering Physics Exchanges/Pan American Health Care Exchanges, GMEPE/PAHCE 2018*. IEEE, (562), pp. 1–4. doi: 10.1109/GMEPE-PAHCE.2018.8400760.
- Tan, M. and Le, Q. V. (2019) ‘EfficientNet: Rethinking model scaling for convolutional neural networks’, *36th International Conference on Machine*

Learning, ICML 2019, pp. 10691–10700.

- 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, S. *et al.* (2015) ‘Hierarchical retinal blood vessel segmentation based on feature and ensemble learning’, *Neurocomputing*. Elsevier, 149(PB), pp. 708–717. doi: 10.1016/j.neucom.2014.07.059.
- Wang, W. *et al.* (2020) ‘A New Image Classification Approach via Improved MobileNet Models with Local Receptive Field Expansion in Shallow Layers’, *Computational Intelligence and Neuroscience*, 2020, pp. 1–10. doi: 10.1155/2020/8817849.
- Yakura, H. *et al.* (2018) ‘Malware analysis of imaged binary samples by convolutional neural network with attention mechanism’, *CODASPY 2018 - Proceedings of the 8th ACM Conference on Data and Application Security and Privacy*, 2018-Janua(September), pp. 127–134. doi: 10.1145/3176258.3176335.
- Yin, R. *et al.* (2021) ‘VirPreNet: A weighted ensemble convolutional neural network for the virulence prediction of influenza A virus using all eight segments’, *Bioinformatics*, 37(6), pp. 737–743. doi: 10.1093/bioinformatics/btaa901.
- Zhang, Y. J. (2015) ‘Image and graphics: 8th international conference, ICIIG 2015 Tianjin, China, august 13–16, 2015 proceedings, part II’, *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9218, pp. 11–17. doi: 10.1007/978-3-319-21963-9.
- Zubair, M., Kim, J. and Yoon, C. (2016) ‘An automated ECG beat classification system using convolutional neural networks’, in *6th International Conference on IT Convergence and Security, ICITCS 2016*. doi: 10.1109/ICITCS.2016.7740310.

