KLASIFIKASI PENYAKIT *DIABETIC RETINOPATHY*MENGGUNAKAN METODE *ENSEMBLE*PADA ARSITEKTUR *DENSENET*, *MOBILENET* DAN *XCEPTION*

SKRIPSI

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

Oleh: FATHONA NUR MUZAYYADAH 08011381722083



JURUSAN MATEMATIKA FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM UNIVERSITAS SRIWIJAYA

2022

LEMBAR PENGESAHAN

KLASIFIKASI PENYAKIT *DIABETIC RETINOPATHY* MENGGUNAKAN METODE *ENSEMBLE* PADA ARSITEKTUR *DENSENET, MOBILENET*, DAN *XCEPTION*

SKRIPSI

Sebagai Salah Satu Syarat untuk Memperoleh Gelar Sarjana Matematika

Oleh

FATHONA NUR MUZAYYADAH 08011381722083

Palembang, Januari 2021

Pembimbing Utama

Des Alwine Zayanti, M.Si

Pembimbing Kedua

NIP. 197012041998022001

Anita Desiani, M.Kom NIP. 197712112003122002

Mengetahui, Ketua Jurusan Matematika

Drs. Sügandi Yabum. M.M NIR. 19580727-198603 1003

HALAMAN PERSEMBAHAN

Kupersembahkan skripsi ini untuk:
Yang MahaKuasa Allah SubhanahuWaTa'ala
Kedua Orangtuaku Tersayang
Adik-adikku Tercinta
Keluarga Besarku Tersayang
Semua Guru dan Dosenku
Sahabat-Sahabatku Tercinta
Alamamaterku
Motto
"Jika sesuatu ditakdirkan untukmu, sampai kapanpun tidak akan pernah menjadi
milik orang lain"

SURAT PERNYATAAN KEASLIAN KARYA ILMIAH

Yang bertanda tangan dibawah ini:

Nama Mahasiswa : Fathona Nur Muzayyadah

NIM : 08011381722083

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 strata (S1) dari Universitas Sriwijaya maupun perguruan tinggi lain. Semua informasi yang dimuat dalam skripsi ini yang berasal dari penulis lain baik yang dipublikasikan atau tidak telah diberikan penghargaan dengan mengutip nama sumber penulis dengan benar. Semua isi dari skripsi ini sepenuhnya menjadi tanggung jawab saya sebagai penulis.

Demikianlah surat pernyataan ini saya buat dengan sebenarnya.

Palembang, 13 Maret 2022

Penulis

Fathona Nur Muzayyadah NIM.08011381722083 HALAMAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK

KEPENTINGAN AKADEMIS

Sebagai Civitas akademik Universitas Sriwijaya, yang bertanda tangan dibawah

ini:

Nama Mahasiswa : Fathona Nur Muzayyadah

NIM : 08011381722083

Fakultas/Jurusan : MIPA/Matematika

Jenis Karya : Skripsi

Demi pengembangan ilmu pengetahuan, saya menyetujui untuk memberikan

kepada Universitas Sriwijaya "Klasifikasi Penyakit Diabetic Retinopathy

Menggunakan Metode Ensemble Pada Arsitektur Densenet, Mobilenet, Dan

Xception". Dengan hak bebas royalty non-ekslusive 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.

Palembang, 13 Maret 2022

Penulis

Fathona Nur Muzayyadah

NIM.08011381722083

iν

KATA PENGANTAR

Assalamu'alaikum Wr.Wb.

Segala puji dan syukur kehadirat Tuhan Yang Maha Esa atas segala rahmat dan karunia-Nya yang senantiasa dilimpahkan kepada penulis, sehingga dapat menyelesaikan skripsi ini dengan judul "KLASIFIKASI PENYAKIT DIABETIC RETINOPATHY MENGGUNAKAN METODE ENSEMBLE PADA ARSITEKTUR DENSENET, MOBILENET, DAN XCEPTION".

Dengan segala hormat dan kerendahan hati mengucapkan terima kasih yang sedalam-dalamnya kepada Orang Tua, yaitu Bapak **Sudarso** dan Ibu **Yuliati** yang telah merawat, mendidik, menuntun, memberi nasehat, semangat serta doa untuk penulis dengan penuh rasa cinta dan kasih sayang. Penulis juga menyampaikan ucapan terima kasih dan penghargaan kepada:

- 1. Bapak **Drs. Sugandi Yahdin, M.M** selaku Ketua jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya yang telah membimbing dan mengarahkan urusan akademik selama belajar di Jurusan Matematika FMIPA Universitas Sriwijaya.
- 2. Ibu **Dr. Dian Cahyawati Sukanda, M.Si** selaku Sekretaris Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya yang telah membimbing dan mengarahkan urusan akademik selama belajar di Jurusan Matematika FMIPA Universitas Sriwijaya
- 3. Ibu **Anita Desiani, M.Kom** selaku Dosen Pembimbing Utama yang telah bersedia meluangkan waktunya, tenaga, pikiran, semangat untuk

- memberikan bimbingan dan arahan dengan penuh pengertian, perhatian, dan kesabaran sehingga skripsi ini dapat diselesaikan.
- 4. Ibu **Des Alwine Zayanti, M.Si** selaku Dosen Pembimbing Kedua yang telah bersedia meluangkan waktunya, tenaga, pikiran, semangat untuk memberikan bimbingan dan arahan dengan penuh pengertian, perhatian, dan kesabaran sehingga skripsi ini dapat diselesaikan.
- 5. Bapak **Drs. Putra Bahtera Jaya Bangun, M.Si** dan Ibu **Dr. Yuli Andriani, M.Si** selaku Dosen Pembahas dan Penguji yang telah meuangkan waktunya dalam memberikan tanggapan, saran, masukan, dan kritik yang sangat bermanfaat untuk perbaikan dan penyelesaian skripsi ini.
- 6. Seluruh Dosen di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya, dan seluruh pendidik yang telah meluangkan waktunya serta memberikan ilmu yang sangat bermanfaat bagi penulis selama menempuh pendidikan.
- 7. Ibu Hamidah selaku Pegawai tata usaha dan Bapak Irwan selaku admin di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Univeritas Sriwijaya, terima kasih atas bantuannya yang telah diberikan kepada penulis.
- 8. Adikku **Vema Ramadhaniah** dan **Najwa Nur Azizah** atas semangat, support dan kasih sayangnya.

- 9. Sahabatku **Dwita Hudalinnas Titi** yang telah memberikan semangat, dukungan, *support*, ada disaat suka maupun duka, tempat curhat dan mengeluh penulis.
- 10. Teman-temanku dibangku SMA Jumi, Ayu, Nanda, Dia, Fifa, Ais, dan seluruh anggota PASKIBRA 25 (ARSA BADHRIKA) yang telah memberi dukungan, semangat, dan menjadi moodbooster penulis.
- 11. Teman-temanku dibangku SMP **Dewi, Elly, Shintya, Riska, dan Lulu** yang telah memberikan dukungan, semangat, dan selalu ada kalo lagi makan-makan.
- 12. Teman-teman dekatku selama perkuliahan Calista, Zaim, Gibran, Ajeng, Filda, Yogi, April, Ussy, Friska, Depianna, Abu, Rian, Enyta, Annabil, Fretti, Oktanza, Jeje, Olin, Dwi, Monica, Mila, Muflika, Nurul, Emik, Amira, yang telah menjadi *moodbooster* selama perkuliahan, memberi dukungan, semangat serta suka dan duka, bantuan yang banyak dan tempat curhat penulis.
- 13. Tim Bimbingan skripsi **kakak angkatan 16 dan adik angkatan 2018** atas bantuan dan kerjasamanya.
- 14. Keluarga KKN Tematik 2020 Penyandingan (Calista, Ajeng, Anabil, Enyta, Tari, Ojik, Santo, Kahfi, Ipul, Bowo, Udin dan Siddiq) serta Julita atas kebersamaanya selama KKN baik suk maupun duka, dan semangat yang diberikan.

15. Peliharaanku Ibu Bapak Hamster dan anak-anaknya (Poci, Degil,

Gepeng, dan Bibble) serta member Neo Culture Technology yang telah

menjadi moodbooster dikala penulis sedang suntuk.

16. Kakak-kakak tingkat angkatan 2015, 2016, Teman-teman Angkatan 2017

terima kasih atas bantuannya, semangat, dan waktunya selama kuliah dan

adik-adik tingkat angkatan 2018, 2019, 2020.

17. Semua pihak yang tidak dapat penulis sebutkan satu persatu yang telah

memberikan bantuan dalam menyelesaikan skripsi ini. Semoga semua

kebaikan yang telah diberikan kepada penulis mendapatkan balasan dari

Tuhan Yang Maha Esa.

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.

Wassalamu'alaikum Wr. Wb

Indralaya, Desember 2021

Penulis

viii

CLASSIFICATION OF DIABETIC RETINOPATHY USING ENSEMBLE METHOD IN DENSENET, MOBILENET, AND XCEPTION ARCHITECTURE

By:

Fathona Nur Muzayyadah 08011381722083

ABSTRACT

Convolutional neural network (CNN) is a deep learning method that is often used in segmentation and classification and can handle input data in the form of images. The application of CNN is widely used in image data, one of which is the image of Diabetic Retinopathy (DR). Diabetic Retinopathy (DR) is a disease that attacks the retinal blood vessels as a result of prolonged complications of diabetes. The ensemble method has the ability to overcome the weaknesses of each architecture in a single classification (DenseNet, MobileNet, and Xception) by combining the performance results in each single classification. This research applies the ensemble method by combining the performance results on *DenseNet*, MobileNet, and Xception architectures on the DR classification for 2 class problems. The steps taken in this research are data collection, training, testing, and evaluation. The results of this study obtained an accuracy value of 85,22%, sensitivity 70,63%, specificity 99.40%, f1-score 87,21% and cohens kappa 0,7032 using the EyePACS dataset as training data and APTOS as testing data. Based on these results, it can be concluded that the ensemble method works well in classifying DR for 2 class problems, indicated by the accuracy value and f1-score above 85%, specificity value above 90% and quite good with sensitivity value above 70% and cohens kappa value 70,32%. In addition, the proposed ensemble method can overcome the problem of overfitting on a single classification.

Keywords: Diabetic Retinopathy, Ensemble, DenseNet, MobileNet, Xception.

KLASIFIKASI PENYAKIT *DIABETIC RETINOPATHY* MENGGUNAKAN METODE *ENSEMBLE* PADA ARSITEKTUR *DENSENET*, *MOBILENET*, DAN *XCEPTION*

Oleh:

Fathona Nur Muzayyadah 08011381722083

ABSTRAK

Convolutional neural network (CNN) merupakan metode deep learning yang sering digunakan dalam segmentasi maupun klasifikasi dan dapat menangani data input berbentuk citra. Penerapan CNN banyak digunakan pada data citra, salah satunya adalah citra Diabetic Retinopathy (DR). Diabetic Retinopathy (DR) adalah penyakit yang menyerang pembuluh darah retina akibat dari komplikasi penyakit diabetes yang berkepanjangan. Metode ensemble memiliki kemampuan dalam mengatasi kelemahan dari setiap arsitektur pada klasifikasi tunggal (DenseNet, MobileNet, dan Xception) dengan cara menggabungkan hasil kinerja pada setiap klasifikasi tunggal. Penelitian ini menerapkan metode ensemble dengan menggabungkan hasil kinerja pada arsitektur DenseNet, MobileNet, dan Xception pada klasifikasi DR untuk permasalahan 2 kelas. Langkah-langkah yang dilakukan pada penelitian ini yaitu pengumpulan data, pelatihan, pengujian, dan evaluasi. Hasil penelitian tersebut diperoleh nilai akurasi sebesar 85,22%, sensitivitas 70,63%, spesifisitas 99,40%, f1-score 87,21% dan cohens kappa 0,7032 dengan menggunakan dataset EyePACS sebagai data latih dan APTOS sebagai data uji. Berdasarkan hasil tersebut dapat disimpulkan bahwa metode ensemble bekerja dengan baik dalam melakukan klasifikasi DR untuk permasalahan 2 kelas, ditunjukkan oleh nilai akurasi dan f1-score diatas 85%, nilai spesifisitas diatas 90% dan cukup baik dengan nilai sensitivitas diatas 70% dan nilai cohens kappa 70,32%. Selain itu, metode ensemble yang diusulkan dapat mengatasi masalah overfitting pada klasifikasi tunggal.

Kata kunci: Diabetic Retinopathy, Ensemble, DenseNet, MobileNet, Xception

DAFTAR ISI

LEMB	AR]	PENGESAHAN	i
HALA	MAI	N PERSEMBAHAN	ii
PERNY	YAT	AAN KEASLIAN KARYA ILMIAH	iii
HALA	MAI	N PERSETUJUAN PUBLIKASI KARYA ILMIAH	iv
KATA	PEN	NGANTAR	v
ABSTF	RAC	T	ix
DAFTA	AR I	SI	xi
DAFT	AR T	TABEL	xiii
DAFT	AR (GAMBAR	xiv
BAB 1			
1.1		tar Belakang	
1.2	Ru	musan Masalah	4
1.3	Ba	tasan Masalah	5
1.4	Tu	juan	5
1.5	Ma	anfaat	5
BAB II	[6
2.1	Re	tina	6
a.	Per	mbuluh Darah Retina	6
b.	Dic	abetic Retinopathy (DR)	6
2.2	Pre	e-processing Citra	7
a.	Gr	een Channel	7
b.	Co	ntrast Limited Adaptive Histogram Equalization (CLAHE)	7
2.3	Kla	asifikasi	8
2.4	Co	nvolutional Neural Network (CNN)	8
2.4	.1	Convolutional Layer	9
2.4	2	Fungsi Aktivasi	11
2.4	3	Batch Normalization	13
2.4	.4	Pooling Layer	14
2.4	5	Concatenate Layer	17

2.4.6		Loss Function: Binary Cross Entropy	17	
2.4	.7	Depthwise Separable Convolution	18	
2.5	We	righted Voting	20	
2.6	De	nsenly Connected Convolutional Network (DenseNet)	20	
2.7	Mo	bileNet	21	
2.8	Xc	eption	22	
2.9	Me	etode <i>Ensemble</i>	24	
2.10	Co	Confusion matrix24		
BAB II	I		28	
3.1	Te	mpat	28	
3.2	Wa	ıktu	28	
3.3	Ala	at	28	
3.4	Me	etode Penelitian	29	
3.4	.1	Pengumpulan Data	29	
3.4	.2	Proses Pelatihan Data	29	
3.4	.3	Proses Pengujian Data	35	
3.4	.4	Evaluasi	36	
3.5	An	alisis Hasil	36	
BAB IV	/ 		37	
4.2	De	skripsi Data	37	
4.3	Pro	oses Klasifikasi	38	
4.3	.1	DenseNet	38	
4.3	.2	MobileNet	44	
4.3	.3	Xception	51	
4.3	.4	Ensemble	59	
4.4	An	alisis	64	
BAB V	•••••		70	
5.1	Ke	simpulan	70	
5.2	Saı	ran	71	
DAFT A	AR P	PUSTAKA	72	
I AMD	ID A	N 1	79	

DAFTAR TABEL

Tabel 2. 1 Tabel Confusion matrix	25
Tabel 2. 2 Kategori nilai evaluasi untuk kualitas kinerja model	26
Tabel 4. 1 Contoh citra pada data latih EyePACS dan data uji APTOS	38
Tabel 4. 2 Tabel <i>confusion matrix</i> pada tahap pelatihan <i>DenseNet</i>	43
Tabel 4. 3 Hasil <i>confusion matrix</i> tahap pengujian <i>DenseNet</i>	44
Tabel 4. 4 Hasil <i>confusion matrix</i> tahap pelatihan <i>MobileNet</i>	49
Tabel 4. 5 Hasil <i>confusion matrix</i> tahap pengujian <i>MobileNet</i>	50
Tabel 4. 6 Hasil <i>confusion matrix</i> tahap pelatihan <i>Xception</i>	
Tabel 4. 7 Hasil <i>confusion matrix</i> tahap pengujian <i>Xception</i>	
Tabel 4. 8 Hasil <i>confusion matrix</i> pada tahap pelatihan <i>ensemble</i>	
Tabel 4. 9 Hasil <i>confusion matrix</i> tahap pengujian <i>ensemble</i>	
Tabel 4. 10 Hasil perbandingan kinerja antara klasifikasi tunggal dan <i>multicla</i>	
Tabel 4. 11 Perbandingan metode yang diusulkan dengan peneliti lain	

DAFTAR GAMBAR

Gambar 2.1 Retina yang terkena DR	7
Gambar 2. 2 Ilustrasi Convolutional Layer	9
Gambar 2. 3 Grafik fungsi Aktivasi ReLU	
Gambar 2. 4 Grafik fungsi aktivasi sigmoid	12
Gambar 2. 5 Ilustrasi max pooling	
Gambar 2. 6 Ilustrasi average pooling	
Gambar 2. 7 Ilustrasi global average pooling	17
Gambar 2. 8 Komponen layer pada depthwise separable convolution	19
Gambar 2. 9 Ilustrasi dense block	
Gambar 2. 10 Ilustrasi arsitektur <i>MobileNet</i>	
Gambar 2. 11 Ilustrasi arsitektur <i>Xception</i>	
Gambar 4. 1 Proses pelatihan data pada DenseNet	39
Gambar 4. 2 Hasil proses pelatihan pada <i>DenseNet</i>	
Gambar 4. 3 Proses pelatihan data pada MobileNet	45
Gambar 4. 4 Hasil proses pelatihan pada <i>MobileNet</i>	
Gambar 4. 5 Grafik akurasi pada proses pelatihan MobileNet	48
Gambar 4. 6 Grafik loss pada proses pelatihan MobileNet	49
Gambar 4. 7 Proses pelatihan data pada <i>Xception</i>	52
Gambar 4. 8 Hasil proses pelatihan pada <i>Xception</i>	55
Gambar 4.9 Grafik akurasi pada proses pelatihan <i>Xception</i>	56
Gambar 4. 10 Grafik loss pada proses pelatihan <i>Xception</i>	57
Gambar 4. 11 Proses pelatihan pada model ensemble	59
Gambar 4. 12 Hasil proses pelatihan pada ensemble	60
Gambar 4. 13 Grafik akurasi pada proses pelatihan model ensemble	61
Gambar 4. 14 Grafik loss pada proses pelatihan model ensemble	62

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Convolutional neural network (CNN) merupakan metode deep learning yang sering digunakan baik dalam segmentasi maupun klasifikasi (Islam et al., 2018). CNN memiliki kelebihan yaitu dapat menangani data input berbentuk citra berukuran $m \times n$ (Haque and Neubert, 2020). Penerapan CNN banyak digunakan pada data citra, salah satunya adalah citra Diabetic Retinopathy (DR) (Wu et al., 2019). DR merupakan penyakit yang menyerang retina mata akibat komplikasi penyakit diabetes yang berkepanjangan dan tidak diobati sehingga menyebabkan kebutaan (Kaur and Mann, 2020). Pemeriksaan citra DR umumnya dilakukan secara manual sehingga memakan waktu yang relatif lama dan dibutuhkan ketelitian yang tinggi (Salamat et al., 2019). Berdasarkan hal tersebut para peneliti melakukan suatu sistem otomatis untuk mendeteksi DR agar dapat diidentifikasi secara cepat dan akurat (Salamat et al., 2019). Beberapa penelitian menggunakan CNN pada klasifikasi DR diantaranya Pratt et al. (2016) dan Xu et al. (2017) memakai dataset Kaggle serta Doshi et al. (2017) dan Ghosh et al. (2017) memakai dataset EyePACS.

CNN berkembang dengan berbagai macam arsitektur diantaranya *MobileNet*, *DenseNet*, dan *Xception*. *MobileNet* merupakan salah satu arsitektur CNN yang memiliki ukuran model yang ringan dan parameter yang kecil. *MobileNet* menggunakan *depthwise separable convolution* yang memisahkan konvolusi biasa

terdiri dari depthwise dan pointwise sehingga arsitektur ini memiliki jumlah parameter yang kecil (Sae-Lim et al., 2019). Namun MobileNet rentan overfitting karena fitur yang ditangkap lebih sedikit, sehingga hasilnya kurang akurat (Howard et al., 2017; Gao et al., 2019). Gao et al. (2019) menggunakan MobileNet pada klasifikasi DR memakai dataset Messidor mendapatkan akurasi dan AUC diatas 90%. Sae-Lim et al. (2019) menggunakan MobileNet melakukan klasifikasi lesi kulit pada dataset Human Againts Machine mendapatkan nilai akurasi, sensitivitas, spesifisitas dan fl-score diatas 80%. Souid et al. (2021) melakukan klasifikasi penyakit paru-paru pada dataset Chest X-Ray mendapatkan nilai akurasi dan spesifisitas diatas 90% sedangkan sensitivitas dan fl-score dibawah 60%.

Arsitektur CNN lainnya yang dapat menangkap fitur lebih baik adalah Densely Connected Convolutional Network (DenseNet). DenseNet merupakan arsitektur yang memiliki koneksi langsung dari setiap lapisan ke semua lapisan berikutnya, sehingga dapat meningkatkan penggunaan fitur yang akan dipakai untuk lapisan selanjutnya (Wu et al., 2019; Zhong et al., 2020; Kandel and Castelli, 2021). Sayangnya DenseNet dapat menurunkan efisiensi komputasi karena meningkatnya jumlah fitur disetiap lapisan dan parameternya yang besar (Huang et al., 2017; Khan et al., 2020). Penelitian Albahli et al. (2021) melakukan klasifikasi DR memakai dataset Kaggle menghasilkan nilai akurasi sebesar 97.20%. Mishra et al. (2020) melakukan klasifikasi DR memakai dataset APTOS menghasilkan nilai akurasi 96%. Hasan et al. (2021) melakukan klasifikasi COVID-19 memakai dataset dari Rumah Sakit Sao Paulo Brazil menghasilkan

nilai akurasi sebesar 92%. Namun ketiga penelitian tersebut hanya mengukur kinerja akurasi saja.

Berbeda dengan DenseNet, arsitektur Xception merupakan metode CNN yang dapat meningkatkan efisiensi pada proses komputasi. Xception juga memiliki depthwise separable convolution seperti pada arsitektur MobileNet, tetapi arsitektur ini memiliki koneksi residual dalam arsitekturnya. Arsitektur Xception memiliki parameter yang kecil dan efisien secara komputasi (Liu et al., 2020; Kandel and Castelli, 2021). Kelemahan *Xception* yaitu membutuhkan data yang banyak untuk dapat melatih semua parameternya (Kandel and Castelli, 2021). Kassani et al. (2019) melakukan klasifikasi DR memakai dataset APTOS sebanyak 3662 data menghasilkan nilai akurasi, sensitivitas dan spesifisitas diatas 80%. Chollet (2017) dalam mengklasifikasikan DR memakai dataset JFT mendapatkan 94.5% sebanyak 16000 akurasi sebesar tidak memepertimbangkan ukuran kinerja yang lain.

Setiap arsitektur memiliki kelemahan dan keunggulan masing-masing, salah satu metode yang dapat mengambil keunggulan dari arsitektur yaitu metode ensemble. Metode ensemble menggabungkan hasil kinerja dari beberapa metode klasifikasi tunggal untuk meningkatkan nilai kinerja pada klasifikasi (Lee et al., 2018). Adapun beberapa penelitian yang menggunakan metode ensemble dalam mengklasifikasikan DR diantaranya Jiang et al. (2019) menerapkan metode ensemble menggunakan arsitektur InceptionV3, InceptionResNetV2, dan ResNet152 dengan akurasi yang naik sebesar 1,11% dari rata-rata akurasi sebelumnya menjadi 88.21%. Jinfeng et al. (2020) menerapkan metode ensemble

pada arsitektur *DenseNet*121, *ResNet*50, dan *InceptionV3* dengan akurasi yang naik sebesar 5,37% dari rata-rata akurasi sebelumnya menjadi 80,36%. Nguyen *et al.* (2020) menerapkan metode *ensemble* dengan arsitektur VGG-16 dan VGG-19 dengan akurasi, sensitivitas dan spesifisitas diatas 80%. Hagos and Kant (2019) menerapkan metode *ensemble* pada arsitektur *Inception V3* dan QIY model menghasilkan akurasi 90%.

Metode *ensemble* memiliki beberapa teknik dalam pengambilan keputusan prediksi yaitu *bagging, stacking, boosting,* dan *voting* (Polikar, 2012). Teknik pengambilan keputusan yang paling sederhana adalah *voting* (Wardoyo \DOPU*et al.*, 2020). Salah satu teknik *voting* yang sering dipakai adalah *weighted voting* (Ko *et al.*, 2019). Teknik ini menggunakan bobot hasil dari tiap arsitektur untuk menentukan hasil prediksi label.

Berdasarkan kelebihan dari masing-masing arsitektur, maka pada tugas akhir ini akan menerapkan metode *ensemble* pada hasil kinerja dari proses latih dari arsitektur *DenseNet*, *MobileNet* dan *Xception* dengan pengambilan keputusan menggunakan teknik *weighted voting*. Evaluasi hasil kinerja dilihat berdasarkan nilai akurasi, sensitivitas, spesifisitas, *fl-score*, dan *cohens kappa*.

1.2 Rumusan Masalah

Rumusan masalah dalam penelitian ini adalah bagaimana menerapkan metode *ensemble* untuk meningkatkan hasil kinerja dari arsitektur *DenseNet*, *MobileNet*, dan *Xception* pada klasifikasi penyakit DR dengan mengukur hasil kinerja berdasarkan akurasi, sensitivitas, spesifisitas, *f1-score* dan *cohens kappa*.

1.3 Batasan Masalah

Batasan masalah dalam penelitian ini adalah sebagai berikut:

- Penelitian ini hanya akan membahas klasifikasi penyakit DR yang terdiri dari 2 kelas yaitu normal dan DR tanpa membahas proses perbaikan citra dan segmentasi pada citra.
- 2. Dibatasi hanya menggunakan teknik *weighted voting* dalam mengambil keputusan berdasarkan pembobotan.
- 3. Evaluasi kinerja model untuk klasifikasi hanya akan mengukur kinerja akurasi, sensitivitas, spesifisitas, *f1-score* dan *cohens kappa*.

1.4 Tujuan

Tujuan dari penelitian ini adalah menerapkan metode *ensemble* untuk meningkatkan hasil kinerja dari arsitektur *DenseNet*, *MobileNet*, dan *Xception* pada klasifikasi penyakit DR dengan mengukur hasil kinerja berdasarkan akurasi, sensitivitas, spesifisitas, *f1-score* dan *cohens kappa*.

1.5 Manfaat

Manfaat dari penelitian ini adalah sebagai berikut:

- Penelitian ini diharapkan bisa menjadi referensi peneliti lain terkait penerapan klasifikasi penyakit DR.
- Dapat membantu para dokter dan tenaga medis untuk mendeteksi penyakit
 DR stadium awal yang efisien dan akurat.

DAFTAR PUSTAKA

- Albahli, S. *et al.* (2021) 'Recognition and Detection of Diabetic Retinopathy using Densenet-65 Based Faster-RCNN', *Computers, Materials and Continua*, 67(2), pp. 1333–1351. doi: 10.32604/cmc.2021.014691.
- Albawi, S., et al. (2017) 'Understanding of a Convolutional Neural Network', International Conference on Engineering and Technology, ICET 2017, pp. 1–6. doi: 10.1109/ICEngTechnol.2017.8308186.
- Banga, D. and Waiganjo, P. (2019) 'Abnormality Detection in Musculoskeletal Radiographs with Convolutional Neural Networks(Ensembles) and Performance Optimization', (August). Available at: http://arxiv.org/abs/1908.02170.
- Brinker, T. J. *et al.* (2019) 'Enhanced Classifier Training to Improve Precision of a Convolutional Neural Network to Identify Images of Skin Lesions', *PLoS ONE*, 14(6), pp. 1–8. doi: 10.1371/journal.pone.0218713.
- Cai, Z. and Vasconcelos, N. (2018) 'Cascade R-CNN: Delving into High Quality Object Detection', *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 6154–6162. doi: 10.1109/CVPR.2018.00644.
- Cardarilli, G. C. *et al.* (2021) 'A Pseudo -Softmax Function for Hardware-Based High Speed Image Classification', *Scientific Reports*, 11(1), pp. 1–10. doi: 10.1038/s41598-021-94691-7.
- Chen, H., et al. (2020) 'Learning Robust Scene Classification Model with Data Augmentation Based on Xception', *Journal of Physics: Conference Series*, 1575(1). doi: 10.1088/1742-6596/1575/1/012009.
- Chen, W. *et al.* (2018) 'A Novel Model Based on AdaBoost and Deep CNN for Vehicle Classification', *IEEE Access*, 6, pp. 60445–60455. doi: 10.1109/ACCESS.2018.2875525.
- Chicco, D., *et al.* (2021) 'The Matthews Correlation Coefficient (MCC) is More Informative Than Cohen's Kappa and Brier Score in Binary Classification Assessment', *IEEE Access*, 9(Mcc), pp. 78368–78381. doi: 10.1109/ACCESS.2021.3084050.
- Chollet, F. (2017) 'Xception: Deep Learning with Depthwise Separable Convolutions', in Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 1800–1807. doi: 10.4271/2014-01-0975.
- Dash, J. and Bhoi, N. (2017) 'Detection of Retinal Blood Vessels from Ophthalmoscope Images using Morphological Approach', *Electronic Letters on Computer Vision and Image Analysis*, 16(1), pp. 1–14. doi: 10.5565/rev/elcvia.913.

- Deng, X. *et al.* (2016) 'An Improved Method to Construct Basic Probability Assignment Based on the Confusion Matrix for Classification Problem', *Information Sciences*, 340–341, pp. 250–261. doi: 10.1016/j.ins.2016.01.033.
- Desiani, A., et al. (2021) 'Bi path Architecture of CNN Segmentation and Classification Method for Cervical Cancer Disorders Based on Pap smear Images', *IAENG International Journal of Computer Science*, 48(3), p. 37.
- Desiani, A., et al. (2021) 'Variasi Thresholding untuk Segmentasi Pembuluh Darah Citra Retina', Jurnal Edukasi dan Penelitian Informatika, 7(2), pp. 255–262.
- Doshi, D. et al. (2017) 'Diabetic Retinopathy Detection using Deep Convolutional Neural Networks', International Conference on Computing, Analytics and Security Trends, CAST 2016, pp. 261–265.
- Dutta, S. *et al.* (2018) 'Classification of Diabetic Retinopathy Images by Using Deep Learning Models', *International Journal of Grid and Distributed Computing*, 11(1), pp. 89–106. doi: 10.14257/ijgdc.2018.11.1.09.
- Fraz, M. M. et al. (2012) 'Blood Vessel Segmentation Methodologies in Retinal Images A Survey', Computer Methods and Programs in Biomedicine, 108(1), pp. 407–433. doi: 10.1016/j.cmpb.2012.03.009.
- Gao, J., et al. (2019) 'Diabetic Retinopathy Classification Using an Efficient Convolutional Neural Network', *Proceedings 2019 IEEE International Conference on Agents, ICA 2019*, pp. 80–85. doi: 10.1109/AGENTS.2019.8929191.
- Ghosh, R., et al. (2017) 'Automatic Detection and Classification of Diabetic Retinopathy stages using CNN', *International Conference on Signal Processing and Integrated Networks (SPIN)*, pp. 550–554. doi: 10.1007/s40998-019-00213-7.
- Gorunescue, F. (2011) 'Classification Performance Evaluation. In: Data Mining', in *Intelligent Systems Reference Library*, pp. 319–330. doi: 10.1007/978-3-642-19721-5_6.
- Hagos, M. T. and Kant, S. (2019) 'Transfer Learning based Detection of Diabetic Retinopathy from Small Dataset', *Computer Vision and Pattern Recognition*. Available at: http://arxiv.org/abs/1905.07203.
- Haque, I. R. I. and Neubert, J. (2020) 'Deep Learning Approaches to Biomedical Image Segmentation', *Informatics in Medicine Unlocked*, 18, p. 100297. doi: 10.1016/j.imu.2020.100297.
- Hasan, N. *et al.* (2021) 'DenseNet Convolutional Neural Networks Application for Predicting COVID-19 Using CT Image', *SN Computer Science*, 2(5). doi: 10.1007/s42979-021-00782-7.

- Howard, A. G. *et al.* (2017) 'MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications', *Computer Vision and Pattern Recognition*. Available at: http://arxiv.org/abs/1704.04861.
- Huang, G. et al. (2017) 'Densely Connected Convolutional Networks', Computer Vision and Pattern Recognition, pp. 2261–2269.
- Ioffe, S. and Szegedy, C. (2015) 'Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift', *Journalism PracticIn Proceedings of the 32nd International Conference on Machine Learning Lille, France Volume 37; ACM: New York, NY, USA*, 37, pp. 448–456. doi: 10.1080/17512786.2015.1058180.
- 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.
- Islam, S. M. S., *et al.* (2018) 'Deep Learning based Early Detection and Grading of Diabetic Retinopathy Using Retinal Fundus Images', *Computer Vision and Pattern Recognition*, pp. 1–12. Available at: http://arxiv.org/abs/1812.10595.
- Jadon, S. (2020) 'A Survey of Loss Functions for Semantic Segmentation', 2020 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology, CIBCB 2020, (June). 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.
- Jiang, Z. et al. (2018) 'Retinal Blood Vessel Segmentation using Fully Convolutional Network with Transfer Learning', Computerized Medical Imaging and Graphics, 68(July 2017), pp. 1–15. doi: 10.1016/j.compmedimag.2018.04.005.
- Jinfeng, G. et al. (2020) 'Ensemble Framework of Deep CNNs for Diabetic Retinopathy Detection', Computational Intelligence and Neuroscience, 2020. doi: 10.1155/2020/8864698.
- Kaiser, L., *et al.* (2018) 'Depthwise Separable Convolutions for Neural Machine Translation', *ICLR*, pp. 1–10.
- Kandel, I. and Castelli, M. (2021) 'Transfer Learning with Convolutional Neural Networks for Diabetic Retinopathy Image Classification. A Review', *applied sciences*, 10.
- 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.
- Kaur, S. and Mann, K. S. (2020) 'Retinal Vessel Segmentation using an Entropy-Based Optimization Algorithm', *International Journal of Healthcare Information Systems and Informatics*, 15(2), pp. 61–79. doi: 10.4018/IJHISI.2020040105.
- Khan, A. *et al.* (2020) 'A Survey of the Recent Architectures Of Deep Convolutional Neural Networks', *Artificial Intelligence Review*, 53(8), pp. 5455–5516. doi: 10.1007/s10462-020-09825-6.
- Ko, H. *et al.* (2019) 'Pneumonia Detection with Weighted Voting Ensemble of CNN Models', *2019 2nd International Conference on Artificial Intelligence and Big Data, ICAIBD 2019*, pp. 306–310. doi: 10.1109/ICAIBD.2019.8837042.
- Lee, J., et al. (2018) 'An Ensemble Method of CNN Models for Object Detection', 9th International Conference onInformation Communication Technology Convergence: ICT Convergence Powered by Smart Intelligence, *ICTC* 2018. pp. 898–901. doi: 10.1109/ICTC.2018.8539396.
- Li, D. *et al.* (2016) 'A Genetic Algorithm-Based Weighted Ensemble Method for Predicting Transposon-Derived piRNAs', *BMC Bioinformatics*, 17(1), pp. 1–11. doi: 10.1186/s12859-016-1206-3.
- 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*. doi: 10.1155/2018/9128527.
- Liu, H. *et al.* (2020) 'Hybrid Model Structure for Diabetic Retinopathy Classification', *Journal of Healthcare Engineering*, 2020. 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.
- Luque, A. *et al.* (2019) 'The Impact of Class Imbalance in Classification Performance Metrics Based on the Binary Confusion Matrix', *Pattern Recognition*, 91, pp. 216–231. doi: 10.1016/j.patcog.2019.02.023.
- Mishra, S., et al. (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.
- Mushtaq, G. and Siddiqui, F. (2021) 'Detection of Diabetic Retinopathy Using

- Deep Learning Methodology', *IOP Conference Series: Materials Science and Engineering*, 1070, p. 012049. doi: 10.1088/1757-899x/1070/1/012049.
- Nguyen, Q. H. et al. (2020) 'Diabetic Retinopathy Detection using Deep Learning', Proceedings of the 4th International Conference On Machine Learning and Soft Computing, pp. 103–107.
- Novakovic, J. *et al.* (2017) 'Evaluation of Classification Models in Machine Learning', *Theory and Applications of Mathematics & Computer Science*, 7(1), pp. 39–46. Available at: https://uav.ro/applications/se/journal/index.php/TAMCS/article/view/158.
- Panwar, M. et al. (2017) 'CNN based approach for activity recognition using a wrist-worn accelerometer', *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, pp. 2438–2441. doi: 10.1109/EMBC.2017.8037349.
- Phiphiphatphaisit, S. and Surinta, O. (2020) 'Food Image Classification with Improved MobileNet Architecture and Data Augmentation', *ACM International Conference Proceeding Series*, (April), pp. 51–56. doi: 10.1145/3388176.3388179.
- Polikar, R. (2012) Ensemble Machine Learning, Ensemble Machine Learning. doi: 10.1007/978-1-4419-9326-7.
- Pratt, H. *et al.* (2016) 'Convolutional Neural Networks for Diabetic Retinopathy', *Procedia Computer Science*, 90(July), pp. 200–205. doi: 10.1016/j.procs.2016.07.014.
- Qomariah, D. U. N., *et al.* (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*, pp. 152–157. doi: 10.1109/ICTS.2019.8850940.
- Sae-Lim, W., et al. (2019) 'Convolutional Neural Networks Using MobileNet for Skin Lesion Classification', JCSSE 2019 16th International Joint Conference on Computer Science and Software Engineering: Knowledge Evolution Towards Singularity of Man-Machine Intelligence, pp. 242–247. doi: 10.1109/JCSSE.2019.8864155.
- Salamat, N., *et al.* (2019) 'Diabetic Retinopathy Techniques in Retinal Images: A review', *Artificial Intelligence in Medicine*, 97(October), pp. 168–188. doi: 10.1016/j.artmed.2018.10.009.
- Shang, R. *et al.* (2020) 'Dense Connection and Depthwise Separable Convolution Based CNN for Polarimetric SAR Image Classification', *Knowledge-Based Systems*, 194(xxxx), p. 105542. doi: 10.1016/j.knosys.2020.105542.
- Shu, L., et al. (2017) 'DOC: Deep open classification of text documents', EMNLP 2017 Conference on Empirical Methods in Natural Language Processing, Proceedings, (2013), pp. 2911–2916. doi: 10.18653/v1/d17-1314.

- Soomro, T. A. *et al.* (2018) 'Impact of ICA-Based Image Enhancement Technique on Retinal Blood Vessels Segmentation', *IEEE Access*, 6(c), pp. 3524–3538. doi: 10.1109/ACCESS.2018.2794463.
- Soomro, T. A., *et al.* (2019) 'Deep Learning Models for Retinal Blood Vessels Segmentation: A Review', *IEEE Access*, 7, pp. 71696–71717. doi: 10.1109/ACCESS.2019.2920616.
- Soomro, T. A., *et al.* (2019) 'Impact of Image Enhancement Technique on CNN Model for Retinal Blood Vessels Segmentation', *IEEE Access*, 7, pp. 158183–158197. doi: 10.1109/ACCESS.2019.2950228.
- Souid, A., *et al.* (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.
- Wang, C. *et al.* (2019) 'Dense U-net Based on Patch-Based Learning for Retinal Vessel Segmentation', *Entropy*, 21(2), pp. 1–15. doi: 10.3390/e21020168.
- Wardoyo, R. *et al.* (2020) 'Weighted Majority Voting by Statistical Performance Analysis on Ensemble Multiclassifier', 2020 5th International Conference on Informatics and Computing, ICIC 2020. doi: 10.1109/ICIC50835.2020.9288552.
- Wu, C., et al. (2019) 'DA-U-Net: Densely Connected Convolutional Networks and Decoder with Attention Gate for Retinal Vessel Segmentation', *IOP Conference Series: Materials Science and Engineering*, 533(1). doi: 10.1088/1757-899X/533/1/012053.
- Xu, K., et al. (2017) 'Deep Convolutional Neural Network-Based Early Automated Detection of Diabetic Retinopathy Using Fundus Image', Molecules, 22(12). doi: 10.3390/molecules22122054.
- Yani, M., et al. (2019) 'Application of Transfer Learning Using Convolutional Neural Network Method for Early Detection of Terry's Nail', *Journal of Physics: Conference Series*, 1201(1), pp. 0–9. doi: 10.1088/1742-6596/1201/1/012052.
- Zhong, Z. et al. (2020) 'Cancer Image Classification Based on DenseNet Model', Journal of Physics: Conference Series, 1651(1). doi: 10.1088/1742-6596/1651/1/012143.