

**PERBANDINGAN PRE-TRAINED CNN MODEL PADA KLASIFIKASI  
PENYAKIT RETINA MATA**



**Theodore Alvin Hartanto**

**0000031064**

**UMMN**

**UNIVERSITAS**

**MULTIMEDIA**

**NUSANTARA**

**PROGRAM STUDI INFORMATIKA  
FAKULTAS TEKNIK DAN INFORMATIKA  
UNIVERSITAS MULTIMEDIA NUSANTARA**

**TANGERANG**

**2022**

## HALAMAN PENGESAHAN

Skripsi dengan judul

### **PERBANDINGAN PRE-TRAINED CNN MODEL PADA KLASIFIKASI PENYAKIT RETINA MATA**

oleh

Nama : Theodore Alvin Hartanto  
NIM : 00000031064  
Program Studi : Informatika  
Fakultas : Fakultas Teknik dan Informatika

Telah diujikan pada hari 30 Juni 2022

Pukul 15.00 s/d 17.00 dan dinyatakan


**LULUS**

Dengan susunan pengujian sebagai berikut

Ketua Sidang

  
6 Juli 2022  
(Andre Rusli, S.Kom., M.Sc.)

Penguji

  
(Adhi Kusnadi, S.T., M.Si.)

Pembimbing

  
(Seng Hansun, S.Si., M.Cs.)

Ketua Program Studi Informatika,



Digitally signed  
by Marlinda  
Vasty Overbeek  
Date:  
2022.07.07  
09:34:39 +07'00'

(Marlinda Vasty Overbeek, S.Kom., M.Kom.)

## HALAMAN PERNYATAAN TIDAK PLAGIAT

Dengan ini saya,

Nama : Theodore Alvin Hartanto  
Nomor Induk Mahasiswa : 00000031064  
Program Studi : Informatika

Skripsi dengan judul:

Perbandingan *Pre-trained* CNN Model pada Klasifikasi Penyakit Retina Mata

merupakan hasil karya saya sendiri bukan plagiat dari karya ilmiah yang ditulis oleh orang lain, dan semua sumber baik yang dikutip maupun dirujuk telah saya nyatakan dengan benar serta dicantumkan di Daftar Pustaka.

Jika di kemudian hari terbukti ditemukan kecurangan/ penyimpangan, baik dalam pelaksanaan Skripsi maupun dalam penulisan laporan Skripsi, saya bersedia menerima konsekuensi dinyatakan TIDAK LULUS untuk Tugas akhir yang telah saya tempuh.

Tangerang, 23 Mei 2022



(Theodore Alvin Hartanto)

U M M  
U N I V E R S I T A S  
M U L T I M E D I A  
N U S A N T A R A

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

Sebagai sivitas akademik Universitas Multimedia Nusantara, saya yang bertanda tangan di bawah ini:

Nama : Theodore Alvin Hartanto  
NIM : 00000031064  
Program Studi : Informatika  
Fakultas : Teknik dan Informatika  
Jenis Karya : Skripsi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada **Universitas Multimedia Nusantara** hak Bebas Royalti Non-eksklusif (*Non-exclusive Royalty-Free Right*) atas karya ilmiah saya yang berjudul:

**PERBANDINGAN PRE-TRAINED CNN MODEL PADA KLASIFIKASI  
PENYAKIT RETINA MATA**

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Non eksklusif ini Universitas Multimedia Nusantara berhak menyimpan, mengalih media / format-kan, mengelola dalam bentuk pangkalan data (*database*), merawat, dan mempublikasikan tugas akhir saya selama tetap mencantumkan nama saya sebagai penulis / pencipta dan sebagai pemilik Hak Cipta. Demikian pernyataan ini saya buat dengan sebenarnya.

Tangerang, 23 Mei 2022  
Yang menyatakan



Theodore Alvin Hartanto

U N I V E R S I T A S  
M U L T I M E D I A  
N U S A N T A R A

## KATA PENGANTAR

Puji Syukur atas berkat dan rahmat kepada Tuhan Yang Maha Esa, atas selesainya penulisan laporan Skripsi ini dengan judul: Perbandingan *Pre-trained CNN Model* pada Klasifikasi Penyakit Retina Mata dilakukan untuk memenuhi salah satu syarat untuk mencapai gelar Sarjana Komputer Jurusan Informatika pada Fakultas Teknik dan Informatika Universitas Multimedia Nusantara. Saya menyadari bahwa, tanpa bantuan dan bimbingan dari berbagai pihak, dari masa perkuliahan sampai pada penyusunan skripsi ini, sangatlah sulit bagi saya untuk menyelesaikan skripsi ini. Oleh karena itu, saya mengucapkan terima kasih kepada:

1. Bapak Dr. Ninok Leksono, selaku Rektor Universitas Multimedia Nusantara.
2. Dr. Eng. Niki Prastomo, S.T., M.Sc., selaku Dekan Fakultas Teknik dan Informatika Universitas Multimedia Nusantara.
3. Ibu Marlinda Vasty Overbeek, S.Kom., M.Kom., selaku Ketua Program Studi Informatika Universitas Multimedia Nusantara.
4. Bapak Seng Hansun, S.Si., M.Cs., sebagai Pembimbing yang telah banyak meluangkan waktu untuk memberikan bimbingan, arahan dan motivasi atas terselesainya skripsi ini.
5. Orang Tua yang telah memberikan bantuan dukungan material dan moral, sehingga penulis dapat menyelesaikan penelitian dan penulisan skripsi ini.

Semoga skripsi ini bermanfaat, baik sebagai sumber informasi maupun sumber inspirasi, bagi para pembaca.

Tangerang, 23 Mei 2022



Theodore Alvin Hartanto

# PERBANDINGAN PRE-TRAINED CNN MODEL PADA KLASIFIKASI PENYAKIT RETINA MATA

Theodore Alvin Hartanto

## ABSTRAK

Pada era industri 4.0 saat ini, keberadaan kecerdasan buatan semakin diperlukan pada berbagai bidang pekerjaan untuk meningkatkan produktivitas dan efisiensi, termasuk di bidang medis. Saat ini, masih terdapat bidang medis yang menggunakan cara manual dalam proses diagnosis penyakit yang diderita oleh pasien, seperti diagnosis penyakit pada retina menggunakan hasil pemindaian *Optical Coherence Tomography* (OCT). Setiap tahunnya, diperkirakan terdapat sekitar 30 juta pemindaian OCT yang dilakukan. Namun, proses analisis dan diagnosis hasil pemindaian OCT oleh ophthalmologist memerlukan waktu yang cukup lama sehingga diperlukan *machine learning* agar dapat mempersingkat proses diagnosis penyakit pada retina pasien dan mempercepat proses penanganan pasien. Dalam penelitian ini, dilakukan perbandingan beberapa *pre-trained model*, antara lain EfficientNetB0, ResNet50V2, InceptionV3, dan DenseNet-169. Pada model-model tersebut akan dilakukan *fine-tuning* dan dilatih dengan *dataset* gambar hasil pemindaian OCT untuk mengklasifikasikan empat kondisi retina, yakni *Choroidal Neovascularization* (CNV), *Diabetic Macular Edema* (DME), *drusen*, serta normal. Model yang sudah dilatih kemudian diuji untuk mengklasifikasikan gambar *dataset* uji dan hasilnya dievaluasi dengan menggunakan *confusion matrix* untuk mendapatkan nilai performa model (*accuracy*, *recall*, *precision*, *f1-score*). Terdapat dua skenario yang diujikan pada masing-masing model, yaitu skenario penggunaan *batch size* sebesar 32 dan 64. Nilai *batch size* menunjukkan jumlah sampel yang diproses dalam sekali latih. Hasil penelitian menunjukkan bahwa model dengan hasil klasifikasi terbaik pada skenario pengujian *batch size* 32 adalah model ResNet50V2 dengan nilai *accuracy* sebesar 98.24%, *precision* sebesar 98.25%, *recall* sebesar 98.24%, serta *f1-score* sebesar 98.24%. Sementara pada skenario pengujian *batch size* 64, model EfficientNetB0 merupakan model dengan hasil klasifikasi terbaik dengan nilai *accuracy* sebesar 96.59%, *precision* sebesar 96.84%, *recall* sebesar 96.59%, serta *f1-score* sebesar 96.59%. Dengan demikian, dapat disimpulkan bahwa *pre-trained CNN model* dengan hasil klasifikasi penyakit retina mata terbaik diantara diantara EfficientNetB0, ResNet50V2, InceptionV3, dan DenseNet-169 adalah ResNet50V2 dengan *batch size* sebesar 32 berdasarkan pertimbangan nilai performa model yang terbaik diantara kedua skenario yang diujikan.

**Kata kunci:** *Convolutional Neural Network*, *fine-tuning*, klasifikasi, *pre-trained model*, *Optical Coherence Tomography*, retina mata

# COMPARISON OF PRE-TRAINED CNN MODELS ON THE CLASSIFICATION OF RETINAL DISEASES

Theodore Alvin Hartanto

## ABSTRACT

In the current industry 4.0 era, the existence of artificial intelligence is increasingly needed in various fields of work to increase productivity and efficiency, including in the medical field. Currently, there are still medical fields that use manual methods in the process of diagnosing diseases suffered by patients, such as diagnosing diseases of the retina using the results of Optical Coherence Tomography (OCT) scans. Annually, it is estimated that around 30 million OCT scans are performed. However, the process of analyzing and diagnosing OCT scan results by an ophthalmologist requires a long time so machine learning is needed in order to shorten the process of diagnosing diseases in the patient's retina and speed up the process of treating patients. In this study, several pre-trained models were compared, including EfficientNetB0, ResNet50V2, InceptionV3, and DenseNet-169. These models will be fine-tuned and trained with a dataset containing OCT scanned images to classify four retinal conditions, namely Choroidal Neovascularization (CNV), Diabetic Macular Edema (DME), drusen, and normal. The model that has been trained is then tested to classify the test dataset images and the results are evaluated using a confusion matrix to obtain model performance values (accuracy, recall, precision, f1-score). There are two scenarios tested in each model, namely the scenario using a batch size of 32 and 64. The batch size value indicates the number of samples processed in one training. The results showed that the model with the best classification results in the batch size of 32 scenario was the ResNet50V2 model with an accuracy value of 98.24%, precision of 98.25%, recall of 98.24%, and f1-score of 98.24%. While in the batch size of 64 scenario, the EfficientNetB0 model is the model with the best classification results with an accuracy value of 96.59%, precision of 96.84%, recall of 96.59%, and f1-score of 96.59%. Thus, it can be concluded that the pre-trained CNN model with the best retinal disease classification results among EfficientNetB0, ResNet50V2, InceptionV3, and DenseNet-169 is ResNet50V2 with the batch size of 32 based on the consideration of the best model performance value between the two scenarios tested.

**Keywords:** classification, Convolutional Neural Network, fine-tuning, pre-trained model, Optical Coherence Tomography, retina

## DAFTAR ISI

HALAMAN PENGESAHAN	ii
PERNYATAAN TIDAK MELAKUKAN PLAGIAT	iii
HALAMAN PERSETUJUAN PUBLIKASI ILMIAH	iv
KATA PENGANTAR	v
ABSTRAK	vi
ABSTRACT	vii
DAFTAR ISI	viii
DAFTAR GAMBAR	x
DAFTAR TABEL	xiii
BAB 1 PENDAHULUAN	1
1.1. Latar Belakang Masalah	1
1.2. Rumusan Masalah	2
1.3. Batasan Permasalahan	3
1.4. Tujuan Penelitian	3
1.5. Manfaat Penelitian	4
1.6. Sistematika Penulisan	4
BAB 2 LANDASAN TEORI	6
2.1. Retina Mata	6
2.2. Choroidal Neovascularization (CNV)	7
2.3. Diabetic Macular Edema (DME)	8
2.4. Drusen	9
2.5. Supervised Learning	9
2.6. Convolutional Neural Network (CNN)	10
2.7. EfficientNet B0	12
2.8. ResNet50V2	14
2.9. DenseNet-169	14
2.10. InceptionV3	15
2.11. Fine-Tuning	16
2.12. Callback	17
2.13. Confusion Matrix	17
2.13.1. Accuracy	18
2.13.2. Precision	18
2.13.3. Recall	18
2.13.4. F1 Score	18
BAB 3 METODOLOGI PENELITIAN	20
3.1. Studi literatur	20
3.2. Pengumpulan Data	20
3.3. Menetapkan <i>Hyperparameter</i> yang akan Digunakan	21
3.4. Pembagian <i>Dataset</i> dan <i>Rescaling</i>	21
3.5. Membaca Gambar yang ada pada <i>Dataset</i>	22
3.6. Memuat ( <i>load</i> ) <i>Pre-Trained Model</i> yang akan Dibandingkan	23
3.7. <i>Fine-tuning</i> Model	24
3.8. Pelatihan Model	25
3.9. Evaluasi Performa Model	26
3.10. Penyusunan Laporan	27
BAB 4 HASIL DAN DISKUSI	28
4.1. Spesifikasi Sistem	28
4.2. Potongan Kode	28



4.2.1.	Pengumpulan Data . . . . .	28
4.2.2.	Penetapan <i>Hyperparameter</i> . . . . .	30
4.2.3.	Pembagian <i>Dataset</i> dan <i>Rescaling</i> . . . . .	31
4.2.4.	Membaca Gambar yang ada pada <i>Dataset</i> . . . . .	32
4.2.5.	Memuat ( <i>load</i> ) <i>Pre-Trained Model</i> yang akan Dibandingkan . . . . .	33
4.2.6.	<i>Fine-tuning</i> Model . . . . .	34
4.2.7.	Pelatihan Model . . . . .	35
4.2.8.	Evaluasi Performa Model . . . . .	36
4.3.	Hasil Penelitian . . . . .	39
4.3.1.	Hasil Pengujian Skenario <i>Batch Size</i> sebesar 32 dengan menggunakan <i>callback</i> . . . . .	40
4.3.2.	Perbandingan Hasil Klasifikasi antar Model dengan <i>Batch Size</i> sebesar 32 dengan menggunakan <i>callback</i> . . . . .	52
4.3.3.	Hasil Pengujian Skenario <i>Batch Size</i> sebesar 64 dengan menggunakan <i>callback</i> . . . . .	54
4.3.4.	Perbandingan Hasil Klasifikasi antar Model dengan <i>Batch Size</i> sebesar 64 dengan menggunakan <i>callback</i> . . . . .	66
4.3.5.	Hasil Pengujian Skenario <i>Batch Size</i> sebesar 32 tanpa menggunakan <i>callback</i> . . . . .	68
4.3.6.	Perbandingan Hasil Klasifikasi antar Model dengan <i>Batch Size</i> sebesar 32 . . . . .	80
4.3.7.	Hasil Pengujian Skenario <i>Batch Size</i> sebesar 64 tanpa <i>callback</i> . . . . .	82
4.3.8.	Perbandingan Hasil Klasifikasi antar Model dengan <i>Batch Size</i> sebesar 64 tanpa <i>callback</i> . . . . .	94
4.4.	Diskusi Hasil Penelitian . . . . .	96
BAB 5	KESIMPULAN DAN SARAN . . . . .	99
5.1.	Simpulan . . . . .	99
5.2.	Saran . . . . .	99
DAFTAR PUSTAKA	. . . . .	100



## DAFTAR GAMBAR

Gambar 2.1	Ilustrasi struktur retina . . . . .	6
Gambar 2.2	Hasil pemindaian OCT pada retina dengan kondisi normal . . . . .	7
Gambar 2.3	Hasil pemindaian OCT pada pasien penderita CNV . . . . .	8
Gambar 2.4	Hasil pemindaian OCT pada pasien penderita DME . . . . .	8
Gambar 2.5	Hasil pemindaian OCT pada pasien penderita <i>drusen</i> . . . . .	9
Gambar 2.6	Simulasi proses perkalian kernel pada <i>convolutional layer</i> . . . . .	11
Gambar 2.7	Simulasi cara kerja <i>max pooling</i> pada <i>pooling layer</i> . . . . .	11
Gambar 2.8	Struktur <i>fully connected layer</i> . . . . .	12
Gambar 2.9	Grafik perbandingan jumlah parameter dengan tingkat akurasi . . . . .	13
Gambar 2.10	Perbedaan ResNet50 dan ResNet50V2 . . . . .	14
Gambar 2.11	Konsep arsitektur DenseNet . . . . .	15
Gambar 2.12	Konsep arsitektur InceptionV3 . . . . .	16
Gambar 3.1	<i>Flowchart</i> proses penelitian . . . . .	20
Gambar 3.2	<i>Flowchart</i> pembagian <i>dataset</i> dan <i>rescaling</i> . . . . .	22
Gambar 3.3	<i>Flowchart</i> membaca gambar pada <i>dataset</i> . . . . .	23
Gambar 3.4	<i>Flowchart</i> proses <i>load pre-trained model</i> . . . . .	24
Gambar 3.5	<i>Flowchart</i> proses <i>fine-tuning</i> model . . . . .	25
Gambar 3.6	<i>Flowchart</i> proses pelatihan model . . . . .	26
Gambar 3.7	<i>Flowchart</i> proses evaluasi model . . . . .	26
Gambar 4.1	Mengakses <i>dataset</i> Kaggle pada Google Colaboratory . . . . .	29
Gambar 4.2	Mengunduh dan mengekstrak <i>dataset</i> Kaggle . . . . .	30
Gambar 4.3	<i>Hyperparameter</i> yang digunakan pada skenario <i>batch_size</i> = 32 . . . . .	31
Gambar 4.4	Pembagian <i>dataset</i> dan <i>rescaling</i> . . . . .	32
Gambar 4.5	Membaca gambar dalam <i>dataset</i> latih . . . . .	33
Gambar 4.6	<i>Load pre-trained model</i> . . . . .	33
Gambar 4.7	<i>Fine-tuning</i> model ResNet50V2 . . . . .	35
Gambar 4.8	Pelatihan model ResNet50V2 . . . . .	36
Gambar 4.9	Membaca gambar dalam <i>dataset</i> uji . . . . .	36
Gambar 4.10	Mendapatkan label kelas <i>dataset</i> uji . . . . .	37
Gambar 4.11	Prediksi model terhadap <i>dataset</i> uji . . . . .	38
Gambar 4.12	Membuat <i>confusion matrix</i> . . . . .	39
Gambar 4.13	Pengukuran performa model . . . . .	39
Gambar 4.14	Grafik akurasi EfficientNetB0 ( <i>batch size</i> 32) . . . . .	41
Gambar 4.15	Grafik <i>loss</i> EfficientNetB0 ( <i>batch size</i> 32) . . . . .	41
Gambar 4.16	<i>Confusion matrix</i> EfficientNetB0 ( <i>batch size</i> 32) . . . . .	42
Gambar 4.17	Pengukuran performa EfficientNetB0 ( <i>batch size</i> 32) . . . . .	43
Gambar 4.18	Grafik akurasi ResNet50V2 ( <i>batch size</i> 32) . . . . .	44
Gambar 4.19	Grafik <i>loss</i> ResNet50V2 ( <i>batch size</i> 32) . . . . .	44
Gambar 4.20	<i>Confusion matrix</i> ResNet50V2 ( <i>batch size</i> 32) . . . . .	45
Gambar 4.21	Pengukuran performa ResNet50V2 ( <i>batch size</i> 32) . . . . .	46
Gambar 4.22	Grafik akurasi InceptionV3 ( <i>batch size</i> 32) . . . . .	47
Gambar 4.23	Grafik <i>loss</i> InceptionV3 ( <i>batch size</i> 32) . . . . .	48
Gambar 4.24	<i>Confusion matrix</i> InceptionV3 ( <i>batch size</i> 32) . . . . .	48
Gambar 4.25	Pengukuran performa InceptionV3 ( <i>batch size</i> 32) . . . . .	49

Gambar 4.26	Grafik akurasi DenseNet-169 ( <i>batch size</i> 32) . . . . .	50
Gambar 4.27	Grafik <i>loss</i> DenseNet-169 ( <i>batch size</i> 32) . . . . .	51
Gambar 4.28	<i>Confusion matrix</i> DenseNet-169 ( <i>batch size</i> 32) . . . . .	51
Gambar 4.29	Pengukuran performa DenseNet-169 ( <i>batch size</i> 32) . . . . .	52
Gambar 4.30	Grafik akurasi EfficientNetB0 ( <i>batch size</i> 64) . . . . .	55
Gambar 4.31	Grafik <i>loss</i> EfficientNetB0 ( <i>batch size</i> 64) . . . . .	55
Gambar 4.32	<i>Confusion matrix</i> EfficientNetB0 ( <i>batch size</i> 64) . . . . .	56
Gambar 4.33	Pengukuran performa EfficientNetB0 ( <i>batch size</i> 64) . . . . .	57
Gambar 4.34	Grafik akurasi ResNet50V2 ( <i>batch size</i> 64) . . . . .	58
Gambar 4.35	Grafik <i>loss</i> ResNet50V2 ( <i>batch size</i> 64) . . . . .	58
Gambar 4.36	<i>Confusion matrix</i> ResNet50V2 ( <i>batch size</i> 64) . . . . .	59
Gambar 4.37	Pengukuran performa ResNet50V2 ( <i>batch size</i> 64) . . . . .	60
Gambar 4.38	Grafik akurasi InceptionV3 ( <i>batch size</i> 64) . . . . .	61
Gambar 4.39	Grafik <i>loss</i> InceptionV3 ( <i>batch size</i> 64) . . . . .	62
Gambar 4.40	<i>Confusion matrix</i> InceptionV3 ( <i>batch size</i> 64) . . . . .	62
Gambar 4.41	Pengukuran performa InceptionV3 ( <i>batch size</i> 64) . . . . .	63
Gambar 4.42	Grafik akurasi DenseNet-169 ( <i>batch size</i> 64) . . . . .	64
Gambar 4.43	Grafik <i>loss</i> DenseNet-169 ( <i>batch size</i> 64) . . . . .	65
Gambar 4.44	<i>Confusion matrix</i> DenseNet-169 ( <i>batch size</i> 64) . . . . .	65
Gambar 4.45	Pengukuran performa DenseNet-169 ( <i>batch size</i> 64) . . . . .	66
Gambar 4.46	Grafik akurasi EfficientNetB0 ( <i>batch size</i> 32) tanpa <i>callback</i>	69
Gambar 4.47	Grafik <i>loss</i> EfficientNetB0 ( <i>batch size</i> 32) tanpa <i>callback</i>	70
Gambar 4.48	<i>Confusion matrix</i> EfficientNetB0 ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	70
Gambar 4.49	Pengukuran performa EfficientNetB0 ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	71
Gambar 4.50	Grafik akurasi ResNet50V2 ( <i>batch size</i> 32) tanpa <i>callback</i>	72
Gambar 4.51	Grafik <i>loss</i> ResNet50V2 ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	73
Gambar 4.52	<i>Confusion matrix</i> ResNet50V2 ( <i>batch size</i> 32) tanpa <i>callback</i>	73
Gambar 4.53	Pengukuran performa ResNet50V2 ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	74
Gambar 4.54	Grafik akurasi InceptionV3 ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	75
Gambar 4.55	Grafik <i>loss</i> InceptionV3 ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	76
Gambar 4.56	<i>Confusion matrix</i> InceptionV3 ( <i>batch size</i> 32) tanpa <i>callback</i>	76
Gambar 4.57	Pengukuran performa InceptionV3 ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	77
Gambar 4.58	Grafik akurasi DenseNet-169 ( <i>batch size</i> 32) tanpa <i>callback</i>	78
Gambar 4.59	Grafik <i>loss</i> DenseNet-169 ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	79
Gambar 4.60	<i>Confusion matrix</i> DenseNet-169 ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	79
Gambar 4.61	Pengukuran performa DenseNet-169 ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	80
Gambar 4.62	Grafik akurasi EfficientNetB0 ( <i>batch size</i> 64) tanpa <i>callback</i>	83
Gambar 4.63	Grafik <i>loss</i> EfficientNetB0 ( <i>batch size</i> 64) tanpa <i>callback</i> . . . . .	84
Gambar 4.64	<i>Confusion matrix</i> EfficientNetB0 ( <i>batch size</i> 64) tanpa <i>callback</i> . . . . .	84
Gambar 4.65	Pengukuran performa EfficientNetB0 ( <i>batch size</i> 64) tanpa <i>callback</i> . . . . .	85
Gambar 4.66	Grafik akurasi ResNet50V2 ( <i>batch size</i> 64) . . . . .	86
Gambar 4.67	Grafik <i>loss</i> ResNet50V2 ( <i>batch size</i> 64) . . . . .	87

Gambar 4.68	<i>Confusion matrix</i> ResNet50V2 ( <i>batch size</i> 64) . . . . .	87
Gambar 4.69	Pengukuran performa ResNet50V2 ( <i>batch size</i> 64) . . . . .	88
Gambar 4.70	Grafik akurasi InceptionV3 ( <i>batch size</i> 64) tanpa <i>callback</i> .	89
Gambar 4.71	Grafik <i>loss</i> InceptionV3 ( <i>batch size</i> 64) tanpa <i>callback</i> . .	90
Gambar 4.72	<i>Confusion matrix</i> InceptionV3 ( <i>batch size</i> 64) tanpa <i>callback</i>	90
Gambar 4.73	Pengukuran performa InceptionV3 ( <i>batch size</i> 64) tanpa <i>callback</i> . . . . .	91
Gambar 4.74	Grafik akurasi DenseNet-169 ( <i>batch size</i> 64) tanpa <i>callback</i>	92
Gambar 4.75	Grafik <i>loss</i> DenseNet-169 ( <i>batch size</i> 64) tanpa <i>callback</i> .	93
Gambar 4.76	<i>Confusion matrix</i> DenseNet-169 ( <i>batch size</i> 64) tanpa <i>callback</i> . . . . .	93
Gambar 4.77	Pengukuran performa DenseNet-169 ( <i>batch size</i> 64) tanpa <i>callback</i> . . . . .	94



## DAFTAR TABEL

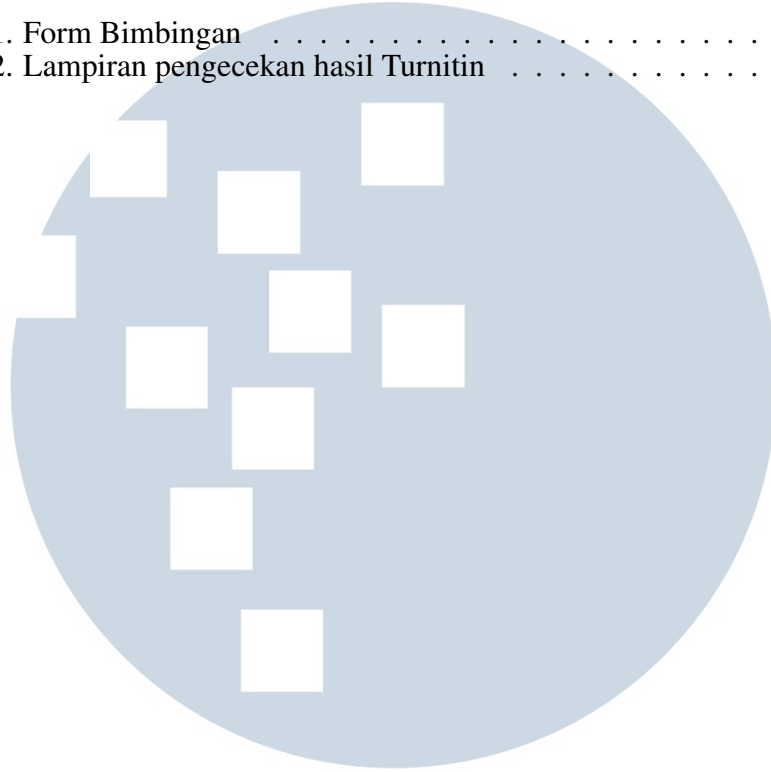
Tabel 2.1	Arsitektur EfficientNet B0 . . . . .	13
Tabel 2.2	Konsep Confusion matrix . . . . .	17
Tabel 3.1	<i>Hyperparameter</i> yang akan digunakan . . . . .	21
Tabel 3.2	Struktur model setelah <i>fine-tuning</i> . . . . .	24
Tabel 4.1	Persebaran jumlah data dalam <i>dataset</i> . . . . .	30
Tabel 4.2	Persebaran jumlah data dalam <i>dataset</i> setelah pembagian .	31
Tabel 4.3	Detail pelatihan model EfficientNet B0 ( <i>batch size</i> 32) . .	41
Tabel 4.4	Detail pelatihan model ResNet50V2 ( <i>batch size</i> 32) . . . .	44
Tabel 4.5	Detail pelatihan model InceptionV3 ( <i>batch size</i> 32) . . . .	47
Tabel 4.6	Detail pelatihan model DenseNet-169 ( <i>batch size</i> 32) . . . .	50
Tabel 4.7	Hasil klasifikasi penyakit CNV tiap model ( <i>batch size</i> 32) .	53
Tabel 4.8	Hasil klasifikasi penyakit DME tiap model ( <i>batch size</i> 32) .	53
Tabel 4.9	Hasil klasifikasi penyakit <i>drusen</i> tiap model ( <i>batch size</i> 32)	53
Tabel 4.10	Hasil klasifikasi retina normal tiap model ( <i>batch size</i> 32) .	53
Tabel 4.11	Performa tiap model secara keseluruhan ( <i>batch size</i> 32) . .	54
Tabel 4.12	Detail pelatihan model EfficientNet B0 ( <i>batch size</i> 64) . .	54
Tabel 4.13	Detail pelatihan model ResNet50V2 ( <i>batch size</i> 64) . . . .	57
Tabel 4.14	Detail pelatihan model InceptionV3 ( <i>batch size</i> 64) . . . .	61
Tabel 4.15	Detail pelatihan model DenseNet-169 ( <i>batch size</i> 64) . . . .	64
Tabel 4.16	Hasil klasifikasi penyakit CNV tiap model ( <i>batch size</i> 64) .	67
Tabel 4.17	Hasil klasifikasi penyakit DME tiap model ( <i>batch size</i> 64) .	67
Tabel 4.18	Hasil klasifikasi penyakit <i>drusen</i> tiap model ( <i>batch size</i> 64)	67
Tabel 4.19	Hasil klasifikasi retina normal tiap model ( <i>batch size</i> 64) .	67
Tabel 4.20	Performa tiap model secara keseluruhan ( <i>batch size</i> 64) . .	68
Tabel 4.21	Detail pelatihan model EfficientNet B0 ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	69
Tabel 4.22	Detail pelatihan model ResNet50V2 ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	72
Tabel 4.23	Detail pelatihan model InceptionV3 ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	75
Tabel 4.24	Detail pelatihan model DenseNet-169 ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	78
Tabel 4.25	Hasil klasifikasi penyakit CNV tiap model ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	81
Tabel 4.26	Hasil klasifikasi penyakit DME tiap model ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	81
Tabel 4.27	Hasil klasifikasi penyakit <i>drusen</i> tiap model ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	81
Tabel 4.28	Hasil klasifikasi retina normal tiap model ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	81
Tabel 4.29	Performa tiap model secara keseluruhan ( <i>batch size</i> 32) tanpa <i>callback</i> . . . . .	82
Tabel 4.30	Detail pelatihan model EfficientNet B0 ( <i>batch size</i> 64) tanpa <i>callback</i> . . . . .	83

Tabel 4.31	Detail pelatihan model ResNet50V2 ( <i>batch size</i> 64) tanpa <i>callback</i> . . . . .	86
Tabel 4.32	Detail pelatihan model InceptionV3 ( <i>batch size</i> 64) tanpa <i>callback</i> . . . . .	89
Tabel 4.33	Detail pelatihan model DenseNet-169 ( <i>batch size</i> 64) tanpa <i>callback</i> . . . . .	92
Tabel 4.34	Hasil klasifikasi penyakit CNV tiap model ( <i>batch size</i> 64) tanpa <i>callback</i> . . . . .	95
Tabel 4.35	Hasil klasifikasi penyakit DME tiap model ( <i>batch size</i> 64) tanpa <i>callback</i> . . . . .	95
Tabel 4.36	Hasil klasifikasi penyakit <i>drusen</i> tiap model ( <i>batch size</i> 64) tanpa <i>callback</i> . . . . .	95
Tabel 4.37	Hasil klasifikasi retina normal tiap model ( <i>batch size</i> 64) tanpa <i>callback</i> . . . . .	95
Tabel 4.38	Performa tiap model secara keseluruhan ( <i>batch size</i> 64) tanpa <i>callback</i> . . . . .	96
Tabel 4.39	Performa model dengan <i>batch size</i> 32 dan 64 secara keseluruhan . . . . .	97



## DAFTAR LAMPIRAN

Lampiran 1. Form Bimbingan . . . . .	102
Lampiran 2. Lampiran pengecekan hasil Turnitin . . . . .	105



**UMN**  
UNIVERSITAS  
MULTIMEDIA  
NUSANTARA