

**KLASIFIKASI PENYAKIT KULIT DERMATITIS ATOPIK
DAN PSORIASIS DENGAN MENGGUNAKAN METODE
*CONVOLUTIONAL NEURAL NETWORK***

TESIS



OLEH :

**DWI MEI RITA SARI
09042681822009**

**PROGRAM STUDI MAGISTER ILMU KOMPUTER
FAKULTAS ILMU KOMPUTER
UNIVERSITAS SRIWIJAYA
2022**

**KLASIFIKASI PENYAKIT KULIT DERMATITIS ATOPIK DAN
PSORIASIS DENGAN MENGGUNAKAN METODE *CONVOLUTIONAL
NEURAL NETWORK***

Tesis

Diajukan Untuk Melengkapi Salah Satu Syarat Memperoleh Gelar Magister



OLEH :

**DWI MEI RITA SARI
09042681822009**

**PROGRAM STUDI MAGISTER ILMU KOMPUTER
FAKULTAS ILMU KOMPUTER
UNIVERSITAS SRIWIJAYA
2022**

LEMBAR PENGESAHAN

**KLASIFIKASI PENYAKIT KULIT DERMATITIS ATOPIK
DAN PSORIASIS DENGAN MENGGUNAKAN METODE
CONVOLUTIONAL NEURAL NETWORK**

TESIS

Diajukan Untuk Melengkapi Salah Satu Syarat Memperoleh Gelar Magister

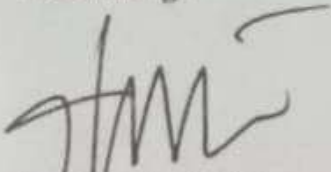
OLEH:

DWI MEI RITA SARI

09042681822009

Palembang, 30 Agustus 2022

Pemimbing I



Prof. Dr. Ir. Siti Nurmaini, M.T.
NIP. 96908021994012001

Pemimbing II



Dian Palupi Rini, M.Kom., Ph.D.
NIP.197802232006042002

Mengetahui,

Koordinator Program Studi Magister Ilmu Komputer



Dian Palupi Rini, M.Kom., Ph.D.
NIP.197802232006042002

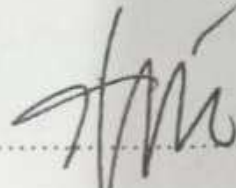
HALAMAN PERSETUJUAN

Pada hari Jumat, 29 Juli 2022 telah dilaksanakan ujian sidang tesis oleh
Magister Ilmu Komputer Fakultas Ilmu Komputer Universitas Sriwijaya.

Nama : Dwi Mei Rita Sari
NIM : 09042681822009
Judul : Klasifikasi Penyakit Kulit Dermatitis Atopik dan Psoriasis
dengan Menggunakan Metode *Convolutional Neural Network*

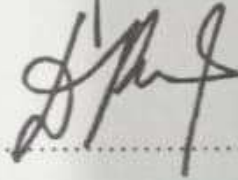
1. Pembimbing I

Prof. Dr. Ir. Siti Nurmaini, M.T.
NIP. 196908021994012001



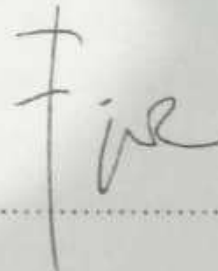
2. Pembimbing II

Dian Palupi Rini, S.Si, M.Kom, Ph.D.
NIP. 197802232006042002



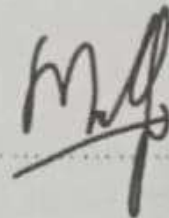
3. Penguji I

Firdaus, S.T, M.Kom.
NIP. 197801212008121003



4. Penguji II

Muhammad Qurhanul Rizqie, Ph.D
NIP. 198712032022031006



Mengetahui,

Ketua Program Studi Magister Ilmu Komputer

Dian Palupi Rini, M.Kom., Ph.D.

NIP.197802232006042002



LEMBAR PERNYATAAN

Yang bertanda tangan di bawah ini :

Nama : Dwi Mei Rita Sari
NIM : 09042681822009
Program Studi : Magister Ilmu Komputer
Judul Tesis : Klasifikasi Penyakit Kulit Dermatitis Atopik dan Psoriasis
dengan Menggunakan Metode *Convolutional Neural Network*

Hasil Pengecekan Software iThenticate/Turnitin : 17 %

Menyatakan bahwa laporan tesis saya merupakan hasil karya sendiri dan bukan hasil penjiplakan/plagiat. Apabila ditemukan unsur penjiplakan/plagiat dalam laporan tesis ini, maka saya bersedia menerima sanksi akademik dari Universitas Sriwijaya sesuai dengan ketentuan yang berlaku.

Demikian, pernyataan ini saya buat dengan sebenarnya dan tidak ada paksaan oleh siapapun.



Palembang, 18 Juli 2022



Dwi Mei Rita Sari

NIM. 09042682822009


KATA PENGANTAR

Puji syukur penulis panjatkan kehadirat Allah SWT, yang telah melimpahkan rahmat dan karunia-Nya sehingga Penulis dapat menyelesaikan tesis dan menyusun laporan tesis yang berjudul “Klasifikasi Penyakit Kulit Dermatitis Atopik dan Psoriasis dengan Menggunakan Metode *Convolutional Neural Network*”.

Pada kesempatan ini, penulis ingin menyampaikan ucapan terima kasih yang tak terhingga kepada pihak-pihak telah banyak membantu penyelesaian Tesis ini, yaitu kepada:

1. Kedua orangtuaku Bapak Misru Syarifudin dan Ibu Susmita, S.Pd yang telah memberikan motivasi, doa, restu dan bantuan.
2. Suamiku Ade Irawan S.P. yang telah memberikan dukungan dan semangat tidak hentinya.
3. Ibu Dian Palupi Rini, S.Si, M.Kom, Ph.D. selaku Ketua Program Studi Magister Ilmu Komputer sekaligus dosen pembimbing II dan Ibu Prof. Dr. Ir. Siti Nurmaini, M.T sebagai dosen Pembimbing I yang sangat sabar dalam membimbing dan membantu penulis.
4. Ade Iriani Sapitri, M.Kom. yang telah banyak membantu penyelesaian penelitian dalam penulisan tesis ini.
5. Semua Dosen dan Staff Magister Ilmu Komputer yang selama ini telah melimpahkan ilmunya kepada penulis selama proses belajar mengajar dan membantu dalam memperlancar kegiatan akademik di Fakultas Ilmu Komputer Universitas Sriwijaya.
6. Semua rekan – rekan Magister Ilmu Komputer dan rekan kerja di Sekolah HighScope Palembang atas bantuannya.

Palembang, 1 Agustus 2022



Penulis

Dermatitis Atopic and Psoriasis Skin Disease Classification by using Convolutional Neural Network

Dwi Mei Rita Sari

ABSTRACT

Skin is the one of the body parts that play a large role in human physical body. There are so many functions of the skin such as offering protection against fungal infection, bacteria, allergy, viruses and controls the temperature of the body. But, the reported shown that the skin disease is the most common disease in humans among all age groups and a significant root of infection. The diagnosis of skin diseases involves several tests. Due to this, the diagnosis process is seen to be intensely laborious, time-consuming and requires an extensive understanding especially for the skin disease that have similar symptoms. Two skin diseases that have similar symptoms and most misdiagnosed are atopic dermatitis and psoriasis. Convolutional Neural Network for image processing and classifying have been developed for more accurate classification of skin diseases with different architectures. However, the accuracy in determining skin lesions using CNNs is on the average level. The factors that affect the accuracy result of a CNN is the depth where gradients vanished as the network goes deeper. Another factor is the variance in the training set which means the need of the large size of training set. Hence, in this study we tried 10 CNN architecture to get the best result for classifying dermatitis atopic and psoriasis. These are VGG 16, VGG 19, ResNet 50, ResNet 101, MobileNet, MobileNet V2, DenseNet 121, DenseNet 201, Inception and Xception. Experimental result shown that the inception V3 architecture give the best result with accuracy for data testing 84%, accuracy for unseen data 82% and confusion matrix with True positive obtained is 248, True Negative is 61, False positive is 54 and False Negative 298.

Keyword: Skin Disease, Dermatitis Atopik, Psoriasis, Classification, Convolutional Neural Network, Inception V3.

KLASIFIKASI PENYAKIT KULIT DERMATITIS ATOPIK DAN PSORIASIS DENGAN MENGGUNAKAN METODE *CONVOLUTIONAL NEURAL NETWORK*

Dwi Mei Rita Sari

ABSTRACT

Kulit merupakan salah satu bagian tubuh yang berperan besar dalam tubuh fisik manusia. Ada begitu banyak fungsi kulit seperti perlindungan terhadap infeksi jamur, bakteri, alergi, virus dan mengontrol suhu tubuh. Namun, laporan menunjukkan bahwa penyakit kulit adalah penyakit paling umum pada manusia di antara semua kelompok umur dan merupakan akar infeksi yang signifikan. Diagnosis penyakit kulit melibatkan beberapa tes. Karena itu, proses diagnosis terlihat sangat melelahkan, memakan waktu dan membutuhkan pemahaman yang luas terutama untuk penyakit kulit yang memiliki gejala serupa. Dua penyakit kulit yang memiliki gejala serupa dan paling sering mengalami kesalahan diagnosis adalah dermatitis atopik dan psoriasis. *Convolutional Neural Network* untuk pemrosesan gambar dan klasifikasi telah dikembangkan untuk klasifikasi penyakit kulit yang lebih akurat dengan arsitektur yang berbeda. Namun akurasi penentuan lesi kulit menggunakan CNNs berada pada level rata-rata. Faktor yang mempengaruhi hasil akurasi CNN adalah kedalaman di mana gradien menghilang saat jaringan semakin dalam. Faktor lainnya adalah varians dalam *training* set yang berarti kebutuhan *training* set yang besar. Oleh karena itu, dalam penelitian ini kami mencoba 10 arsitektur CNN untuk mendapatkan hasil terbaik dalam mengklasifikasikan dermatitis atopik dan psoriasis. Ini adalah VGG 16, VGG 19, ResNet 50, ResNet 101, MobileNet, MobileNet V2, DenseNet 121, DenseNet 201, Inception dan Xception. Hasil percobaan menunjukkan bahwa arsitektur awal V3 memberikan hasil terbaik dengan akurasi untuk pengujian data 84%, akurasi untuk data yang tidak terlihat 82% dan *confusion matrix* dengan *True positif* yang diperoleh adalah 248, *True Negative* adalah 61, *False positive* adalah 54 dan *False Negative* 298.

Kata kunci: Penyakit Kulit, Dermatitis Atopik, Psoriasis, Klasifikasi,

Convolutional Neural Network, Inception V3.

DAFTAR ISI

LEMBAR PENGESAHAN	i
HALAMAN PERSETUJUAN	ii
LEMBAR PERNYATAAN	iii
KATA PENGANTAR	iv
ABSTRACT	v
ABSTRAK	vi
DAFTAR ISI	vii
DAFTAR GAMBAR	ix
DAFTAR TABEL	x
DAFTAR LAMPIRAN	xi
BAB I PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Perumusan Masalah.....	4
1.3 Batasan Masalah.....	4
1.4 Tujuan dan Manfaat.....	4
1.5 Sistematika Penulisan.....	5
BAB II TINJAUAN PUSTAKA	7
2.1 Tinjauan Pustaka.....	7
2.2 Dermatitis Atopik.....	9
2.3 Psoriasis.....	10
2.4 <i>Deep Learning</i> Pada Klasifikasi Lesi Kulit.....	11
2.5 <i>Transfer Learning</i>	14
2.6 <i>Performance Matrix</i>	16
BAB III METODOLOGI PENELITIAN	17
4.1 Kerangka Kerja Penelitian.....	17
4.2 Studi Pustaka dan Literatur.....	20
4.3 Persiapan Data.....	21
4.4 Pra – Pengolahan.....	22
4.5 Pengklasifikasian CNN.....	25
4.5.1 Model Matematis CNN.....	26
4.5.1.1 <i>Forward Pass</i>	26
4.5.1.2 <i>BackPropagation</i>	32
4.5.1.3 Update Bobot.....	47
4.5.2 Model <i>Pre-Trained CNN</i> dan <i>Fine-Tuning</i>	50
4.5.3 Proses Pelatihan.....	51
4.5.4 Proses Pengujian.....	51
4.6 Analisis Hasil.....	51
4.7 Kesimpulan.....	52
BAB IV HASIL DAN PEMBAHASAN	53
4.1 Hasil Model VGG 16.....	53
4.2 Hasil Model ResNet 50.....	61
4.3 Hasil Model MobileNet.....	69

4.4 Hasil Model DenseNet 121.....	77
4.5 Hasil Model Xception.....	85
4.6 Hasil Model VGG 19.....	92
4.7 Hasil Model ResNet 101.....	98
4.8 Hasil Model MobileNet V2.....	103
4.9 Hasil Model DenseNet 201.....	110
4.10 Hasil Model Inception.....	116
4.11 Analisa Hasil Pengujian.....	122
BAB V KESIMPULAN.....	125
5.1 Kesimpulan.....	125
5.2 Saran.....	126
DAFTAR PUSTAKA.....	127
RIWAYAT HIDUP PENULS.....	128

DAFTAR GAMBAR

Gambar 2.1 Dermatitis Atopik.....	11
Gambar 2.2 Psoriasis.....	12
Gambar 2.3 Ilustrasi Proses Utama dalam CNN.....	14
Gambar 2.4 Ilustrasi Arsitektur VGGNET.....	17
Gambar 3.1 Kerangka Penelitian.....	19
Gambar 3.2 Metodologi Penelitian.....	20
Gambar 3.3 Tahapan Pra – Pengolahan Data.....	22
Gambar 3.4 Sample Data Gambar Pasien Dermatitis Atopik dan Psoriasis.....	23
Gambar 3.5 Proses <i>Forward Pass</i> CNN.....	25
Gambar 3.6 Kernel yang telah diputar 180^0	25
Gambar 3.7 Operasi Konvolusi antara Matriks input I dan Matriks Kernel F....	26
Gambar 3.8 CNN dengan Gambar RGB.....	28
Gambar 3.9 Proses <i>Backpropagation</i> CNN.....	49
Gambar 3.10 Arsitektur CNN dengan model VGG16 (a) dan ResNet50 (b).....	51
Gambar 4.1 Hasil Kinerja Evaluasi Model Arsitektur VGG 16.....	54
Gambar 4.2 Plot Akurasi arsitektur VGG16 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	55
Gambar 4.3 Plot Akurasi arsitektur VGG16 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	56
Gambar 4.4 Plot <i>loss</i> arsitektur VGG16 dengan menggunakan <i>learning rate</i> 10^{-3} dan 30 <i>epoch</i>	57
Gambar 4.5 Plot <i>loss</i> arsitektur VGG16 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	57
Gambar 4.6 Plot <i>loss</i> arsitektur VGG16 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	58
Gambar 4.7 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur VGG 16 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	59

Gambar 4.8 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur VGG 16 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	60
Gambar 4.9 <i>Confusion Matrix Unseen</i> arsitektur VGG 16 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	61
Gambar 4.10 Plot Akurasi arsitektur ResNet 50 dengan menggunakan <i>learning rate</i> 10^{-3} dan 30 <i>epoch</i>	62
Gambar 4.11 Plot Akurasi arsitektur ResNet 50 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	63
Gambar 4.12 Plot Akurasi arsitektur ResNet 50 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	64
Gambar 4.13 Plot <i>loss</i> arsitektur ResNet 50 dengan menggunakan <i>learning rate</i> 10^{-3} dan 30 <i>epoch</i>	64
Gambar 4.14 Plot <i>loss</i> arsitektur ResNet 50 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	65
Gambar 4.15 Plot <i>loss</i> arsitektur ResNet 50 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	66
Gambar 4.16 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur ResNet 50 dengan menggunakan <i>learning rate</i> 10^{-3} dan 30 <i>epoch</i>	67
Gambar 4.17 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur ResNet 50 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	67
Gambar 4.18 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur ResNet 50 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	68
Gambar 4.19 <i>Confusion Matrix Unseen</i> arsitektur ResNet 50 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	69
Gambar 4.20 Plot Akurasi arsitektur MobileNet dengan menggunakan <i>learning rate</i> 10^{-3} dan 30 <i>epoch</i>	70
Gambar 4.21 Plot Akurasi arsitektur MobileNet dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	71
Gambar 4.22 Plot Akurasi arsitektur MobileNet dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	72

Gambar 4.23 Plot <i>loss</i> arsitektur MobileNet dengan menggunakan <i>learning rate</i> 10^{-3} dan 30 <i>epoch</i>	72
Gambar 4.24 Plot <i>loss</i> arsitektur MobileNet dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	73
Gambar 4.25 Plot <i>loss</i> arsitektur MobileNet dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	74
Gambar 4.26 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur MobileNet dengan menggunakan <i>learning rate</i> 10^{-3} dan 30 <i>epoch</i>	75
Gambar 4.27 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur MobileNet dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	75
Gambar 4.28 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur MobileNet dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	76
Gambar 4.29 <i>Confusion Matrix Unseen</i> arsitektur MobileNet dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	77
Gambar 4.30 Plot Akurasi arsitektur DenseNet 121 dengan menggunakan <i>learning rate</i> 10^{-3} dan 30 <i>epoch</i>	78
Gambar 4.31 Plot Akurasi arsitektur DenseNet 121 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	79
Gambar 4.32 Plot Akurasi arsitektur DenseNet 121 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	80
Gambar 4.33 Plot <i>loss</i> arsitektur ResNet 50 dengan menggunakan <i>learning rate</i> 10^{-3} dan 30 <i>epoch</i>	80
Gambar 4.34 Plot <i>loss</i> arsitektur DenseNet 121 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	81
Gambar 4.35 Plot <i>loss</i> arsitektur DenseNet 121 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	82
Gambar 4.36 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur DenseNet 121 dengan menggunakan <i>learning rate</i> 10^{-3} dan 30 <i>epoch</i>	83
Gambar 4.37 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur DenseNet 121 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	83

Gambar 4.38 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur DenseNet 121 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	84
Gambar 4.39 <i>Confusion Matrix Unseen</i> arsitektur DenseNet 121 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	85
Gambar 4.40 Plot Akurasi arsitektur Xception dengan menggunakan <i>learning rate</i> 10^{-4} dan 30 <i>epoch</i>	86
Gambar 4.41 Plot Akurasi arsitektur Xception dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	87
Gambar 4.42 Plot Akurasi arsitektur Xception dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	88
Gambar 4.43 Plot <i>loss</i> arsitektur Xception dengan menggunakan <i>learning rate</i> 10^{-3} dan 30 <i>epoch</i>	88
Gambar 4.44 Plot <i>loss</i> arsitektur Xception dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	89
Gambar 4.45 Plot <i>loss</i> arsitektur Xception dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	89
Gambar 4.46 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur Xception dengan menggunakan <i>learning rate</i> 10^{-3} dan 30 <i>epoch</i>	90
Gambar 4.47 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur Xception dengan menggunakan <i>learning rate</i> 10^{-4} dan 30 <i>epoch</i>	91
Gambar 4.48 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur Xception dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	91
Gambar 4.49 <i>Confusion Matrix Unseen</i> arsitektur Xception dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	92
Gambar 4.50 Plot Akurasi arsitektur VGG 19 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	94
Gambar 4.51 Plot Akurasi arsitektur VGG 19 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	94
Gambar 4.52 Plot <i>loss</i> arsitektur VGG 19 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	95

Gambar 4.53 Plot <i>loss</i> arsitektur VGG 19 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	95
Gambar 4.54 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur VGG 19 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	96
Gambar 4.55 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur VGG 19 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	97
Gambar 4.56 <i>Confusion Matrix Unseen</i> arsitektur VGG 19 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	98
Gambar 4.57 Plot Akurasi arsitektur ResNet 101 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	99
Gambar 4.58 Plot Akurasi arsitektur ResNet 101 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	100
Gambar 4.59 Plot <i>loss</i> arsitektur ResNet 101 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	100
Gambar 4.60 Plot <i>loss</i> arsitektur ResNet 101 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	101
Gambar 4.61 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur ResNet 101 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	102
Gambar 4.62 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur ResNet 101 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	102
Gambar 4.63 <i>Confusion Matrix Unseen</i> arsitektur ResNet 101 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	103
Gambar 4.64 Plot Akurasi arsitektur MobileNet V2 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	105
Gambar 4.65 Plot Akurasi arsitektur MobileNet V2 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	105
Gambar 4.66 Plot <i>loss</i> arsitektur MobileNet V2 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	106
Gambar 4.67 Plot <i>loss</i> arsitektur MobileNet V2 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	107

Gambar 4.68 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur MobileNet V2 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	108
Gambar 4.69 <i>Confusion Matrix Testing</i> dengan menggunakan arsitektur MobileNet V2 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	108
Gambar 4.70 <i>Confusion Matrix Unseen</i> arsitektur MobileNet V2 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	109
Gambar 4.71 Plot Akurasi arsitektur DenseNet 201 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	111
Gambar 4.72 Plot Akurasi arsitektur DenseNet 201 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	111
Gambar 4.73 Plot <i>loss</i> arsitektur DenseNet 201 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	112
Gambar 4.74 Plot <i>loss</i> arsitektur DenseNet 201 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	113
Gambar 4.75 <i>Confusion Matrix</i> dengan menggunakan arsitektur DenseNet 201 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	114
Gambar 4.76 <i>Confusion Matrix</i> dengan menggunakan arsitektur DenseNet 201 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	114
Gambar 4.77 <i>Confusion Matrix Unseen</i> arsitektur DenseNet 201 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	115
Gambar 4.78 Plot Akurasi arsitektur Inception V3 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	117
Gambar 4.79 Plot Akurasi arsitektur Inception V3 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	117
Gambar 4.80 Plot <i>loss</i> arsitektur Inception V3 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	118
Gambar 4.81 Plot <i>loss</i> arsitektur Inception V3 dengan menggunakan <i>learning rate</i> 10^{-4} dan 50 <i>epoch</i>	118
Gambar 4.82 <i>Confusion Matrix</i> dengan menggunakan arsitektur Inception V3 dengan menggunakan <i>learning rate</i> 10^{-3} dan 50 <i>epoch</i>	119

Gambar 4.83 <i>Confusion Matrix</i> dengan menggunakan arsitektur Inception V3 dengan menggunakan <i>learning rate</i> 10^{-3} dan <i>50 epoch</i>	120
Gambar 4.84 <i>Confusion Matrix Unseen</i> arsitektur Inception dengan menggunakan <i>learning rate</i> 10^{-3} dan <i>50 epoch</i>	121

DAFTAR TABEL

Tabel 2.1 Penelitian Terkait Teknik Klasifikasi yang Pernah Dilakukan.....	9
Tabel 3.1 Dataset yang digunakan pada klasifikasi penyakit kulit dermatitis atopik dan psoriasis.....	21
Tabel 3.2 Pembagian data yang digunakan pada klasifikasi penyakit kulit dermatitis atopik dan psoriasis.....	22
Tabel 4.1 Hasil Kinerja Evaluasi Model Arsitektur VGG16.....	54
Tabel 4.2 Hasil Kinerja Evaluasi Model Arsitektur ResNet50.....	62
Tabel 4.3 Hasil Kinerja Evaluasi Model Arsitektur MobileNet.....	70
Tabel 4.4 Hasil Kinerja Evaluasi Model Arsitektur DenseNet 121.....	78
Tabel 4.5 Hasil Kinerja Evaluasi Model Arsitektur Xception.....	86
Tabel 4.6 Hasil Kinerja Evaluasi Model Arsitektur VGG19.....	93
Tabel 4.7 Hasil Kinerja Evaluasi Model Arsitektur ResNet101.....	99
Tabel 4.8 Hasil Kinerja Evaluasi Model Arsitektur MobileNetV2.....	104
Tabel 4.9 Hasil Kinerja Evaluasi Model Arsitektur DenseNet 201.....	110
Tabel 4.10 Hasil Kinerja Evaluasi Model Arsitektur Inception V3.....	116
Tabel 4.11 Hasil Pengujian Klasifikasi Penyakit Kulit Dermatitis Atopik dan Psoriasis dengan Menggunakan Metode <i>Convolutional Neural Network</i>	122
Tabel 4.12 Perbandingan Hasil Klasifikasi Penyakit Kulit Dermatitis Atopik dengan Psoriasis.....	123

DAFTAR LAMPIRAN

- LAMPIRAN 1.** Form Konsultasi Tesis
- LAMPIRAN 2.** Lembar Revisi Ujian Proposal Tesis
- LAMPIRAN 3.** Lembar Revisian Ujian Tesis
- LAMPIRAN 4.** Hasil Pengecekan *Software Ithenticate/Turniting*
- LAMPIRAN 5.** Publikasi Ilmiah
- LAMPIRAN 6.** *Source Code Python*

BAB I

PENDAHULUAN

Pada bab ini berisi latar belakang dilakukannya penelitian yang berjudul: “Klasifikasi penyakit kulit dermatitis atopik dengan menggunakan *convolutional neural network*”. Kemudian dari latar belakang tersebut dapat dirumuskan permasalahan yang akan diangkat, agar permasalahan tidak meluas maka diberikan batasan masalah. Kemudian diberikan tujuan dan manfaat dari penelitian yang dibuat, dan metodologi yang digunakan dalam penelitian tersebut.

1.1.Latar Belakang

Kulit merupakan salah satu bagian tubuh yang memainkan peran yang cukup besar dalam penampilan fisik manusia. Selain itu, kulit juga merupakan organ terbesar dari tubuh manusia, dengan berat antara enam sampai sembilan pon dan luas permukaan sekitar dua meter persegi. Kulit juga berfungsi untuk memberikan perlindungan terhadap jamur, infeksi, bakteri, alergi, virus serta mengontrol suhu tubuh (Yadav, Narang, utpal, 2016).

Penyakit kulit atau berubahnya tekstur kulit, sangat umum terjadi saat ini. Dampak yang dapat disebabkan oleh penyakit kulit dapat bervariasi, mulai dari gatal - gatal, iritasi, bahkan hingga menyebabkan menurunnya sistem kekebalan, komplikasi dan yang paling parah adalah dapat menyebabkan terjadinya kanker kulit. Kerusakan kulit atau sebuah situasi yang mengubah tekstur kulit dapat menghasilkan gejala seperti bengkak, terbakar, kemerahan dan gatal (Rees, 2006). Beberapa penyakit kulit yang ditemukan pada manusia menyebabkan dampak yang sederhana dan mudah dipulihkan. Namun, dampak lainnya sangat berbahaya dan mungkin tidak dapat disembuhkan. Oleh karena itu, cukup penting untuk memberikan perhatian pada kulit yang juga merupakan salah satu organ penting dalam tubuh manusia. Akan tetapi, diagnosis penyakit kulit ternyata cukup rumit, khususnya ketika dua atau lebih penyakit menggambarkan gejala yang sama atau serupa, oleh karena itu dibutuhkan dokter kulit dengan pengalaman kulit yang luas tentang penyakit kulit (Rosenbeum et al, 2017). Dua dari beberapa penyakit kulit yang memiliki gejala yang serupa adalah dermatitis atopik dan psoriasis.

Dermatitis atopik adalah salah satu penyakit kulit yang biasanya berkembang di daerah fleksor seperti: leher, siku bagian dalam dan di belakang lutut. Gejalanya ditunjukkan dengan eksim di mana bercak kulit menjadi meradang (Leung, Yassky). Menurut Alam et al (2016) Dermatitis atopik telah menjadi masalah bagi 20% bayi dan 3% orang dewasa di seluruh dunia. Berdasarkan penelitian tersebut dapat dikatakan bahwa penyakit Dermatitis Atopik lebih banyak terjadi pada bayi dan anak – anak dibandingkan dengan orang dewasa. Hal ini tidak jauh berbeda dengan Psoriasis. Psoriasis paling umum terjadi pada anak-anak dibandingkan orang dewasa (Pinson, 2021). Selain itu, Penyakit kulit Dermatitis atopik dan Psoriasis merupakan peradangan penyakit kulit kronis dengan aspek-aspek yang hampir sama, termasuk kesamaan dalam karakteristik, penampakan, dan gejala (Griffith, 2017). Kesamaan dalam beberapa aspek pada penyakit Dermatitis atopik dan Psoriasis inilah yang menyebabkan sering terjadi kesalah diagnosis pada keduanya.

Metode yang dapat digunakan untuk meminimalisasi kesalahan diagnosis pada penyakit Dermatitis atopik dan Psoriasis ini adalah dengan menggunakan kecerdasan buatan. Penggunaan kecerdasan buatan telah mengalami peningkatan yang luar biasa di dalam bidang kesehatan terutama dalam diagnosa penyakit kulit dan penyakit lainnya (Pinson, 2021). Salah satu metode kecerdasan buatan yang paling sering di gunakan di dalam bidang kesehatan terutama dalam diagnosa suatu penyakit adalah *Convolutional Neural Network* (CNN).

Beberapa penelitian telah menggunakan *Convolutional Neural Network* (CNN) dalam bidang pengenalan dan klasifikasi citra. Selain itu, berbagai jenis arsitektur CNN juga telah di implementasikan di berbagai sistem klasifikasi penyakit kulit. Studi dan penelitian yang dilakukan sebelumnya telah berhasil dilakukan dalam mengklasifikasikan penyakit kulit melalui teknik pengolahan citra dan algoritma yang berbeda seperti *Support Vector Machine* (Rosenbeum et al, 2017), *Gray-Level Occurrence Matrix* (Pinson, 2021), Jaringan Syaraf Tiruan (Eichenfield et al, 2015) dan banyak lagi. Saat ini, studi dan penelitian di bidang *Convolutional Neural Network* juga telah dikembangkan untuk klasifikasi penyakit kulit yang lebih akurat dengan menggunakan arsitektur yang berbeda,

antara lain dengan menggunakan arsitektur AlexNet oleh Liao et al. untuk klasifikasi penyakit kulit yang menghasilkan skor mAP atau 0,70 untuk klasifikasi *multiple class* (Liao et al, 2016). Penelitian lain yang menggunakan metode CNN untuk klasifikasi enam penyakit kulit umum menggunakan arsitektur struktur *nested residual* yang menghasilkan akurasi 65,8%. Studi lain juga telah membandingkan beberapa arsitektur yang berbeda seperti VGG-16, GoogleNet, ResNet-50 dan ResNext-50 dan telah mencapai kinerja yang lebih baik untuk akurasi keseluruhan yaitu, psoriasis, eksim, nevus dan kelas karsinoma basal. Untuk kelas eksim dan psoriasis, Zhou et. Al. telah mencapai akurasi 75,3% dan 55,2%(Zhou et. Al). Penelitian serta studi sebelumnya tersebut telah membuktikan kemampuannya dalam mendeteksi lesi kulit menggunakan berbagai model dan arsitektur CNN (B. Harangi, Baran and Hajdu, 2018). Melalui pengembangan teknik *deep learning* dan *image processing*, metode invasif dapat diminimalisir dalam menentukan penyakit kulit (Linsangan, Adtoon and Torres, 2018). Namun akurasi dalam menentukan lesi kulit menggunakan CNN berada pada level rata-rata (Kawahara et al, 2019). Salah satu faktor yang mempengaruhi hasil akurasi CNN adalah kedalamannya dimana gradien menghilang saat jaringan semakin dalam (Erhan et al, 2014). Faktor lainnya adalah adanya varians pada *training set* yang berarti perlunya ukuran *training set* yang lebih besar (Shin et al, 2016). Pengembangan sistem yang lebih baik dapat meningkatkan akurasi dalam menentukan lesi kulit dapat membantu mengidentifikasi penyakit kulit dengan lebih baik terutama antara Dermatitis atopik dan Psoriasis yang memiliki kesamaan aspek paling banyak (Withana and Fernando, 2014).

Dalam penelitian ini, kami melakukan percobaan menggunakan CNN dengan menggunakan 10 arsitektur yaitu VGG-16, VGG-19, ResNet 50, ResNet 101, MobileNet, MobileNet V2, DenseNet 121, DenseNet 201, Exception dan Inception V3 serta model yang berbeda sehingga didapatkan arsitektur dan model yang memberikan hasil terbaik dalam pengklasifikasian penyakit kulit Dermatitis atopik dan Psoriasis.

1.1.Perumusan Masalah

Berdasarkan latar belakang yang telah dijelaskan, maka perumusan masalah pada penelitian ini yaitu “Bagaimana mendapatkan arsitektur yang sesuai untuk mengklasifikasi penyakit Dermatitis Atopik dan Psoriasis dengan menggunakan metode *Convolutional Neural Network* berdasarkan dataset gambar penderita penyakit Dermatitis atopik dan Psoriasis?”. Dalam penelitian ini, basis data disiapkan dan disediakan oleh *DermNet*, *DermIS* dan *DermatoWeb* yang selanjutnya digunakan untuk melatih dan mendeteksi dengan menggunakan metode *Convolutional Neural Network*. Dari rumusan masalah tersebut, maka dapat diuraikan menjadi :

1. Bagaimana mendapatkan arsitektur yang sesuai dari berbagai macam model arsitektur untuk mengklasifikasikan penyakit kulit Dermatitis atopik dan Psoriasis dengan menggunakan metode *Convolutional Neural Network*?
2. Bagaimana merancang model klasifikasi yang dapat meningkatkan akurasi klasifikasi penyakit kulit Dermatitis atopik dan Psoriasis dengan menggunakan metode *Convolutional Neural Network*?
3. Bagaimana mengukur kinerja pengklasifikasi yang optimal dalam hal nilai akurasi, presisi, dan *recall*?

1.2.Batasan Masalah

Batasan masalah dalam sistem klasifikasi lesi kulit yang dirancang pada tesis ini adalah:

1. Sistem hanya berupa simulasi untuk mengklasifikasi lesi kulit.
2. Dataset yang digunakan sebaga input dari sistem jaringan yang dibuat merupakan data gambar yang disiapkan dan disediakan oleh *DermNet*, *DermIS* dan *DermatoWeb*.

1.3.Tujuan dan Manfaat

Secara umum tujuan dari penelitian ini adalah untuk mendapatkan model arsitektur yang paling sesuai untuk klasifikasi penyakit kulit Dermatitis atopik dan

Psoriasis dengan menggunakan metode *Convolutional Neural Network* berdasarkan dataset penyakit kulit Dermatitis Atopik dan Psoriasis. Adapun tujuan yang ingin dicapai pada penelitian ini adalah :

1. Membuat pra-pengolahan dataset untuk mengklasifikasikan penyakit kulit Dermatitis atopik dan Psoriasis dengan menggunakan metode *Convolutional Neural Network*.
2. Mendapatkan model arsitektur terbaik untuk mengklasifikasi penyakit kulit Dermatitis Atopik dan Psoriasis dengan menggunakan metode *Convolutional Neural Network*.
3. Mengukur kinerja pengklasifikasian yang optimal dalam hal nilai akurasi, presisi, dan *recall*.

1.4 Sistematika Penulisan

Untuk lebih memudahkan dalam menyusun tesis ini dan memperjelas isi dari setiap bab yang ada pada laporan ini, maka dibuatlah sistematika penulisan sebagai berikut :

1. BAB I Pendahuluan

Bab ini berisi tentang latar belakang, rumusan masalah, batasan masalah, tujuan, manfaat, metodologi penelitian, dan sistematika penulisan.

2. BAB II Tinjauan Pustaka

Bab ini berisi tentang seluruh penjelasan mengenai landasan teori yang berhubungan dengan permasalahan yang dibahas pada penulisan tesis ini.

3. BAB III Metodologi Penelitian

Bab ini berisi penjelasan secara bertahap dan terperinci tentang langkah-langkah (metodologi) yang digunakan untuk membuat kerangka berfikir dan kerangka kerja dalam menyelesaikan tesis.

4. BAB IV Analisa dan Pembahasan

Bab ini berisi tentang analisa dan pembahasan dari tiap – tiap blok diagram perencanaan rangkaian dan data – data hasil pengukuran.

5. BAB V Kesimpulan

Bab ini berisi kesimpulan tentang hasil yang telah diperoleh serta merupakan jawaban dari tujuan yang ingin dicapai pada bab 1 (pendahuluan).

DAFTAR PUSTAKA

- A. Krizhevsky, I. Sutskever, G. Hinton. 2012. *ImageNet Classification with Deep Convolutional Neural Networks*. Neural Information and Processing Systems.
- A. Kawahara, S. Daneshvar, G. Argenziano and G. Hamarneh. 2019. *SevenPoint Checklist and Skin Lesion Classification Using Multitask Multimodal Neural Nets*. IEEE Journal of Biomedical and Health Informatics. Vol. 23. No. 2. pp. 538-546.
- B. Harangi, A. Baran and A. Hajdu. 2018. *Classification Of Skin Lesions Using An Ensemble Of Deep Neural Networks*. IEEE Engineering in Medicine and Biology Society (EMBC). Honolulu. pp. 2575-2578.
- C. Griffiths, P. Kerkhof, M. Czernacka-Operacz. 2017. *Psoriasis and atopic dermatitis*. Dermatol Ther. pp. 31–41.
- C. Szegedy. 2015. *Going deeper with convolutions*. IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston. pp. 1-9.
- D. Erhan, C. Szegedy, A. Toshev and D. Anguelov. 2014. *Scalable Object Detection Using Deep Neural Networks*. IEEE Conference on Computer Vision and Pattern Recognition. pp. 2155-2162.
- D.Y. Leung, E. Guttman-Yassky. *Deciphering the complexities of atopic dermatitis: shifting paradigms in treatment approaches*. J Allergy Clin Immunol. pp. 134:769–779.
- L.F. Eichenfield, M. Boguniewicz, E.L. Simpson, J.J. Russell, J.K. Block, S.R. Feldman, A.R. Clark, S. Tofte, J.D. Dunn, A.S. Paller. 2015. *Translating atopic dermatitis management guidelines into practice for primary care providers*. Pediatrics. pp.136:554–565.

- H. Liao, Y. Li, J. Luo. 2016. *Skin disease classification versus skin lesion characterization: Achieving robust diagnosis using multi-label deep neural networks*. 23rd International Conference on Pattern Recognition (ICPR). Cancun. pp. 355-360.
- H. Shin et al. 2016. *Deep Convolutional Neural Networks for ComputerAided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning*. IEEE Transactions on Medical Imaging. pp. 1285-1298.
- H. Zhou, F. Xie, Z. Jiang, J. Liu, S. Wang and C. Zhu. 2017. *Multiclassification of skin diseases for dermoscopy images using deep learning*. IEEE International Conference on Imaging Systems and Techniques (IST). Beijing. pp. 1-5.
- J. A. Galindo and M. V. Caya. 2018. *Development of Street Lighting System with Object Detection*. IEEE 10th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM). Baguio City: Philippines. pp. 1-5.
- J. M. G Aglibut, L. L. Alonzo, M. F. B. Coching, J. L. Torres, & N. B. Linsangan. 2017. *Skin Disease Identification System using Gray Level Cooccurrence Matrix*. Proceedings of the 9th International Conference on Computer and Automation Engineering – ICCAE. pp. 136-140.
- K. He, X. Zhang, S. Ren, et al. 2016. *Deep Residual Learning for Image Recognition*. pp. 770- 778.
- K. Nguyen, C. Fookes and S. Sridharan. 2015. *Improving deep convolutional neural networks with unsupervised feature learning*. IEEE International Conference on Image Processing (ICIP). Quebec City. pp. 2270-2274.
- L. C. De Guzman, R. P. C. Maglaque, V. M. B. Torres, S. P. A. Zapido and M. O. Cordel. 2015. *Design and Evaluation of a Multi-model, Multi-level Artificial Neural Network for Eczema Skin Lesion Detection*. 3rd International

Conference on Artificial Intelligence, Modelling and Simulation (AIMS).
Kota Kinabalu. pp. 42-47.

M. N. Alam, T. T. K. Munia, K. Tavakolian, F. Vasefi, N. MacKinnon and R. Fazel-Rezai. 2016. *Automatic detection and severity measurement of eczema using image processing*. 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Orlando. pp. 1365-1368.

N. B. Linsangan, J. J. Adtoon and J. L. Torres. 2018. *Geometric Analysis of Skin Lesion for Skin Cancer Using Image Processing*. IEEE 10th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM). Baguio City: Philippines. pp. 1-5.

N. Hameed, A. Shabut and M. A. Hossain, "A Computer-aided diagnosis system for classifying prominent skin lesions using machine learning," 2018 10th Computer Science and Electronic Engineering (CEECE), Colchester, United Kingdom, 2018, pp. 186-191.

Rees JL, schoffield OMV. 2006. *Skin disease*. Davidson's Principles and practice of Medicine: 1049–1080.

Rosenbaum BE, Klein R, Hagan PG, Seadey MY, Quarcoo NL, et al. 2017. *Dermatology in Ghana: A retrospective review of skin disease at the Korle Bu Teaching Hospital Dermatology Clinic*. Pan Afr Med J 26: 125.

U. Withana and P. Fernando, "Differential diagnosis of eczema and psoriasis using categorical data in image processing," 2017 Seventeenth International Conference on Advances in ICT for Emerging Regions (ICTer), Colombo, 2017, pp. 1-6.

R. Pinson. *Psoriasis in children*. Auckland, N.Z. Vol. 6 121- 129.

- S. T. A. Aberin and J. C. d. Goma, "Detecting Periodontal Disease Using Convolutional Neural Networks," 2018 IEEE 10th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM), Baguio City, Philippines, 2018, pp. 1-6.
- S. Xie, R. Girshick, P. Dollr, et al., "Aggregated Residual Transformations for Deep Neural Networks," Computer Vision and Pattern Recognition, 2016.
- U. Withana and P. Fernando, "Differential diagnosis of eczema and psoriasis using categorical data in image processing," 2017 Seventeenth International Conference on Advances in ICT for Emerging Regions (ICTer), Colombo, 2017, pp. 1-6.
- Yadav N, Narang VK, Utpal S. 2016. *Skin diseases detection models using image processing : A survey*. Int J Com Appl 137: 34–39.
- Z. Ge et al. 2017. *Exploiting local and generic features for accurate skin lesions classification using clinical and dermoscopy imaging*. IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017). Melbourne. pp. 986-990.
- Karen Simonyan dan Andrew Zisserman, "Jaringan Konvolusi Sangat Dalam untuk Pengenalan Gambar Skala Besar," arXiv (2014), <https://arxiv.org/abs/1409.1556>
- He, K., Zhang, X., Ren, S., & Sun, "Deep Residual Learning for Image Recognition Kaiming.," IIEE, vol. 32(5), 428, 2015, <https://doi.org/10.1246/cl.2003.428>.