

Klasifikasi Penyakit Berdasarkan Warna Kuku Menggunakan Pengolahan Sinyal Digital (*Classification Of Diseases Based On Nail Color Using Digital Signal Processing*)

1st Muhammad Obi Nugraha
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
Muhammadobi@telkomuniversity.ac.id

2nd Rita Purnamasari
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
ritapurnamasari@telkomuniversity.ac.id

3rd Suci Aulia
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
sucia@telkomuniversity.ac.id

Abstrak—Pada manusia, berbagai penyakit sistemik dan dermatologis dapat dengan mudah didiagnosis dengan pemeriksaan kuku kedua tangan dan kaki. Banyak penyakit kuku telah ditemukan sebagai tanda-tanda awal dari berbagai penyakit sistemik yang mendasar. Warna, tekstur atau perubahan bentuk pada kuku adalah gejala dari berbagai Penyakit terutama yang mempengaruhi kuku. Masalah umum yang terjadi masih banyak orang yang tidak tahu bahwa perubahan kuku dapat mengindikasikan kesehatan manusia, yang dapat dilihat langsung dari perubahan kuku dan lunula atau biasa disebut bulan sabit yang terdapat pada kuku (*half moon fingernails*). Berdasarkan permasalahan umum yang terjadi maka dibuatlah suatu sistem yang dapat memprediksi suatu penyakit dengan memanfaatkan *image processing* sebagai solusinya. Dari proses *image processing* tersebut maka suatu citra dapat dikelompokkan berdasarkan kebutuhan medis yang diperlukan yang dapat menganalisis kuku manusia Hasil yang didapatkan dari penelitian untuk klasifikasi tiga kelas penyakit kuku yaitu *Terry's Nails*, *Yellow Nail Syndrom*, dan yang terakhir *Muehrcke lines* mendapat nilai akurasi 94% dari parameter terbaik, yaitu *epoch* = 25 dan *batch* = 30. Menggunakan data sebesar 166 data citra yg di uji.

Kata Kunci — kuku, *image processing*, *convolutional neural network*, *VGG16net*

Abstract —*In humans, various systemic and dermatological diseases can be easily diagnosed by examination of the nails of both hands and*

feet. Many hoof diseases have been found as early signs of various underlying systemic diseases. Color, texture or deformation of the nails are symptoms of various Diseases especially those that affect the nails. A common problem that occurs is still many people who do not know that changes in nails can indicate human health, which can be seen directly from changes in nails and lunula or commonly called crescents found in the nails (half moon fingernails). The lunula pattern found in the nails can tell the condition of the body that is good or the condition is not good, such as the pattern of lunula that is large, small or has no lunula at all. Based on the general problems that occur, a system is created that can predict a disease by utilizing image processing as a solution. From the image processing process, an image can be grouped based on the necessary medical needs that can analyze human nails The results obtained from the study for the classification of three classes of nail diseases, namely Terry's Nails, Yellow Nail Syndrom, and finally Muehrcke lines got an accuracy value of 94% of the best parameters, namely epoch = 25 and batch = 30. Using data of 166 image data that was tested

Keyword — *nails, image processing, convolutional neural network, VGG16net*

I. PENDAHULUAN

Pengolahan sinyal digital, telah menjadi teknologi utama untuk menciptakan, memproses, mentransmisikan dan

menyimpan informasi dalam berbagai bentuk seperti audio, video, teks, gambar, sebagai contoh pengolahan sinyal digital seperti CS Radar[1], identifikasi objek, Pengenalan gerakan tangan menggunakan transformasi wavelet diskrit[2], jika dikelompokkan, kita dapat menyebutnya sebagai bentuk multimedia. Pengolahan citra digital dapat didefinisikan sebagai akuisi dan pemrosesan informasi visual oleh komputer [3], pengolahan citra digital memiliki spektrum aplikasi yang luas, salah satunya yaitu dalam bidang *biomedical engineering*. Oleh karena itu meningkatnya teknologi dalam bidang *biomedical engineering* semakin banyak digunakan dalam diagnosis klinis.

Manfaat dari pengolahan citra digital memiliki spektrum aplikasi yang luas salah satunya, kita dapat membuat suatu sistem yang ditujukan untuk proses klasifikasi suatu jenis penyakit yang dimana klasifikasi tersebut digunakan sebagai sarana dalam mendiagnosis suatu penyakit. Masalah umum yang terjadi masih banyak orang yang tidak tahu bahwa perubahan kuku dapat mengindikasikan kesehatan manusia, dalam beberapa kasus pasien dengan penyakit tertentu baru mengetahui bahwa perubahan kuku tersebut disebabkan oleh penyakit yang sedang pasien idap seperti kasus anak berusia 16 tahun yang memiliki *Terry's Nails*, pada hasil biopsi bahwa anak tersebut menderita sirosis sekunder hepatitis *autoimun* [7]. Beberapa penyakit kuku bisa menjadi tanda dari salah satu gejala suatu penyakit, Oleh karena itu, penting untuk memperhatikan kondisi kuku dan mengenali beragam penyakit yang dapat menyerang kuku, faktor lain yang mengindikasikan pentingnya memperhatikan warna kuku adalah adanya langkah awal untuk mengetahui gejala dari kelainan kuku terhadap kesehatan[8]. Dengan implementasi teknologi *deep learning* dalam *digital signal processing* untuk mengolah suatu *image* dengan meniru proses kerja otak manusia dibuatlah suatu sistem yang dapat memprediksi suatu penyakit dengan mengklasifikasikan kuku yang sepenuhnya berbasis komputer. Maka pada tugas akhir ini didesain suatu sistem klasifikasi tiga kelas penyakit kuku yaitu *Terry nails*, *Yellow Nail Syndrom*, dan *Muehrcke Lines* berbasis pengolahan citra dengan teknologi *deep learning* menggunakan *Convolutional Neural Network (CNN)*. Metode CNN mempunyai beberapa jenis arsitektur,

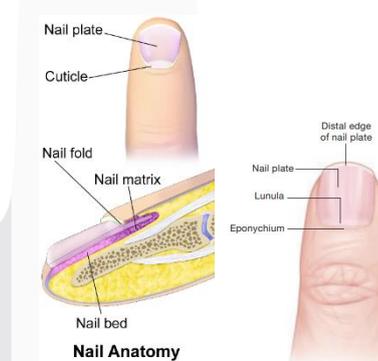
arsitektur yang digunakan pada penelitian kali ini adalah *VGG16net*. Pada proses pembelajaran, arsitektur *VGG16net* menggunakan *16 Layer*. *VGG16net* ditandai oleh lapisan konvolusi 3×3 .

Dengan adanya sistem klasifikasi penyakit kuku ini, diharapkan dapat menjadi sarana penelitian yang mendukung tim medis dalam mengidentifikasi gejala dari suatu penyakit.

II. KAJIAN TEORI

A. Struktur Kuku

Matriks, sering disebut sebagai *matriks unguis*, matriks kuku, atau *onikostroma*, adalah jaringan (atau *matriks germinal*) yang dilindungi kuku. Ini adalah bagian dasar kuku yang berada di bawah kuku dan berisi saraf, getah bening, dan pembuluh darah.[10] *Matriks* menghasilkan sel-sel yang menjadi lempeng kuku. Lebar dan ketebalan lempeng kuku ditentukan oleh ukuran, panjang, dan ketebalan matriks, sedangkan bentuk tulang ujung jari menentukan apakah lempeng kuku itu datar, melengkung, atau bengkok, matriks akan terus memproduksi sel selama mendapat nutrisi dan tetap dalam kondisi sehat.[11]



GAMBAR 1
STRUKTUR KUKU [11]

The lunula ("bulan kecil") adalah bagian yang terlihat dari matriks, dasar berbentuk bulan sabit keputihan dari kuku yang terlihat. Lunula paling baik dapat dilihat di ibu jari dan mungkin tidak terlihat di jari kelingking. Dasar kuku adalah kulit di bawah lempeng kuku Seperti semua kulit, itu terbuat dari dua jenis jaringan : dermis yang lebih dalam, jaringan hidup yang meliputi kapiler dan kelenjar, serta epidermis, pada lapisan tepat di bawah lempeng kuku, yang bergerak ke arah ujung jari. Epidermis melekat pada dermis oleh

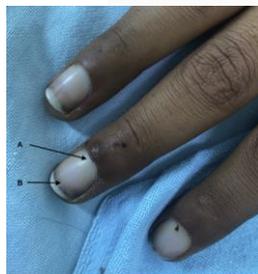
"alur" longitudinal kecil yang disebut puncak *matriks* (*cristae matricis unguis*).[10]



GAMBAR 2
LUNULA PADA KUKU [10]

1. Terry's Nails

Kuku *Terry's* merupakan kondisi fisik dimana kuku jari tangan dan kaki seseorang mengalami perubahan dimana semua kukunya berwarna putih tanpa memiliki lunula atau bulan sabit pada kuku. Ini sering terjadi dalam dalam beberapa kasus penyakit gagal hati, sirosis, diabetes mellitus, gagal jantung kongestif, hipertiroidisme, atau malnutrisi. Delapan puluh persen pasien dengan penyakit hati yang parah memiliki kuku *Terry's* [12]



GAMBAR 2
PASIEN DENGAN KUKU *TERRY'S* [7]

Dalam contoh kasus anak berusia 16 tahun ditemukan kuku *terry's* dengan kondisi warna pada kuku berwarna putih tanpa lunula, dilakukan evaluasi lebih lanjut, termasuk hati, biopsi mengungkapkan bahwa anak tersebut menderita sirosis sekunder hepatitis autoimun [7].

2. Yellow Nail Syndrome

Sindrom Kuku Kuning adalah kelainan yang sangat langka. YNS didiagnosis berdasarkan triad yang menghubungkan kuku kuning, perubahan warna, manifestasi

paru (batuk kronis, bronkiektasia, efusi pleura) dan limfedema ekstremitas bawah. Sinusitis kronis sering dikaitkan dengan tiga serangkai itu.[13]



GAMBAR 3
SINDROM KUKU KUNING [13]

3. Muehrcke line

Munculnya garis *Muehrcke line* dikaitkan secara khusus dengan hipoalbuminemia yang ditandai (albumin serum $\leq 2,2$ g / dL) yang menunjukkan penurunan sintesis protein, yang dapat terjadi selama periode stres metabolik (misalnya infeksi sistemik, trauma, AIDS, kemoterapi), atau dalam keadaan hipoalbuminemik seperti sindrom nefrotik atau kekurangan protein makanan. Mereka juga terlihat pada pasien dengan penyakit ginjal stadium akhir pada hemodialisis, penyakit *Hodgkin*, *pellagra*, dan anemia sel sabit. [14]



GAMBAR 5
MUEHRCKE LINE[14]

B. Deep Learning

Deep Learning adalah salah satu teknik dalam *machine learning* yang memanfaatkan banyak lapisan pemrosesan informasi nonlinier untuk melakukan ekstraksi fitur, pengenalan pola, dan klasifikasi. *deep learning* adalah pendekatan pemecahan masalah untuk sistem pembelajaran komputer yang menggunakan konsep hierarkis.

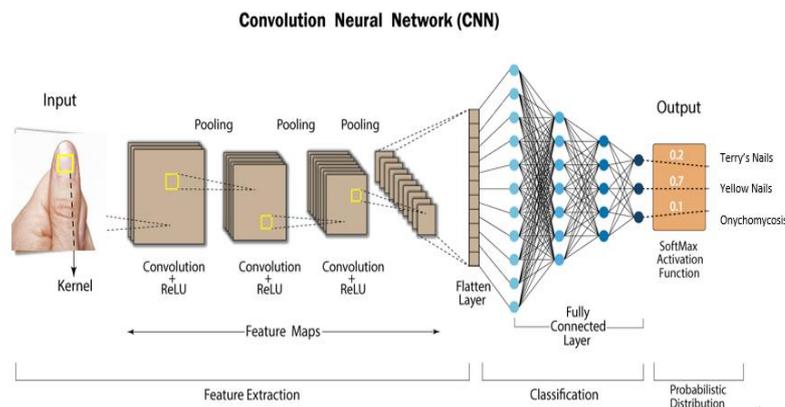
Konsep hierarki membuat komputer dapat belajar kompleks, dengan menggabungkan dari konsep yang lebih sederhana, jika

digambarkan sebagai grafik bagaimana konsep dibangun di atas konsep lain, grafik ini akan mempunyai banyak lapisan, itu adalah alasannya disebut sebagai *deep learning* [15]

C. Convolutional Neural Network

Convolutional neural network adalah jenis jaringan saraf tiruan yang digunakan dalam pengenalan dan pemrosesan gambar.

convolutional neural network meniru cara sel-sel saraf kita berkomunikasi dengan *neuron* yang saling berhubungan dan *convolutional neural network* memiliki arsitektur yang sama. Apa yang membuatnya unik dari jaringan saraf lain adalah operasi konvolusional yang menerapkan filter pada setiap bagian dari input sebelumnya untuk mengekstraksi pola dan *features maps*. [16]



GAMBAR 4
CONVOLUTIONAL NEURAL NETWORK [16]

CNN terdiri dari tiga jenis layer yaitu layer convolutional, layer pooling, dan layer fully connected. Layer convolutional memiliki sekumpulan filter yang dapat menggabungkan seluruh input gambar dan menghasilkan berbagai jenis feature map. Feature map adalah sebuah output yang berupa map yang dihasilkan oleh proses konvolusi. *Layer pooling* mengikuti *layer convolutional* dan digunakan untuk mengurangi ukuran spasial *feature map* dan beban pada komputasi jaringan. *Average pooling* dan *max pooling* adalah dua strategi pengambilan *downsampling nonlinier* yang paling umum digunakan untuk menerjemahkan invarian. Layer *fully connected (FC)* umumnya digunakan di akhir jaringan untuk memastikan bahwa semua neuron di layer tersebut sepenuhnya terhubung ke *activation* di layer 7 sebelumnya dan untuk mengaktifkan *feature map 2D* untuk diubah menjadi *feature map 1D* untuk fitur representasi dan klasifikasi lanjutan [16].

D. Layer CNN

Pada tugas akhir ini, terdapat beberapa layer yang digunakan yang membentuk arsitektur neural network, antara lain:

1. Convolutional Layer

Convolutional Layer merupakan layer inti pada algoritma CNN. Seluruh data yang dimasukkan pada layer ini akan melakukan proses konvolusi dimana dilakukan konversi setiap filter pada seluruh bagian data masukan dan menghasilkan sebuah *activation map* atau feature map. *Filter* yang terdapat pada *Convolutional Layer* memiliki ukuran panjang, tinggi dan tebal sesuai dengan *channel* data masukan. Setiap *filter* akan mengalami pergeseran dan mengalami operasi dot antara data masukan dan nilai dari *filter*. Layer ini secara signifikan mengalami kompleksitas model melalui optimalisasi keluarannya.

2. Pooling Layer

Pooling Layer digunakan untuk *downsampling* pada matriks citra, layer ini biasanya digunakan setelah tahap *Convolutional Layer*. *Pooling layer* terdiri dari sebuah filter dengan ukuran dan stride tertentu. Setiap pergeseran akan ditentukan oleh jumlah stride yang akan digeser pada area *feature map*. Terdapat dua jenis *pooling* yaitu adalah *Max Pooling* dan *Average Pooling*. *Max pooling* mengambil nilai maksimal pada setiap dilakukan pergeseran filter, sedangkan *average pooling* mengambil nilai rata-rata [17]

3. Fully Connected Layer (FC Layer)

FC layer pada CNN pada dasarnya sama seperti FC layer yang terdapat pada neural network lainnya. FC layer adalah lapisan dimana semua neuron aktivasi dari lapisan sebelumnya terhubung semua dengan neuron di lapisan selanjutnya seperti halnya jaringan saraf tiruan biasa. Feature map yang dihasilkan oleh layer sebelumnya berbentuk multidimensional array sehingga sebelum masuk pada tahap fully connected layer, feature map tersebut akan melalui proses flatten atau reshape. Proses flatten menghasilkan sebuah vektor yang akan digunakan sebagai input dari FC layer.

E. Fungsi Aktivasi (Activation Function)

Fungsi aktivasi adalah sebuah fungsi yang mengambil nilai masukan dari sebuah neuron dan mengeluarkan nilai keluaran yang kemudian dilanjutkan ke neuron lain. Fungsi ini juga berguna untuk menambahkan fungsi non linear pada algoritma sehingga model dapat menyelesaikan permasalahan yang kompleks [21]. Berikut merupakan beberapa fungsi aktivasi:

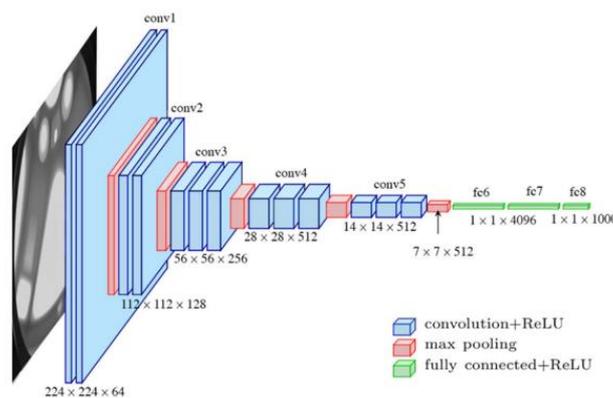
1. ReLU (Rectified Linear Unit) ReLU merupakan operasi untuk mengenalkan non linearitas dan meningkatkan representasi dari model. Nilai keluaran dari neuron bisa dinyatakan sebagai 0 jika inputnya adalah negatif. Namun,

jika nilai input adalah positif maka keluaran dari neuron adalah nilai masukan aktivasi itu sendiri [22].

2. Softmax Fungsi aktivasi softmax umumnya digunakan pada layer terakhir dari sebuah neural network untuk menghitung dan mencari probabilitas kelas target. Fungsi aktivasi softmax digunakan untuk mendapatkan hasil klasifikasi. Fungsi aktivasi menghasilkan nilai yang diinterpretasi sebagai probabilitas yang belum dinormalisasi untuk tiap kelas. Maka dari itu, nilai kelas dihitung dengan menggunakan fungsi softmax [23].

F. Visual Geometry Group-16 Weight layer (VGG16)

VGG16 merupakan model CNN dari Karen Simonyan dan Andrew Zisserman [16]. Model ini menunjukkan bahwa deep networks merupakan komponen penting untuk kinerja yang baik. Arsitektur VGG16 memiliki total 16 weight layer yang terdiri dari Convolutional layer dan FC yang terdapat pada Gambar 2.8. Keunggulan model ini menampilkan arsitektur yang sangat homogen yang hanya melakukan convolutional 3x3 dan pooling 2x2 dari awal hingga akhir. Kelemahan dari VGG16 adalah lebih berat untuk mengevaluasi dan menggunakan lebih banyak memori dan parameter mencapai 138 juta.



GAMBAR 5 ARSITEKTUR VGG16

G. Performansi sistem

Akurasi didefinisikan sebagai tingkat kedekatan antara nilai prediksi dengan nilai

aktual. Selain pengukuran tingkat akurasi, dilakukan juga parameter performansi sistem lainnya seperti precision, recall dan f-measure. Precision merupakan tingkat

ketepatan antara informasi yang diminta oleh pengguna dengan jawaban yang diberikan oleh sistem. Dan kemudian *Recall* adalah tingkat keberhasilan sistem dalam menemukan kembali sebuah informasi, yang terakhir yaitu *F-Measure* merupakan salah satu perhitungan evaluasi dalam informasi temu kembali yang mengkombinasikan *recall* dan *precision*. Nilai *recall* dan *precision* pada suatu keadaan dapat memiliki bobot yang berbeda. Ukuran yang menampilkan timbal balik antara *Recall* dan *Precision* adalah *F-Measure* yang merupakan bobot *harmonic mean* dan *recall* dan *precision*. Berikut merupakan persamaan untuk mencari nilai *accuracy*, *precision*, dan *recall*

$$\text{Accuracy} = \frac{TP+TN}{TP+FP+FN+TN} \times 100\% \quad 1$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad 2$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad 3$$

$$\text{F-Measure } \mathcal{F}1 - \text{Score} = 2 \times \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad 4$$

Penjelasan:



GAMBAR 9
DESAIN SISTEM

Proses awal dalam pembuatan tugas akhir ini yaitu menggunakan proses training data. Pada proses training data, mempunyai fungsi untuk pembuatan model yang nantinya digunakan untuk pengujian testing data, Parameter yang dilihat pada pengukuran tingkat keberhasilan model ini adalah nilai akurasi.

Pada proses *preprocessing* dan model pelatihan, *training data* dan *testing data* menggunakan Keras pada *python* yang merupakan *library* jaringan syaraf tiruan dengan *tensorflow* dan menggunakan program *Google Colab*. Untuk *data training* diambil sebanyak 80% citra dari semua dataset yang ada, lalu pada data testing, hanya diambil sebanyak 20% citra dari dataset yang ada dengan format **.jpg dan *.png*. Berikut adalah alur sistem proses

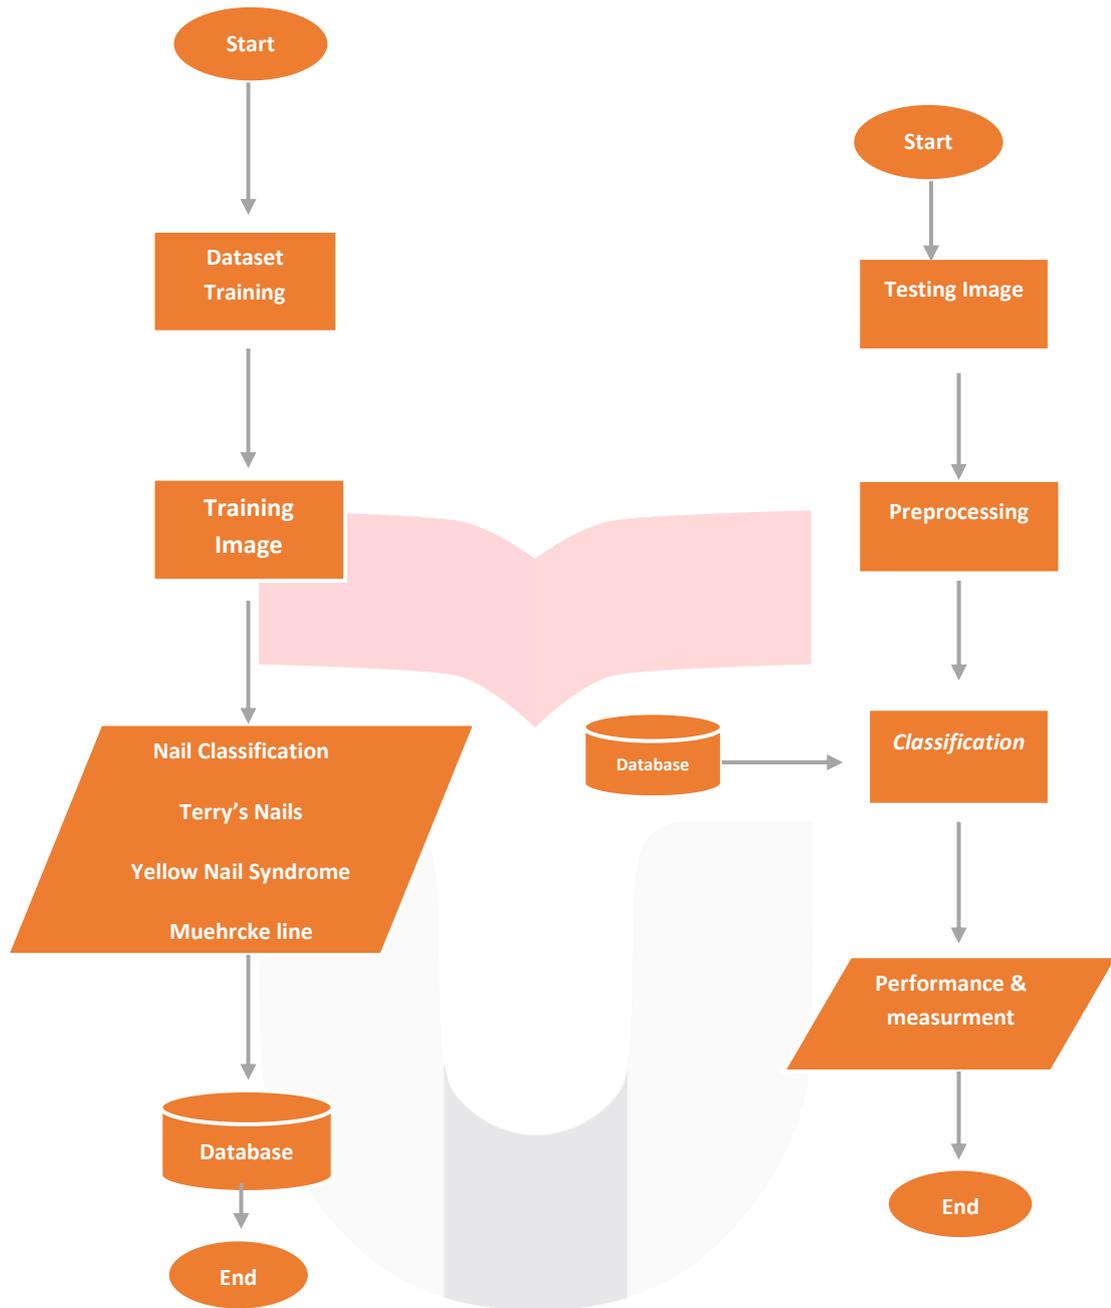
1. TP adalah *True Positive*, yaitu jumlah data positif yang terklasifikasi dengan benar oleh sistem.
2. TN adalah *True Negative*, yaitu jumlah data negatif yang terklasifikasi dengan benar oleh sistem.
3. FN adalah *False Negative*, yaitu jumlah data negatif namun terklasifikasi salah oleh sistem.
4. FP adalah *False Positive*, yaitu jumlah data positif namun terklasifikasi salah oleh sistem

III. METODE

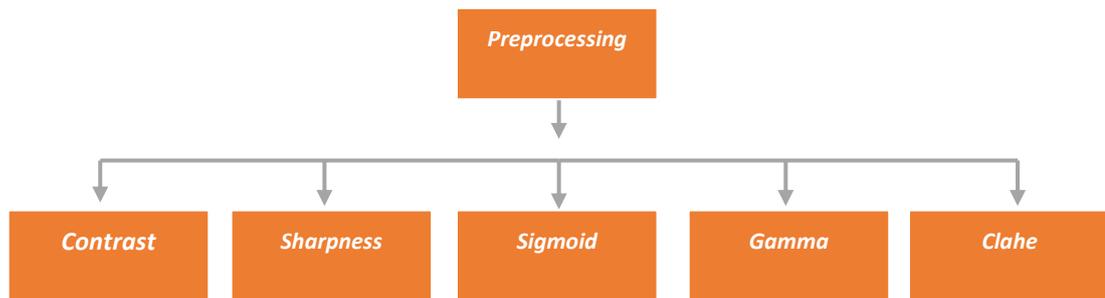
A. Desain Sistem

Pada tugas akhir ini yang telah dibuat, menggunakan suatu metode yang digunakan untuk proses klasifikasi penyakit terhadap kuku jari adalah *Convolutional Neural Network (CNN)*. Adapun arsitektur *CNN* yang digunakan yaitu *VGG16*. Dalam arsitektur *VGG16* memiliki total 16 *weight layer* yang terdiri dari *Convolutional layer* dan *Fully Connected layer*. Pada akhirnya, metode dan arsitektur tersebut akan digunakan untuk klasifikasi citra penyakit terhadap warna kuku jari. Berikut ini gambaran umum dari sistem yang di rancang pada tugas akhir ini dapat di lihat pada Gambar 9

training data dan *testing data* dapat dilihat pada Gambar 10.



GAMBAR 10
FLOWCHART PROSES TRAINING DATA DAN TESTING DATA

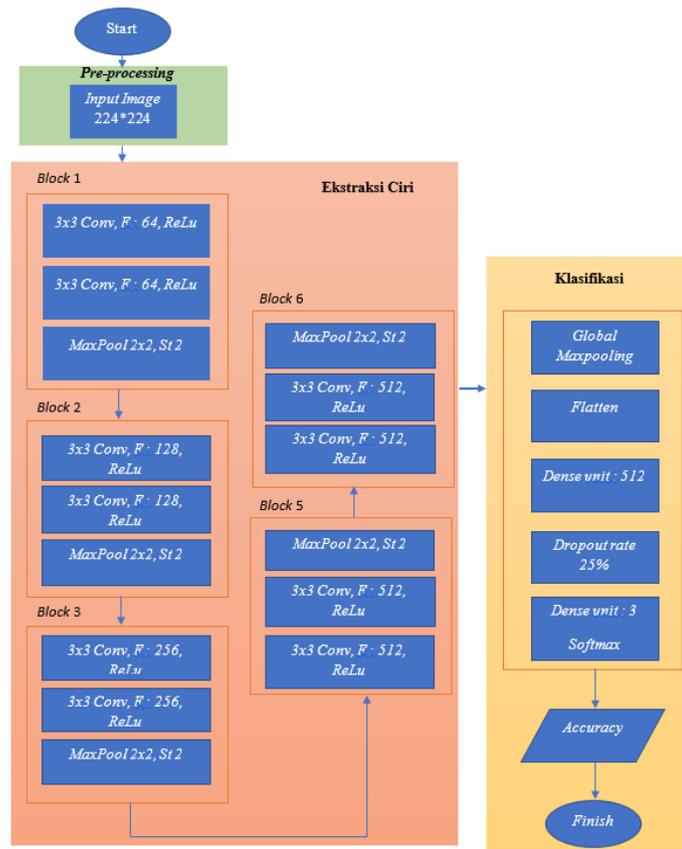


GAMBAR 11
PREPROCESSING

Pada tahap ini dapat dilihat pada Gambar 3.4, merupakan proses yang dapat digunakan pada awal atau akhir pengolahan citra yang mempunyai tujuan sebagai penghasil citra yang lebih baik untuk di proses ke tahap berikutnya. Tahapan *preprocessing* ini meliputi *contrast*, *Sharpness*, *Sigmoid*, *Gamma*, dan yang terakhir yaitu *Clahe* yang dimana semua proses ini sebagai perbaikan kualitas suatu citra atau disebut sebagai *image enhancement*. Proses ini digunakan pada *original image* yang nantinya akan di tambahkan metode dan parameter dari masing-masing metode tersebut. Metode *contrast* dilakukan dengan menaik turunkan parameter *contrast* pada *original image* yang bertujuan untuk meningkatkan nilai akurasi kemudian metode *Sharpness* adalah salah satu proses yang digunakan untuk

menempertajam kualitas citra, yaitu suatu proses yang bertujuan memperjelas tepi pada objek di dalam citra. Metode *Sigmoid corection* pada *image*. dikenal sebagai Penyesuaian Kontras. Fungsi ini mentransformasikan gambar masukan secara piksel setelah menskalakan setiap piksel ke kisaran 0 hingga 1. setelah itu metode *Gamma* proses ini dilakukan untuk mengontrol tingkat kecerahan *image*, dimana *image* dapat terlihat terang maupun terlihat gelap dan yang terakhir metode *contrast limited AHE (clahe)* yang dimana *clahe* melakukan pemerataan histogram pada *image*. Tujuannya digunakan *image enhancement* pada program ini yaitu untuk memperoleh citra yang lebih sesuai digunakan untuk mendapatkan nilai akurasi maksimum dalam proses klasifikasi.

B. Desain model sistem vgg16



GAMBAR 12
DESAIN SYSTEM MODEL VGG16

Dalam *VGG16* mempunyai beberapa tahap, yaitu tahap *Convolutional Layer*, *Activation ReLU Layer*, *Pooling Layer*, *Fully Connected Layer*, dan *Softmax*. Pada Arsitektur *VGG16*, terdapat lima blok layer konvusal sebagai fitur ekstraksi dan blok layer fully connected sebagai klasifikasi. Berikut merupakan penjelasan lengkap mengenai arsitektur *VGG16*:

1. Citra input yang digunakan dengan ukuran yang bervariasi dengan format (*RGB*), maka dilakukan proses *resize* yang merupakan teknik *preprocessing* dengan melakukan perubahan ukuran pada *image*, perubahan pada *image* dapat diperkecil maupun diperbesar. Pada model ini dengan merubah format ukuran dataset menjadi 224x224 sebagai mana parameter bawaan dari *vgg16* hanya dapat mengeksekusi data berukuran 224x224, proses ini tidak menghilangkan isi dari *image* tersebut, hanya merubah skala dari *image* yang di *resize*.
2. Pada blok 1 dan 2, terdapat dua layer konvolusi menggunakan *kernel* berukuran 3x3, dan ditambahkan *ReLU* sebagai fungsi aktivasi, fungsi aktivasi ini yang mengambil nilai masukan dari sebuah *neuron* dan mengeluarkan nilai keluaran yang kemudian dilanjutkan ke *neuron* lain. *ReLU* bertugas untuk mengubah nilai input menjadi nilai positif. Filter pada *layer* konvolusi yang terdapat pada blok 1 berukuran 64, dan filter yang terdapat pada *layer* konvolusi di blok 2 dengan ukuran filter 128, kemudian terdapat juga *pooling layer* dengan teknik max pooling menggunakan *kernel* 2x2 dengan *strides* 2.
3. Selanjutnya pada blok 3, 4, dan 5, terdapat tiga *layer* konvolusi dengan *kernel* berukuran 3x3, dan menggunakan *ReLU* sebagai fungsi aktivasi seperti pada blok 1 dan 2. Filter *layer* konvolusi pada blok 3 berukuran 256 dan filter *layer* konvolusi yang terdapat pada blok

4 dan 5 berukuran 512. kemudian terdapat juga *pooling layer* dengan teknik *max pooling* menggunakan kernel 2x2 dengan strides 2.

4. kemudian terakhir yaitu blok *layer fully connected* terdapat *layer flatten* sebagai nilai masukan dimana *matriks* akan dikonversi menjadi data satu dimensi *single vector*. Setelahnya terdapat proses *dense* fungsi ini untuk menambahkan layer yang *fully connected*. pada blok ini dengan unit sejumlah 512 dan menggunakan *ReLU* sebagai fungsi aktivasi. Pada setiap layer *fully connected* setelahnya terdapat layer *dropout* yang bertugas untuk mencegah *overfitting* akibat neuron yang terlalu bergantung antar satu sama lain, nilai *dropout* sebesar 25%. Terakhir merupakan *layer fully connected* untuk klasifikasi

menggunakan *softmax* yang bertugas untuk menghitung dan mencari probabilitas kelas target. Fungsi aktivasi *softmax* digunakan untuk mendapatkan hasil klasifikasi, dengan unit berjumlah 3 sesuai dengan jumlah kelas pada penyakit kuku yaitu *Terry's Nails*, *Yellow Nails Syndrom*, dan *Muehrckes lines*.

IV. HASIL DAN PEMBAHASAN

A. Hasil pegujian skenario 1

Pengujian skenario 1 merupakan pengujian awal terhadap 166 dataset dari keseluruhan kelas (*Terry's Nails*, *Yellow Nail Syndrome*, *Muehrcke line*). Pengujian tahap awal ini tidak melalui tahap *preprocessing* dengan tujuan untuk mengetahui parameter *epoch* dan *batch* yang paling optimum.



Adapun hasil pengujian ditunjukkan pada.

Gambar 13. Grafik pengaruh epoch dan batch

Dari Gambar 13, dapat dilihat bahwa tingkat akurasi maksimum diperoleh pada nilai $25 < epoch < 30$ dan $batch = 30$. Sehingga nilai minimum $epoch = 25$ dan $batch = 30$ akan digunakan sebagai parameter *VGG-16* pada pengujian selanjutnya.

Pengujian skenario 2 merupakan kelanjutan dari hasil pengujian skenario 1, yaitu mengujikan 166 dataset dengan $epoch=25$ dan $batch=30$. Perbedaannya pada tahap ini dilakukan *preprocessing* terlebih dahulu.

1. *Preprocessing image enhancement* : *Sigmoid*

B. Hasil pengujian skenario 2

Skala numerik epoch dan batch

Accuracy

TABEL.1

Akurasi	Gain	Precision	Recall	F1-score	Waktu Proses
59%	6	70%	59%	58%	1 jam, 33 menit, 11 detik
79%	5	79%	79%	79%	2 jam, 18 menit, 9 detik
76%	4	70%	59%	58%	2 jam, 3 menit, 49 detik
56%	2	41%	51%	43%	1 jam, 28 menit, 49 detik

Dari hasil pengujian klasifikasi penyakit kuku dengan melalui tahapan *preprocessing image enhancement* dengan metode *sigmoid* pada tabel 4.2, diperoleh tingkat akurasi tertinggi 79% pada parameter $gain=5$. nilai akurasi tersebut lebih kecil

dibandingkan dengan pengujian di skenario 1 tanpa tahapan *preprocessing*, yaitu 94%

2. *Preprocessing image enhancement* : *Contrast*

TABEL. 2

Akurasi	Contrast	Precision	Recall	F1-score	Waktu Proses
71%	1.25	72%	68%	66%	1 jam, 37 menit, 58 detik
74%	1.5	72%	71%	69%	1 jam, 49 menit, 32 detik
82%	0.5	82%	82%	82%	2 jam, 17 menit, 11 detik

Pada Pengujian kedua *preprocessing image enhancement*, kali ini pengujian dengan menambahkan *contrast* pada *image*. Dari hasil pengujian klasifikasi penyakit kuku dengan melalui tahapan *preprocessing image enhancement* dengan metode *contrast* pada Tabel 2 pengujian ini dilakukan dengan menaik turunkan *contrast original*

image yang bertujuan untuk meningkatkan nilai akurasi, diperoleh tingkat akurasi tertinggi 82% pada parameter $contrast = 0.5$.

3. *Preprocessing image enhancement* : *Sharpness*

TABEL. 3

Akurasi	Sharpness	Precision	Recall	F1-score	Waktu proses
76%	8	75%	76%	76%	1 jam, 46 menit, 11 detik
82%	7	87%	80%	80%	2 jam, 14 menit, 8 detik
91%	6	91%	90%	91%	2 jam, 23 menit, 43 detik
76%	5	78%	74%	72%	1 jam, 38 menit, 9 detik

Selanjutnya pengujian ketiga *preprocessing image enhancement*, pengujian ketiga ini memberikan gambar yang dipertajam, proses ini dinamakan *sharpness*. Dari hasil pengujian klasifikasi penyakit kuku dengan melalui tahapan *preprocessing image enhancement* dengan

metode *sharpness* pada Tabel 3 diperoleh tingkat akurasi tertinggi 91% pada parameter $sharpness = 6$.

4. *Preprocessing image enhancement* : *Gamma*

TABEL. 4

Akurasi	Gain	Precision	Recall	F1-score	Waktu Proses
76%	1.25	79%	74%	73%	2 jam, 11 menit, 21 detik
79%	1.5	79%	77%	75%	2 jam, 25 menit, 33 detik
82%	1	91%	90%	91%	2 jam, 28 menit, 48 detik
74%	0.5	81%	70%	62%	2 jam, 8 menit, 10 detik

Kemudian pengujian keempat *preprocessing image enhancement* dengan menggunakan metode *gamma correction*, proses ini dilakukan untuk mengontrol kecerahan *image*, dimana *image* dapat

terlihat terang maupun terlihat gelap, dari hasil pengujian klasifikasi penyakit kuku dengan melalui tahapan *preprocessing image enhancement* dengan metode *gamma correction* pada Tabel 4, diperoleh tingkat

akurasi tertinggi 82% pada paramater gain = 1

5. *Preprocessing image enhancement : Clahe*

TABEL. 5

Akurasi	Cliplimit	Precision	Recall	F1-score	Waktu Proses
82%	0.01	79%	74%	73%	2 jam, 16 menit, 11 detik
82%	0.02	79%	77%	75%	2 jam, 14 menit, 8 detik
68%	0.09	74%	70%	66%	2 jam, 3 menit, 21 detik
59%	0.1	64%	59%	60%	1 jam, 52 menit, 4 detik
68%	0.005	91%	90%	91%	2 jam, 7 menit, 48 detik

Pada pengujian terakhir preprocessing image enhancement dengan metode *contrast limited AHE (clahe)* yang dimana clahe melakukan pemerataan histogram pada image, dari hasil pengujian klasifikasi penyakit kuku dengan melalui tahapan *preprocessing image enhancement* dengan metode *clahe* pada Tabel 5 hasil pengujian terbaik terdapat pada nilai *clip limit* 0.01 dan 0.02 diperoleh tingkat akurasi tertinggi 82%.

V. KESIMPULAN

Berdasarkan hasil yang telah diujikan pada bab-bab sebelumnya, dapat disimpulkan bahwa klasifikasi penyakit berdasarkan warna kuku menggunakan pengolahan sinyal digital dengan metode *Convolutional Neural Network* dengan arsitektur *VGG16* mampu mengklasifikasikan berdasarkan kelasnya. Nilai akurasi maksimum pada skenario terbaik dan parameter terbaik. Dapat ditarik kesimpulan sebagai berikut :

1. Skenario 1 tanpa melalui tahapan preprocessing image enhancement Hasil yang didapat pada parameter epoch dan batch yang paling optimum diperoleh pada nilai *epoch* = 25 dan *batch* = 30 dengan memperoleh nilai akurasi 94%
2. Skenario 2 melalui tahapan preprocessing image enhancement Proses optimasi dengan 5 metode pada tahap preprocessing tidak berhasil meningkatkan tingkat akurasi metode *sigmoid* dengan nilai akurasi 79%, metode *contrast*, *gamma*, dan *clahe* memperoleh nilai akurasi 82%, hasil akurasi yang mendekati pengujian skenario 1 yaitu metode sharpness dengan nilai akurasi 91%

A. Saran

Berdasarkan hasil simulasi klasifikasi penyakit berdasarkan warna kuku menggunakan pengolahan sinyal digital, maka penulis dapat mengambil saran sebagai berikut :

1. Kekurangan yang belum dilakukan yaitu menambahkan metode selain yang penulis uji kan pada tahap *preprocessing* untuk menaikkan tingkat akurasi.
2. Menggunakan Teknik dengan memilah antara objek dan background agar mengenali objek secara maksimal, seperti contoh metode segmentasi.
3. Memperbanyak dataset yang akan digunakan untuk penelitian selanjutnya.

REFERENSI

- December 8, 2021, <https://www.kaggle.com/>
- [1] R. Purnamasari, A. B. Suksmono, I. Zakia, and I. J. M. Edward, "Compressive Sampling of Polarimetric Doppler Weather Radar Processing Via Inverse Fast Fourier Transform," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 14, pp. 5269–5284, 2021, doi: 10.1109/JSTARS.2021.3081265
- [2] M. B. Priatama, L. Novamizanti, S. Aulia, and E. B. Candrasari, "Hand gesture recognition using discrete wavelet transform and convolutional neural network," *Bulletin of Electrical Engineering and Informatics*, vol. 9, no. 3, pp. 996–1004, Jun. 2020, doi: 10.11591/eei.v9i3.1977.
- [3] Scott E. Umbaugh. *Digital Image Processing and Analysis*. 3th ed. CRC Press; 2017
- [4] Putra D. *Pengolahan citra digital*. 1th ed. Penerbit Andi; 2010
- [5] S. Loncaric, A. P. Dhawan, D. Cosic, D. Kovacevic, J. Broderick, and T. Brott, "Quantitative intracerebral brain hemorrhage analysis," *Medical Imaging 1999: Image Processing*, vol. 3661, pp. 886–894, May 1999, doi: 10.1117/12.348648.
- [6] R. Rahmadewi and R. Kurnia, "Klasifikasi Penyakit Paru Berdasarkan Citra Rontgen dengan Metoda Segmentasi Sobel", *JNTE*, vol. 5, no. 1, pp. 7–12, Jan. 2016.
- [7] Bolia R, "Terry's Nails in a Child". *Journal of Pediatrics*, vol. 235. pp. 292, April. 2021, doi:10.1016/j.jpeds.2021.04.020
- [8] M. N. Zaiac and A. Walker, "Nail abnormalities associated with systemic pathologies," *Clinics in Dermatology*, vol. 31, no. 5, pp. 627–649, Sep. 2013. doi: 10.1016/j.clindermatol.2013.06.018.
- [9] Kaggle, "nail disease image augmentation", Kaggle, accessed
- [10]. Feneis HDW. *Pocket Atlas of Human Anatomy 4th Edition*. 4th ed. Thieme; 2000.
- [11] Douglas Schoon. *Nail Structure and Product Chemistry*. 2th ed. Thomson Delmar Learning; 2005.
- [12] Pitukweerakul S, Pilla S, "Terry's Nails and Lindsay's Nails: Two Nail Abnormalities in Chronic Systemic Diseases". *Journal of General Internal Medicine*, vol 8, no. 31, pp. 970, Aug. 2016, doi:10.1007/s11606-016-3628-z
- [13] Vignes S, Baran R, "Yellow nail syndrome," *Orphanet Journal of Rare Diseases*, vol 1, pp. 1-10, Des. 2017, doi:10.1186/s13023-017-0594-4
- [14] Singal A, Arora R, "Nail as a window of systemic diseases," *Indian Dermatology Online Journal*. vol 2, pp. 67, Feb. 2015, doi:10.4103/2229-5178.153002
- [15] Kholik A, Harjoko A, Wahyono W, "Classification of Traffic Vehicle Density Using Deep Learning," *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol 14, pp. 69-80, januari 2020, doi:10.22146/ijccs.50376
- [16] Kholik A. "KLASIFIKASI MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) PADA TANGKAPAN LAYAR HALAMAN INSTAGRAM," *JDMSI*, vol 2, pp. 10-20, Feb 2021, doi: /10.33365/jdmsi.v2i2.1345
- [17] Sugiarta, I Gusti Rai Agung, Sudarma, Made widyantara, I Made Oka, "Ekstraksi Fitur Warna, Tekstur dan Bentuk untuk Clustered-Based Retrieval of Images (CLUE)," *Majalah Ilmiah Teknologi Elektro*, [S.l.], v. 16, no. 1, pp. 85-90, july 2016. ISSN 2503-2372 doi: 10.24843/MITE.1601.12
- [18] Bezdán T, Bačanin Džakula N, "Convolutional Neural Network Layers and Architectures,"

- Singidunum University, vol 5, pp 445-451, 2019, doi:10.15308/sinteza
- [19] SRIVASTAVA, Nitish, "Dropout: a simple way to prevent neural networks from overfitting," *The journal of machine learning research*, vol 15, no. 56, pp. 1929-1958, januari 2014, doi : 10.26483/ijarcs.v11i4.6632
- [20] IOFFE, Sergey; SZEGEDY, Christian, "Batch normalization: Accelerating deep network training by reducing internal covariate shift," In: *International conference on machine learning*, PMLR, 2015. p. 448-456.
- [21] Guo Y, Xia Y, Wang J, Yu H, Chen RC, "Real-Time Facial Affective Computing on Mobile Devices", *Sensors (Basel)*, vol 20, no. 3, pp.870, feb 2020, doi: 10.3390/s20030870. PMID: 32041323; PMCID: PMC7039298
- [22] Kim J, Sangjun O, Kim Y, Lee M, "Convolutional Neural Network with Biologically Inspired Retinal Structure", In: *Procedia Computer Science*, vol 88, pp. 145-154, juli 2016, doi:10.1016/j.procs.2016.07.418
- [23] Xie, Siying, Daniel Kaiser, and Radoslaw M. Cichy, "Visual imagery and perception share neural representations in the alpha frequency band," *Elsevier Inc*, vol 30, no. 13, pp. 2621-2627, July 2020, doi:10.1016/j.cub.2020.04.074
- [24] D. Soydaner, "A Comparison of Optimization Algorithms for Deep Learning," *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 34, no. 13, Dec. 2020, doi: 10.1142/S0218001420520138.

