

Image Hashing Utilization on Skin Disease Image Classification on Redundant Images

Pemanfaatan *Image Hashing* Pada Klasifikasi Penyakit Kulit Terhadap Citra yang Terduplikasi

Reiner D. Lantang, Agustinus Jacobus, Sherwin R. U. A Sompie

Dept. of Electrical Engineering, Sam Ratulangi University Manado, Kampus Bahu St., 95115, Indonesia

e-mails: allabovebeyond@gmail.com, a.jacobus@unsrat.ac.id, aldo@unsrat.ac.id

Received: 23 December 2024; revised: 16 January 2024; accepted: 17 January 2024

Abstract — Skin disease is one of the most common diseases that attack humans when the skin cannot adapt to the environment or certain conditions. Skin diseases have various common causes, including fungal growth, virus infection, and hormonal factors. Early skin disease detection can make humans more cautious for further causes and eliminate the diseases. Some people don't know which type of skin disease is attacking them. This study aims to develop a predictive model of skin disease images to classify skin diseases using a machine-learning model from 3 skin disease classes: Acne, Candidiasis, and Melanoma. This study develops a CNN model based on ResNet50 and VGGnet19 architecture and trials of image hashing algorithm to detect duplicated images on the dataset. The model with the highest learning performance achieves 96.62% training accuracy and the lowest overfitting indications on training and validation percentage differences. We also provide results from the trained models with cleaned and redundant data based on the study.

Keywords— deep neural network; image hash; machine learning; skin diseases classification; skin disease imagery.

Abstrak — Penyakit kulit adalah salah satu penyakit yang paling sering menyerang manusia disaat kulit tidak dapat beradaptasi dengan lingkungan ataupun kondisi tertentu. Penyakit kulit memiliki penyebab yang bervariasi seperti pertumbuhan jamur, infeksi virus, dan faktor hormonal. Deteksi penyakit kulit yang lebih awal dapat membuat manusia lebih waspada terhadap kondisi yang lebih parah dan menangani penyakit tersebut. Beberapa orang tidak tahu jenis penyakit kulit apa yang menyerang mereka. Penelitian ini bertujuan untuk mengembangkan sebuah model prediktif terhadap citra penyakit kulit untuk mengklasifikasikan penyakit kulit menggunakan model pembelajaran mesin berdasarkan 3 kelas yaitu *Acne*, *Candidiasis*, dan *Melanoma*. Penelitian ini mengembangkan model CNN dengan arsitektur ResNet50 dan VGGnet19 serta mengimplementasikan algoritma *image hashing* untuk mendeteksi citra yang terduplikasi dalam dataset. Model yang memiliki performa pembelajaran terbaik mencapai 96.62% akurasi dan juga memiliki indikasi *overfitting* terendah. Berdasarkan hasil penelitian, kami juga memberikan hasil dari model yang dilatih dengan data bebas dari duplikasi dan juga data dengan jumlah duplikasi yang tinggi.

Kata kunci — citra penyakit kulit; *image hash*; jaringan saraf mendalam; klasifikasi penyakit kulit; pembelajaran mesin.

I. PENDAHULUAN

Teknologi pada era digital berkembang dengan sangat pesat dan memunculkan teknologi baru yang sangat membantu kehidupan manusia. Perkembangan tersebut memiliki peran yang sangat besar dan membantu bidang pekerjaan atau studi yang memerlukan teknologi yang dikembangkan tersebut.

Salah satu hasil dari perkembangan tersebut yaitu teknologi kecerdasan buatan yang berkembang menjadi *deep learning*. Teknologi ini memungkinkan komputer melakukan pemrosesan dan komputasi terhadap macam-macam jenis data hingga dapat melakukan analisa terhadap citra gambar. Teknologi *deep learning* terlebih khusus *Convolutional Neural Network* atau CNN sudah banyak dikembangkan dan terbukti dapat melakukan analisa hingga melakukan klasifikasi yang prediktif terhadap data citra gambar dan terbukti dapat melakukan klasifikasi terhadap citra radiografi, buah, biji-bijian, kendaraan dan masih banyak lagi objek yang dapat diklasifikasikan oleh teknologi ini.

Menurut jurnal yang ditulis oleh Seth dkk. pada tahun 2017 disebutkan bahwa pada perhitungan *DALYs*, penyakit kulit berkontribusi sebesar 1.79% dari total 306 jumlah penyakit dan cedera dan dibandingkan dengan penyakit lain, penyakit kulit juga menduduki peringkat 4 teratas penyakit non-fatal.

Dengan mengenal penyakit yang dialami, masyarakat dapat melakukan tindakan preventif atau pengobatan yang lebih awal. Untuk mengenali penyakit tersebut, dibutuhkan teknologi yang dapat membantu manusia untuk mengidentifikasi penyakit kulit.

Untuk mengembangkan sebuah model *Deep learning*, dibutuhkan data berupa citra yang akan menjadi bahan pembelajaran untuk model melatih jaringan saraf tiruannya. Data yang akan digunakan merupakan data yang dikumpulkan secara acak dari internet.

Namun dengan pengambilan data yang acak tersebut memiliki kompleksitas data yang sangat besar dari sudut pandang dimensi, sifat gambar, warna gambar, terdapat duplikasi dari dataset yang satu terhadap dataset yang lain dan banyak lagi kompleksitas yang harus disederhanakan terlebih dahulu.

Penelitian ini bertujuan untuk melakukan percobaan terhadap dataset yang memiliki duplikasi data dengan jumlah yang cukup besar dan dataset yang nantinya akan dibersihkan duplikasinya menggunakan algoritma *image hash*.

TABEL I
ERROR RATE PENGUJIAN

| Arsitektur | Error rate | |
|--------------------|------------|-----------|
| | CIFAR-10 | CIFAR-100 |
| Plain-11 | 5.91% | 27.82% |
| ResNet-110 | 5.26% | 26.05% |
| WRN-28-10 | 3.89% | 18.95% |
| DenseNet-BC | 3.90% | 18.62% |
| ResNeXt-29 | 3.56% | 18.38% |
| PyramidNet-272-200 | 3.58% | 17.05% |

A. Penelitian Terkait

Penelusuran terhadap beberapa penelitian-penelitian sebelumnya dilakukan untuk memperdalam teori untuk mendasari penelitian dan menjadi referensi penelitian ini yang tercantum dibawah ini.

Penelitian sebelumnya yang pernah dilakukan oleh Barz & Denzler membandingkan hasil latih antara dua *dataset* yaitu CIFAR-10 yang memiliki 10 kelas dan CIFAR-100 yang memiliki 100 kelas dengan jumlah 50.000 data latih dan 10.000 data uji. Dalam penelitian tersebut merka mendapati 3.3% jumlah data terduplikasi dalam *dataset* CIFAR-10 dan 10% jumlah data terduplikasi dalam *dataset* CIFAR-100. Berdasarkan perbandingan pada Tabel I mereka menyimpulkan bahwa jumlah data dan jumlah data yang terduplikasi pada sebuah *dataset* dapat mempengaruhi nilai error pelatihan terhadap sebuah model CNN [1].

Penelitian yang dilakukan oleh J. A. Wuisan et al, penelitian ini terkait dengan *dataset* citra radiografi dengan 4 kelas yang tidak seimbang yang menyebabkan proses pelatihan model yang tidak optimal atau terjadinya *overfitting* terhadap proses pelatihan 3 jenis model dengan basis arsitektur yang berbeda-beda [2].

Penelitian yang dilakukan oleh R. Tedjo et al, penelitian ini terkait dengan pembangunan model CNN dengan 2 basis arsitektur dalam mengklasifikasikan makanan segar dan yang busuk untuk penderita buta warna. Dalam penelitian ini juga, dilakukan peluncuran atau penerapan sistem klasifikasi dengan basis CNN kedalam sebuah aplikasi *android* [3].

Penelitian mengenai pengembangan sistem deteksi penyakit kulit yang dilakukan oleh N. Soliman et al, penelitian ini berfokus untuk melakukan pendeteksian penyakit kulit melalui citra yang diproses melalui sebuah *pre-trained* model CNN dengan memanfaatkan *Support Vector Machine* sebagai *classifier* [4].

Penelitian yang dilakukan oleh V. R. Allugunti mengembangkan sebuah model CNN yang mampu mengklasifikasikan 3 kelas *Melanoma* yang jenisnya berbeda. Pada penelitian ini juga membandingkan hasil klasifikasi oleh *classifier* jaringan saraf mendalam yang mampu mencapai akurasi 90.07% sedangkan dengan 3 jenis *classifier* pembelajaran mesin yang lebih sederhana lainnya hanya mampu mencapai 71% keakuratan [5].

Pada penelitian yang dilakukan oleh Y. Liu dkk, penelitian ini membahas mengenai *weighted aggregation* dan *perceptual hash*. Penelitian ini dilakukan untuk mengembangkan sebuah

algoritma *perceptual hash* dalam mendeteksi keberadaan pejalan kaki pada sebuah citra. Dalam penelitian ini juga mereka berhasil mengembangkan pendekatan sebuah *perceptual hash* dengan rerata *miss rate* yang lebih baik dari pendekatan sebelumnya dalam mendeteksi pejalan kaki pada dataset INRIA [6].

Pada penelitian mengenai pengembangan sebuah pendekatan dari penerapan *image hashing* yang dilakukan oleh Y. Li dan J. V. Gemert, penelitian ini berhasil mengembangkan sebuah pendekatan *image hashing* yang mampu melampaui presisi dari 8 pendekatan *image hashing* yang dikembangkan sebelumnya melalui pengujian terhadap 3 *dataset* yang berbeda. Pendekatan ini disebut *Bi-half net hashing* dimana penelitian ini menerapkan *Bi-half layer* yang akan melakukan transformasi dari citra yang kontinu ke bentuk biner sebelum melakukan *image hashing* [7].

Pada penelitian yang dilakukan oleh H. Cui dkk, pengembangan sebuah algoritma *image hashing* pada bagian ekstraksi fitur sebuah citra. Penelitian ini memanfaatkan model CNN dengan basis arsitektur VGG16 untuk mengekstraksi fitur-fitur citra. Kemudian setelah fitur-fitur tersebut berhasil diekstraksi akan diproses melalui algoritma *image hashing* yang sudah dioptimisasi. Penelitian ini bertujuan untuk mengembangkan sebuah algoritma *image hashing* secara mendalam terhadap citra dan dikembangkan untuk lebih optimal dalam transformasi fitur ke bentuk hash sekaligus mengurangi resiko munculnya sinyal yang tidak diinginkan pada citra pada saat proses *encoding* ke bentuk *hash* [8].


B. Kulit dan Penyakit Kulit

Kulit adalah organ terbesar dalam tubuh, yang juga merupakan sebuah batas antara seorang individu dan dunia di sekitarnya. Peran utamadari kulit adalah sebagai penghalang, mencegah masuknya bahan kimia berbahaya, organisme menular, dan sebagai jalan keluar air dan bahan kimia lainnya. Ketika dihadapkan dengan paparan dari luar, biasanya kulit mudah beradaptasi dan kembali pada keadaan normal, tapi kadang kadang gagal untuk melakukannya dan menyebabkan munculnya penyakit kulit.

Jerawat atau *acne* adalah gangguan dari kelenjar *pilosebaceous* yang ditandai dengan komedo, papul, pustul, kista dan bekas luka. Jerawat dapat terlihat seperti lesi primer dalam bentuk komedo atau folikel yang tersumbat yang mungkin terlihat pucat dan tertutup (*whitehead*) atau gelap dan terbuka (komedo) [9].

Candidiasis adalah salah satu penyakit kulit yang disebabkan oleh infeksi jamur *Candida Albicans* yang dapat muncul diberbagai daerah tubuh seperti pada mulut, lipatan tubuh, dan pada alat kelamin. Temuan klasik yang sering muncul pada *candidiasis* yang terjadi pada daerah mulut adalah munculnya selaput berwarna putih semu yang mudah hilang. Pada *candidiasis* yang terdapat pada lipatan tubuh biasanya menunjukkan gambaran klinis berupa erosi.

Melanoma adalah tumor ganas dari melanosit epidermis dengan potensi metastatik yang menyebabkan kematian pada sebagian besar kasus yang berhubungan dengan kanker kulit [10].



Gambar 1. Relasi Kecerdasan Buatan, *Machine Learning* dan *Deep Learning*

Beberapa penyakit kulit yang sering dialami seorang individu yang berusia 1-74 tahun dan membutuhkan perawatan medis adalah penyakit kulit yang disebabkan oleh infeksi jamur seperti *Kandidiasis (Candidiasis)*, *Jerawat (acne)*, dan *Melanoma* [11].


C. Artificial Intelligence

Artificial intelligence atau kecerdasan buatan adalah suatu ilmu yang mempelajari cara membuat komputer melakukan sesuatu seperti yang dilakukan oleh manusia [12]. Dalam konsep kecerdasan buatan, mesin dibuat untuk bisa bekerja dan berperilaku seperti manusia dengan menerapkan prinsip bahwa setiap aspek kecerdasan dapat dipelajari dan diwujudkan dalam suatu sistem [13].

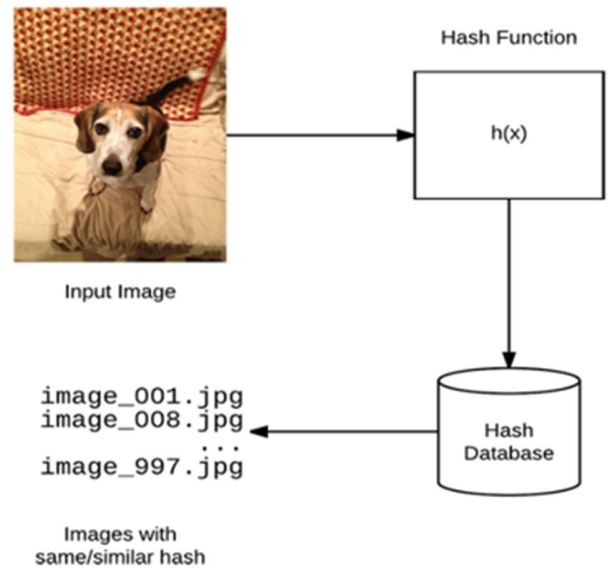
Kecerdasan buatan mulai berkembang hingga munculnya cabang kecerdasan buatan yang mampu mempelajari lingkungan atau dalam hal ini berupa kumpulan data. Cabang kecerdasan buatan ini disebut *Machine learning* atau pembelajaran mesin yang dapat didefinisikan sebagai bidang yang mempelajari metode perancangan algoritma yang mampu belajar dari data tanpa diprogram secara eksplisit [14]. Ada juga yang berpendapat bahwa yang menyebutkan bahwa *Machine learning* adalah sebuah studi yang mempelajari tentang metode komputasi untuk meningkatkan kinerja dengan mekanisasi perolehan pengetahuan dari pengalaman [15].

Dari prinsip-prinsip yang dikembangkan dari kecerdasan buatan hingga *machine learning* dikembangkan sebuah bidang studi yang disebut *deep learning*. *Deep learning* adalah sub bidang kecerdasan buatan yang berfokus pada pembuatan model jaringan saraf besar yang mampu membuat keputusan berbasis data yang akurat [16].

Convolutional Neural Network atau CNN adalah salah satu arsitektur untuk *deep learning*, dan dapat mempelajari fitur gambar secara otomatis [17]. CNN merupakan salah satu tipe jaringan saraf tiruan yang memerlukan *Convolutional layer*. Tetapi dapat memiliki jenis lapisan lain seperti lapisan non-linier, penyatuan dan lapisan yang terhubung sepenuhnya untuk membuat jaringan saraf konvolusional yang dalam [18].



Gambar 2. Lapisan-lapisan *Convolutional Neural Network* (I. H. Sarker. 2021) [19].



Gambar 3. Konsep Dasar *Image Hashing*

D. Image Hashing

Image Hashing dapat diartikan sebagai proses *encoding* yang cepat pada gambar *input* menjadi sekumpulan kode yang ringkas oleh *hash function* sambil mempertahankan sifat dan fitur dari gambar tersebut. Dengan kode tersebut, memungkinkan untuk dapat dengan mudah melakukan pencarian yang sangat efisien dengan waktu yang jauh lebih singkat [20].

E. Anaconda Navigator

Anaconda Navigator adalah sebuah platform yang *open source* yang dapat menginterpretasikan bahasa pemrograman *Python* dan *R* untuk pengembangan atau pekerjaan mengenai *data science*. *Anaconda* digunakan dalam bentuk *environent* yang menjadi *workspace* mengerjakan permasalahan-permasalahan *data science*.

Dalam penelitian ini *Anaconda* digunakan untuk melakukan *image hashing* dan pra-pemrosesan data citra lainnya seperti augmentasi dan transformasi dimensi citra.

F. Google Colab

Google Colaboratory adalah suatu *tool* yang digunakan untuk mengeksekusi kode *python* melalui sebuah *web browser*. *Google colab* merupakan sebuah platform berbasis *cloud* yang cocok untuk *machine learning*. *Google colab* juga menyediakan GPU untuk mendukung komputasi *machine learning* yang tersedia secara gratis.

G. Tensorflow

Tensorflow adalah sebuah *framework* yang secara orisinal dikembangkan oleh Google untuk memungkinkan penelitian dan mengembangkan *machine learning*. Google menyebutkan *Tensorflow* adalah sebuah antarmuka untuk mengekspresikan algoritma *machine learning* dan mengimplementasi untuk mengeksekusi algoritma tersebut. *Tensorflow* secara khusus menyediakan *library* atau *framework* untuk mempermudah penerapan *machine learning* dalam beberapa platform [21].

Tensorflow juga merupakan *library* yang sudah menyediakan macam-macam *pre-trained model* seperti Resnet50 dan VGGnet19 yang nantinya akan menjadi objek pengujian kedua *dataset*.

Beberapa fitur utama yang dimanfaatkan dari *tensorflow* untuk penelitian ini antara lain, melakukan komputasi secara optimal terhadap *array* yang diekstraksi dari citra, *library* untuk komputasi pembelajaran mesin dan pembelajaran mendalam, penggunaan perangkat keras pemrosesan citra seperti GPU yang akan menopang proses komputasi, dan memungkinkan komputasi pada data dengan skala yang besar.

II. METODE

A. Instrumen Penelitian

Untuk melaksanakan penelitian ini, dimanfaatkan sebuah perangkat komputer dengan spesifikasi *Processor Intel Core i5*, *Memory RAM 16GB*, *SSD 1.5 TB*, dan *Video Card NVIDIA RTX 4070 12GB VRAM*.

Selain perangkat keras komputer, dimanfaatkan juga beberapa perangkat lunak seperti Anaconda Navigator yang digunakan sebagai perangkat lunak untuk melakukan pengolahan data, dan Google Colaboratory sebagai perangkat lunak berbasis *cloud* yang ditenagai oleh mesin virtual dengan kartu grafis NVIDIA T4 yang dimanfaatkan untuk proses pelatihan dan pengujian model CNN.

Ada juga beberapa *library* dan *framework* dari bahasa pemrograman Python yang digunakan seperti *Tensorflow*, *Matplotlib*, *Keras*, *Numpy*, dan juga *Flask*.

B. Pengumpulan Data

Kumpulan dataset diperlukan untuk pelatihan dan pengujian sebuah model CNN. Data tersebut dikumpulkan dari beberapa kumpulan dataset yang dipublikasikan di website Kaggle. Pengambilan data-data tersebut dilakukan secara acak disesuaikan dengan setiap kelas yang ditentukan pada awal mulai penelitian yaitu *Acne*, *Candidiasis*, dan *Melanoma*. Total data yang dikumpulkan berjumlah 11.088 data citra yang terbagi menjadi 3 kelas.

TABEL II
JUMLAH DATA PER KELAS

| Kelas | Non-image hash | Image hash |
|--------------------|----------------|------------|
| <i>Acne</i> | 2891 | 1410 |
| <i>Melanoma</i> | 5027 | 4353 |
| <i>Candidiasis</i> | 3170 | 930 |

C. Image Hashing

Setelah data berhasil dikumpulkan, langkah selanjutnya yang dilakukan adalah membagi data tersebut menjadi 2 jenis data yaitu, dataset mentah yang berisikan beberapa data yang memiliki duplikasi dan dataset yang disaring menggunakan algoritma *image hashing*. Algoritma *image hashing* akan melakukan proses *encoding* data gambar menjadi kumpulan kode *hash* berdasarkan fitur-fitur gambar seperti warna, pola dan bentuk tanpa mengubah atau menghilangkan fitur-fitur tersebut.

Gambar dengan kode *hash* yang sama akan dianggap sebagai gambar yang sama ataupun identik. Kemampuan algoritma ini akan dimanfaatkan untuk mendeteksi gambar yang dianggap memiliki duplikat dalam dataset dan menyisakan 1 gambar saja. Algoritma *image hashing* yang akan digunakan adalah algoritma dengan pendekatan *Perceptual hash* yang merupakan algoritma yang mendeteksi kemiripan citra secara perseptual.

Setelah proses *image hashing* selesai maka akan dilakukan pembagian data untuk pelatihan, validasi dan data uji. Perbandingan yang digunakan untuk pembagian dataset yaitu, 80% untuk data latih dan masing-masing 10% untuk data validasi dan 10% data uji.

D. Data Preprocessing

Data Preprocessing atau pra-pemrosesan data adalah proses untuk mempersiapkan data agar data dapat digunakan sebagai data latih ataupun data uji untuk model yang akan digunakan. Proses ini sangat penting untuk dilakukan dikarenakan banyaknya variasi data yang berasal dari berbagai dataset sehingga Ada beberapa langkah atau teknik dalam proses ini yaitu sebagai berikut:

1) *Resize data*

Ukuran data awal memiliki dimensi yang sangat bervariasi dan dilakukan *resize data* ke 200x200 pixel.

2) *Augmentasi Data*

Augmentasi data adalah teknik yang digunakan untuk menambah variasi data menggunakan teknik-teknik transformasi terhadap data citra. Teknik yang diterapkan adalah *random brightness* untuk menambah variasi pada gambar yang rendah pencahayaan dan *zoom in* untuk menambah variasi terhadap data yang memuat fitur utama dengan ukuran yang kecil.


3) *Normalisasi data*

Normalisasi data adalah tahap paling terakhir dalam proses pra-pemrosesan data. Tahap ini akan mengubah semua data menjadi format yang sama yaitu menjadi *array* dimensi yang terdiri dari ukuran pixel (*height x width*) dan index warna yaitu RGB.


E. Arsitektur Jaringan

Dalam penelitian ini terdapat 2 arsitektur *Convolutional Neural Network* yang akan digunakan yang merupakan *pre-trained model* yang sebelumnya sudah dilatih dan menghasilkan performa pelatihan yang baik terhadap berbagai jenis pengklasifikasian.

Arsitektur yang pertama akan menggunakan *pre-trained model* ResNet 50 dan arsitektur kedua yaitu VGGnet19 sebagai basis arsitektur keempat model yang akan dibuat.



Gambar 4. Arsitektur Model A dan B (ResNet50)



Gambar 5. Arsitektur Model C dan D (VGGnet19)

Setelah itu akan ditambahkan *fully connected layer* yang dilengkapi dengan layer *bias regularization* dan fungsi *dropout* yang diterapkan untuk menangani data dengan kompleksitas tinggi. Untuk kedua model akan dilengkapi dengan *fully connected layer* yang sama yang dikustomisasi sesuai dengan kebutuhan dan dilengkapi dengan layer *softmax* sebagai *classifier*. Agar terlihat secara jelas kedua arsitektur dapat dilihat pada Gambar 4 dan 5.

III. HASIL DAN PEMBAHASAN

Pada bagian ini akan dijelaskan mengenai hasil dari penelitian mulai dari pengolahan data, hasil pelatihan model, dan evaluasi. Untuk pelatihan dan evaluasi model akan dibandingkan 4 model yaitu, model yang dibangun menggunakan arsitektur ResNet50 dengan pelatihan menggunakan data yang dibersihkan dan tidak oleh *image hash* dan juga dengan model yang dibangun menggunakan arsitektur VGGnet19.

A. Augmentasi data

Perbandingan data latih antara setiap kelas terhadap data mentah memiliki selisih yang besar menyebabkan data tidak seimbang untuk setiap kelas. Begitu pula dengan data yang dibersihkan memiliki perbandingan yang jauh berbeda untuk jumlah data latih setiap kelas.

Untuk mengatasi permasalahan tersebut maka dilakukan augmentasi data. Augmentasi tersebut dilakukan tidak hanya untuk menambah variasi data, tetapi juga dimanfaatkan untuk menambah jumlah data pada kelas minoritas untuk menimbangi jumlah data kelas mayor. Untuk perbandingan jumlah data latih dapat dilihat pada tabel III.

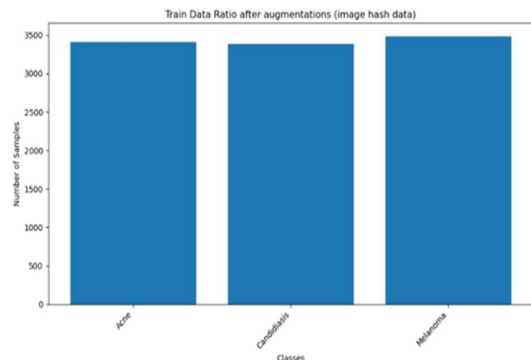
Setelah didapat nilai selisih jumlah data latih antar kelas maka dilakukan teknik augmentasi data dengan mengatur banyaknya jumlah data yang digenerasi oleh program. Untuk perbandingan data setelah diterapkan augmentasi data dapat dilihat pada visualisasi jumlah data pada Gambar 6 dan 7.

TABEL III
PERBANDINGAN DATA LATIH

| Kelas | Non-image hash | Image hash |
|-------------|----------------|------------|
| Acne | 2312 | 1128 |
| Candidiasis | 2536 | 744 |
| Melanoma | 4021 | 3482 |



Gambar 6. Rasio Data Latih non-Image Hash Setelah Augmentasi



Gambar 7. Rasio Data Latih Image Hash Setelah Augmentasi

TABEL IV
TUNING MODEL A, B, C, DAN D

| Model | Arsitektur | Batch Size | Epochs | Input Size | Input Array | Optimizer |
|-------|------------|------------|--------|------------|---------------|-----------|
| A | ResNet 50 | 32 | 15 | 200px | (200, 200, 3) | Adamax |
| B | ResNet 50 | 32 | 15 | 200px | (200, 200, 3) | Adamax |
| C | VGGnet 19 | 32 | 15 | 200px | (200, 200, 3) | Adamax |
| D | VGGnet 19 | 32 | 15 | 200px | (200, 200, 3) | Adamax |

B. Pembuatan Model CNN

Setelah data selesai diproses dan siap menjadi bahan pembelajaran model CNN, maka proses selanjutnya adalah pembuatan model CNN.

Model CNN dibuat dengan mengimplementasikan *pre-trained model* yang sudah dilatih sebelumnya dengan basis arsitektur ResNet50 dan VGGnet19.

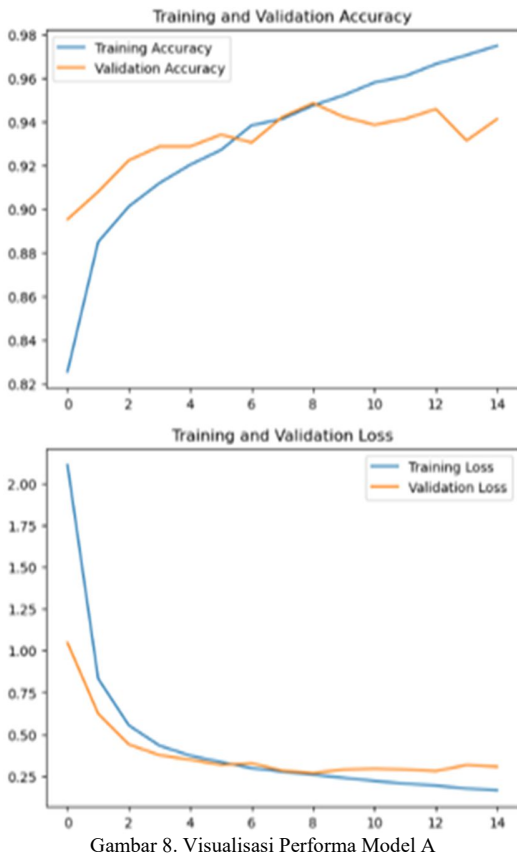
Setelah diimplementasikan *pre-trained model*, ditambahkan sebuah *fully connected layer* yang dikustomisasi sebagai layer akhir dari model yang akan melakukan klasifikasi.

Dalam proses pelatihan ditetapkan beberapa parameter untuk melakukan *fine tuning* terhadap model dan juga fungsi *callback* untuk mengatur proses pembelajaran model terhadap data latih dan validasi. Beberapa parameter yang dimaksudkan seperti; *Batch size* yang ditentukan sebesar 32 untuk semua model, pelatihan akan dilakukan sebanyak 15 iterasi (15 *Epochs*), pengaturan format *input* gambar dengan dimensi 200x200 pixel dengan format gambar RGB (*input array* = 200, 200, 3), menggunakan *optimizer* Adamax dengan *learning rate* bawaan yaitu 0.001. *fine tuning* yang dikonfigurasi untuk keempat model dapat dilihat di Tabel IV.

Selain *fine tuning* yang sudah diterapkan tersebut ada juga fungsi *callbacks* *EarlyStopping* yang diterapkan untuk menghentikan proses pelatihan apabila model mencapai 98% akurasi pelatihan.

C. Hasil Pelatihan

Pada bagian ini akan dijelaskan secara detail mengenai hasil pelatihan terhadap 4 model CNN yang sudah dibuat. Pelatihan dilakukan pada platform Google Colaboratory dengan memanfaatkan Virtual Machine berbasis Cloud yang tersedia pada platform tersebut dengan menggunakan GPU NVIDIA T4. Pada akhir bagian, disimpulkan model dengan performa pelatihan yang paling optimal dan juga model yang mampu menangani dataset dengan duplikasi data.



Gambar 8. Visualisasi Performa Model A

1) Pelatihan Model A

Model A adalah model CNN yang dibangun dengan *pre-trained model* ResNet50 yang dilatih menggunakan dataset yang tidak dibersihkan dengan *image hashing*. Pelatihan dilakukan sebanyak 15 *epochs* dan diatur menggunakan fungsi *callbacks* untuk menghentikan iterasi apabila akurasi model mencapai 98%.

Hasil dari pelatihan model A pada Gambar 8, mendapat akurasi pelatihan sebesar 97.49% akurasi latih dengan 94.13% akurasi validasi, dan 16.45% nilai error terhadap data latih dan 30.56% pada validasi.

2) Pelatihan Model B

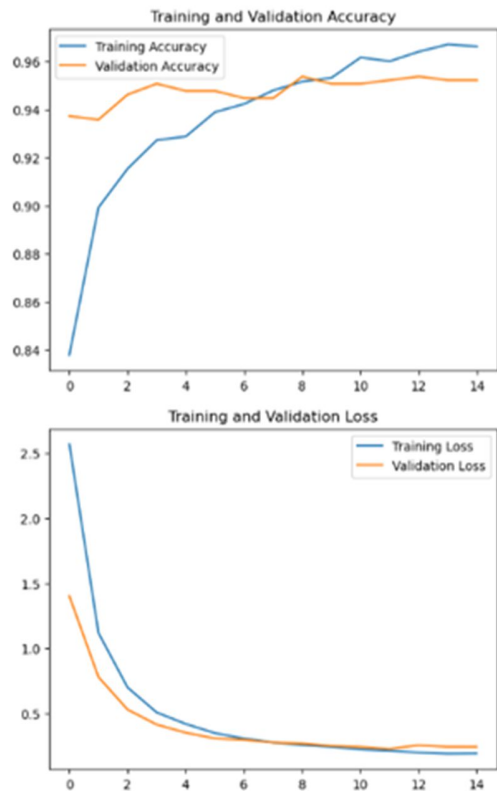
Model B adalah model CNN yang dibangun dengan *pre-trained model* ResNet50 yang dilatih menggunakan dataset yang dibersihkan menggunakan *image hashing*. Parameter pelatihan menggunakan parameter yang sama dengan Model A.

Hasil dari pelatihan model B, mendapat akurasi pelatihan sebesar 96,73% akurasi latih dengan 95.07% akurasi validasi, dan 18.23% nilai error terhadap data latih dan 25.23% pada validasi.



3) Pelatihan Model C

Model C adalah model CNN yang dibangun dengan *pre-trained model* VGGnet19 yang dilatih menggunakan dataset yang tidak dibersihkan dengan *image hashing*. Pelatihan dilakukan sebanyak 15 *epochs* dan diatur menggunakan fungsi *callbacks* untuk menghentikan iterasi apabila akurasi model mencapai 98%.



Hasil dari pelatihan model C, mendapat akurasi pelatihan sebesar 96.34% akurasi latih dengan 93.5% akurasi validasi, dan 29.74% nilai error terhadap data latih dan 39.84% pada validasi.



Gambar 9. Visualisasi Performa Model B



Gambar 10. Visualisasi Performa Model C



Gambar 11. Visualisasi Performa model D

| | Train acc | Val acc | Train loss | Val loss |
|---------|-----------|---------|------------|----------|
| Model A | 97.49% | 94.13% | 16.45% | 30.56% |
| Model B | 96.73% | 95.07% | 18.23% | 25.23% |
| Model C | 96.34% | 93.50% | 29.74% | 39.84% |
| Model D | 96.86% | 94.62% | 30.50% | 40.84% |

TABEL VI
PERBANDINGAN AKURASI DAN NILAI ERROR (LOSS)

| Model | Akurasi (train-val) | Loss (train-val) |
|-------|---------------------|------------------|
| A | 3.36% | 14.11% |
| B | 1.36% | 7% |
| C | 2.48% | 10.1% |
| D | 2.24% | 10.34% |

4) Pelatihan Model D

Model D adalah model CNN yang dibangun dengan *pre-trained model* VGGnet19 yang dilatih menggunakan dataset yang dibersihkan menggunakan *image hashing*.

Tuning dari model D menggunakan *tuning* yang sama dengan model C dan juga menggunakan fungsi *callbacks* dan jumlah *epoch* yang sama.

Hasil dari pelatihan model D, mendapat akurasi pelatihan sebesar 96.86% akurasi latih dan 94.62 akurasi validasi, dan 30.50% nilai error atau *loss* pada data latih dan 40.84% pada data validasi.

Berdasarkan hasil pelatihan dari keempat model tersebut, didapatkan kesimpulan bahwa model B memiliki performa yang paling optimal dengan indikasi *overfitting* terendah. Kemudian model A merupakan model dengan performa terburuk dengan indikasi *overfitting* tertinggi. Model C menjadi model yang mampu menangani dataset dengan duplikasi data yang memiliki indikasi *overfitting* lebih rendah dari model A. Sebagai perbandingan untuk melihat indikasi *overfitting* terhadap 4 model, performa pelatihan keempat model dapat dilihat pada Tabel V dan selisih nilai-nilai akurasi dan *loss* keempat model tersebut dapat dilihat pada Tabel VI.

D.Evaluasi Model

Untuk mengevaluasi setiap model, digunakan metrik penilaian seperti *precision*, *recall*, dan *f1-score* sebagai acuan penilaian pengujian data terhadap data uji. Namun sebelum mendapatkan nilai-nilai tersebut, akan diambil hasil pengujian terhadap data uji yang dikemas dalam suatu *confusion matrix*.

TABEL V
PERFORMA PELATIHAN KEEMPAT MODEL

TABEL VII
DETAIL SET DATA UJI

| Kelas | Jumlah Data |
|--------------------|-------------|
| <i>Acne</i> | 290 |
| <i>Candidiasis</i> | 317 |
| <i>Melanoma</i> | 504 |

TABEL VIII
CONFUSION MATRIX MODEL A

| Kelas Aktual | Kelas | Hasil Prediksi | | |
|--------------|--------------------|----------------|--------------------|-----------------|
| | | <i>Acne</i> | <i>Candidiasis</i> | <i>Melanoma</i> |
| Kelas Aktual | <i>Acne</i> | 247 | 41 | 2 |
| | <i>Candidiasis</i> | 2 | 314 | 1 |
| | <i>Melanoma</i> | 0 | 22 | 482 |

TABEL IX
CLASSIFICATION REPORT MODEL A

| Kelas | <i>Precision</i> | <i>Recall</i> | <i>F1-score</i> |
|--------------------|------------------|---------------|-----------------|
| <i>Acne</i> | 0.99 | 0.85 | 0.92 |
| <i>Candidiasis</i> | 0.83 | 0.99 | 0.90 |
| <i>Melanoma</i> | 0.99 | 0.96 | 0.97 |

1) Evaluasi Model A

Setelah dilatih menggunakan data latih dan data validasi, selanjutnya model akan diuji menggunakan set data uji yang hasil pengujiannya dapat dilihat pada *confusion matrix* dan *classification report* model.

Dalam evaluasi model A dapat dilihat bahwa berdasarkan *confusion matrix* pada Tabel VIII dapat disimpulkan bahwa model ini dapat melakukan klasifikasi yang baik terhadap kelas *acne* dan *melanoma* yang hanya terdapat 2 data dari kelas lain yang terklasifikasi sebagai *acne* dan hanya terdapat 3 data dari kelas lain yang terklasifikasi sebagai *melanoma*. Namun terdapat 63 data dari kelas lain yang terklasifikasi sebagai *candidiasis*.

Untuk hasil klasifikasi, model A mendapatkan *precision* yang cukup tinggi terhadap kelas *melanoma* dan *acne* yang mencapai 99% keakuratan namun mendapat hasil yang buruk terhadap kelas *candidiasis* yang hanya mencapai 83%.

2) Evaluasi Model B

Dalam evaluasi model B dapat dilihat bahwa berdasarkan pada Tabel X dapat disimpulkan bahwa model ini dapat melakukan klasifikasi pada kelas *melanoma* yang terdapat 19 data dari kelas lain yang terklasifikasi sebagai kelas ini.

TABEL X
CONFUSION MATRIX MODEL B

| Kelas Aktual | Kelas | Hasil Prediksi | | |
|--------------|--------------------|----------------|--------------------|-----------------|
| | | <i>Acne</i> | <i>Candidiasis</i> | <i>Melanoma</i> |
| Kelas Aktual | <i>Acne</i> | 260 | 25 | 5 |
| | <i>Candidiasis</i> | 16 | 287 | 14 |
| | <i>Melanoma</i> | 8 | 21 | 475 |

TABEL XI
CLASSIFICATION REPORT MODEL B

| Kelas | <i>Precision</i> | <i>Recall</i> | <i>F1-score</i> |
|--------------------|------------------|---------------|-----------------|
| <i>Acne</i> | 0.92 | 0.90 | 0.91 |
| <i>Candidiasis</i> | 0.86 | 0.91 | 0.88 |
| <i>Melanoma</i> | 0.96 | 0.94 | 0.95 |

Namun pada kelas *acne*, terdapat 24 data dari kelas lain yang terklasifikasi sebagai kelas tersebut. Dan pada kelas *candidiasis* terdapat 46 data dari kelas lain yang terklasifikasikan kelas ini.

Untuk hasil klasifikasi, berdasarkan Tabel XI model B mendapatkan hasil *precision* yang sangat baik terhadap kelas *melanoma* dengan keakuratan mencapai 96% dan diikuti oleh kelas *acne* yang mencapai 92% dan 86% pada kelas *candidiasis*.

3) Evaluasi Model C

Dalam evaluasi model C dapat dilihat pada *confusion matrix* di Tabel XII dapat disimpulkan bahwa model ini dapat melakukan klasifikasi terhadap kelas *melanoma* dimana terdapat 9 data dari kelas lain yang terklasifikasi sebagai kelas ini. Kemudian ada 6 data dari kelas lain yang terklasifikasi sebagai kelas *acne* dan hasil prediksi terhadap kelas *candidiasis* oleh model ini mendapat hasil sebanyak 27 data dari kelas lain terklasifikasi sebagai *candidiasis*.

Kemudian pada hasil *classification report* pada Tabel XIII menunjukkan hasil yang sangat baik dalam melakukan klasifikasi terhadap kelas *acne* dan *melanoma* dengan *precision* yang mencapai 98%. Pada pengujian terhadap kelas *candidiasis*, model ini mendapat keakuratan prediksi kelas *candidiasis* sebanyak 92%.

TABEL XII
CONFUSION MATRIX MODEL C

| Kelas Aktual | Kelas | Hasil Prediksi | | |
|--------------|--------------------|----------------|--------------------|-----------------|
| | | <i>Acne</i> | <i>Candidiasis</i> | <i>Melanoma</i> |
| Kelas Aktual | <i>Acne</i> | 268 | 17 | 4 |
| | <i>Candidiasis</i> | 4 | 308 | 5 |
| | <i>Melanoma</i> | 2 | 10 | 492 |

TABEL XIII
CLASSIFICATION REPORT MODEL C

| Kelas | <i>Precision</i> | <i>Recall</i> | <i>F1-score</i> |
|--------------------|------------------|---------------|-----------------|
| <i>Acne</i> | 0.98 | 0.93 | 0.95 |
| <i>Candidiasis</i> | 0.92 | 0.97 | 0.94 |
| <i>Melanoma</i> | 0.98 | 0.98 | 0.98 |

TABEL XIV
 CONFUSION MATRIX MODEL D

| Kelas | | Hasil Prediksi | | |
|--------------|--------------------|----------------|--------------------|-----------------|
| | | <i>Acne</i> | <i>Candidiasis</i> | <i>Melanoma</i> |
| Kelas Aktual | <i>Acne</i> | 269 | 17 | 4 |
| | <i>Candidiasis</i> | 12 | 289 | 16 |
| | <i>Melanoma</i> | 10 | 20 | 474 |

TABEL XV
 CLASSIFICATION REPORT MODEL D

| Kelas | <i>Precision</i> | <i>Recall</i> | <i>F1-score</i> |
|--------------------|------------------|---------------|-----------------|
| <i>Acne</i> | 0.92 | 0.93 | 0.93 |
| <i>Candidiasis</i> | 0.89 | 0.91 | 0.90 |
| <i>Melanoma</i> | 0.96 | 0.94 | 0.95 |

4) Evaluasi model D

Pada hasil prediksi yang ditunjukkan oleh *confusion matrix* pada Tabel XIV menunjukkan bahwa model D dapat melakukan prediksi pada kelas *melanoma* dengan hanya terdapat 20 data dari kelas lain yang terklasifikasi sebagai kelas tersebut. Sedangkan pada kelas *candidiasis* terdapat 37 data dari kelas lain terklasifikasi sebagai kelas *candidiasis* dan pada kelas *acne* terdapat 22 data dari kelas lain yang terklasifikasi sebagai kelas ini.

Pada hasil yang didapat pada *classification report* pada Tabel XV, menunjukkan hasil *precision* pada kelas *melanoma* yang mencapai 92% sedangkan pada kelas *acne* masih menunjukkan *precision* hingga 92% namun pada kelas *candidiasis* hanya mencapai 89%.

Dari hasil keakuratan klasifikasi terhadap data uji dari keempat model tersebut, disimpulkan bahwa model C dengan *pre-trained model* VGGnet19 adalah model dengan hasil terbaik dalam menangani data dengan duplikasi dengan rata-rata nilai *f1-score* 95% untuk setiap kelas dibandingkan model C dengan *pre-trained model* Resnet50 yang mencapai 93% *f1-score*.

Sedangkan pada data yang dibersihkan dengan *image hash*, hasil evaluasi yang terbaik juga terdapat pada model D yang menggunakan *pre-trained model* VGGnet19 dengan rata-rata *f1-score* 92.66% sedangkan pada model B dengan *pre-trained model* Resnet50 mencapai rata-rata *f1-score* 91.33%.

IV. KESIMPULAN DAN SARAN

A. Kesimpulan

Dari hasil pelatihan dan pengujian terhadap beberapa model dapat ditarik beberapa kesimpulan antara lain;

Dari hasil pelatihan keempat model tersebut mendapat hasil yang variatif dan dengan mesin pelatihan yang terdiri dari 2 jenis yaitu Resnet50 dan VGGnet19. Keempat model tersebut memiliki kemampuan mengklasifikasikan penyakit kulit yang berbeda-beda

Diterapkannya *image hashing* pada dataset, membantu model untuk memiliki performa pembelajaran lebih baik. Dapat dilihat pada perbandingan anatar akurasi dan nilai *error*, model

yang dilatih dengan data set yang melalui proses *image hashing* memiliki indikasi *overfitting* yang lebih rendah dibandingkan tanpa *image hashing*.

B. Saran

Berdasarkan hasil penelitian yang diperoleh maka ada beberapa saran yang dapat diberikan untuk melanjutkan penelitian, antara lain yaitu menambahkan jumlah kelas dari penyakit kulit atau menambahkan dataset untuk kelas kulit normal agar dapat membedakan kulit sehat dan tidak sehat, penelitian selanjutnya dapat memanfaatkan *pre-trained model* yang lainnya ataupun melakukan *fine tuning* yang lain yang dapat membuat model lebih optimal dalam menangani data yang memiliki banyak duplikat ataupun data yang lebih kompleks.

V. REFERENSI

- [1] B. Barz, J. Denzler. "Do We Train on Test Data? Purging CIFAR of Near-Duplicates.". Friedrich Schiller University Jena, Jena, 2020.
- [2] J. A. Wuisan, A. Jacobus, S. R. U. A. Sompie. "Data Balancing Methods on Radiographic Image Classification on Unbalance Dataset." *Jurnal Teknik Elektro dan Komputer*, Vol. 11, No. 1, pp 1-8, 2022.
- [3] R. T. Tedjo, A. M. Sambul, A. S. M. Lumenta. "Foodstuffs Image Classification for People with Color Blindness" *Jurnal Teknik Elektro dan Komputer*, Vol. 11, No. 2, pp 67-76, 2022.
- [4] N. Soliman et al. "A Method of Skin Disease Detection Using Image Processing and Machine Learning". *Procedia Computer Science*, Vol. 163, pp 85-92, 2019.
- [5] V. R. Allugunti. "A Machine Learning Model for Skin Disease Classification using Convolution Neural Network". *International Journal of Computing, Programming and Database Management*. Vol. 3, pp 141-147, 2022.
- [6] Y. Liu, L. Zou, J. Li, J. Yan, W. Shi, D. Deng. 2018 "Segmentation by Weighted Aggregation and Perceptual Hash for Pedestrian Detection", *Journal of Visual Communication and Image Representation*, Vol 36, pp 80-89, 2018.
- [7] Y. Li, & J. van Gemert. "Deep Unsupervised Image Hashing by Maximizing Bit Entropy". *Proceedings of the AAAI Conference on Artificial Intelligence*, <https://doi.org/10.1609/aaai.v35i3.16296>
- [8] H. Cui et al. "Scaleable Deep Hashing for Large-Scale Social Image Retrieval" *IEEE*, vol. 29, pp 1271-1284, 2019.
- [9] H. Hunter, R. Weller, M. Mann. "Clinical Dermatology, 5th Edition". Wiley, Hoboken, 2015
- [10] M. Rocken, M. Schaller, E. Sattler, W. Burgdorf. "Color Atlas of Dermatology, 1st Edition". Thieme, New York, 2012.
- [11] L. A. Goldsmith et al., "Fitzpatrick's Dermatology in General Medicine, 8th Edition". McGraw-Hill, New York, 2012.
- [12] Y. Devianto, S. Dwiasnati. "Kerangka Kerja Sistem Kecerdasan Buatan dalam Meningkatkan Kompetensi Sumber Daya Manusia Indonesia". *Publikasi Mercubuana*, Vol.10, No. 1, pp 19-24, 2020.
- [13] D. Sudrajat, Suryanto, A. Rosano. "Aplikasi Pengolahan Sinyal Suara pada Teknologi Kecerdasan Buatan." *INSANtek*, Vol. 1, No. 2, 2020
- [14] A. Samuel. "Artificial Intelligence: A Frontier of Automation." 1962
- [15] P. Langley, H. A. Simon "Applications of Machine Learning and Rule Induction." *Communications of the ACM*,
- [16] J. D. Kelleher. "Deep Learning". *Massachusetts Institute of Technology*, Cambridge, 2019.
- [17] M. G. Alaslani, L. A. Elrefaai. "Transfer Learning with Convolutional Neural Networks for Iris Recognition". Vol. 10, No. 5, *International Journal of Artificial Intelligence & Applications (IJAA)*, 2019.
- [18] S. Albawi, O. Bayat, S. Al-Azawi, O. N. Ucan. "Social Touch Gesture Recognition Using Convolutional Neural Network". *Hindawi Computational Neuroscience*, 2018. DOI: <https://doi.org/10.1155/2018/6973103>
- [19] I. H Sarker. "Machine Learning: Algorithms, Real-World Applications and Research Directions". *SN Computer Science*, 2021.
- [20] S. Liu, Z. Huang. "Efficient Image Hashing with Geometric Invariant Vector Distance for Copy Detection." *Tianjin University*, Tianjin, 2019.
- [21] B. Planche, E. Andres. "Hands-on Computer Vision with TensorFlow.". *Packt Publishing Ltd.*, Birmingham, 2019.



Penulis bernama lengkap **Reiner D. Lantang**. Lahir di Modoinding tanggal 18 Januari 2001. Penulis tinggal di kelurahan Teling Atas, Kecamatan Wanea, Manado, Sulawesi Utara. Penulis memulai pendidikan di TK GMIM Sion Pinasungkulan, kemudian melanjutkan pendidikan di SD GMIM Pinasungkulan, kemudian melanjutkan pendidikan di SMPN 1 Modoinding, setelah itu melanjutkan pendidikan di

SMAN 2 Manado, dan pada tahun 2018 penulis melanjutkan pendidikan di Universitas Sam Ratulangi dan mengambil Program Studi S1 Teknik Informatika di Jurusan Teknik Elektro, Fakultas Teknik. Selama masa perkuliahan, penulis tergabung dalam komunitas kemahasiswaan yaitu, Unsrat IT Community (UNITY).