

Makalah Penelitian

## Implementasi Convolutional Neural Network (CNN) untuk Klasifikasi Jenis Jerawat Berbasis Web Menggunakan Streamlit

Ayu Asyva Irfita<sup>1</sup>, Muhammad Muttaqin<sup>2</sup> Hafni<sup>3</sup>

<sup>1,2,3</sup>Sistem Komputer,Fakultas Sains dan Teknologi,Universitas Pembangunan Panca Budi

e-mail: <sup>1</sup>aaasyva<sup>irfita@gmail.com</sup>, <sup>3</sup>taqin@pancabudi.ac.id, <sup>3</sup>hafni@pancabudi.ac.id

Corresponding Author Ayu Asyva Irfita

### ABSTRACT

Acne vulgaris is one of the most common skin problems, particularly on the facial area, and it negatively affects the quality of life of sufferers both physically and mentally. The prevalence of acne continues to rise globally and nationally, especially among adolescents and young adults. This study aims to classify types of acne using the Convolutional Neural Network (CNN) method and to implement the results into an interactive web-based application using Streamlit, in order to facilitate users in independently detecting acne. The dataset used consists of 360 acne images collected from Google and Kaggle, which were categorized into four acne types: whiteheads, blackheads, pustules, and nodules before being split into training and testing datasets. This study employs three CNN architectures: InceptionV3, VGG16, and EfficientNetB0. Training was carried out in two stages with a learning rate of 0.0001 during the initial phase and 0.000005 during the fine-tuning phase, across a total of 50 epochs. The models were trained using the Adam optimizer, along with callbacks such as EarlyStopping, ModelCheckpoint, and ReduceLROnPlateau to prevent overfitting and enhance training efficiency. Model performance was evaluated using a confusion matrix. The evaluation results showed that the VGG16 architecture achieved the highest accuracy at 97%, followed by InceptionV3 with 96%, while EfficientNetB0 only reached 26% accuracy. The best-performing model was then integrated into a Streamlit-based application featuring a simple interface that allows users to upload facial images, detect acne types, and receive initial treatment recommendations.

**Keywords:** Convolutional Neural Network(CNN),Acne Classification,Streamlit,Deep learning

### ABSTRAK

Jerawat(Acne vulgaris) merupakan salah satu permasalahan kulit yang paling umum,terutama pada area wajah dan berdampak negatif terhadap kualitas hidup penderitanya secara kesehatan fisik maupun Kesehatan mental.Prevalensi jerawat terus meningkat secara global maupun nasional terutama pada remaja dan dewasa muda.Penelitian ini bertujuan untuk mengklasifikasikan jenis jerawat menggunakan metode Convolutional Neural Network(CNN)serta mengimplementasikan hasilnya kedalam aplikasi web interaktif berbasis streamlit,guna mempermudah pengguna dalam mendeteksi jerawat secara mandiri.Dataset yang digunakan menggunakan 360 gambar jerawat yang diambil dari google dan Kaggle yang kemudian dibagi sesuai kelas jerawat yaitu whitehead,blackhead,pustula,dan nodul sebelum menjadi data latih dan data uji.Penelitian ini menggunakan tiga arsitektur CNN terdiri dari , yakni InceptionV3, VGG16, dan EfficientNetB0.Pelatihan dilakukan dalam dua tahap dengan learning rate sebesar 0,0001 pada tahap awal dan 0,000005 pada tahap fine-tuning, selama total 50 epoch. Model dilatih menggunakan Adam optimizer serta callback seperti EarlyStopping, ModelCheckpoint, dan ReduceLROnPlateau untuk mencegah overfitting dan meningkatkan efisiensi pelatihan. Evaluasi kinerja model dilakukan menggunakan confusion matrix. Hasil evaluasi menunjukkan bahwa arsitektur VGG16 memberikan akurasi terbaik sebesar 97%, diikuti oleh InceptionV3 dengan akurasi 96%, sementara EfficientNetB0 hanya mencapai akurasi 26%. Model terbaik kemudian diintegrasikan ke dalam aplikasi berbasis Streamlit dengan antarmuka sederhana yang memungkinkan pengguna mengunggah gambar wajah, mendeteksi jenis jerawat, serta menerima saran perawatan awal.

**Kata kunci:** Convolutional Neural Network(CNN),Klasifikasi jerawat,Streamlit,Deep Learning



Lisensi  
Lisensi Internasional Creative Commons Attribution-ShareAlike 4.0.

## 1. Pendahuluan

Kulit merupakan organ terbesar pada tubuh manusia dalam *system integument*. Secara umum kulit mencakup sekitar 15% dari total berat badan dan memiliki luas permukaan sekitar 1,5 hingga 2 meter persegi pada orang dewasa [1]. Permasalahan kulit yang paling umum sering terjadi pada area wajah adalah jerawat (*acne vulgaris*).

Suatu penyakit yang ditandai dengan peradangan pada unit *Pilosebaceous* disebut dengan *Acne Vulgaris* [7]. Penyakit ini bersifat kronis pada kulit yang inflamasi dan umumnya terjadi akibat penyumbatan folikel rambut oleh minyak (*sebum*) namun dapat membaik secara alami tanpa pengobatan khusus. Manifestasi klinis jerawat beragam meliputi kemunculan komedo, pustula, nodul, hingga bekas luka. Sehingga dikategorikan sebagai penyakit kulit *pleomorfik*. Selain faktor hormonal dan penyumbatan folikel rambut, infeksi bakteri juga memperburuk kondisi jerawat. Bakteri yang paling sering terlibat dalam infeksi kulit dan pembentukan nanah adalah *Propionibacterium acnes* (*P. acnes*), disusul oleh *Staphylococcus aureus* dan *Staphylococcus epidermidis*. Kedua mikroorganisme tersebut yaitu *P. acnes* dan *S. epidermidis* memiliki peran penting dalam memperparah dan membentuk berbagai tipe jerawat [10].

Jerawat merupakan salah satu gangguan kulit yang paling umum dan dapat mempengaruhi sekitar 80% hingga 100% populasi. Berdasarkan studi *Global Burden of Disease* sekitar 85% anak remaja sampai dewasa muda berusia antara 12 hingga 25 tahun mengalami masalah jerawat. Penelitian yang dilakukan di Jerman menunjukkan bahwa jerawat masih dialami oleh 64% individu berusia 20-29 tahun dan 43% individu berusia 30-39 tahun. Di India, jerawat tercatat menyerang lebih dari 80% populasi pada berbagai usia. Dan sekitar 85% remaja di negara-negara maju juga mengalami kondisi ini. Di Kawasan Asia Tenggara, prevalensi jerawat berkisar antara 40% hingga 80% kasus. Sementara itu, data dari Dermatologi kosmetika Indonesia menunjukkan peningkatan signifikan jumlah penderita jerawat, yaitu 60% pada tahun 2006, naik menjadi 80% pada 2007, dan mencapai 90% pada tahun 2009 [2].

Tingginya peningkatan prevalensi jerawat setiap tahunnya, baik secara global maupun nasional menunjukkan perlunya perhatian yang lebih serius terhadap penanganan serta identifikasi faktor-faktor pemicunya. Meskipun jerawat (*acne vulgaris*) bukan penyakit kulit yang membahayakan secara fisik namun dampaknya berperan besar terhadap kualitas hidup penderitanya. Salah satu kondisi yang dapat mempengaruhinya yaitu aspek *psikologis*, menurunkan rasa percaya diri, dan meningkatkan risiko terjadinya stigma sosial maupun *bullying* terutama di kalangan remaja.

Pada penelitian [4] mengidentifikasi jenis jerawat dengan menggunakan dataset yang terdiri dari 71 citra *acne nodules*, serta 70 citra *fungus acne* dan *acne fulminans*. Penelitian ini menggunakan metode *Convolutional Neural Network* (CNN) dengan tingkat akurasi mencapai sekitar 99,8% hingga 100% pada beberapa kelas jerawat dan performa model cukup baik dengan nilai recall 0,83 dan f1-score 0,83 untuk deteksi jerawat nodul. Penelitian lainnya [8] melakukan klasifikasi dengan 5 jenis penyakit kulit dengan menggunakan metode *Convolutional Neural Network* (CNN) dan mendapatkan akurasi 90% dengan menggunakan arsitektur VGG16, selain terbukti sangat efektif dalam klasifikasi deteksi jerawat hingga analisis data seismik untuk prediksi gempa bumi.

Penelitian sebelumnya seperti yang dilakukan oleh [15] menunjukkan penerapan CNN dalam memprediksi gempa bumi dengan memanfaatkan pola-pola dalam data seismik, yang menunjukkan betapa fleksibelnya teknik ini dalam mengolah data yang



tidak hanya terkait dengan citra medis dari uraian diatas dapat dilihat kinerja CNN menunjukkan hasil yang baik dengan berbagai macam arsitektur. Di era digital saat ini, perkembangan teknologi pembelajaran mesin menawarkan solusi inovatif untuk mengatasi berbagai tantangan. Pembelajaran mesin, yang merupakan cabang dari kecerdasan buatan (AI), memungkinkan sistem untuk belajar dari data dan membuat keputusan dengan sedikit atau tanpa campur tangan manusia[13]pendekatan berbasis kecerdasan buatan (AI)mulai banyak dimanfaatkan dalam berbagai bidang salah satunya dalam kecantikan dan kesehatan kulit.Dengan memanfaatkan teknik deep learning, sistem dapat mengidentifikasi pola-pola kompleks dalam data besar, meningkatkan efisiensi dan akurasi dalam berbagai aplikasi, termasuk pengenalan citra digital[14].

Penelitian ini bertujuan untuk mengimplementasi metode CNN dalam melakukan klasifikasi masalah kulit wajah khususnya jerawat. Streamlit sebuah framework pyhton yang memungkinkan pembuatan aplikasi web interaktif dengan cepat dan mudah untuk mengimplementasikan model CNN dalam deteksi jerawat dirancang agar dapat diakses dari remaja sampai dewasa.Melalui antarmuka yang sederhana dan ramah pengguna,individu dapat mengunggah gambar wajah mereka dan secara otomatis memperoleh jenis jerawat, rekomendasi perawatan,serta saran pengangan awal.

Diharapkan,kemudahan penggunaan aplikasi ini dapat membantu pengguna melakukan pemeriksaan mandiri sebelum kondisi jerawat memburuk.Selain itu,aplikasi ini diharapkan mampu meningkatkan kepercayaan diri dengan memberikan solusi atas permasalahan kulit,serta mengurangi risiko tekanan psikologis seperti perundungan (*bulliyng*) yang kerap dialami akibat kondisi kulit wajah.

## 2. Metode Penelitian

### 2.1 Alat dan Bahan

#### 2.1.1 Alat

Berikut merupakan alat-alat berupa software (perangkat lunak) dan hardware yang dimanfaatkan dalam penelitian:

Tabel 1 Spesifikasi Software

Spesifikasi	Keterangan
Visual Studio Code Version	1.99.3
Python Version	3.10.8
Tensorflow Version	2.19

Tabel 2 Spesifikasi Hardware

Spesifikasi	Keterangan
Processor	1.99.3
Ram	AMD Ryzen3 7320U
Storage	256GB



### 2.1.2 Bahan

Bahan yang digunakan pada penelitian ini adalah dataset citra kulit jerawat yang terdiri dari 4 kelas ,yaitu citra kulit dengan jenis jerawat yang terlihat pada table 3.Jerawat pustula,nodul,komedo hitam(blackhead),dan komedo putih(whitehead).

Seluruh kelas mempunyai total 340 buah citra.Setiap kategoriberisi 85gambar.Pengambilan dataset diambil dari google dan situs Kaggle <https://www.kaggle.com/datasets/herutriana/skin-disease-2025/> dan semua gambar disimpan dalam format jpg.lalu data dibagi menjadi 80% data training dan 20% data testing

Tabel 3 kelas dataset

Blackhead	Whitehead
	
Pustula	Nodul
	

### 2.2 Preprocessing

Data preprocessing merupakan persiapan awal sebelum pengolahan melibatkan proses Augmentasi data seperti *flipping,rotasi,brightness* untuk menambah keberagaman dataset serta membantu untuk mengatasi *overfitting* dan meningkatkan kinerja model pada data[5].Untuk memastikan konsistensi dalam pemrosesan setiap gambar diubah ukurannya secara *unified* dengan ukuran 299x299x3.

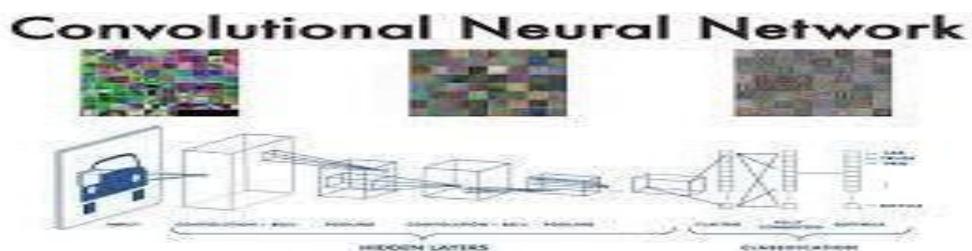


Gambar 1 hasil augmentasi

### 2.3. Model Convolutional Neural Network (CNN)

Convolutional Neural Network(CNN) digunakan untuk mengklasifikasi jenis jerawat berdasarkan gambar dengan memproses gambar yang di input kemudian mengklasifikasinya pada kategori tertentu.CNN di pilih karena kemampuannya dalam mengekstraksi fitur-fitur visual seperti pola ,tekstur,dan tepi gambar yang krusial untuk klasifikasi objek[11]CNN adalah perkembangan dari jaringan saraf tiruan (ANN)konvensional yang terdiri dari puluhan hingga ratusan lapisan[9]CNN mempunyai berbagai jenis layer diantaranya *Pooling layer,convolution*

*layer dan fully connected.*Fully connected merupakan bentuk jaringan dari neural network dimana citra yang telah diubah menjadi satu dimesi dijadikan sebagi nilai masukan lapisan input agar dapat diprediksi[12]Metode CNN mempunyai output yang paling relevan dalam pengolahan citra digital.Hal ini dikarenakan CNN dapat di terapkan dengan sistem pengolah citra pada *visual cortex* manusia.Oleh karena itu alogaritma Convolutional Neural Network(CNN) sering digunakan karena memiliki hasil yang signifikan dalam pengenalan citra digital.



Gambar 2 Alogaritma CNN

### 2.4 Pelatihan Model

Pada tahap ini ,pelatihan model memiliki peran penting dalam menyesuaikan parameter seperti bobot untuk mengurangi kesalahan prediksi.Pada penelitian ini digunakan tiga aritektur model CNN yaitu Inceptionv3,VGG16,dan EfficientNetB0 sebagai aritektur dasar.Ketiga model tersebut bekerja sebagai *Pre-trained* model bertujuan untuk mengenali fitur umum pada gambar.

Kemudian masuk ketahap lapisan awal model digunakan untuk mengekstrak fitur dari dataset.lapisan-lapisan ini biasanya dibekukan atau tidak dilatih ulang.Setelah itu masuk ke tahap *fine tuning* disini kita dapat menambahkan beberapa lapisan baru diatas *pre-trained* model,lalu melatih ulang seluruh maupun sebagian model pada dataset spesifik agar model lebih sesuai dengan tugas baru.

Selain itu untuk mengatasi *overfitting* teknik seperti *augmentasi* data dan *early stopping* dapat diimplementasikan selama pelatihan model bertujuan untuk memastikan model tidak hanya menghafal pada pola-pola dalam latihan namun mampu menganalisa dan generalisasi terhadap data baru.optimasi kerja model juga dicapai melalui penggunaan *optimizer* dan fungsi *loss* yang tepat .

## 2.5 Pengujian Model

### 2.5.1 Evaluasi Model

Performa model dapat dievaluasi dengan menggunakan dataset pengujian untuk mengukur metrik-metrik seperti akurasi, presisi, recall, dan F1-score. Salah satu cara yang paling umum digunakan untuk mengevaluasi performa model adalah dengan menggunakan confusion matrix, yang memberikan gambaran menyeluruh tentang prediksi yang benar dan salah dari model. Confusion matrix mengklasifikasikan hasil prediksi menjadi empat kategori: True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN), yang masing-masing memiliki peran penting dalam menghitung metrik-metrik evaluasi.[6]

### 2.5.2 Analisis hasil

Berdasarkan hasil evaluasi model, akan terlihat hasil klasifikasi yang digunakan untuk memahami performa model, baik dari segi kelebihan maupun kekurangan.

Hasil analisis menunjukkan perbandingan antara data latih dan akurasi pada data validasi.

## 2.6 Rancangan Graphic User Interface Menggunakan Streamlit

GUI aplikasi web dibuat untuk mempermudah pengguna dalam proses deteksi jerawat. Dalam pembuatannya akan digunakan framework streamlit untuk pembuatan aplikasi web dengan menggunakan streamlit dan bahasa Python, pengembang dapat dengan mudah membuat aplikasi berbasis web yang terstruktur untuk mengatur interaksi pengguna dan menampilkan hasil prediksi dari model yang digunakan.



Gambar 3 Alur Kerja Web

## 3 Hasil dan Pembahasan

### 3.1 Pengumpulan Data

Data citra yang digunakan pada penelitian ini menggunakan 340 gambar yang dibagi menjadi 4 kelas jenis jerawat, yaitu blackhead, pustula, nodul, dan whitehead. Masing-masing kelas memiliki 85 gambar yang diambil dari google dan situs kaggle sebuah



platform yang menyediakan berbagai data set untuk keperluan penelitian dan pembelajaran mesin.

Semua gambar disimpan dalam format.jpg ,kemudian dataset ini dibagi menjadi dua dataset training dan data testing dimana data akan dibagi menjadi rasio 80% untuk data training dan 20% untuk data testing.Pada tahap pembagian ini sangat penting karena memungkinkan model untuk belajar dari data yang tidak termasuk dalam proses pelatihan.

## 3.2 Pengolahan data

### 3.2.1 Mengubah Ukuran Citra(resize)

Tahap awal dalam penelitian ini adalah melakukan pra-pemrosesan terhadap data citra.Dataset asli Disimpan dalam direktori dataset\_baru,yang berisi subfolder sesuai dengan masing-masing kelas jerawat.

Semua citra diproses secara *unified* dengan ukuran 299x299x3(sesuai input default Inceptionv3,yang kemudian akan di resize kembali mengikuti model CNN yang akan digunakan). Penyesuaian citra dilakukan untuk keperluan pengujian kinerja model dengan menggunakan citra yang berbeda.

### 3.2.2 Augmentasi

Pada proses *deep learning* jumlah citra yang terkumpul terbilang sangat kecil sehingga dengan menerapkan teknik-teknik augmentasi dataset menjadi lebih beragam,yang diharapkan dapat meningkatkan kemampuan model untuk mengenali objek dengan berbagai variasi,dan pada akhirnya menghasilkan model yang lebih generalis dan tidak mudah terjebak pada pola tertentu yang ada di dalam pelatihan.

Selain itu proses augmentasi dilakukan dengan menggunakan fungsi *ImageDataGenerator* dari Keras yang menerapkan beberapa teknik augmentasi seperti *Rotation,Width shift,Heigh shift,Zoom,Horizon Flip,Brightness*.

Proses augmentasi lanjutan(jika diperlukan)juga dapat diaplikasikan kembali pada citra 224x224 saat pipeline *flow\_from\_directory* untuk VGG16 dan EfficientNetB0 menggunakan parameter augmentasi yang sama.Dengan demikian ,ketiga model tetap mendapatkan variasi data yang seragam sekaligus memenuhi kondisi input size masing-masing arsitektur.

## 3.3 Pembagian dataset

Didapatkan 4 jenis dataset setelah dilakukan proses pengolahan data.Dari 1360 data citra dilakukan pembagian sebanyak 80% sebagai data latih dan 20% sebagai data validasi.Sehingga terdapat 1088 data yang digunakan sebagai data latih dengan masing-masing perkelasnya terdapat 272 data dan yang digunakan pada data validasi dengan total 272 dimana perkelasnya terdapat 68 data.



### 3.4 Pembangunan Model

Pada penelitian ini menggunakan tiga arsitektur untuk membangun model klasifikasi citra yaitu Inceptionv3, VGG16, dan EfficientnetB0. Walaupun jumlah data yang digunakan dalam penelitian ini tergolong terbatas, hasil yang diperoleh tetap mampu memberikan pemahaman yang lebih komprehensif terhadap performa model. Hal ini sangat bermanfaat untuk mengevaluasi keunggulan dan kelemahan dari setiap arsitektur yang diuji. Dalam proses pengembangan digunakan *library Tensorflow* untuk melakukan inisialisasi serta pengaturan mode

### 3.4 Pengujian Model

Untuk meningkatkan kemampuan model dalam pengujian mengenali karakteristik masing-masing jenis jerawat seperti blackhead, whitehead, pustula, dan nodul pada penelitian ini menerapkan teknik fine-tuning. Teknik ini dilakukan dengan membekukan (Freeze) beberapa lapisan awal dari model yang bertugas mengenali fitur dasar, kemudian melatih ulang (retrain) lapisan-lapisan akhir yang lebih spesifik terhadap fitur dari dataset yang digunakan.

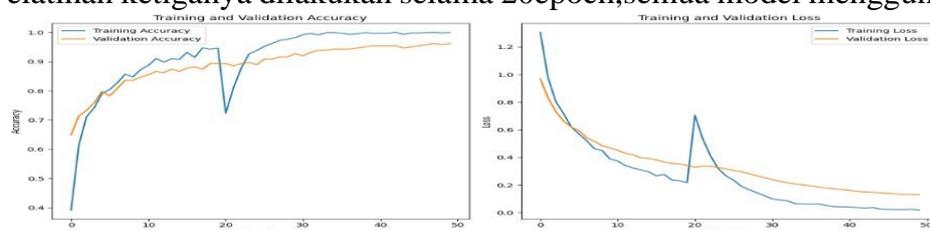
Pada InceptionV3, fine-tuning di fokuskan pada bagian Inception Module. Pada VGG16, proses fine-tuning dilakukan pada bagian fully connected layers yang berada setelah seluruh lapisan konvolusional, karena bagian ini memegang peranan penting dalam tahap klasifikasi akhir. Pada EfficientNetB0, pelatihan ulang dilakukan pada bagian akhir dari blok MBConv dan layer klasifikasi yang bertugas dalam pemrosesan fitur kompleks dan pengambilan keputusan akhir.

Dengan menerapkan fine-tuning pada bagian akhir dari masing-masing arsitektur diharapkan model mampu menangkap pola-pola yang lebih relevan terhadap karakteristik visual dari setiap jenis jerawat. Pendekatan ini bertujuan untuk meningkatkan akurasi model secara signifikan dalam melakukan prediksi pada data uji.

### 3.5 Hasil Pengujian Model

Pengujian model merupakan tahap pelatihan model terhadap data uji melakukan klasifikasi terhadap kelas-kelas yang telah ditentukan. Pada penelitian ini menggunakan tiga arsitektur yaitu Inception V3, VGG16, dan EfficientnetB0. Pelatihan model CNN merupakan proses berulang untuk mendapatkan performa model terbaik yaitu forward propagation untuk menghasilkan prediksi, perhitungan loss untuk menilai kesalahan prediksi, back propagation untuk menghitung gradien yang dibutuhkan untuk memperbarui parameter.

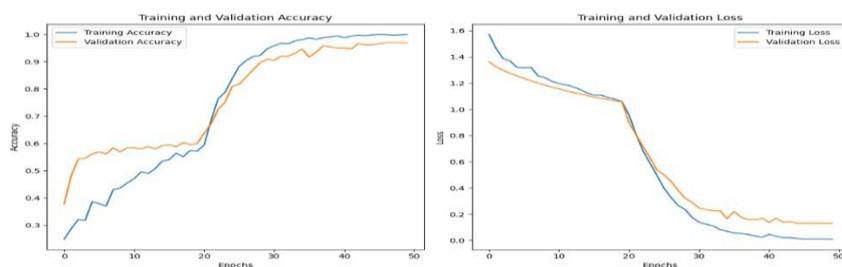
Dalam pelatihan ini, model dilatih menggunakan optimizer Adam dengan learning rate sebesar 0,0001 dan Loss function yang digunakan adalah categorical crossentropy. Pelatihan ketiganya dilakukan selama 20 epoch, semua model menggunakan



callback EarlyStopping,dan pada VGG16 dengan patience=3 dan restore\_best\_weights=True,yang artinya pelatihan akan berhenti jika val\_loss tidak membaik selama 3epoch berturut-turut,dan model akan mengembalikan bobot terbaik.

Gambar 4 Grafik Accuracy &amp;Loss InceptionV3

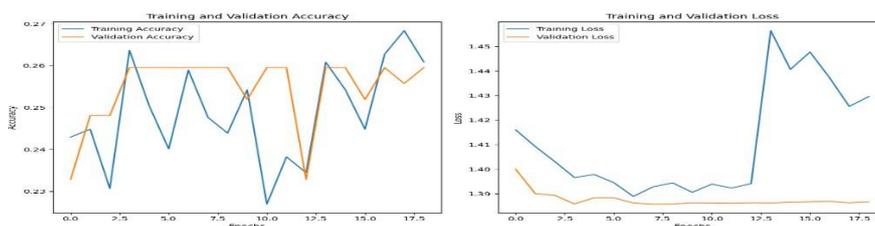
Pada gambar 4 diatas ditampilkan grafik akurasi dan loss untuk data training dan validasi selama 50epoch.Berdasarkan grafik tersebut,akurasi model menunjukkan peningkatan yang signifikan pada awal pelatihan dan mencapai nilai mendekati 100% untuk data training dan sekitar 96% untuk data validasi.Grafik juga menunjukkan bahwa tidak terjadi overfitting yang signifikan,terlihat dari nilai loss validasi yang terus menurun seiring dengan penurunan loss training.Pada epoch ke-20,terjadi lonjakan pada grafik akurasi dan loss,yang merupakan indikasi transisi dari tahap pelatihan awal menuju tahap fine-tuning.Setelah tahap fine-tuning dimulai,performa model meningkat secara stabil hingga akhir epoch ke-50.



Gambar 5 Grafik Accuracy&amp;Loss VGG16

Pada gambar 5 diatas ditampilkan grafik akurasi dan loss untuk data training dan validasi dilakukan selama 50 epoch,diperoleh peningkatan kinerja yang signifikan pada proses klasifikasi empat jenis jerawat,yaitu whitehead,blackhead,pustula,dan nodul.Grafik akurasi pelatihan dan validasi menunjukkan tren yang stabil meningkat,dimana akurasi validasi mencapai mendekati 0,97 di akhir pelatihan.

Hal ini menunjukkan bahwa model mampu belajar dengan baik dari data pelatihan tanpa mengalami overfitting yang signifikan,sebagaimana terlihat dari nilai akurasi validasi yang sejalan dengan akurasi pelatihan.Sementara itu grafik loss juga menunjukkan penurunan yang konsisten pada kedua data pelatihan dan validasi.Nilai loss validasi cenderung stabil mendekati titik minimum dibawah 0,2.Pada akhir epoch ke-50



Lisensi

Lisensi Internasional Creative Commons Attribution-ShareAlike 4.0.

,mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya.

Gambar 6 Grafik Accuracy &amp; Loss EfficientNetB0

Berdasarkan grafik pada gambar 6 hasil pelatihan model EfficientNetB0, terlihat bahwa nilai akurasi data pelatihan dan validasi berada pada kisaran 23% hingga 27%. Pola fluktuasi yang cukup tinggi dari akurasi pelatihan menunjukkan bahwa model belum mampu belajar secara stabil terhadap data yang diberikan. Sementara itu, akurasi validasi cenderung stagnan dan tidak menunjukkan peningkatan signifikan seiring bertambahnya epoch. Grafik loss menunjukkan bahwa nilai loss pada data pelatihan mengalami penurunan di awal, namun kembali meningkat secara drastis pada epoch ke -13 sebelum akhirnya menurun kembali.

Di sisi lain, nilai loss pada data validasi terlihat relatif stabil dari awal hingga akhir pelatihan, namun juga tidak mengalami perbaikan yang berarti. Pola ini mengindikasikan bahwa model EfficientNetB0 belum mencapai performa yang optimal dan kemungkinan besar mengalami overfitting ringan atau tidak mampu menangkap pola yang relevan dari data.

### 3.5.2 Hasil Pengujian Klasifikasi

Evaluasi lebih lanjut dilakukan dengan menguji model terhadap data uji. Hasil klasifikasi ditunjukkan pada tabel

Tabel 4 Hasil Evaluasi Model InceptionV3

Kelas	Precision	Recall	F1-Score	Support
Blackhead	0.97	0.97	0.97	61
Nodul	0.93	0.97	0.95	68
Pustula	0.98	0.92	0.95	65
Whitehead	0.97	0.99	0.98	68
Accuracy			0.96	262
Macro Avg	0.96	0.96	0.96	262

Berdasarkan hasil tersebut, model InceptionV3 berhasil mengklasifikasi jenis jerawat dengan akurasi keseluruhan sebesar 96%. Nilai precision, recall, dan f1-score untuk masing-masing kelas juga menunjukkan performa yang tinggi, dengan nilai tertinggi diperoleh pada kelas whitehead (F1-score 0,98) dan terendah pada pustula (recall 0.92). Model memiliki kinerja yang baik dan seimbang di semua kelas.

Tabel 5 Hasil Evaluasi Model VGG16



Kelas	Precision	Recall	F1-Score	Support
Blackhead	1.00	0.98	0.95	61
Nodul	0.96	0.96	0.98	68
Pustula	0.95	0.95	0.95	65
Whitehead	0.97	0.99	0.98	68
Accuracy	-	-	0.97	262
Macro Avg	0.97	0.97	0.97	262

Berdasarkan hasil dari tabel 5 menunjukkan bahwa model VGG16 mencapai nilai akurasi keseluruhan sebesar 97%, dengan skor precision, recall, dan f1-score rata-rata (macro avg) masing-masing sebesar 0,97. Nilai f1-score tertinggi diperoleh pada kelas blackhead sebesar 0.99 diikuti oleh whitehead (0,98), serta nodul dan pustula yang masing-masing sebesar 0,96 dan 0,95. Hal ini menunjukkan bahwa model sangat baik dalam membedakan keempat jenis jerawat, terutama pada whitehead dan blackhead.

Tabel 6 Evaluasi	Kelas	Precision	Recall	F1-Score	Support	Hasil Model
	Blackhead	0.00	0.00	0.00	61	
Nodul	0.00	0.00	0.00	68		
Pustula	0.00	0.00	0.00	65		
Whitehead	0.26	1.00	0.41	68		
Accuracy	-	-	0.26	262		
Macro Avg	0.06	0.25	0.10	262		

EfficientNetB0

Hasil evaluasi model EfficientNetB0 terhadap data uji ditunjukkan pada tabel diatas. Berdasarkan hasil tersebut, terlihat bahwa model mampu mengenali kelas whitehead dengan baik, dengan nilai precision sebesar 0,26 recall sebesar 1,00 dan f1-score sebesar 0,41. Sementara itu, tiga kelas lainnya, yaitu blackhead, nodul dan pustula, tidak berhasil diprediksi sama sekali oleh model (nilai precision, recall, dan f1-score sebesar 0.00). Hal ini mengindikasikan bahwa model mengalami ketidakseimbangan dalam mengenali kelas dan cenderung melakukan prediksi yang bias terhadap satu kelas dominan, dalam hal ini adalah whitehead.

Nilai akurasi keseluruhan sebesar 0.26 menunjukkan performa model yang masih sangat rendah, bahkan lebih rendah dari prediksi acak. Pada data dengan empat kelas seimbang (sekitar 25%). Nilai macro average f1-score sebesar 0.10 dan weighted



Lisensi

Lisensi Internasional Creative Commons Attribution-ShareAlike 4.0.

average f1-score sebesar 0.11 memperkuat kesimpulan bahwa model belum mampu melakukan generalisasi dengan baik terhadap semua kelas.

### 3.6 Implementasi User Interface Streamlit

Menggunakan aplikasi web yang dikembangkan dengan bantuan streamlit, yaitu sebuah framework berbasis python yang memungkinkan pembuatan antarmuka pengguna secara interaktif dan cepat.

Aplikasi ini dijalankan secara lokal melalui alamat <http://localhost:8501/>. Berikut merupakan tampilan utama antarmuka aplikasi klasifikasi jenis jerawat berbasis



streamlit:

Gambar 7 Halaman Utama Website

Pada halaman utama merupakan titik awal situs web yang memberikan gambaran menyeluruh tentang konten dan fitur yang tersedia. Pada halaman utama dari website terdapat bagian atau tombol browse file untuk mengunggah gambar yang akan di klasifikasi. Setelah memilih gambar yang akan di klasifikasikan secara otomatis akan muncul tampilan pada gambar 8 dibawah



Gambar 8 Halaman Utama Setelah gambar di Upload

Setelah gambar di unggah, sistem akan melakukan proses prapengolahan (preprocessing) secara otomatis, kemudian menjalankan prediksi menggunakan

**Hasil Prediksi Model** ⇄

Berikut hasil prediksi dan waktu inferensi dari masing-masing model:

	Model	Tipe Jerawat	Confidence	Waktu Inference
0	InceptionV3	Pustula	71.5%	3.67s
1	VGG16	Pustula	41.0%	0.69s
2	EfficientNetB0	Whitehead	25.6%	2.82s

model CNN yang telah dilatih sebelumnya.

Gambar 9 Halaman Utama Setelah gambar di Upload



Lisensi

Lisensi Internasional Creative Commons Attribution-ShareAlike 4.0.

Hasil klasifikasi akan ditampilkan secara langsung di halaman web, termasuk jenis jerawat yang terdeteksi menggunakan ke tiga jenis model yang berbeda dan tingkat akurasi dari setiap modelnya. Setelah proses klasifikasi selesai halaman akan menampilkan jenis jerawat dan saran perawatan apa yang cocok untuk jenis jerawat yang

💡 **Saran Perawatan**

**Deskripsi:**  
❗ Pustula adalah jerawat merah meradang yang memiliki nanah putih atau kuning di tengahnya. Biasanya terasa nyeri saat disentuh.

**Perawatan:**  
 Gunakan spot treatment dengan Benzoyl Peroxide atau salicylic acid.

**Saran:**  
 Jika tidak membaik dalam 6-8 minggu, konsultasi ke dokter kulit.

👉



**Hasil Prediksi Model**

Berkas hasil prediksi dan validasi dari masing-masing model:

Model	Tipe Jerawat	Confidence
InceptionV3	Whitehead	82%
VGG16	Whitehead	82%
EfficientNetB0	Whitehead	82%

**Whitehead**

Hasil menunjukkan model inception dan VGG16 memberikan akurasi tertinggi dan sesuai



**Hasil Prediksi Model**

Berkas hasil prediksi dan validasi dari masing-masing model:

Model	Tipe Jerawat	Confidence
InceptionV3	Whitehead	82%
VGG16	Whitehead	82%
EfficientNetB0	Whitehead	82%

Hasil menunjukkan model Inception Memberikan akurasi tertinggi dan sesuai



**Hasil Prediksi Model**

Berkas hasil prediksi dan validasi dari masing-masing model:

Model	Tipe Jerawat	Confidence
InceptionV3	Whitehead	82%
VGG16	Pustula	82%
EfficientNetB0	Whitehead	82%

Hasil menunjukkan model Inception Memberikan akurasi tertinggi dan sesuai

teridentifikasi.

Gambar 10 Halaman Utama Setelah gambar di Upload

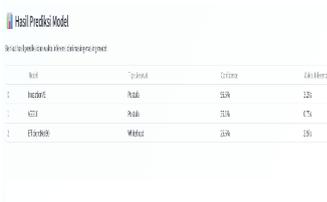
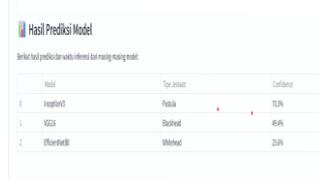
### 3.6.2 Hasil Uji Coba

Pada bagian ini akan di perlihatkan hasil testing menggunakan model yang dipilih dengan data test. Dalam hasil uji coba akan menunjukkan hasil prediksi dari ketiga model, dan akan dilihat mana yang memiliki tingkat akurasi yang paling tinggi. Berikut hasil testing dengan ketiga model dapat dilihat pada tabel 7 .



Lisensi  
 Lisensi Internasional Creative Commons Attribution-ShareAlike 4.0.

308

Gambar	Hasil Prediksi	Keterangan																
	<p style="text-align: center;"><b>Pustula</b></p>  <table border="1"> <thead> <tr> <th>Model</th> <th>Spesies</th> <th>Confidence</th> <th>Ekstensi</th> </tr> </thead> <tbody> <tr> <td>0</td> <td>InceptionV3</td> <td>Pustula</td> <td>85%</td> </tr> <tr> <td>1</td> <td>VGG16</td> <td>Pustula</td> <td>33%</td> </tr> <tr> <td>2</td> <td>EfficientNetB0</td> <td>Whitehead</td> <td>28%</td> </tr> </tbody> </table>	Model	Spesies	Confidence	Ekstensi	0	InceptionV3	Pustula	85%	1	VGG16	Pustula	33%	2	EfficientNetB0	Whitehead	28%	<p>Hasil menunjukkan model Inception dan VGG16 Memberikan akurasi tertinggi dan sesuai</p>
Model	Spesies	Confidence	Ekstensi															
0	InceptionV3	Pustula	85%															
1	VGG16	Pustula	33%															
2	EfficientNetB0	Whitehead	28%															
	 <table border="1"> <thead> <tr> <th>Model</th> <th>Type Lesion</th> <th>Confidence</th> </tr> </thead> <tbody> <tr> <td>0</td> <td>InceptionV3</td> <td>Nodul</td> <td>78.3%</td> </tr> <tr> <td>1</td> <td>VGG16</td> <td>Blackhead</td> <td>45.6%</td> </tr> <tr> <td>2</td> <td>EfficientNetB0</td> <td>Whitehead</td> <td>25.8%</td> </tr> </tbody> </table> <p style="text-align: center;"><b>Nodul</b></p>	Model	Type Lesion	Confidence	0	InceptionV3	Nodul	78.3%	1	VGG16	Blackhead	45.6%	2	EfficientNetB0	Whitehead	25.8%	<p>Hasil menunjukkan model Inception Memberikan akurasi tertinggi dan sesuai</p>	
Model	Type Lesion	Confidence																
0	InceptionV3	Nodul	78.3%															
1	VGG16	Blackhead	45.6%															
2	EfficientNetB0	Whitehead	25.8%															
	 <table border="1"> <thead> <tr> <th>Model</th> <th>Type Lesion</th> </tr> </thead> <tbody> <tr> <td>0</td> <td>InceptionV3</td> <td>Nodul</td> </tr> <tr> <td>1</td> <td>VGG16</td> <td>Pustula</td> </tr> <tr> <td>2</td> <td>EfficientNetB0</td> <td>Whitehead</td> </tr> </tbody> </table>	Model	Type Lesion	0	InceptionV3	Nodul	1	VGG16	Pustula	2	EfficientNetB0	Whitehead	<p>Hasil menunjukkan model Inception Memberikan akurasi tertinggi dan sesuai</p>					
Model	Type Lesion																	
0	InceptionV3	Nodul																
1	VGG16	Pustula																
2	EfficientNetB0	Whitehead																
	 <table border="1"> <thead> <tr> <th>Model</th> <th>Type Lesion</th> </tr> </thead> <tbody> <tr> <td>InceptionV3</td> <td>Nodul</td> </tr> <tr> <td>VGG16</td> <td>Pustula</td> </tr> <tr> <td>EfficientNetB0</td> <td>Whitehead</td> </tr> </tbody> </table>	Model	Type Lesion	InceptionV3	Nodul	VGG16	Pustula	EfficientNetB0	Whitehead	<p>Hasil menunjukkan model Inception Memberikan akurasi tertinggi dan sesuai</p>								
Model	Type Lesion																	
InceptionV3	Nodul																	
VGG16	Pustula																	
EfficientNetB0	Whitehead																	

#### 4. Kesimpulan

Penelitian ini membahas implementasi model Convolutional Neural Network (CNN) untuk klasifikasi jenis jerawat berbasis web menggunakan platform Streamlit. Tiga arsitektur CNN yang dievaluasi dalam penelitian ini adalah InceptionV3, VGG16, dan EfficientNetB0. Evaluasi dilakukan berdasarkan data uji yang mencakup empat kelas jerawat, yaitu *blackhead*, *nodul*, *pustula*, dan *whitehead*, menggunakan metrik precision, recall, f1-score, dan akurasi.

Hasil evaluasi menunjukkan bahwa model VGG16 memiliki performa terbaik dengan akurasi keseluruhan sebesar 97%, serta nilai f1-score tertinggi pada kelas *blackhead* (0,99) dan *whitehead* (0,98). Model InceptionV3 menyusul dengan akurasi sebesar 96%, dengan nilai f1-score tertinggi pada *whitehead* (0,98). Kedua model ini menunjukkan performa yang baik dan seimbang dalam mengenali keempat jenis jerawat. Sebaliknya, model EfficientNetB0 hanya memperoleh akurasi 26%, dengan kemampuan prediksi yang terbatas pada satu kelas (*whitehead*) dan gagal mengenali kelas lainnya.

Hasil ini mengindikasikan bahwa model mengalami bias dan kesulitan dalam melakukan generalisasi, kemungkinan disebabkan oleh ketidakseimbangan data, kurangnya fitur representatif, serta konfigurasi hyperparameter yang belum optimal.

Dengan demikian, dapat disimpulkan bahwa model VGG16 adalah arsitektur yang paling direkomendasikan untuk diimplementasikan dalam sistem klasifikasi jerawat berbasis web menggunakan Streamlit.

#### REFRENSI

- [1] J. E. Hall, *Guyton and Hall Textbook of Medical Physiology*, 13th ed. Philadelphia: W. B. Saunders, 2015.
- [2] H. T. Sibero, A. Sirajudin, dan D. Anggraini, "Prevalensi dan Gambaran Epidemiologi Akne Vulgaris di Provinsi Lampung," *Jurnal Kedokteran Universitas Lampung*, vol. 3, no. 2, pp. 308–312, 2019.
- [3] A. N. All About Skincare, 2nd ed., Nimas, Ed. Yogyakarta: Brilliant, 2021, hal. 7–175.
- [4] F. Sudana Putra, Kusrini, dan M. P. Kurniawan, "Deteksi Otomatis Jerawat Wajah Menggunakan Metode Convolutional Neural Network (CNN)," *Journal of Information Technology*, vol. 1, no. 2, pp. 30–34, 2021. Tersedia: <https://doi.org/10.46229/jifotech.v1i2.308>.
- [5] F. S. Dewi, Ramadhani, dan S. Djasmayena, "Klasifikasi Jenis Jerawat berdasarkan Gambar Menggunakan Algoritma CNN (Convolutional Neural Network)," *Hello World: Jurnal Ilmu Komputer*, vol. 3, no. 2, pp. 68–73, Jul. 2024, doi: 10.562211/heloworld.v3i2.518.
- [6] H. I. Islam, M. K. Mulyadien, U. Enri, U. Singaperbangsa, dan K. Abstract, "Penerapan Algoritma C4.5 dalam Klasifikasi Status Gizi Balita," *Jurnal Ilmiah Wahana Pendidikan*, vol. 8, no. 10, pp. 116–125, 2022. Tersedia:



Lisensi

Lisensi Internasional Creative Commons Attribution-ShareAlike 4.0.

<https://doi.org/10.5281/zenodo.6791722>.

[7] A. A. Meliala dan R. A. S. Lubis, "Hubungan Akne Vulgaris dengan Gejala Ansietas pada Mahasiswa Fakultas Kedokteran Universitas Muhammadiyah Sumatera Utara," *Jurnal Pandu Husada*, vol. 1, no. 2, p. 101, Mei 2020.

[8] Nurkasanah and murinto,"Klasifikasi Penyakit Kulit Wajah Menggunakan Metode Convolutional Neural Network,"*Sainteks*,vo18 no.2,p.183,Feb.2022, doi:10.30595/sainteks. v18i2.121188.

[9] Wahyudi Setiawan, *Deep Learning menggunakan Convolutional Neuarl Network* , Cetakan 1. Malang: Media Nusa Creative, 2021.

[10] M. Marlina, S. Sartini, dan A. Karim, "Efektivitas Beberapa Produk Pembersih Wajah Antiacne terhadap Bakteri Penyebab Jerawat *Propionibacterium acnes*," *BIOLINK (Jurnal Biologi Lingkungan Industri Kesehatan)*, vol. 5, no. 1, pp. 31–41, 2018. Tersedia: <https://doi.org/10.31289/biolink.v5i1.1668>.

[11]Supiyandi, M. A. Mujib, K. Azis, R. Abdillah, dan S. N. Iskandar, "Penerapan Teknologi Pengolahan Citra dalam Analisis Data Visual pada Tinjauan Komprehensif," \**Jurnal Kendali Teknik dan Sains\**, vol. 2, no. 3, pp. 179–.

[12]H. Herdianto and D. Nasution, "Implementasi metode CNN untuk klasifikasi objek," *METHOMIKA: Jurnal Manajemen Informatika & Komputerisasi Akuntansi*, vol. 7, no. 1, pp. 54- 60, Apr. 2023. doi: 10.46880/jmika.Vol7No1.pp54-60.

[13]M. Rasyid, Z. Sitorus, R. F. Wijaya, M. Iqbal, and K. Khairul, "Machine learning analysis in improving the efficiency of the student admission decision making process new at Panca Budi Medan Development University," *unpublished*.

[14]H. Herdianto, D. Nasution, N. S. Atmaja, and S. Ramadhan, "Penerapan Deep Learning YOLO untuk Pengukuran Jarak Objek Menggunakan Mono Kamera," *METHOMIKA: Jurnal Manajemen Informatika & Komputerisasi Akuntansi*, vol. 8, no. 1, pp. 51-56, Apr. 2024. doi: [10.46880/jmika.Vol8No1.pp51-56](https://doi.org/10.46880/jmika.Vol8No1.pp51-56).

[15]A. Khaliq and M. Muttaqin, "Early Earthquake Prediction Using a Hybrid Feature Selection and Ensemble Learning Approach," *International Journal of Computer Sciences and Mathematics Engineering*, vol. 3, no. 3, pp. 331, Sep. 2024. E-ISSN: 2962-4274. Available:



Lisensi

Lisensi Internasional Creative Commons Attribution-ShareAlike 4.0.