

# Klasifikasi Jerawat dengan Deep Learning Berbasis *Convolutional Neural Network*

Risdianti<sup>1,\*</sup>, M. Riko Anshori Prasetya<sup>1</sup>, Ahmad Hidayat<sup>2</sup>, Mambang<sup>3</sup>

<sup>1,2</sup>Sains dan Teknologi, Sistem Informasi, Universitas Sari Mulia, Banjarmasin, Indonesia

<sup>3</sup>Sains dan Teknologi, Teknologi Informasi, Universitas Sari Mulia, Banjarmasin, Indonesia

Email: <sup>1,\*</sup>risdianti01@gmail.com, <sup>1</sup>riko.anshori@gmail.com, <sup>2</sup>ayat5621@gmail.com, <sup>3</sup>mambang@unism.ac.id

<sup>\*)</sup> risdianti01@gmail.com

**Abstrak**—Jerawat adalah kondisi kulit yang umum terjadi di dunia, menyerang sekitar 9,4% populasi global. Dampaknya tidak hanya terbatas pada kesehatan fisik, tetapi juga kesehatan mental, seperti menurunkan kepercayaan diri. Deteksi dan diagnosis jerawat secara manual oleh dokter kulit membutuhkan waktu yang tidak sedikit dan bisa memerlukan sumber daya yang signifikan. Selain itu, kemampuan diagnosis bisa bervariasi antar dokter, yang dapat mengakibatkan perbedaan dalam perawatan. Oleh karena itu, diperlukan teknologi untuk mendeteksi jerawat secara otomatis yang dapat mendeteksi dan mengklasifikasikan jerawat secara akurat. Penelitian ini bertujuan untuk mengembangkan model klasifikasi jerawat menggunakan *Convolutional Neural Network* (CNN) untuk mengidentifikasi empat jenis jerawat: *cystic*, hormonal, pasir, dan papula berdasarkan gambar wajah. Penelitian ini terdiri dari empat tahapan: pengumpulan data, *preprocessing* data, pembuatan model klasifikasi jerawat, dan pengujian model. Dataset yang digunakan terdiri dari 400 gambar jerawat yang diambil dari situs *Kaggle*, dibagi menjadi data latih dan data uji dengan rasio 80:20. Proses *preprocessing* dilakukan dengan *augmentasi* data menggunakan *ImageDataGenerator* dari *Keras* untuk meningkatkan variasi gambar. Model *Convolutional Neural Network* yang digunakan adalah *InceptionV3* yang dimodifikasi dengan lapisan *GlobalAveragePooling2D*, *dense layer* dengan fungsi aktivasi *ReLU*, *dropout* sebesar 20%, dan *output layer* dengan fungsi aktivasi *softmax*. Model dilatih menggunakan *optimizer RMSprop* dengan *learning rate* 0.0001 dan *loss function categorical\_crossentropy* selama 70 *epoch*, dengan *callback early stopping* untuk menghentikan pelatihan jika tidak ada peningkatan pada *loss function*. Evaluasi model dilakukan menggunakan *confusion matrix* untuk mengukur akurasi, presisi, dan *recall*. Hasil evaluasi menunjukkan bahwa model memiliki akurasi sebesar 85%, presisi 85%, dan *recall* 84%, yang mengindikasikan kinerja yang baik dalam mengklasifikasikan jenis-jenis jerawat pada gambar wajah. Secara keseluruhan, penelitian ini membuktikan bahwa penggunaan CNN dalam klasifikasi jerawat dapat menghasilkan model yang andal dan efisien. Dengan akurasi, presisi, dan *recall* yang tinggi, model ini dapat membantu dalam diagnosis dan penanganan masalah kulit berjerawat. Penggunaan teknologi *deep learning* seperti *Convolutional Neural Network* menunjukkan potensi besar dalam bidang dermatologi, khususnya dalam mendeteksi dan mengklasifikasikan kondisi kulit secara otomatis. Hasil penelitian ini memberikan kontribusi penting dalam pengembangan sistem otomatis untuk diagnosis jerawat, yang dapat digunakan oleh profesional medis untuk mempercepat dan meningkatkan akurasi diagnosis.

**Kata Kunci:** *Convolutional Neural Network, Deep Learning, Diagnosis Jerawat, Klasifikasi Jerawat*

**Abstract**— Acne is a common skin condition worldwide, affecting around 9.4% of the global population. Its impact is not limited to physical health but also mental well-being, often lowering self-confidence. Manual detection and diagnosis of acne by dermatologists can be time-consuming and may require significant resources. Moreover, diagnostic abilities may vary among doctors, leading to differences in treatment. Therefore, there is a need for technology that can automatically detect and accurately classify acne. This research aims to develop an acne classification model using Convolutional Neural Networks (CNN) to identify four types of acne: cystic, hormonal, sand, and papule based on facial images. The research involves four stages: data collection, data preprocessing, acne classification model development, and model testing. The dataset used consists of 400 acne images sourced from *Kaggle*, divided into training and test data with an 80:20 ratio. The preprocessing process included data augmentation using *ImageDataGenerator* from *Keras* to increase image variation. The Convolutional Neural Network model used is *InceptionV3*, modified with a *GlobalAveragePooling2D* layer, *dense layer* with *ReLU* activation function, 20% dropout, and an output layer with a *softmax* activation function. The model was trained using the *RMSprop* optimizer with a learning rate of 0.0001 and categorical crossentropy loss function for 70 epochs, with an early stopping callback to halt training if there was no improvement in the loss function. Model evaluation was performed using a confusion matrix to measure accuracy, precision, and recall. The evaluation results showed that the model achieved an accuracy of 85%, precision of 85%, and recall of 84%, indicating strong performance in classifying acne types in facial images. Overall, this research demonstrates that using CNN for acne classification can produce a reliable and efficient model. With high accuracy, precision, and recall, this model can aid in diagnosing and managing acne problems. The use of deep learning technologies, such as Convolutional Neural Networks, shows great potential in the field of dermatology, especially in detecting and classifying skin conditions automatically. The results of this study make a significant contribution to the development of automatic systems for acne diagnosis, which can be used by medical professionals to expedite and improve the accuracy of diagnosis.

**Keywords:** *Convolutional Neural Network, Deep Learning, Acne Diagnosis, Acne Classification*

## 1. PENDAHULUAN

Dunia tata rias terus berkembang pesat akhir-akhir ini, seiring dengan kemunculan berbagai merek perawatan kulit dan kosmetik. Produk-produk ini menawarkan berbagai kelebihan dan kekurangan, salah satunya adalah dalam menangani kulit berjerawat [1]. Jerawat, meskipun sering dianggap sebagai masalah kosmetik, sebenarnya merupakan kondisi kulit yang sangat umum dan signifikan, dengan prevalensi mencapai 9,4% dari populasi global, menjadikannya penyakit kulit paling umum kedelapan di dunia [2][3]. Tingginya prevalensi ini menandakan bahwa banyak individu yang membutuhkan solusi perawatan yang efektif. Namun, deteksi jerawat secara manual oleh dokter kulit seringkali memerlukan waktu yang lama dan tidak selalu konsisten. Oleh karena itu, teknologi yang dapat mendeteksi jerawat secara lebih cepat dan akurat sangat diperlukan. Salah satu pendekatan yang menjanjikan adalah menggunakan *deep learning*, khususnya dengan memanfaatkan algoritma *Convolutional Neural Network* (CNN) untuk mengklasifikasikan dan mendiagnosis jerawat secara akurat dan cepat [4].

Jerawat seringkali disebabkan oleh produksi sebum yang berlebihan, yang dapat menyebabkan pori-pori tersumbat dan peradangan. Meskipun jerawat tidak berbahaya secara fisik, kondisi ini dapat menyebabkan gangguan emosional dan sosial yang signifikan bagi penderitanya, seperti menurunkan rasa percaya diri dan bahkan menyebabkan depresi [5]. Adapun masalah utama yang dihadapi dalam penelitian terkait deteksi dan klasifikasi jerawat adalah tingginya variasi kondisi kulit, karakteristik jerawat, serta perbedaan jenis dan tingkat keparahannya. Kondisi kulit berjerawat sering kali memerlukan diagnosis cepat dan akurat untuk menentukan perawatan yang tepat. Namun, metode konvensional memakan waktu dan memerlukan keahlian klinis yang tinggi, yang tidak selalu tersedia di setiap tempat. Sehingga, ada urgensi untuk mengembangkan sistem otomatis yang dapat mendeteksi, mengklasifikasikan, dan memprediksi kondisi kulit berjerawat secara lebih efisien dan akurat. Dalam penelitian ini, penerapan *Convolutional Neural Network* (CNN) sebagai metode pembelajaran mendalam pada gambar jerawat diharapkan dapat meningkatkan akurasi deteksi serta klasifikasi jerawat dibandingkan dengan metode tradisional atau metode *machine learning* lain. Penggunaan CNN telah terbukti efektif dalam berbagai bidang klasifikasi gambar, namun dalam konteks jerawat, masih banyak ruang untuk eksplorasi dan optimasi. Penelitian ini bertujuan untuk mengembangkan model *Convolutional Neural Network* (CNN) yang mampu secara otomatis mengklasifikasikan jenis jerawat berdasarkan gambar, sehingga dapat meningkatkan akurasi dan konsistensi dalam diagnosis jerawat. Dengan mengotomatisasi proses identifikasi, penelitian ini bertujuan untuk mempercepat proses diagnosis di klinik dermatologi dan mengurangi ketergantungan pada keterampilan individu dokter, yang sering kali menyebabkan perbedaan dalam hasil diagnosis. Pada penelitian ini menggunakan *pre-trained* model yang dapat membantu mempercepat pelatihan dan meningkatkan akurasi pada dataset jerawat.

Berbagai penelitian sebelumnya telah mengeksplorasi metode yang berbeda untuk mendiagnosis kulit berjerawat. Sebagai contoh, penelitian oleh Hasma & Silfianti menggunakan metode *Faster Regional Convolutional Neural Network* (FRCNN) untuk mengklasifikasikan jenis jerawat, pus, dan bekas pada kulit [6]. Metode ini memanfaatkan kemampuan FRCNN dalam mendeteksi dan mengklasifikasikan berbagai kondisi kulit dengan lebih rinci. Selain itu, penelitian oleh Zhang & Ma menggunakan model *Ensemble Neural Network* untuk memprediksi tingkat keparahan jerawat serta menemukan jumlah dan lokasi jerawat berdasarkan foto wajah [7]. Pendekatan ini memberikan data yang lebih komprehensif dan membantu dalam merancang perawatan yang lebih efektif. Penelitian lain yang dilakukan oleh Fauzia Achmad menggunakan metode *Gray-Level Co-occurrence Matrix* (GLCM) dan *Backpropagation* untuk identifikasi jerawat berdasarkan analisis tekstur, mencapai tingkat akurasi sebesar 56,67% [4]. Walaupun hasil ini menunjukkan bahwa masih ada ruang untuk peningkatan, penelitian ini menyoroti potensi penggunaan analisis tekstur dalam deteksi jerawat. Selain itu, penggunaan algoritma YOLOV3 untuk deteksi jerawat juga telah diuji, memberikan input penting untuk penilaian perawatan kulit berjerawat dengan *Mean Average Precision* (mAP) sebesar 42,849% dan *Frame Per Second* (FPS) 6,89 setelah 100 *epoch* [8].

Adapun perbedaan dengan penelitian sebelumnya adalah keterbatasan akurasi dalam mendeteksi jerawat berdasarkan analisis tekstur seperti penelitian Fauzia Achmad dengan akurasi 56,67% [4]. Selain itu, beberapa metode yang digunakan sebelumnya, seperti YOLOV3, masih memiliki mAP yang relatif rendah untuk deteksi jerawat (sebesar 42,849%). Hasil ini menunjukkan bahwa meskipun berbagai pendekatan telah dicoba, masih ada tantangan dalam hal akurasi dan kecepatan deteksi pada sistem otomatis ini. Penelitian Zhang & Ma menggunakan model *ensemble* untuk prediksi tingkat keparahan jerawat, namun tidak banyak memberikan informasi tentang bagaimana sistem dapat digunakan untuk personalisasi perawatan kulit, yang bisa menjadi area yang lebih spesifik untuk ditingkatkan [7].

Penelitian ini memiliki perbedaan signifikan dibandingkan dengan penelitian terdahulu. Jika penelitian sebelumnya umumnya hanya berfokus untuk membedakan antara jerawat, pus, dan bekas jerawat serta

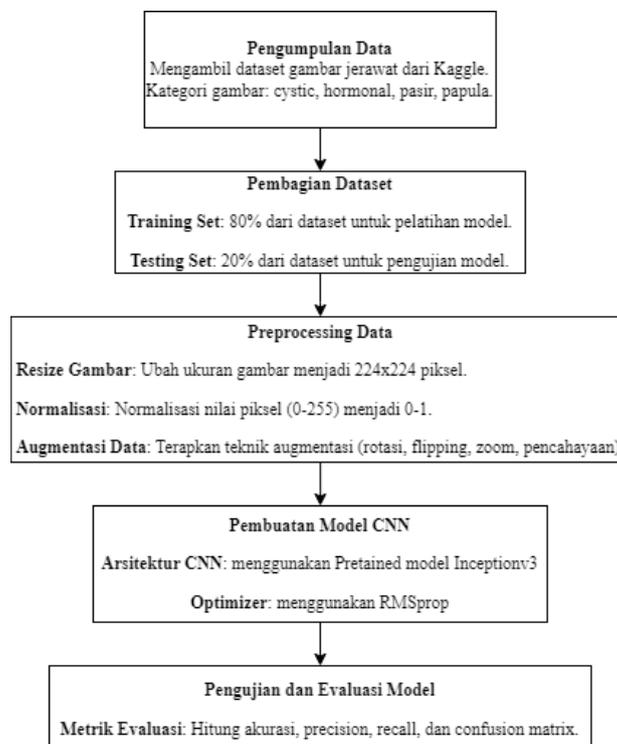
menentukan lokasi jerawat, penelitian ini lebih mendalam dengan mengembangkan metode untuk mengklasifikasikan jenis-jenis jerawat secara spesifik.

Penelitian ini tidak hanya menerapkan CNN, tetapi juga mencoba untuk mengatasi beberapa kelemahan dari pendekatan sebelumnya dengan mengeksplorasi variasi model CNN, seperti *InceptionV3*, yang lebih efektif dalam menangani kompleksitas data gambar, terutama dengan perbedaan tekstur kulit, bentuk jerawat, dan pencahayaan yang mungkin bervariasi. Selain itu, penelitian ini juga bisa mengeksplorasi penyesuaian hiperparameter atau penggunaan teknik *augmentasi* data yang lebih maju untuk meningkatkan generalisasi model pada dataset jerawat. CNN bekerja dengan beberapa lapisan (*layers*) yang secara bertahap mengekstrak fitur dari gambar, mulai dari fitur dasar seperti tepi dan tekstur hingga fitur yang lebih kompleks, yang akhirnya memberikan klasifikasi dalam bentuk skor [9]. Model CNN juga telah banyak digunakan dalam berbagai aplikasi lain, seperti dalam deteksi dan klasifikasi jenis daging hewan ternak. Dalam penelitian ini, digunakan 70 gambar jenis daging hewan ternak dan berhasil mencapai akurasi hingga 100% pada beberapa pengujian, serta rata-rata akurasi sistem sebesar 85,71% [10]. Ini menunjukkan fleksibilitas dan kemampuan CNN dalam mengenali berbagai jenis pola dan fitur dalam gambar. Selain itu, penelitian lain menggunakan CNN untuk mendeteksi penyakit pada gambar daun kentang, dengan hasil pengujian menunjukkan akurasi data validasi tertinggi mencapai 99%, menunjukkan bahwa algoritma ini sangat efektif dalam deteksi penyakit pada citra daun [11].

Berdasarkan penjelasan yang telah diberikan, penelitian ini bertujuan untuk mengklasifikasikan jenis-jenis jerawat pada kulit manusia dengan memanfaatkan algoritma *deep learning*, khususnya *Convolutional Neural Network*, menggunakan *framework TensorFlow* dari data berupa gambar jerawat. Dengan memanfaatkan kemampuan CNN dalam ekstraksi fitur dan klasifikasi gambar, diharapkan dapat dicapai hasil akurasi yang tinggi dalam membedakan jenis-jenis jerawat. Hasil penelitian ini diharapkan memberikan kontribusi signifikan dalam pengembangan sistem otomatis untuk melakukan diagnosis jerawat dengan tingkat akurasi, presisi, dan *recall* yang tinggi. Sistem ini dapat digunakan oleh tenaga profesional medis untuk mempercepat diagnosis dan penanganan masalah kulit berjerawat, memberikan perawatan yang lebih tepat dan efektif kepada pasien.

## 2. METODE PENELITIAN

Penelitian ini terdiri dari 5 tahapan yaitu, pengumpulan data, pembagian dataset, *preprocessing* data, pembuatan model klasifikasi jerawat, dan pengujian model. Setiap tahapan memiliki peran penting dalam memastikan bahwa model yang dibangun dapat mengklasifikasikan jenis-jenis jerawat dengan akurat dan efisien. Bisa dilihat pada Gambar 1.



Gambar 1. Alur Penelitian

## 2.1 Pengumpulan Data

Pada penelitian ini, dataset yang digunakan terdiri dari 400 gambar jerawat, yang masing-masing terdapat empat kategori: jerawat *cystic*, jerawat hormonal, jerawat pasir, dan jerawat papula. Setiap kategori berisi 100 gambar, yang diambil dari situs *Kaggle* <https://www.kaggle.com/datasets/lexuanhieu131297/acne-severity-classification> dan semua gambar disimpan dalam format jpg. Dataset ini kemudian dibagi menjadi dua bagian, yaitu data *training* (80%) dan data *testing* (20%), untuk memastikan bahwa model yang dikembangkan dapat diuji dan divalidasi secara efektif [12]. Pembagian data yang proposional ini sangat penting untuk menghindari *overfitting*, dan untuk memastikan bahwa model tidak hanya mampu mengenali pola pada data *training* tetapi juga dapat melakukan klasifikasi dengan baik pada data *testing* yang belum pernah dilatih sebelumnya. Penggunaan CNN dengan dataset 400 gambar menjadi tantangan dalam penelitian ini, karena terbatasnya data dengan jenis jerawat yang sesuai, tetapi dengan pendekatan yang tepat seperti melakukan *pretained model* dan data *augmentasi*, memungkinkan untuk mendapatkan model yang efektif.

## 2.2 Preprocessing

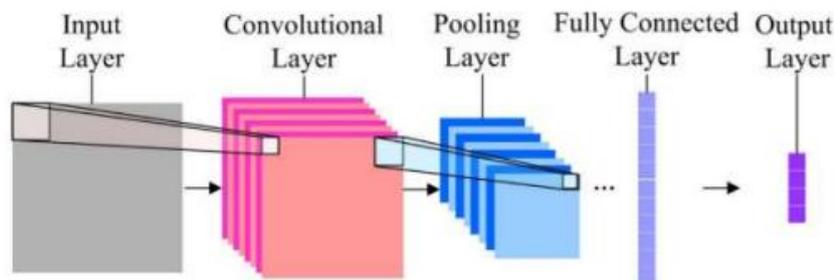
Data *preprocessing* merupakan tahap sebelum membersihkan data yang sudah diambil [13]. Dalam penelitian ini, *preprocessing* yang akan dilakukan adalah *Augmentasi Data*. *Augmentasi data* adalah proses pengolahan data gambar atau mengubah gambar sedemikian rupa sehingga komputer dapat mengetahui bahwa gambar yang diubah adalah gambar yang sama [14]. *Augmentasi data* dilakukan untuk meningkatkan dan menambah jumlah variasi gambar dalam dataset. Beberapa teknik *augmentasi* yang digunakan termasuk *zoom*, rotasi, *flipping horizintal*, perubahan *brightness*. Data *augmentasi* dapat membantu mengurangi *overfitting* dan meningkatkan kinerja model pada data yang belum pernah dilihat sebelumnya. Untuk memastikan konsistensi dalam pemrosesan, setiap gambar diubah ukurannya menjadi 244 x 244 piksel. Kemudian, gambar-gambar ini diproses dalam *batch* yang terdiri dari 32 gambar per *batch*. Pada Gambar 2. merupakan gambar hasil *augmentasi*.



Gambar 2. Hasil *Augmentasi*

## 2.3 Model Convolutional Neural Network

Pada penelitian ini, *Convolutional Neural Network* (CNN) digunakan untuk mengklasifikasikan jenis jerawat berdasarkan gambar. Ini dipilih karena kemampuan CNN untuk mengekstraksi fitur hierarkis dari data gambar, yang memungkinkan CNN untuk mengambil pola kompleks dari setiap jenis jerawat [3]. *Convolutional Neural Network* (CNN) adalah perkembangan dari jaringan saraf tiruan (ANN) konvensional yang terdiri dari puluhan hingga ratusan lapisan [15]. CNN, terinspirasi oleh jaringan saraf manusia, sering digunakan untuk mendeteksi dan mengenali objek dalam data gambar [16]. CNN memiliki keunggulan dalam hal *preprocessing* yang relatif sederhana dibandingkan dengan algoritma klasifikasi gambar lainnya [15]. Pada Gambar 3. merupakan gambaran dari model lapisan CNN pada penelitian ini.



Gambar 3. Model Lapisan CNN

### 2.3.1 Pelatihan Model

Pelatihan model CNN memiliki peran penting dalam menyesuaikan parameter seperti bobot dan bias untuk mengurangi kesalahan prediksi dan memfasilitasi pembelajaran model dari data. Ini sangat penting untuk meningkatkan kemampuan generalisasi, memungkinkan model mengenali pola umum dalam data pelatihan dan membuat prediksi yang akurat pada data baru. Untuk mengatasi *overfitting*, teknik seperti *augmentasi data* dan

*early stopping* dapat diimplementasikan selama pelatihan model. Pendekatan ini bertujuan untuk memastikan bahwa model tidak hanya menghafal pola-pola dalam data pelatihan, tetapi juga mampu melakukan generalisasi secara efektif terhadap data baru yang belum pernah diobservasi sebelumnya, sehingga meningkatkan kinerja model pada data uji. Optimasi kinerja model dicapai melalui penggunaan *optimizer* dan fungsi *loss* yang tepat, yang membantu menemukan parameter optimal untuk performa terbaik.

## 2.4 Pengujian model

### 2.4.1 Evaluasi

Proses pengukuran dan penilaian data dikenal sebagai data evaluasi, yang dilakukan untuk menentukan seberapa dapat diandalkan, akurat, lengkap, dan relevannya data tersebut. Evaluasi dilakukan secara menyeluruh dengan tujuan menemukan model yang sesuai dengan tujuan [17]. Model dievaluasi menggunakan *confusion matrix* untuk mengukur akurasi, *precision*, dan *recall*. *Confusion matrix* adalah matriks yang digunakan untuk mengevaluasi kinerja model klasifikasi dengan membandingkan hasil prediksi. Akurasi adalah metrik yang mengukur kemampuan model klasifikasi untuk memprediksi kelas dengan benar dari seluruh kasus evaluasi. *Precision* adalah metrik yang mengukur sejauh mana prediksi positif dari model. Sedangkan *recall* adalah metrik yang mengukur sejauh mana model mampu mengidentifikasi semua contoh sebenarnya yang masuk ke dalam suatu kelas tertentu [18]. Pada Tabel 1. merupakan tabel *confusion matrix*.

Tabel 1. Confusion Matrix

True Class	Positif Negatif	Predicted Class	
		Positif TP (True Positif) FN (False Negatif)	Negatif FP (False Positif) TN (True Negatif)

Berikut ini adalah beberapa metrik evaluasi yang umum digunakan dalam analisis performa model klasifikasi, yaitu akurasi, presisi, dan *recall*. Metrik-metrik ini dihitung berdasarkan nilai-nilai yang terdapat dalam *confusion matrix*, seperti *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Persamaan untuk masing-masing metrik tersebut disajikan sebagai berikut:

$$\text{Akurasi} = \frac{TN+TP}{TP+TN+FP+FN} \tag{1}$$

$$\text{Presisi} = \frac{TP}{TP+FP} \tag{2}$$

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

Keterangan:

- TP = Jumlah prediksi benar untuk kelas yang benar.
- FP = Jumlah prediksi salah untuk kelas yang salah.
- TN = Jumlah prediksi benar untuk kelas yang benar lainnya.
- FN = Jumlah prediksi salah untuk kelas yang benar lainnya.

### 2.4.2 Analisis Hasil

Hasil klasifikasi dianalisis untuk memahami performa model, termasuk kelebihan dan kekurangan. Analisis ini melibatkan perbandingan antara prediksi model dengan label sebenarnya dari dataset pengujian untuk mendapatkan wawasan lebih mendalam tentang kemampuan model dalam mengenali dan mengklasifikasikan jenis-jenis jerawat. Hal ini penting untuk pengembangan lebih lanjut dan perbaikan model agar lebih akurat dan andal dalam aplikasi dunia nyata.

## 3. HASIL DAN PEMBAHASAN

### 3.1 Pengumpulan Data

Dalam penelitian ini, dataset yang digunakan terdiri dari 400 gambar jerawat yang dibagi menjadi empat kategori utama: jerawat *cystic*, jerawat hormonal, jerawat pasir, dan jerawat papula. Masing-masing kategori memiliki 100 gambar, yang diambil dari situs *Kaggle*, sebuah platform yang menyediakan berbagai dataset untuk keperluan penelitian dan pembelajaran mesin. Semua gambar disimpan dalam format jpg, yang merupakan format gambar umum dan mudah diakses. Dataset ini kemudian dipecah menjadi dua subset utama: data *training* dan data *testing*. Pembagian ini dilakukan dengan proporsi 80% untuk data *training* dan 20% untuk data *testing*. Dengan demikian,

320 gambar digunakan untuk melatih model (data *training*), sementara 80 gambar sisanya digunakan untuk menguji kinerja model (data *testing*). Pembagian ini sangat penting karena memungkinkan model untuk belajar dari data yang sudah ada dan kemudian diuji kemampuannya dalam menggeneralisasi informasi pada data yang tidak termasuk dalam proses pelatihan. Dengan menggunakan data *testing*, peneliti dapat mengevaluasi seberapa baik model melakukan klasifikasi jenis jerawat dan menilai kemampuan model dalam situasi dunia nyata. Selain itu, pemilihan proporsi 80% untuk data *training* dan 20% untuk data *testing* didasarkan pada praktik terbaik dalam pembelajaran mesin, yang menyarankan pembagian yang cukup besar untuk pelatihan guna memberikan model dengan cukup data untuk belajar, sementara tetap menyisakan cukup data untuk pengujian guna mendapatkan evaluasi yang akurat tentang kinerja model. Pembagian yang tepat ini memastikan bahwa hasil dari pengujian model dapat diandalkan dan menunjukkan seberapa baik model dapat diharapkan bekerja pada data baru, yang sangat penting untuk aplikasi praktis dalam diagnosis klinis atau penggunaan lainnya.

**Tabel 2.** Jumlah Dataset

Jenis Jerawat	Dataset
Cystic	100
Pasir	100
Hormonal	100
Papula	100



**Gambar 4.** Jerawat Pasir



**Gambar 5.** Jerawat Hormonal



Gambar 6. Jerawat Papula



Gambar 7. Jerawat Cystic

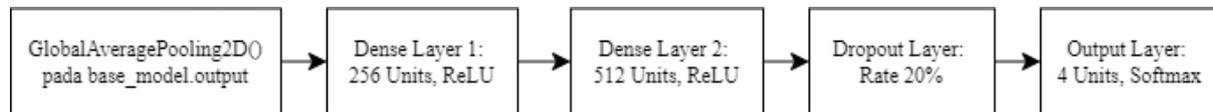
### 3.2 Preprocessing

*Preprocessing* adalah langkah krusial dalam pengolahan data sebelum digunakan dalam model pembelajaran mesin, karena tahap ini memastikan bahwa data siap untuk dianalisis dan dipelajari oleh model. Dalam penelitian ini, *preprocessing* mencakup berbagai teknik *augmentasi* data yang bertujuan untuk meningkatkan variasi gambar dalam dataset dan mengurangi risiko *overfitting*. *Augmentasi* data melibatkan penerapan transformasi seperti *zoom*, *rotasi*, *flipping horizontal*, dan perubahan *brightness* pada gambar asli. Teknik ini membantu menciptakan variasi gambar yang lebih luas tanpa memerlukan pengumpulan data tambahan. Dengan menggunakan *ImageDataGenerator* dari *Keras*, gambar dapat dimanipulasi secara acak, sehingga ukuran dataset secara virtual meningkat. Misalnya, gambar dapat diputar hingga 40 derajat, digeser hingga 20% dari ukuran aslinya, serta diperbesar atau diperkecil hingga 20%. Semua gambar juga diubah ukurannya menjadi 244 x 244 piksel untuk memastikan konsistensi dalam pemrosesan data, yang penting untuk kinerja model yang stabil dan dapat diandalkan. Selain itu, setiap gambar diberi label kelas yang sesuai dalam format *categorical*, yang penting untuk klasifikasi multi-kelas. Proses ini tidak hanya memperkaya dataset dengan variasi yang berbeda tetapi juga membantu model belajar mengenali pola-pola yang lebih umum, sehingga meningkatkan generalisasi dan akurasi model dalam pengujian data baru.

#### 3.2.1 Model CNN

Dalam penelitian ini, digunakan model *InceptionV3* yang telah dilatih sebelumnya pada dataset *ImageNet* untuk klasifikasi jenis jerawat. Model ini dikenal memiliki arsitektur yang kompleks dan efisien dalam ekstraksi fitur dari gambar, menjadikannya pilihan ideal untuk tugas pengenalan pola yang memerlukan detail yang tinggi. Proses modifikasi model *InceptionV3* dilakukan dengan beberapa langkah untuk menyesuaikannya dengan tugas klasifikasi jerawat. Pertama, lapisan *GlobalAveragePooling2D* digunakan untuk menggantikan lapisan *flatten* tradisional. Lapisan ini berfungsi untuk mengurangi dimensi spasial dari peta fitur menjadi satu vektor, yang memudahkan proses klasifikasi dengan mengurangi jumlah parameter dan mengurangi risiko *overfitting*. Selanjutnya, lapisan *Dense* ditambahkan, menggunakan fungsi aktivasi *ReLU* (*Rectified Linear Unit*). Fungsi aktivasi *ReLU* dipilih karena kemampuannya untuk memperkenalkan non-linearitas ke dalam model, yang memungkinkan model untuk belajar representasi fitur yang lebih kompleks dan bervariasi. Untuk lebih mencegah *overfitting*, teknik *Dropout* diterapkan dengan tingkat *dropout* sebesar 20%. *Dropout* bekerja dengan cara menghapus secara acak sejumlah unit *neuron* selama pelatihan, yang membantu dalam memperkenalkan

regularisasi ke dalam model dan mengurangi risiko *overfitting*. Terakhir, lapisan *output* menggunakan fungsi aktivasi *softmax*, yang mengkonversi *output* dari model menjadi probabilitas, sehingga memungkinkan klasifikasi gambar ke dalam empat kategori jenis jerawat: jerawat *cystic*, jerawat hormonal, jerawat pasir, dan jerawat papula. Model ini dipilih dan disesuaikan setelah serangkaian eksperimen dan optimasi untuk mencapai akurasi terbaik dalam klasifikasi jerawat. Pendekatan ini memastikan bahwa model tidak hanya mampu mengenali fitur dasar dari gambar tetapi juga mampu memahami pola yang lebih kompleks, memberikan hasil yang akurat dan andal dalam klasifikasi jenis jerawat. Bisa dilihat pada Gambar 8. merupakan *pre-trained* model yang digunakan pada penelitian ini.



Gambar 8. Modifikasi Pre-trained Model

Setelah berhasil mendefinisikan arsitektur jaringan dan melakukan modifikasi pada model *pre-trained*, seperti yang digambarkan pada Gambar 8, langkah selanjutnya adalah melakukan konfigurasi detail dari jaringan *neural* tersebut. Kode yang ditampilkan menunjukkan penambahan beberapa lapisan kunci seperti *Global Average Pooling2D*, lapisan *Dense*, serta *dropout* untuk mengurangi risiko *overfitting*. Penambahan lapisan-lapisan ini bertujuan untuk menyesuaikan model dengan kebutuhan spesifik tugas klasifikasi yang ditargetkan. Selanjutnya, Tabel 4. menyajikan rincian parameter *neural network* yang digunakan dalam model, termasuk berbagai lapisan konvolusi, normalisasi *batch*, aktivasi, dan *pooling*.

Tabel 3. Parameter Neural Network

Layer (type)	Output Shape	#Param
conv2d_6 (Conv2D)	(None, 25, 25, 48)	9216
conv2d_9 (Conv2D)	(None, 25, 25, 96)	55296
batch_normalization_6 (BatchNorm)	(None, 25, 25, 48)	144
batch_normalization_9 (BatchNorm)	(None, 25, 25, 96)	288
activation_6 (Activation)	(None, 25, 25, 48)	0
activation_9 (Activation)	(None, 25, 25, 96)	0
average_pooling2d (AvgPooling2D)	(None, 25, 25, 192)	0
conv2d_5 (Conv2D)	(None, 25, 25, 64)	12288
conv2d_7 (Conv2D)	(None, 25, 25, 64)	76800
conv2d_10 (Conv2D)	(None, 25, 25, 96)	82944
conv2d_11 (Conv2D)	(None, 25, 25, 32)	6144
batch_normalization_5 (BatchNorm)	(None, 25, 25, 64)	192
batch_normalization_7 (BatchNorm)	(None, 25, 25, 64)	192
batch_normalization_10 (BatchNorm)	(None, 25, 25, 96)	288
batch_normalization_11 (BatchNorm)	(None, 25, 25, 32)	96
activation_5 (Activation)	(None, 25, 25, 64)	0
activation_7 (Activation)	(None, 25, 25, 64)	0
activation_10 (Activation)	(None, 25, 25, 96)	0
activation_11 (Activation)	(None, 25, 25, 32)	0
mixed0 (Concatenate)	(None, 25, 25, 256)	0
conv2d_15 (Conv2D)	(None, 25, 25, 64)	16384
batch_normalization_15 (BatchNorm)	(None, 25, 25, 64)	192
activation_15 (Activation)	(None, 25, 25, 64)	0
conv2d_13 (Conv2D)	(None, 25, 25, 48)	12288
conv2d_16 (Conv2D)	(None, 25, 25, 96)	55296
batch_normalization_13 (BatchNorm)	(None, 25, 25, 48)	144
Total params: 22460964 (85.68 MB)		
Trainable params: 658180 (2.51 MB)		
Non-trainable params: 21802784 (83.17 MB)		

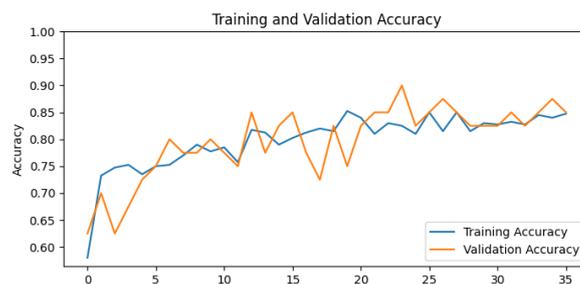
### 3.2.2 Pelatihan Model

Pelatihan model CNN merupakan proses berulang yang mencakup *forward propagation* untuk menghasilkan prediksi, perhitungan *loss* untuk menilai kesalahan prediksi, *backward propagation* untuk menghitung *gradien* yang dibutuhkan guna memperbarui parameter, serta penyesuaian parameter untuk mengoptimalkan model. Proses ini terus diulangi hingga model mencapai performa yang diinginkan. Dengan memahami dan menjalankan langkah-langkah ini, model CNN dapat dioptimalkan untuk berbagai aplikasi, khususnya dalam pengenalan dan klasifikasi gambar. Dalam penelitian ini, model dilatih menggunakan *optimizer RMSprop* dengan *learning rate* sebesar 0.0001, dan *loss function* yang digunakan adalah *categorical crossentropy*. Pelatihan dilakukan selama 70 *epoch* dengan *callback early stopping*, yang bertujuan menghentikan pelatihan jika tidak ada peningkatan pada *loss function*, seperti yang bisa dilihat pada Gambar 9. merupakan metrik hasil pelatihan model.

	Metric	Value
0	Loss	0.3186
1	Recall	0.8450
2	Precision	0.8471
3	Accuracy	0.8475
4	Val Loss	0.3980
5	Val Recall	0.8500
6	Val Precision	0.8500
7	Val Accuracy	0.8500

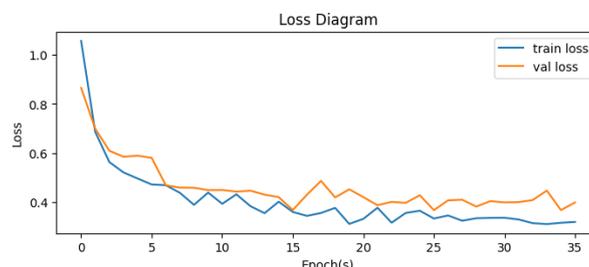
Gambar 9. Hasil Pelatihan Model

Setelah proses pelatihan model selesai, hasil berupa akurasi dan *loss* dari data *training* dan *testing* dianalisis. Hasil pelatihan model yang diperoleh digambarkan dalam bentuk grafik, yang menunjukkan tren peningkatan akurasi dan penurunan *loss* seiring berjalannya *epoch* [19]. Grafik ini penting untuk memvisualisasikan performa model dan untuk menentukan kapan model mencapai titik terbaiknya sebelum *overfitting* terjadi.



Gambar 10. Grafik Training dan Validation

Pada Gambar 10. merupakan grafik *training* dan *validation*. Grafik ini menunjukkan peningkatan pada pelatihan dan data validasi seiring dengan bertambahnya jumlah *epoch*. Dari grafik ini, tidak menunjukkan tanda tanda *overfitting* yang jelas, karena akurasi pelatihan dan validasi tetap seimbang sepanjang proses pelatihan. Namun fluktuasi yang terlihat pada kurva dapat mengindikasikan adanya ketidakstabilan atau sensitivitas model terhadap variasi dalam data, yang mungkin disebabkan oleh ukuran dataset yang terbatas.



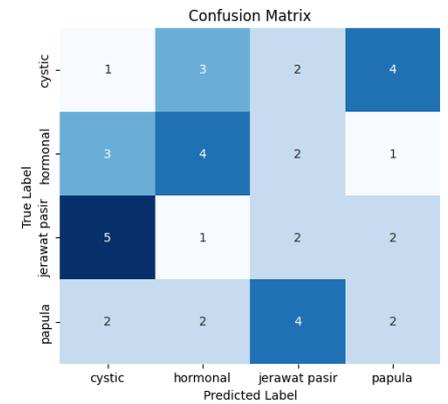
Gambar 11. Loss Diagram

Pada Gambar 11. merupakan grafik *loss* diagram. Grafik ini menunjukkan bahwa model telah dilatih dengan baik tanpa mengalami *overfitting* yang signifikan. Ada penurunan yang konsisten dalam *loss*, dengan sedikit fluktuasi yang mungkin memerlukan perhatian lebih lanjut. Namun secara keseluruhan, model menunjukkan kemampuan

generalisasi yang baik dan telah mencapai titik stabil dalam pelatihan, yang tercermin dari kurva yang mulai mendatar.

### 3.2 Pengujian Model

Gambar 12. di bawah ini menyajikan visualisasi *confusion matrix*. *Confusion matrix* ini digunakan untuk mengevaluasi performa model dalam mengklasifikasikan data ke setiap kategori.



Gambar 12. Confusion Matrix

#### 3.2.1 Evaluasi

Evaluasi model klasifikasi gambar menggunakan *Convolutional Neural Network* (CNN) dilakukan dengan beberapa metrik evaluasi, termasuk akurasi, presisi, dan *recall*. Metrik ini memberikan gambaran komprehensif tentang performa model.

$$\text{Akurasi} = \frac{84+86}{84+86+14+16} = \frac{170}{200} = 0.85 \tag{4}$$

Akurasi mengukur sejauh mana model dapat memprediksi kelas yang benar dari seluruh kasus evaluasi. Pada penelitian ini, akurasi model mencapai 85%, yang berarti 85% dari prediksi yang dibuat oleh model adalah benar.

$$\text{Presisi} = \frac{84}{84+84} = \frac{84}{98} = 0.85 \tag{5}$$

Presisi mengukur keakuratan prediksi positif dari model. Dengan presisi sebesar 85%, ini menunjukkan bahwa dari semua prediksi positif yang dibuat oleh model, 85% adalah benar-benar positif.

$$\text{Recall} = \frac{84}{84+16} = \frac{84}{100} = 0.84 \tag{6}$$

*Recall* mengukur kemampuan model untuk mendeteksi semua contoh positif yang ada dalam dataset. Dengan *recall* sebesar 84%, ini menunjukkan bahwa model berhasil mendeteksi 84% dari semua contoh positif yang ada

Evaluasi ini menunjukkan bahwa model CNN memiliki kinerja yang cukup baik dengan akurasi 85%, presisi 85%, dan *recall* 84%. Metrik-metrik ini menunjukkan bahwa model cukup andal dalam melakukan klasifikasi gambar. Akurasi yang tinggi menunjukkan bahwa model secara umum bekerja dengan baik, sedangkan presisi dan *recall* yang seimbang menunjukkan bahwa model tidak hanya baik dalam memprediksi kelas yang benar tetapi juga cukup konsisten dalam mendeteksi kelas positif dan negatif. Hal ini sangat penting dalam aplikasi dunia nyata, seperti diagnosis medis, di mana kesalahan klasifikasi bisa berdampak serius pada perawatan pasien.

#### 3.2.2 Pengujian Klasifikasi

Tabel 4. Tabel Hasil Eksperimen

Metrik	Nilai
Akurasi	85%
Presisi	85%
Recall	84%

Pada Tabel 5. hasil eksperimen menunjukkan bahwa akurasi sebesar 85% dan presisi sebesar 85%, model CNN menunjukkan kinerja yang baik, yang berarti bahwa model hasil mengklasifikasikan jenis jerawat dengan benar pada sebagian besar prediksi. Dengan *recall* sebesar 84% model ini juga mampu mendeteksi sebagian besar prediksi positif, yang mengurangi kemungkinan prediksi positif salah. Secara keseluruhan, model ini mampu diandalkan dan cocok untuk digunakan dalam aplikasi medis yang membutuhkan klasifikasi jerawat yang akurat. Ini menunjukkan bahwa model mampu mengenali dan mengklasifikasikan sebagian besar gambar jerawat dengan tepat, tetapi akurasi ini tidak mencapai tingkat maksimal, yang menunjukkan banyak faktor yang mempengaruhi performa model. Pencapaian akurasi tinggi pada model CNN ini disebabkan oleh penggunaan arsitektur CNN yang efektif seperti *InceptionV3*, *preprocessing* dan *augmentasi* data yang meningkatkan variasi dan generalisasi model, serta pemilihan *optimizer Adam* dengan *learning rate* yang tepat (0.0001) yang membantu model mencapai konvergensi optimal selama pelatihan. Meskipun model menunjukkan kinerja yang baik dengan akurasi dan presisi sebesar 85%, akurasi ini tidak maksimal karena ukuran dataset yang terbatas, hanya 400 gambar, mungkin tidak cukup untuk melatih model secara optimal, terutama dalam klasifikasi multi-kelas. Selain itu, variasi antar kategori jerawat yang tidak selalu jelas membuat model sulit membedakan jenis yang mirip, dan adanya kemungkinan *overfitting* ringan akibat dataset yang kecil dapat menurunkan performa model saat diuji pada data baru.

Dalam konteks penelitian deteksi jerawat performa berbagai penelitian menunjukkan hasil akurasi yang bervariasi dalam mendeteksi jerawat. Misalnya, GLCM dengan *Backpropagation* hanya mencapai akurasi 56,67% dan YOLOV3 mencapai mAP 42,849%, yang lebih rendah dibandingkan dengan model CNN yang digunakan dalam penelitian ini, yang mencapai akurasi dan presisi 85%. Sementara itu, model CNN dalam penelitian ini mampu mencapai akurasi dan presisi sebesar 85%, yang lebih baik dibandingkan dengan metode sebelumnya, namun masih jauh dari ideal jika dibandingkan dengan penelitian lain seperti deteksi penyakit pada daun yang mencapai akurasi hingga 99%. Perbandingan ini menyoroti bahwa meskipun CNN efektif dalam tugas klasifikasi gambar, tantangan seperti keterbatasan dataset dan kompleksitas kategori jerawat mempengaruhi performa model secara keseluruhan, menurut pendekatan yang lebih mendalam dalam upaya meningkatkan akurasi.

#### 4. KESIMPULAN

Penelitian ini berhasil mengembangkan dan mengimplementasikan sebuah model klasifikasi jerawat berbasis *Convolutional Neural Network* (CNN) dengan memanfaatkan arsitektur *InceptionV3* yang telah dimodifikasi. Proses pelatihan model dilakukan melalui *augmentasi* data serta optimasi parameter, termasuk penggunaan *optimizer RMSprop*, dengan *learning rate* sebesar 0,0001, serta penerapan *callback early stopping*. Model yang dihasilkan mampu mendeteksi dan mengklasifikasikan empat jenis jerawat, yaitu cystic, hormonal, pasir, dan papula, dengan kinerja yang signifikan. Berdasarkan hasil evaluasi, model menunjukkan akurasi sebesar 85%, presisi sebesar 85%, dan *recall* sebesar 84%. Hal ini menunjukkan kapabilitas yang andal dan konsisten dalam mengidentifikasi jenis jerawat berdasarkan citra wajah. Penelitian ini memberikan kontribusi penting dalam ranah dermatologi digital, khususnya terkait dengan potensi teknologi *deep learning* untuk meningkatkan efisiensi dan akurasi dalam proses diagnosis klinis. Implementasi sistem otomatis ini dapat mendukung dokter kulit dalam mempercepat proses diagnosis, mengurangi subjektivitas dalam penilaian, serta menekan waktu dan biaya yang diperlukan dalam penanganan jerawat. Dengan pengujian lebih lanjut pada dataset yang lebih besar dan beragam, model yang diusulkan memiliki potensi untuk diintegrasikan ke dalam sistem kesehatan sebagai alat bantu yang dapat digunakan oleh profesional medis, maupun sebagai aplikasi berbasis konsumen untuk mendeteksi dan menangani jerawat secara lebih tepat waktu. Secara keseluruhan, penelitian ini menegaskan bahwa teknologi berbasis CNN memiliki peran penting dalam mendukung revolusi otomatisasi diagnosis kulit. Implementasi ini menawarkan solusi yang efisien dan andal dalam mendukung perawatan kulit yang lebih tepat dan akurat, dengan implikasi signifikan terhadap perbaikan kualitas perawatan kesehatan dermatologis secara umum.

#### UCAPAN TERIMAKASIH

Puji syukur kehadirat Tuhan Yang Maha Esa atas rahmat dan bimbingan-Nya sehingga jurnal ini dapat terselesaikan dengan baik. Saya mengucapkan terima kasih yang sebesar-besarnya kepada Bapak M. Riko Anshori Prasetya, Bapak Mambang dan Bapak Ahmad Hidayat atas bimbingan, dukungan, dan motivasinya selama proses penelitian ini. Terima kasih juga saya sampaikan kepada seluruh staf pengajar di Universitas Sari Mulia atas ilmu yang telah diberikan selama masa studi. Ucapan terima kasih saya haturkan pula kepada semua pihak yang telah membantu, baik secara langsung maupun tidak langsung, dalam penyelesaian jurnal ini. Saya menyadari bahwa

jurnal ini masih memiliki kekurangan, oleh karena itu saya sangat mengharapkan kritik dan saran yang membangun untuk perbaikan di masa depan. Semoga jurnal ini dapat memberikan manfaat dan kontribusi positif bagi perkembangan ilmu pengetahuan.

## REFERENCES

- [1] F. Sudana Putra, D. Otomatis Jerawat Wajah, and M. P. Kurniawan, "Deteksi Otomatis Jerawat Wajah Menggunakan Metode Convolutional Neural Network (CNN)," *JIFOTECH (JOURNAL OF INFORMATION TECHNOLOGY)*, vol. 1, no. 2, 2021.
- [2] I. Hasan, H. Suprayogi, and D. Bethaningtyas, "KLASIFIKASI JENIS JERAWAT MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORKS."
- [3] S. Dewi, F. Ramadhani, and 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: 10.56211/helloworld.v3i2.518.
- [4] Y. Fauzia Achmad, A. Yulfitri, and M. B. Ulum, "Identifikasi Jenis Jerawat Berdasarkan Tekstur Menggunakan GLCM dan Backpropagation," *Jurnal Sains Manajemen Informatika dan Komputer*, vol. 20, no. 2, pp. 139–146, 2021, [Online]. Available: <https://ojs.trigunadharma.ac.id/>
- [5] Y. F. Achmad, A. Yulfitri, and P. Maharani, "Penerapan Algoritma GLCM dan KNN dalam Pengenalan Jenis Jerawat," *Jurnal Komtika (Komputasi dan Informatika)*, vol. 6, no. 2, pp. 74–82, Nov. 2022, doi: 10.31603/komtika.v6i2.8078.
- [6] Y. A. Hasma and W. Silfianti, "IMPLEMENTASI DEEP LEARNING MENGGUNAKAN FRAMEWORK TENSORFLOW DENGAN METODE FASTER REGIONAL CONVOLUTIONAL NEURAL NETWORK UNTUK PENDETEKSIAN JERAWAT," *Jurnal Ilmiah Teknologi dan Rekayasa*, vol. 23, no. 2, pp. 89–102, 2019, doi: 10.35760/tr.2018.v23i2.2459.
- [7] H. Zhang and T. Ma, "Acne Detection by Ensemble Neural Networks," *Sensors*, vol. 22, no. 18, Sep. 2022, doi: 10.3390/s22186828.
- [8] S. Panjaitan, C. Sitepu, J. Sinaga, P. Matematika, F. Keguruan, and I. Pendidikan, "DETEKSI JERAWAT MENGGUNAKAN ARSITEKTUR YOLOV3".
- [9] P. Adi Nugroho, I. Fenriana, and R. Arijanto, "IMPLEMENTASI DEEP LEARNING MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK ( CNN ) PADA EKSPRESI MANUSIA," *JURNAL ALGOR*, vol. 2, no. 1, 2020, [Online]. Available: <https://jurnal.buddhidharma.ac.id/index.php/algor/index>
- [10] Z. Febriana, D. Mellinia, and E. Zuliarso, "Implementasi Model CNN Dan Tensorflow Dalam Pendeteksian Jenis Daging Hewan Ternak," 2022. [Online]. Available: <https://doi.org/10.25047/jtit.v9i1.278>
- [11] A. M. Lesmana, R. P. Fadhillah, and C. Rozikin, "Identifikasi Penyakit pada Citra Daun Kentang Menggunakan Convolutional Neural Network (CNN)," *Jurnal Sains dan Informatika*, vol. 8, no. 1, pp. 21–30, Jun. 2022, doi: 10.34128/jsi.v8i1.377.
- [12] R. Puspitasari and A. Dwi Indriyanti, "ANALISIS SENTIMEN OPINI PUBLIK TERHADAP KEBIJAKAN BARU SKRIPSI PADA MEDIA SOSIAL TWITTER MENGGUNAKAN METODE NAÏVE BAYES," 2024.
- [13] M. Riko Anshori Prasetya and A. Mudi Priyatno, "Penanganan Imputasi Missing Values pada Data Time Series dengan Menggunakan Metode Data Mining", doi: 10.37034/jidt.v5i1.324.
- [14] S. Lasniari, J. Jasril, S. Sanjaya, F. Yanto, and M. Affandes, "Klasifikasi Citra Daging Babi dan Daging Sapi Menggunakan Deep Learning Arsitektur ResNet-50 dengan Augmentasi Citra," *Jurnal Sistem Komputer dan Informatika (JSON)*, vol. 3, no. 4, p. 450, Jun. 2022, doi: 10.30865/json.v3i4.4167.
- [15] Wahyudi Setiawan, *Deep Learning menggunakan Convolutional Neuarl Network*, Cetakan 1. Malang: Media Nusa Creative, 2021.
- [16] R. Darma Nurfitia and G. Ariyanto, "IMPLEMENTASI DEEP LEARNING BERBASIS TENSORFLOW UNTUK PENGENALAN SIDIK JARI." [Online]. Available: <http://bias.csr.unibo.it/fvc2004/databases.asp>
- [17] L. Firdaus and T. Setiadi, "Perbandingan Algoritma Naive Bayes, Decision Tree, dan KNN untuk Klasifikasi Produk Populer Adidas US dengan Confusion Matrix," *Jurnal Sistem Komputer dan Informatika (JSON) Hal: 185-*, vol. 195, no. 2, 2023, doi: 10.30865/json.v5i2.6124.

- [18] Prastyadi Wibawa Rahayu *et al.*, *Buku Ajar Data Mining*, 1st ed. Jambi: PT. Sonpedia Publishing Indonesia, 2024.
- [19] I. Y. Pangestu and S. R. Ramadhani, "Perancangan Sistem Deteksi Penyakit Kulit Pada Kucing Menggunakan Deep Learning Berbasis Android," *Teknika*, vol. 12, no. 3, pp. 173–182, Oct. 2023, doi: 10.34148/teknika.v12i3.673.