



## *Classification of Acne Type Based on Convolutional Neural Network*

### **Klasifikasi Jenis Jerawat Berdasarkan *Convolutional Neural Network***

**Aulia Rizqi Andini<sup>1\*</sup>, Imam Yuadi<sup>2</sup>**

<sup>1</sup>Jurusan Pengembangan Sumber Daya Manusia, Fakultas Sekolah Pascasarjana,  
Universitass Airlangga, Surabaya, Indonesia

<sup>2</sup>Fakultas Ilmu Sosial dan Politik Universitas Airlangga, Surabaya, Indonesia

E-Mail: <sup>1</sup>[aulia.rizqi.andini-2023@pasca.unair.ac.id](mailto:aulia.rizqi.andini-2023@pasca.unair.ac.id), <sup>2</sup>[imam.yuadi@fisip.unair.ac.id](mailto:imam.yuadi@fisip.unair.ac.id)

Received Sep 20th 2024; Revised Dec 15th 2024; Accepted Dec 22th 2024; Available Online Jan 9th 2025, Published Jan 26th 2025

Corresponding Author: Aulia Rizqi Andini

Copyright © 2025 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

#### **Abstract**

*Acne usually begins in early puberty with increased oil production on the face. This research is an implementation of the classification and detection of acne types using Image Processing. Acne can be classified into several types, namely blackheads, whiteheads, pustules, and papules. Classification using Deep Learning Convolutional Neural Network (CNN) method using the Keras Tensorflow library. Based on the research that has been done, the purpose of this research is to classify various types of acne with image data owned by each type of acne. The research results obtained from the test results resulted in a high accuracy value of 96.57% and Loss 24.78%. Using Deep Learning is proven to work quite efficiently because it has produced high accuracy values..*

*Keyword: Acne, Classification, CNN, Neural Network*

#### **Abstrak**

Jerawat biasanya dimulai pada masa awal pubertas dengan meningkatnya produksi minyak pada wajah. Penelitian ini merupakan implementasi dari klasifikasi dan pendeteksian jenis jerawat menggunakan *Image Processing*. Jerawat dapat diklasifikasikan kedalam beberapa jenis, yaitu komedo hitam, komedo putih, pustula, dan papula. Klasifikasi menggunakan *Deep Learning* metode Convolutional Neural Network (CNN) menggunakan pustaka *Tensorflow Keras*. Berdasarkan penelitian yang telah dilakukan, tujuan penelitian ini untuk mengklasifikasikan berbagai macam jenis jerawat dengan data gambar yang dimiliki setiap jenis jerawat. Hasil penelitian yang didapat dari hasil pengujian menghasilkan nilai akurasi yang tinggi 96.57% dan Loss 24.78%. Menggunakan *Deep Learning* terbukti bekerja cukup efisien karena telah menghasilkan nilai akurasi yang tinggi.

Kata Kunci: CNN, Jerawat, Klasifikasi, *Neural Network*

### **1. PENDAHULUAN**

Memiliki penampilan menarik serta kulit wajah yang sehat merupakan hal yang diidamkan oleh setiap orang. Kulit wajah memiliki nilai estetika menjadi perhatian individu [1]. Sebagian besar permasalahan umum pada kulit wajah adalah jerawat. Meski tidak berbahaya, jerawat terbukti berdampak buruk pada kehidupan sosial [2], kehilangan kepercayaan diri untuk tampil didepan umum, bahkan dapat terjadinya gangguan psikologis seperti depresi dan kecemasan [3]. Jerawat biasanya dimulai pada masa awal pubertas dengan meningkatnya produksi minyak pada wajah [4]. Namun, jerawat tidak hanya pada masa awal puberta, orang dewasa dapat mengalami masalah jerawat ini [5]. Di Indonesia, 80-85% penderita jerawat adalah remaja yang berusia 15-20 tahun, 12% mengalami jerawat diusia 25 tahun keatas, dan sekitar 3% mengalami jerawat pada usia 25-44 tahun [6]. Jerawat dapat diklasifikasikan kedalam beberapa jenis, yaitu komedo hitam, komedo putih, pustula, dan papula [7].

Dalam klasifikasi jenis jerawat pada permasalahan kulit wajah, dapat dikenali dengan mudah secara kasat mata. Namun hal tersebut bagaimana jika diterapkan pada mesin komputer. Upaya dalam mesin komputer mengenali permasalahan, diperlukannya pengenalan yang dilakukan oleh manusia dengan menjadikan masalah tersebut sebagai objek yang akan diteliti, hal ini biasa disebut dengan *Machine Learning* [8]. *Machine Learning* digunakan untuk mengenali data dengan lebih efisien [9], mencoba menirukan

bagaimana manusia belajar dan menggeneralisasi melalui proses *training* [10]. Seiring perkembangan zaman, *machine learning* memiliki evolusi lanjutannya yaitu *Deep Learning* [11]. *Deep learning* dapat merepresentasikan suatu konsep yang kompleks dengan lebih sederhana [12], yang berfungsi untuk mengklasifikasi data gambar menjadi hasil klasifikasi yang berupa prediksi [13]. *Deep Learning* salah satu teknik yang populer telah banyak direkomendasikan dalam penelitian sebagai solusi untuk mendeteksi dan klasifikasi gambar, dengan menganalisis daerah kulit wajah tertentu [14]. Namun *Deep Learning* menggunakan pendekatan *Neural Network* yang berbeda. Menggunakan *Neural Network* secara otomatis mempelajari data, yang memungkinkan untuk menangkap pola yang lebih rumit [15]. Salah satu algoritma pada *deep learning* ialah *Convolutional Neural Network* (CNN). CNN secara efektif dapat mengurangi kompleksitas dan mengurangi bobot dalam gambar [16] yang terutama lebih efisien dalam menangani gambar yang berdimensi tinggi [13]. CNN merupakan jenis algoritma yang dapat diterapkan sebagai pembelajaran mesin untuk memproses data [17] menggunakan lapisan tersembunyi atau *hidden layer* untuk memproses suatu pola gambar [18].

Beberapa penelitian terdahulu terkait bidang klasifikasi jenis jerawat. Penelitian untuk mendeteksi lesi jerawat pada citra wajah menggunakan metode K-Means Clustering dengan mendeteksi kulit yang berjerawat dan tidak berjerawat [19]. Penelitian yang menggunakan *Deep Learning* berbasis CNN untuk mendeteksi kanker kulit, dengan mengembangkan sub model CNN dari gambar tahi lalat melanoma ganas yang mencapai nilai akurasi yang tinggi 95,76% [20]. Penelitian klasifikasi tingkat keparahan jerawat menggunakan *Deep Learning* dengan CNN menggunakan ADAM yang diperoleh hasil akurasi 92% [21].

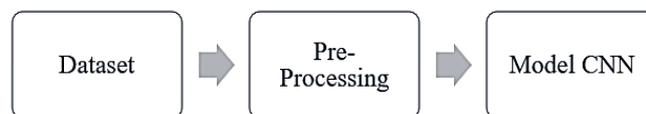
Berdasarkan penelitian terdahulu yang telah diuraikan, penelitian ini menggunakan *Deep Learning* Metode CNN, karena pada penelitian terdahulu menunjukkan keefektifan menggunakan Metode CNN sebagai metode untuk mengklasifikasi jenis jerawat. Adapun penelitian ini dilakukan dengan *Tensorflow Keras* dan *ImageNet* untuk mengidentifikasi jenis jerawat pada kulit wajah. Maka penelitian ini dilakukan dengan tujuan untuk mengklasifikasikan berbagai macam jenis jerawat dengan data gambar yang dimiliki setiap jenis jerawat. Jenis-jenis jerawat diklasifikasi ke dalam empat jenis jerawat, yaitu *Blackhead*, *Papula*, *Puspula*, dan *Whitehead* yang dimotifikasi untuk pendeteksian kondisi wajah pada data *training*.

Pada penelitian disusun melalui proses dan hasil penelitian. Pada bagian 2, menguraikan tentang metode penelitian mengeksplorasi metode yang digunakan. Penelitian ini berfokus pada *Deep Learning* Metode CNN dengan *Tensorflow Keras* dan *Mobile Net*, serta memberikan perincian tentang pemrosesan penelitian. Dibagian 3, hasil dan pembahasan penelitian yang merujuk pada pengujian dari hasil implementasi yang telah dilakukan. Dan dibagian 4, kesimpulan yang menunjukkan implikasi yang lebih luas, menilai potensi, dan akurasi, serta menyarankan penelitian menggunakan metode lainnya. Sehingga menghasilkan model klasifikasi dan deteksi dengan lebih baik.

## 2. METODE PENELITIAN

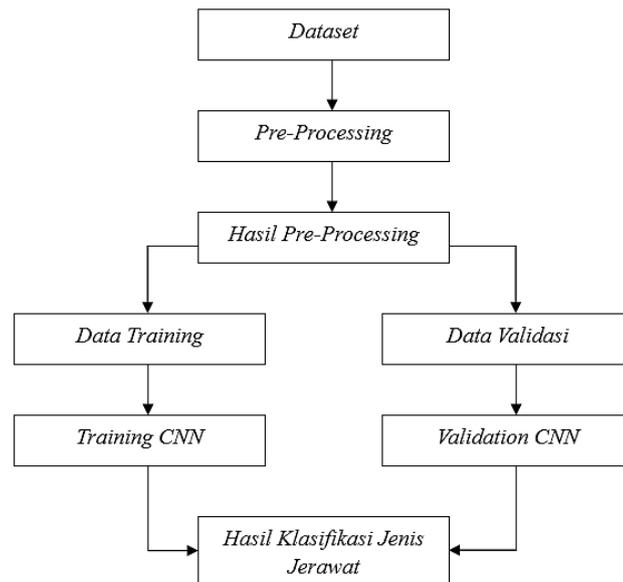
### 2.1 Desain Sistem

Pada penelitian ini, sistem dirancang untuk mengetahui jenis jerawat, yaitu *Blackhead*, *Papula*, *Puspula*, dan *Whitehead*. Didalam sistem ini dilakukan 3 proses utama. Yaitu dataset, *preprocessing*, dan pelatihan model. Sampel yang digunakan berupa citra wajah manusia yang diambil dari *Kaggle*, *Bing*, dan *Google*, lalu dilakukan *preprocessing* yaitu normalisasi. Selanjutnya, hasil yang digunakan dalam proses *training* dan uji validasi CNN adalah metode yang digunakan pada penelitian ini. Terdapat rancangan desain sistem penelitian pada Gambar 1.



Gambar 1. Desain Sistem

Dalam penelitian menggunakan metode CNN ini terdapat dua proses yang menjadi sorotan dalam penelitian, yaitu data CNN *training* dan validasi sistem CNN. Terdapat proses yang menjadi hal pertama sebelum masuk kedalam proses utama. Gambar kulit wajah berjerawat menjadi dataset dalam penelitian ini akan diproses dalam *pre-processing*. Hasil yang didapatkan dalam proses tersebut akan dibagi menjadi data *training* dan data validasi. Data gambar atau citra ini akan digunakan dalam proses *training* CNN. data *training* tersebut akan diekstraksi cirinya didalam proses *training* CNN. Hasil ekstraksian ciri dari data *training* diklasifikasikan kedalam empat kelas. Hal ini bertujuan untuk melatih model untuk mengenali ciri-ciri citra disetiap kelasnya. Selanjutnya, dilakukan pengujian data gambar atau citra pada validasi, sistem juga akan mengekstraksi ciri data validasi dan mengklasifikasikannya ke dalam empat kelas yang ada.



**Gambar 2.** Diagram Perencanaan Siste

Pada gambar 2 adalah diagram perencanaan sistem dengan alur proses untuk melakukan klasifikasi jenis jerawat menggunakan metode CNN. Mempersiapkan dataset yang berisikan gambar yang terbagi menjadi empat kelas jenis jerawat. Tahap pre-processing mencakup proses pengolahan data mentah sehingga siap digunakan dalam *machine learning*. Setelah melalui tahapan pre-processing, data akan dibagi menjadi dua yaitu data latih (*Data Training*) dan data uji (*Data Validasi*). Data akan dimasukkan kedalam model CNN untuk melatih machine dalam klasifikasi. Dan tahap akhir model menghasilkan *output* berupa klasifikasi jenis jerawat.

## 2.2 Dataset

Salah satu tantangan dalam klasifikasi adalah menyediakan kumpulan-kumpulan data dengan jumlah yang cukup. Dalam penelitian ini, menggunakan citra dengan jenis jerawat memiliki empat kelas yang berbeda. Data yang tersedia berasal dari *Kaggle*, *Bing*, dan *Google*. Data tersebut dikumpulkan dan proses *cleaning* dengan *cropping image* pada bagian tertentu dan menghapus *background* gambar. Sehingga, diperoleh dengan jenis jerawat *blackhead*, *papula*, *puspula* dan *whitehead*. Dengan jumlah data latih 175 dan data uji 38.

**Tabel 1.** Dataset Penelitian

No.	Jenis Jerawat	Data	
		Latih	Uji
1.	Blackhead	46	10
2.	Papula	42	10
3.	Puspula	46	9
4.	Whitehead	41	9

Berdasarkan Tabel 1 diatas, dapat diketahui bahwa dataset yang digunakan dalam penelitian ini merupakan *unbalance dataset*, yang dimana jenis *Blackhead* memiliki data terbanyak sejumlah 56 data gambar dengan 46 data latih dan 10 data uji. Jenis *Papula* memiliki data sejumlah 52 data gambar dengan 42 data latih dan 10 data uji. Jenis *Puspula* dengan jumlah 55 yaitu 46 data latih dan 9 data uji. Sedangkan jenis *Whitehead* memiliki 50 data gambar dengan data latih sebanyak 41 data dan 9 data uji untuk data yang paling sedikit.

## 2.3 Pre-Processing

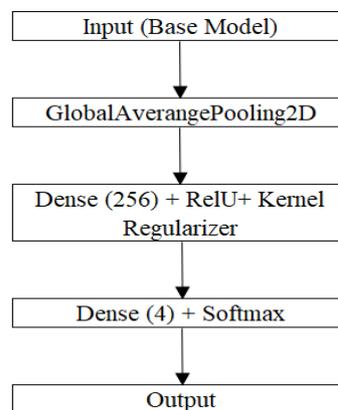
Pre-processing merupakan tahapan untuk membuat gambar menjadi sesuai dengan kriteria yang mampu diterima dan mampu mengenai gambar, meskipun terdapat perbedaan pada gambar. Pada tahapan ini, menggunakan *Image Data Generator* dari pustaka *TensorFlow Keras* dan *Mobile Net Preprocessing Image*. Terdapat *training generator* dan *validation generator* dengan dilakukannya *resize*, *rescale rotation range*, *horizontal flip*, *shear range*, *fill mode*, *width height shift*, dan *zoom range*.

Dari dataset dilakukannya *resize* untuk menyamakan gambar yang dapat diperoleh mesin, pada analisis ini menggunakan *target size* 150 X 150, 224 X 224, dan 256 X 256. Menggunakan *batch size*

16,24,36, dan 64. Selanjutnya, memasuki tahapan normalisasi, yang bertujuan untuk membuat piksel dari setiap citra memiliki rentang nilai yang sama yaitu 0 (hitam) sampai 255(putih). Untuk ukuran yang dilakukan untuk analisis ini adalah 1./225. Membalikkan gambar latih secara acak hingga 30 derajat, menggeser gambar latih hingga lebar dan tinggi gambar 20%, serta secara acak memperbesar gambar latih sebanyak 10%.

## 2.4 Model Penelitian

Model merupakan tahapan untuk memilih dan menerapkan berbagai teknik dalam CNN. Model latih bobot pada pemetaan dari input ke output. Metode yang digunakan pada analisis ini adalah CNN dengan tujuan mengklasifikasikan jenis kulit manusia keempat yaitu kelas *blackhead*, *papula*, *puspula*, dan *whitehead*. Tahapan ini melibatkan penetapan data set yang akan digunakan dalam melatih model. Data set penelitian terdiri dari data *training* 175 dan *testing* 38. Data ini kemudian dikonversi dan disusun dalam sebuah lapisan dengan model CNN dengan menggunakan fungsi dari pustaka *Tensorflow Keras*, yaitu menggunakan *MobileNetV1* dan *GlobalAveragePooling2D*. Pada penelitian ini, dibuat menggunakan fungsi Keras yang dapat dilihat pada gambar 3.



**Gambar 3.** Model Lapisan Penelitian

Pada gambar 3 terlihat model lapisan penelitian dengan lapisan pertama yaitu input atau *base model*. Menggunakan *MobileNet* sebagai base model untuk ekstraksi fitur. Selanjutnya mereduksi dimensi fitur dari output base model dalam bentuk *vektor1D* menggunakan *globalaveragepooling2D*. Menggunakan 256 unit pada *Danse layer* dan fungsi aktivasi *ReLU*. Dan lapisan akhir output distribusi probabilitas untuk setiap kelas menggunakan fungsi aktivasi *softmax*.

## 3. HASIL DAN PEMBAHASAN

Pada tahapan ini, yaitu melakukan pengujian terhadap implementasi diatas. Pada pengujian ini, terbagai menjadi 3 skenario. Skenario pertama adalah pengujian terhadap nilai *Batch Size* dengan 16,24,32, dan 64. Yang kedua merupakan pengujian *resize* atau *target size* dengan *size* 150 X 150, 224 X 224, dan 256 X 256. Skenario selanjutnya adalah pengujian terhadap *Epoch* yaitu 5,15,25,50, 100, dan 200.

### 3.1. Pengujian Batch Size

**Tabel 2.** Hasil Pengujian Batch Size

Batch Size	Accuracy	Precision	Recall	F1 Score
16	92.5%	18.41%	18.34%	18.34%
24	93.14%	25.59%	26.31%	25.93%
32	90.84%	23.92%	26.31%	25.00%
64	97.71%	26.31%	26.42%	26.05%

Berdasarkan tabel 2 pengujian *Batch Size* diatas, performa model dengan berbagai ukuran *batch* yang berbeda selama pelatihan dengan metrik *Accuracy*, *Precision*, *Recall*, dan *F1 Score*. *Batch size* 16 dan 24 menunjukkan akurasi yang tergolong baik, namun memiliki banyak prediksi salah untuk masing-masing kelas yang memungkinkan adanya ketidakseimbangan. Pada *batch size* 32 memiliki akurasi 90.84% lebih rendah dibanding *batch* sebelumnya, memiliki nilai metrik lainnya tergolong rendah yang memungkinkan disebabkan oleh kurangnya stabilitas pelatihan. Dan *batch size* 64 memiliki nilai akurasi yang tertinggi, namun menunjukkan model mengalami *overfitting* pada kelas.

### 3.2. Pengujian *Resize*

**Tabel 3.** Hasil Pengujian *Resize*

Resize	Accuracy	Precision	Recall	F1 Score
150x150	90.86%	23.92%	26.31%	25%
224x224	95.43%	10.13%	10.52%	10.30%
256x256	95.43%	23.68%	23.68%	23.87%

Setelah pengujian pada *Batch Size* dan menggunakan 64, selanjutnya mengukur ketahanan *Resize*. Berdasarkan tabel pengujian *Resize* diatas, diperoleh nilai performansi terbaik pada citra berukuran 224 X 224 memiliki nilai akurasi 95.43% Namun, hasil pengujian tersebut mengalami ketidakstabilan sehingga mengalami *overfitting*. Sehingga penelitian menggunakan *Target Size* 150 X 150 dengan akurasi 90.86% dan *Loss* 60.83%.

### 3.3. Pengujian *Epoch*

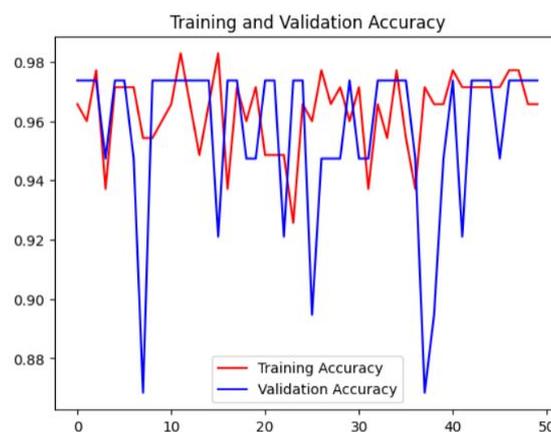
**Tabel 1.** Hasil Pengujian *Epoch*

Epoch	Accuracy	Precision	Recall	F1 Score
5	88.57%	29%	28.94%	28.81%
15	89.71%	26%	26.31%	24.94%
25	94.29%	23.13%	23.68%	23.36%
50	94.29%	27%	28.94%	27.89%
100	96%	25.59%	26.31%	25.93%
200	100%	18.55%	18.42%	18.45%

Berdasarkan tabel pengujian *Epoch* diatas, nilai *Epoch* mengalami peningkatan yang signifikan pada nilai 200. Namun, nilai tersebut mengalami ketidakstabilan pada parameter, dan nilai *Precision*, *Recall*, maupun *F1* memiliki nilai yang paling rendah dibandingkan nilai *Epoch* yang lain. Pada nilai *Epoch* 50, terdapat sistem yang bekerja dengan stabil sehingga nilai tersebut dapat menjadi parameter yang baik untuk diterapkan. Selain itu, memiliki nilai *Precision*, *Recall*, dan *F1* yang tinggi dibanding nilai *Epoch* lainnya.

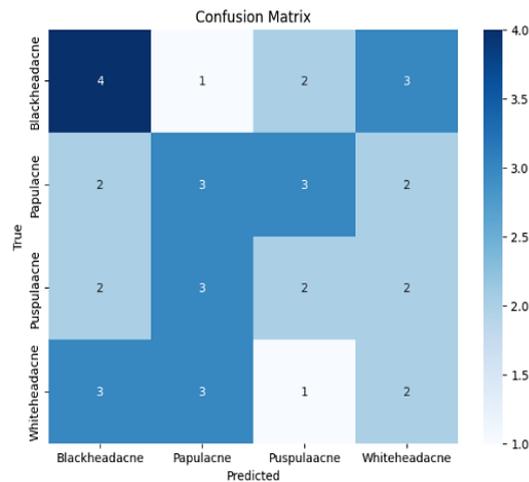
### 3.4. Validasi dan Evaluasi

Setelah melalui tiga skenario pengujian, didapatkan nilai parameter terbaik untuk sistem tersebut adalah *Batch size* 64, jenis ukuran dengan target size 150 X 150, dan *Epoch* 50. Dengan menggunakan parameter tersebut, sistem dirancang berhasil memperoleh nilai akurasi 96.57%. Diagram garis dan *confusion matrix* dari hasil prediksi data uji dapat dilihat pada gambar 4. Pada gambar 5 *confusion matrix* ini menunjukkan hubungan antara label sebenarnya (*True*) dan prediksi (*Predicted*) dengan *Blackhead* memiliki prediksi benar tertinggi bahwa model lebih baik mengenali.



**Gambar 1.** Diagram Garis pada Hasil Parameter Akurasi

Karakter dari gambar jenis jerawat *blackhead*. Namun, jenis jerawat *Puspula* memiliki prediksi benar yang rendah dengan banyak data yang diprediksi sebagai kelas lain. Hal ini menunjukkan bahwa model kesulitan membedakan kelas atau jenis jerawat berdasarkan data gambar.



**Gambar 5.** Confusion Matrix Hasil Pengujian

#### 4. DISKUSI

Hasil klasifikasi jenis jerawat menggunakan data gambar berjumlah 213 dengan empat jenis jerawat yaitu *blackhead*, *Papula*, *Puspula*, dan *whitehead*. Data dengan jenis *blackhead* memiliki data terbanyak sejumlah 56 data dengan 46 data latih dan 10 data uji. Data yang memiliki jumlah paling sedikit adalah data *whitehead*, dengan 41 data latih dan 9 data uji. Hal ini menunjukkan adanya ketidakseimbangan antar kelas yang dimana data kelas *blackhead* proporsi yang jauh lebih besar dibandingkan dengan data kelas *whitehead*. Ketidakseimbangan ini yang menjadi perhatian selama proses pelatihan. Selanjutnya, jenis jerawat *puspula* dan *papula* memiliki sifat warna yang cenderung sama. Sehingga pada penelitian ini mengindikasikan data gambar yang cenderung tidak menunjukkan preferensi kuat yang baik kearah *puspula* dan *papula*.

Hasil penelitian menunjukkan bahwa klasifikasi jenis jerawat yang menggunakan CNN dengan parameter *Batch size* 64, *target size* 150x150 dan *epoch* 50, mampu mencapai akurasi sebesar 96.57%. Akurasi yang tinggi menunjukkan bahwa model mampu mengklasifikasikan data dengan baik secara keseluruhan. Namun, nilai metrik lainnya seperti *precision*, *recall*, dan *F1 score* menunjukkan hasil yang lebih rendah. Hal ini adanya ketidakseimbangan dalam prediksi terhadap jenis jerawat atau kelas, yang disebabkan oleh data yang digunakan tidak kaya dan ketidakseimbangan antar kelas. Adapun penelitian ini memerlukan pendekatan tambahan untuk meningkatkan performa CNN secara keseluruhan. Keterbatasan penelitian yang belum mengeksplorasi menggunakan teknik penyeimbangan kelas, yang dapat membantu meningkatkan hasil metrik lainnya.

Penelitian terdahulu mengenai klasifikasi jerawat menggunakan CNN memiliki tingkat akurasi yang tinggi. Akurasi data latih pada *epoch* menunjukkan pola serupa, yang dimana tingkat akurasi meningkat dengan bertambahnya *epoch* hingga titik tertentu. Pada performa data uji tetap rendah terutama untuk jerawat yang memiliki sifat warna yang sama.

Pada CNN ini menunjukkan potensi untuk diterapkan pada sistem pendukung keputusan klinis untuk klasifikasi atau pendeteksi jenis jerawat. Namun, memerlukan peningkatan lanjutan seperti dalam CNN dapat menggunakan pendekatan lainnya seperti VGG16, ResNet, atau EfficientNet yang perlu disesuaikan dengan lapisan *machine learning*. Selain itu, pendeteksian jenis jerawat dapat menggunakan pendekatan *Deep Learning* dengan algoritma lainnya. Selain itu, pada proses pengumpulan data dapat menggunakan data gambar yang jauh lebih banyak sehingga menghasilkan model yang dapat mendeteksi jenis jerawat dengan lebih baik. Menggunakan penerapan metode *oversampling* untuk kelas yang memiliki ketidakseimbangan atau kelas minoritas dan menerapkan *weighted loss function* untuk dapat membantu meningkatkan hasil metrik seperti *recall* dan *F1 score*.

#### 5. KESIMPULAN

Berdasarkan penelitian dan implementasi terhadap proses pengujian, pada penelitian ini telah berhasil dibuat sistem klasifikasi jenis jerawat dan pendeteksian yaitu *blackhead*, *papula*, *puspula*, dan *whitehead*. Proses training menggunakan CNN dengan dataset berupa gambar yang memiliki kategori dari empat kelas deteksi dan menjadi acuan alternatif untuk melakukan klasifikasi dan deteksi pada gambar agar hasil dapat maksimal dan lebih efisien. Proses preprocessing memiliki dataset yang termasuk dalam data training dan testing untuk *machine learning* mempelajari kelas dari dataset. Tahap selanjutnya, dilakukannya proses untuk mengenali jenis jerawat pada kulit wajah dengan klasifikasi dimana sistem mengambil gambar, kemudian prediksi menggunakan model, hingga menampilkan hasil prediksi.

Pengujian menggunakan ukuran 150x150 dengan batch size 64, dan menggunakan *Tensorflow Keras* menghasilkan nilai akurasi yang cukup tinggi 96.57%. Menggunakan teknologi *Deep Learning* terbukti bekerja cukup efisien karena telah menghasilkan nilai akurasi yang cukup tinggi. Namun memiliki masalah pada nilai *Predicision*, *Recall*, dan *F1* yang dimana memiliki nilai masih dibawah 50%. Hal ini disebabkan karena dataset yang kurang cukup untuk *machine* mempelajari kelas yang ada, dan memiliki jumlah data setiap kelas yang tidak seimbang. Pada penelitian terdahulu menggunakan dataset dengan jumlah data yang lebih besar, hal ini disebabkan karena CNN dirancang untuk menangkap pola visual yang kompleks.

## REFERENSI

- [1] I. Hasan, H. Suprayogi, and D. Bethaningtyas, "Klasifikasi Jenis Jerawat Menggunakan Convolutional Neural Networks," *e-Proceeding of Engineering*, vol. 8, no. 1, pp. 358–371, 2021.
- [2] R. Try Lestari *et al.*, "Perilaku Mahasiswa Terkait Cara Mengatasi Jerawat," 2021.
- [3] A. H. S. Heng and F. T. Chew, "Systematic review of the epidemiology of acne vulgaris," *Sci Rep*, vol. 10, no. 1, Dec. 2020, doi: 10.1038/s41598-020-62715-3.
- [4] R. Ju, Y. Ying, Q. Zhou, and Y. Cao, "Exploring Genetic Drug Targets in Acne Vulgaris: A Comprehensive Proteome-Wide Mendelian Randomization Study," *J Cosmet Dermatol*, Dec. 2024, doi: 10.1111/jocd.16567.
- [5] A. Nadhya Maimanah and F. Makhrus, "Acne Classification with Gaussian Mixture Model based on Texture Features," 2022. [Online]. Available: [www.ijacsa.thesai.org](http://www.ijacsa.thesai.org)
- [6] 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.
- [7] 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/>
- [8] C. D. Sinaulan and A. Hantara, "Model Klasifikasi Permasalahan Kulit Wajah Menggunakan Metode Support Vector Machine," *Jurnal Pendidikan dan Kewirausahaan*, vol. 9, no. 1, pp. 297–308, Oct. 2021, doi: 10.47668/pkwu.v9i1.246.
- [9] Z. Lu *et al.*, "Natural language processing and machine learning methods to characterize unstructured patient-reported outcomes: validation study," *J Med Internet Res*, vol. 23, no. 11, Nov. 2021, doi: 10.2196/26777.
- [10] B. Mahesh, "Machine Learning Algorithms-A Review," *International Journal of Science and Research*, 2018, doi: 10.21275/ART20203995.
- [11] P. Yao *et al.*, "Single Model Deep Learning on Imbalanced Small Datasets for Skin Lesion Classification," *IEEE Trans Med Imaging*, vol. 41, no. 5, pp. 1242–1254, May 2022, doi: 10.1109/TMI.2021.3136682.
- [12] A. Adegun and S. Viriri, "Deep learning techniques for skin lesion analysis and melanoma cancer detection: a survey of state-of-the-art," *Artif Intell Rev*, vol. 54, no. 2, pp. 811–841, Feb. 2021, doi: 10.1007/s10462-020-09865-y.
- [13] S. Dong, P. Wang, and K. Abbas, "A survey on deep learning and its applications," *Comput Sci Rev*, vol. 40, May 2021, doi: 10.1016/j.cosrev.2021.100379.
- [14] S. W. Kusuma, F. Natalia, C. S. Ko, and S. Sudirman, "DETECTION OF AI-GENERATED ANIME IMAGES USING DEEP LEARNING," *ICIC Express Letters, Part B: Applications*, vol. 15, no. 3, pp. 295–301, Mar. 2024, doi: 10.24507/icicelb.15.03.295.
- [15] 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.
- [16] M. B. Islam, M. S. Junayed, A. Sadeghzadeh, N. Anjum, A. A. Jeny, and A. F. M. S. Shah, "Acne Vulgaris Detection and Classification: A Dual Integrated Deep CNN Model," *Informatika (Slovenia)*, vol. 47, no. 4, pp. 577–592, Dec. 2023, doi: 10.31449/inf.v47i4.4384.
- [17] E. Joelianto *et al.*, "Convolutional neural network-based real-time mosquito genus identification using wingbeat frequency: A binary and multiclass classification approach," *Ecol Inform*, vol. 80, May 2024, doi: 10.1016/j.ecoinf.2024.102495.
- [18] M. Novita *et al.*, "Exploring deep learning and machine learning for novel red phosphor materials," *J Lumin*, vol. 269, May 2024, doi: 10.1016/j.jlumin.2024.120476.
- [19] R. L. Hasanah and M. Hasan, "Deteksi Lesi Acne Vulgaris Pada Citra Jerawat Wajah Menggunakan Metode K-Means Clustering," *Indonesian Journal on Software Engineering (IJSE)*, vol. 8, no. 1, pp. 46–51, 2022, [Online]. Available: <http://ejournal.bsi.ac.id/ejournal/index.php/ijse46>

- [20] M. Shorfuzzaman, "An explainable stacked ensemble of deep learning models for improved melanoma skin cancer detection," in *Multimedia Systems*, Springer Science and Business Media Deutschland GmbH, Aug. 2022, pp. 1309–1323. doi: 10.1007/s00530-021-00787-5.
- [21] R. Rianto, D. Risdho Listianto, U. Teknologi Yogyakarta Jl Siliwangi Jl Ring Road Utara, and D. Istimewa Yogyakarta, "Convolutional Neural Network untuk mengklasifikasi tingkat keparahan jerawat," *AITI: Jurnal Teknologi Informasi*, vol. 20, no. Agustus, pp. 167–176, 2023, [Online]. Available: [www.kaggle.com](http://www.kaggle.com)