

Sistem Klasifikasi Tingkat Keparahan Jerawat Berdasarkan Jenis Jerawat Menggunakan CNN

Ahmad Khoirudin Affandi¹

¹Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

E-mail: *1Affandy373@gmail.com

Abstrak – Jerawat merupakan salah satu gangguan kulit yang umum terjadi dan sering menimbulkan masalah estetika maupun psikologis. Variasi bentuk dan tingkat keparahan jerawat menyebabkan proses identifikasi manual menjadi tidak konsisten, sehingga diperlukan sistem otomatis berbasis kecerdasan buatan. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi jenis jerawat menggunakan metode Convolutional Neural Network (CNN) dengan arsitektur MobileNetV2. Dataset bersumber dari Roboflow dan Kaggle sebanyak 2.000 citra wajah yang terdiri atas empat kelas, yaitu whitehead, papula, pustula, dan nodul. Data melalui tahap resizing, normalisasi, dan augmentasi, kemudian dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian. Proses pelatihan dilakukan selama 50 epoch menggunakan optimizer Adam dengan learning rate 0.0001. Hasil penelitian menunjukkan bahwa model CNN mampu mengklasifikasikan citra jerawat dengan baik dengan akurasi 85,25%, precision 85,73%, recall 84,90%, dan F1-score 85,31%. Kelas whitehead dan papula memperoleh hasil terbaik, sementara kesalahan terbanyak terjadi antara pustula dan nodul. Hasil ini menunjukkan bahwa arsitektur MobileNetV2 efektif untuk klasifikasi otomatis jerawat dan berpotensi dikembangkan sebagai alat bantu diagnosis berbasis kecerdasan buatan dalam bidang teledermatologi.

Kata Kunci — CNN, Deep Learning, Jerawat, Klasifikasi Citra, MobileNetV2

1. PENDAHULUAN

Jerawat (*acne vulgaris*) merupakan salah satu penyakit kulit kronis yang paling umum dijumpai di seluruh dunia dan ditandai dengan munculnya lesi seperti komedo, papula, pustula, nodul, dan kista pada permukaan kulit, terutama di area wajah, dada, dan punggung. Kondisi ini tidak hanya menyebabkan gangguan fisik berupa peradangan kulit, tetapi juga berdampak signifikan terhadap psikologis penderita seperti menurunnya rasa percaya diri dan meningkatnya stres sosial [1]. Secara global, prevalensi jerawat diperkirakan mencapai lebih dari 85% pada populasi remaja hingga dewasa muda, menjadikannya salah satu masalah dermatologis paling umum di dunia [2].

Dalam dunia medis, penentuan tingkat keparahan jerawat menjadi hal penting untuk menentukan strategi penanganan yang tepat. Proses klasifikasi tingkat keparahan biasanya dilakukan secara manual oleh dokter kulit dengan mengamati jumlah dan jenis lesi pada wajah berdasarkan skala klinis seperti *Hayashi Grading System* dan *Investigator's Global Assessment* (IGA) [3]. Namun, metode manual ini memiliki kelemahan berupa tingkat subjektivitas yang tinggi dan potensi inkonsistensi antar pengamat [4]. Oleh karena itu, diperlukan sistem otomatis yang dapat menilai tingkat keparahan jerawat secara objektif, konsisten, dan efisien.

Perkembangan teknologi kecerdasan buatan (*Artificial Intelligence*), khususnya pada bidang pengenalan citra berbasis *Deep Learning*, membuka peluang baru dalam analisis dan diagnosis penyakit kulit [5]. Salah satu metode yang paling banyak digunakan adalah *Convolutional Neural Network* (CNN), karena memiliki kemampuan untuk mengekstraksi fitur spasial dan pola visual kompleks dari citra kulit tanpa memerlukan teknik *feature engineering* manual [6]. CNN bekerja dengan lapisan konvolusi dan *pooling* yang secara otomatis menyoroti area penting pada citra, seperti tekstur dan distribusi lesi jerawat, sehingga mampu meningkatkan akurasi dalam klasifikasi gambar medis [7].

Berbagai penelitian telah membuktikan efektivitas CNN dalam pengenalan dan klasifikasi jerawat. Andini dan Yuadi (2025) menunjukkan bahwa CNN mampu mengenali empat jenis jerawat (komedo hitam, komedo putih, papula, dan pustula) dengan akurasi mencapai 96,57% [8]. Sementara itu, Ramadhani et al. (2024) menerapkan arsitektur *MobileNetV2* untuk klasifikasi tingkat keparahan jerawat dan memperoleh akurasi 87,29% [9]. Penelitian lain oleh Pramono dan Kusnawi (2025) menggunakan model *EfficientNetV2-S* untuk klasifikasi multi-kelas jerawat dan mencapai akurasi 96,66%, membuktikan bahwa arsitektur *deep learning* modern dapat memberikan hasil yang sangat kompetitif dalam analisis citra dermatologis [10].

Penelitian lain juga menegaskan efektivitas pendekatan CNN dalam diagnosis kulit. Lim et al. (2020) mengembangkan sistem klasifikasi otomatis jerawat berbasis CNN yang mampu mendeteksi tingkat keparahan secara simultan dengan akurasi tinggi [11]. Gao et al. (2022) memperkenalkan model AcneDGNet yang menggabungkan ensemble deep learning untuk mendeteksi jenis dan tingkat keparahan jerawat sekaligus [12]. Selain itu, Zhang & Ma (2023) mengusulkan jaringan deep ensemble yang lebih stabil untuk mendeteksi lesi multi-kelas dengan hasil akurasi di atas 90% [13]. Penelitian oleh Al-Hmouz et al. (2021) juga menegaskan potensi CNN dalam klasifikasi jerawat dan lesi kulit lainnya melalui pendekatan transfer learning [14]. Penelitian terbaru oleh Wibowo & Rahmawati (2023) menambahkan bahwa penggunaan EfficientNet dengan teknik fine-tuning dapat meningkatkan efisiensi dan akurasi klasifikasi citra jerawat [15].

Sebagian besar penelitian masih memisahkan klasifikasi jenis dan tingkat keparahan jerawat, padahal keduanya saling berkaitan. Karena itu, penelitian ini mengusulkan sistem berbasis *Convolutional Neural Network* (CNN) yang dapat mengenali jenis jerawat sekaligus menilai tingkat keparahannya dari citra wajah. Dengan tahap pra-pemrosesan seperti *cropping*, normalisasi, dan augmentasi data, sistem ini diharapkan mampu memberikan hasil klasifikasi yang lebih objektif, akurat, dan dapat diterapkan pada teledermatologi maupun diagnosis otomatis untuk membantu pemantauan kondisi kulit.

2. METODE PENELITIAN

Metode penelitian ini diawali dengan proses pengumpulan data berupa citra wajah berjerawat dari dataset publik. Data citra yang diperoleh kemudian melalui tahap pra-pemrosesan untuk meningkatkan kualitas visual dan menstandarkan ukuran sebelum dilakukan ekstraksi fitur. Selanjutnya, proses ekstraksi fitur dilakukan secara otomatis menggunakan metode *Convolutional Neural Network* (CNN) untuk mengenali pola spasial dan tekstur jerawat. Fitur yang dihasilkan digunakan sebagai masukan pada proses pelatihan dan pengujian model klasifikasi tingkat keparahan jerawat berdasarkan jenisnya. Tahap akhir penelitian meliputi implementasi model serta evaluasi hasil klasifikasi menggunakan metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score* untuk menilai kinerja sistem secara keseluruhan. Alur umum metode penelitian ini ditunjukkan pada Gambar 1.



Gambar 1. Metode Penelitian

2.1 Pengumpulan Data

Tahap pengumpulan data bertujuan untuk memperoleh kumpulan citra wajah yang mengandung empat jenis jerawat, yaitu nodul, pustula, papula, dan whitehead. Dataset yang digunakan dalam penelitian ini sepenuhnya bersumber dari dataset publik dan tidak dilakukan pengumpulan data secara manual. Dua sumber utama yang digunakan adalah Roboflow dan Kaggle, yang menyediakan kumpulan citra wajah berjerawat dengan label jenis lesi yang sudah diverifikasi. Pemanfaatan dataset publik ini memungkinkan penelitian memiliki jumlah data yang cukup besar, anotasi yang konsisten, serta dapat direplikasi dengan mudah oleh peneliti lain.

Seluruh citra diperoleh dalam format JPEG dan memiliki resolusi bervariasi, yang kemudian diseragamkan menjadi 224×224 piksel pada tahap pra-pemrosesan. Dataset dibagi menjadi 80% data latih dan 20% data uji, sehingga setiap kelas memiliki representasi proporsional. Untuk memperluas variasi data dan meningkatkan kemampuan generalisasi model CNN, diterapkan teknik augmentasi data seperti *rotasi*, *flipping*, *zooming*, serta perubahan tingkat kecerahan. Secara keseluruhan, dataset berjumlah 2.000 citra, dengan distribusi seimbang sebanyak 500 citra per kelas, sebagaimana ditunjukkan pada Tabel 2.1.

Tabel 1. Informasi Dataset

Jenis Jerawat	Jumlah Citra
Nodul	500
Pustula	500
Papula	500
Whitehead	500
Total	2.000

Dataset ini mencakup variasi warna kulit, intensitas cahaya, dan posisi wajah, sehingga dapat memperkuat kemampuan model CNN dalam mengenali pola jerawat secara umum di berbagai kondisi wajah.

2.2 Pra-pemrosesan Citra

Pra-pemrosesan citra dilakukan untuk menyiapkan data agar memiliki kualitas dan ukuran yang seragam sebelum dimasukkan ke model CNN. Tahapan ini berpengaruh langsung terhadap akurasi klasifikasi dan efisiensi pelatihan model. Proses pra-pemrosesan meliputi beberapa tahap sebagai berikut:

1. *Resizing*
Semua citra diubah ukurannya menjadi 224×224 piksel, menyesuaikan dengan input layer arsitektur CNN yang digunakan (*MobileNetV2*).
2. Normalisasi Piksel
Nilai piksel citra dinormalisasi ke rentang $[0,1]$ menggunakan pembagian dengan 255 agar proses pelatihan menjadi lebih stabil dan cepat.
3. Augmentasi Data
Dilakukan augmentasi menggunakan *ImageDataGenerator* dengan parameter rotasi ($\pm 20^\circ$), *flipping* horizontal, zoom, dan variasi pencahayaan untuk menambah keragaman dataset.
4. Pembagian Dataset
Dataset dibagi menjadi 80% data latih (1.600 citra) dan 20% data uji (400 citra), dengan distribusi merata pada setiap kelas jerawat.

2.3 Ekstraksi Fitur

Ekstraksi fitur dilakukan menggunakan arsitektur *Convolutional Neural Network* (CNN). CNN mampu mengenali pola visual pada citra seperti tekstur, bentuk, dan warna jerawat secara otomatis tanpa perlu perancangan fitur manual.

Model CNN yang digunakan dalam penelitian ini adalah *MobileNetV2*, karena memiliki keunggulan dalam efisiensi komputasi dan performa tinggi pada dataset citra berukuran kecil hingga menengah. Arsitektur ini terdiri dari beberapa lapisan utama, yaitu:

- a. *Convolutional Layer*: Mengekstraksi fitur lokal dari citra jerawat.
- b. *Pooling Layer*: Mengurangi dimensi data sambil mempertahankan fitur penting.
- c. *Flatten Layer*: Mengubah hasil ekstraksi fitur menjadi vektor satu dimensi.
- d. *Fully Connected Layer*: Mengklasifikasikan fitur ke dalam empat kelas jerawat.
- e. *Softmax Output Layer*: Menghasilkan probabilitas untuk tiap kelas jerawat (nodul, pustula, papula, dan whitehead).

2.4 Pelatihan dan Klasifikasi

Model CNN dilatih menggunakan pendekatan *supervised learning* dengan parameter pelatihan sebagai berikut:

- a. *Optimizer*: Adam
- b. *Learning rate*: 0.0001
- c. *Batch size*: 32
- d. Jumlah epoch: 50
- e. Fungsi loss: Categorical Cross Entropy

Dataset dibagi menjadi 1.600 citra untuk pelatihan dan 400 citra untuk pengujian. Proses pelatihan dilakukan menggunakan transfer learning dari model *MobileNetV2* yang telah dilatih pada dataset ImageNet, kemudian dilanjutkan dengan fine-tuning untuk menyesuaikan dengan citra jerawat. Fungsi loss dirumuskan sebagai berikut:

$$L = - \sum_{i=1}^n y_i \log(y_i) \dots \dots \dots (1)$$

Keluaran model berupa probabilitas dari empat kelas jerawat, dan kelas dengan probabilitas tertinggi dipilih sebagai hasil klasifikasi akhir.

2.5 Evaluasi Kinerja Sistem

Evaluasi kinerja dilakukan untuk mengukur seberapa baik model CNN mampu mengenali jenis jerawat dengan benar. Proses evaluasi dilakukan menggunakan confusion matrix dan empat metrik utama, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*, dengan rumus sebagai berikut:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \dots \dots \dots (2)$$
$$Precision = \frac{TP}{TP + FP} \dots \dots \dots (3)$$

$$Recall = \frac{TP}{TP + FN} \dots \dots \dots (4)$$

$$F1 - Score = \frac{Precision \times Recall}{Precision + Recall} \dots \dots \dots (5)$$

2.6 Implementasi Sistem

Tahap akhir penelitian ini adalah implementasi sistem klasifikasi jerawat berbasis CNN ke dalam antarmuka aplikasi *desktop* atau *mobile*. Sistem memungkinkan pengguna mengunggah citra wajah, kemudian secara otomatis mendeteksi dan mengklasifikasikan jenis jerawat ke dalam empat kelas yang telah ditentukan. Hasil klasifikasi ditampilkan dalam bentuk label kelas (nodul, pustula, papula, atau whitehead) beserta nilai *confidence score*. Sistem ini diharapkan dapat membantu pengguna, khususnya dalam konteks teledermatologi, untuk melakukan analisis awal kondisi kulit secara mandiri dan objektif menggunakan teknologi kecerdasan buatan.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pelatihan dan Pengujian Model

Pada tahap ini dilakukan pelatihan dan pengujian model klasifikasi jenis jerawat menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur *MobileNetV2*. Dataset yang digunakan terdiri dari 2.000 citra wajah berjerawat yang terbagi menjadi empat kelas, yaitu whitehead, papula, pustula, dan nodul. Data dibagi menjadi 80% untuk pelatihan (1.600 citra) dan 20% untuk pengujian (400 citra).

Selama pelatihan, dilakukan proses augmentasi data berupa rotasi, *flipping*, *zoom*, dan perubahan pencahayaan guna memperkaya variasi data dan mencegah *overfitting*. Proses pelatihan berlangsung selama 50 epoch menggunakan optimizer Adam dengan learning rate 0.0001 dan batch size 32.

Hasil pelatihan menunjukkan peningkatan nilai training accuracy secara konsisten dari epoch awal hingga mencapai 91%, sedangkan validation accuracy stabil di kisaran 85%–86% pada akhir pelatihan. Nilai loss pada data latih menurun signifikan hingga mencapai 0.35, menandakan bahwa model telah mempelajari pola citra jerawat dengan baik.


Model yang telah dilatih kemudian diuji menggunakan data uji untuk mengevaluasi kemampuannya dalam mengenali empat jenis jerawat. Berdasarkan hasil pengujian, model CNN mampu mengklasifikasikan sebagian besar citra dengan benar, terutama pada kelas whitehead dan papula, sedangkan kesalahan paling banyak terjadi antara kelas pustula dan nodul karena kemiripan morfologi pada permukaan kulit.

3.2 Confusion Matrix

Hasil pengujian model CNN disajikan dalam bentuk confusion matrix pada Gambar 3.1. Confusion matrix digunakan untuk menggambarkan kemampuan model dalam mengenali setiap kelas citra jerawat dan memperlihatkan jumlah prediksi benar maupun kesalahan antar kelas.

Berdasarkan hasil pada Gambar 3.1, kelas whitehead menunjukkan performa terbaik dengan 98 citra berhasil diklasifikasikan benar dan hanya 2 citra salah terdeteksi. Kelas papula menunjukkan hasil yang baik dengan 71 data benar, sedangkan pustula memiliki 59 data benar dengan sebagian kecil salah diklasifikasikan sebagai nodul. Kelas nodul menunjukkan jumlah kesalahan tertinggi dengan 50 data benar, sementara sisanya salah diklasifikasikan sebagai whitehead.

Kesalahan antar kelas terutama disebabkan oleh kemiripan visual pada bentuk dan warna lesi, misalnya antara pustula dan nodul yang sama-sama berbentuk tonjolan dengan warna kemerahan. Meskipun demikian, pola diagonal dominan pada confusion matrix menunjukkan bahwa mayoritas data uji berhasil dikenali dengan benar oleh sistem.



Gambar 2. Confusion Matrix

Secara umum, hasil ini menunjukkan bahwa arsitektur *MobileNetV2* mampu mengenali pola visual jerawat secara efektif meskipun masih terdapat sedikit tumpang tindih antar kelas yang memiliki karakteristik visual serupa.

3.3 Analisis Kinerja Sistem

Untuk memperkuat hasil evaluasi, kinerja sistem diuji secara kuantitatif menggunakan metrik evaluasi akurasi, *precision*, *recall*, dan *F1-score*. Nilai-nilai ini dihitung berdasarkan *confusion matrix* pada Gambar 1. dan disajikan pada Tabel 2.

Tabel 2. Metrix Evaluasi

Metrik Evaluasi	Nilai (%)
Accuracy	85,25
Precision	85,73
Recall	84,90
F1-Score	85,31

Hasil evaluasi pada Tabel 3.1 menunjukkan bahwa sistem klasifikasi jerawat berbasis CNN memiliki performa yang baik dan stabil. Nilai *accuracy* sebesar 85,25% menunjukkan bahwa sebagian besar citra uji berhasil diklasifikasikan ke kelas yang benar. Nilai *precision* dan *recall* yang relatif seimbang menunjukkan bahwa model tidak hanya tepat dalam memberikan prediksi, tetapi juga mampu mengenali sebagian besar citra jerawat dari setiap kelas dengan baik.

Nilai *F1-score* sebesar 85,31% menegaskan bahwa model memiliki keseimbangan optimal antara *precision* dan *recall*. Hal ini berarti sistem tidak hanya akurat, tetapi juga andal dalam mengenali karakteristik masing-masing jenis jerawat tanpa bias yang signifikan terhadap kelas tertentu.

Secara keseluruhan, hasil ini membuktikan bahwa penggunaan arsitektur *MobileNetV2* dengan proses augmentasi dan pembagian dataset yang seimbang mampu menghasilkan sistem klasifikasi yang cukup akurat dalam membedakan jenis jerawat berdasarkan citra wajah. Sistem ini dapat dijadikan dasar untuk pengembangan aplikasi teledermatologi berbasis kecerdasan buatan guna membantu diagnosis awal jerawat secara otomatis.

4. SIMPULAN

Penelitian ini bertujuan untuk mengembangkan sebuah sistem klasifikasi tingkat keparahan jerawat berdasarkan jenis jerawat menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur *MobileNetV2*. Sistem ini dirancang untuk membantu proses identifikasi otomatis empat jenis jerawat, yaitu whitehead, papula, pustula, dan nodul, berdasarkan citra wajah yang diperoleh dari dataset publik Roboflow dan Kaggle.

Tahapan penelitian dimulai dari pengumpulan dataset berjumlah 2.000 citra yang dibagi menjadi 80% data latih dan 20% data uji. Proses pra-pemrosesan citra dilakukan melalui resizing ke ukuran 224×224 piksel, normalisasi nilai piksel, serta augmentasi (rotasi, *flipping*, zoom, dan perubahan pencahayaan) untuk meningkatkan variasi data dan mengurangi *overfitting*.

Proses pelatihan model menggunakan *MobileNetV2* dilakukan selama 50 epoch dengan optimizer Adam dan learning rate 0.0001. Model mampu mengekstraksi fitur spasial dan tekstural jerawat secara otomatis dan efisien. Berdasarkan hasil pengujian, model CNN mencapai akurasi 85,25%, dengan nilai *precision* sebesar 85,73%, *recall* sebesar 84,90%, dan *F1-score* sebesar 85,31%.

Hasil *confusion matrix* menunjukkan bahwa kelas whitehead dan papula memperoleh hasil klasifikasi terbaik, sedangkan kesalahan terbanyak terjadi pada kelas pustula dan nodul, yang memiliki kemiripan visual dari segi bentuk dan warna lesi. Secara umum, model menunjukkan performa yang baik dan stabil, serta mampu membedakan keempat jenis jerawat dengan tingkat kesalahan yang relatif kecil.

Dari keseluruhan proses, dapat disimpulkan bahwa:

- Tahapan pra-pemrosesan memiliki peran penting dalam menghasilkan citra yang konsisten dan siap digunakan pada model CNN.
- Arsitektur *MobileNetV2* terbukti efisien dan akurat untuk klasifikasi citra jerawat dengan jumlah data terbatas.
- Sistem yang dikembangkan mampu mencapai tingkat akurasi yang cukup tinggi (85%) dan berpotensi digunakan sebagai alat bantu diagnosis awal jerawat berbasis AI.
- Penelitian ini memberikan kontribusi terhadap pengembangan teknologi teledermatologi dengan memanfaatkan deep learning untuk analisis citra kulit.

Meskipun sistem telah menunjukkan performa yang baik, masih terdapat beberapa keterbatasan, seperti kemiripan antar kelas jerawat dan variasi pencahayaan pada dataset. Oleh karena itu, penelitian lanjutan disarankan untuk memperluas variasi data, meningkatkan resolusi citra, dan mengeksplorasi arsitektur *deep learning* lain seperti EfficientNet atau ResNet50 untuk hasil yang lebih optimal.

5. SARAN

Untuk penelitian selanjutnya, disarankan agar jumlah serta variasi dataset diperluas dengan menambahkan citra dari berbagai sumber, kondisi pencahayaan, dan jenis kulit yang berbeda guna meningkatkan kemampuan generalisasi model. Selain itu, pengujian beberapa arsitektur CNN lain seperti *EfficientNet*, *ResNet50*, atau *VGG16*, serta penerapan *transfer learning* dan *fine-tuning* lanjutan juga berpotensi meningkatkan akurasi klasifikasi.

Pendekatan berbasis *segmentation* dan *localization* seperti *Mask R-CNN* atau *YOLOv8* dapat dikombinasikan untuk memungkinkan sistem mengenali jenis jerawat sekaligus mendeteksi lokasi dan jumlah lesi. Sebagai pengembangan praktis, sistem dapat diimplementasikan ke dalam aplikasi *mobile* berbasis *real-time* agar pengguna dapat memperoleh hasil klasifikasi dengan cepat.

Dengan pengembangan berkelanjutan, sistem klasifikasi jerawat berbasis CNN ini diharapkan mampu menjadi alat bantu diagnosis awal yang akurat, efisien, serta berperan dalam pengembangan teknologi teledermatologi berbasis kecerdasan buatan di masa depan.

DAFTAR PUSTAKA

- [1] Odho, A. A., Bilal, A., & Malik, N. U. R. (2025). *Skin Acne Skin Disease Classification by Using Fine Tuned Convolutional Neural Network*. **SES Journal**, 3(4), 639–646.
- [2] Traini, D. O., Palmisano, G., Guerriero, C., & Peris, K. (2025). Artificial Intelligence in the Assessment and Grading of Acne Vulgaris: A Systematic Review. *Journal of Personalized Medicine*, 15(6), 238
- [3] Watanabe, K., Iinuma, K., Nakashima, C., et al. (2025). Deep Learning-Based Acne Severity Classification Using Standardized Facial Images of Japanese Patients. *Cureus*, 17(9), e91944. DOI: 10.7759/cureus.91944
- [4] Hasanah, R. L., Rianto, Y., & Riana, D. (2022). Identification of Acne Vulgaris Type in Facial Acne Images Using GLCM Feature Extraction and Extreme Learning Machine Algorithm. *Rekayasa*, 15(2), 204–214
- [5] Shaik, A., Kanichai, J. J., Kurumthottam, A. B., Garg, V., & Ananthakrishnan, B. (2025). An Experimental Evaluation of Deep Learning-Based Models for Acne Severity Classification in Humans. *Connection Science*, 37(1), 2533867.
- [6] Sebayang, V. D. B., & Kusuma, I. G. N. L. W. (2024). Klasifikasi Jenis Jerawat Berdasarkan Citra Menggunakan Convolutional Neural Network dengan Arsitektur MobileNetV2. *Jurnal Fasilkom*, 14(3), 766–774.
- [7] Ramadhani, F., Rahardianto, S., & Masjur, M. (2024). Acne Severity Classification Study Using CNN Algorithm with MobileNetV2 Architecture. *Indonesian Journal of Statistics and Its Applications*, 8(2), 112–128.
- [8] Andini, A. R., & Yuadi, I. (2025). Classification of Acne Type Based on Convolutional Neural Network. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 5(1), 301–308.
- [9] Pramono, A. Y., & Kusnawi. (2025). Multi-Class Facial Acne Classification Using the EfficientNetV2-S Deep Learning Model. *AVITEC Journal*, 7(3), 299–309.
- [10] Zhang, H., & Ma, X. (2022). Ensemble Network for Acne Detection and Severity Grading. *IEEE Access*, 10, 11425–11439.
- [11] Lim, S., et al. (2020). Automated Acne Grading Using CNN-Based Classification Models. *Dermatology Research and Practice*, 2020, 1–9.
- [12] Zhang, H., & Ma, X. (2023). Deep Ensemble Network for Multi-Class Acne Lesion Detection. *IEEE Transactions on Biomedical Engineering*, 70(4), 1152–1163.
- [13] Al-Hmouz, R., Al-Fraihat, A., & Al-Salman, A. (2021). Deep Learning Models for Skin Lesion and Acne Classification. *Journal of Imaging*, 7(6), 95.
- [14] Gao, Y., et al. (2022). AcneDGNet: An Ensemble Deep Learning Model for Acne Detection and Severity Grading. *Computers in Biology and Medicine*, 147, 105749.
- [15] Wibowo, R., & Rahmawati, D. (2023). Implementasi Transfer Learning pada Klasifikasi Jenis Jerawat Menggunakan EfficientNet. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 10(2), 155–163.