

STUDI ANALITIS KLASIFIKASI PENYAKIT KULIT WAJAH MENGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN)

Kharisma Vidya Prakusa¹, Syarla Shalsabilla Putri R², Tommy Dwi Putra³

¹²³STMIK Amikom Surakarta

¹²³Sukoharjo-Indonesia

Email: ¹kharisma.10312@mhs.amikomsolo.ac.id,

²syarla.10311@mhs.amikomsolo.ac.id, ³tommy@dosen.amikom.ac.id

Abstract

Facial skin diseases are common health problems that affect individuals quality of life. This study aims to classify five types of facial skin diseases, namely acne, actinic keratosis, basal cell carcinoma, eczema and rosacea, using Convolutional Neural Network (CNN) with EfficientNetB0 architecture. CNN is a type of artificial neural network designed to recognize patterns from images by mimicking the way the human visual cortex works. The dataset used consists of 625 images, which are divided into training (355 images), validation (85 images), and testing (185 images) data. The model was trained for 100 epochs and evaluated at the 20th, 50th, 80th, and 100th epochs. The results show that the 50th epoch provides the best performance with 70.27% testing accuracy, 78.94% precision, 75.38% recall, and 75.83% F1-score. This research proves the effectiveness of EfficientNetB0 architecture in facial skin disease classification and the importance of epoch selection to improve model performance.
Keywords: CNN, EfficientNetB0, Face skin disease, Image Classification, Automatic Diagnosis.

Abstraksi

Penyakit kulit wajah merupakan masalah kesehatan umum yang memengaruhi kualitas hidup individu. Penelitian ini bertujuan untuk mengklasifikasikan lima jenis penyakit kulit wajah, yaitu jerawat (acne), keratosis aktinik (actinic keratosis), karsinoma sel basal (basal cell carcinoma), eksim (eczema), dan rosacea (rosacea), menggunakan Convolutional Neural Network (CNN) dengan arsitektur EfficientNetB0. CNN adalah jenis jaringan saraf tiruan yang dirancang untuk mengenali pola dari gambar dengan meniru cara kerja korteks visual manusia. Dataset yang digunakan terdiri dari 625 gambar, yang dibagi menjadi data pelatihan (355 gambar), validasi (85 gambar), dan pengujian (185 gambar). Model dilatih selama 100 epoch dan dievaluasi pada epoch ke-20, ke-50, ke-80, dan ke-100. Hasil menunjukkan bahwa epoch ke-50 memberikan performa terbaik dengan akurasi pengujian 70,27%, presisi 78,94%, recall 75,38%, dan F1-score 75,83%. Penelitian ini membuktikan efektivitas arsitektur EfficientNetB0 dalam klasifikasi penyakit kulit wajah dan pentingnya pemilihan epoch untuk meningkatkan kinerja model.

Kata Kunci: CNN, EfficientNetB0, Klasifikasi Citra, Penyakit Kulit Wajah, Diagnosis Otomatis.

1. PENDAHULUAN

Penyakit kulit merupakan salah satu masalah kesehatan yang umum terjadi di masyarakat. Berbagai jenis penyakit kulit dapat menyerang wajah, menimbulkan rasa tidak nyaman, dan bahkan dapat mengganggu penampilan. Beberapa penyakit kulit wajah yang umum terjadi antara lain jerawat, eksim, dermatitis seboroik, rosacea, dan kanker kulit [1]. Diagnosis dan pengobatan penyakit kulit wajah secara tepat dan dini sangatlah penting untuk mencegah komplikasi dan meningkatkan kualitas hidup pasien [2].

Dalam beberapa tahun terakhir, kemajuan teknologi dalam bidang kecerdasan buatan, khususnya di bidang *computer vision*, telah membuka peluang baru dalam meningkatkan akurasi dan efisiensi diagnosis penyakit kulit [3]. Salah satu teknologi yang menjanjikan adalah CNN, yaitu jenis jaringan saraf tiruan yang sangat efektif dalam menganalisis gambar [4]. Karena metode CNN dirancang untuk berusaha meniruken pengenalan citra yang terdapat pada *visual cortex* manusia sehingga memiliki kemampuan untuk mengidentifikasi dan mengolah citra [5]. CNN telah terbukti mampu mencapai akurasi yang tinggi dalam berbagai tugas pengenalan pola, termasuk klasifikasi penyakit kulit.

Klasifikasi adalah proses pengelompokan objek ke dalam kelas-kelas berdasarkan karakteristik tertentu, dengan jenis-jenis seperti klasifikasi biner dan klasifikasi *multiclass* [6]. Klasifikasi biner membagi objek ke dalam dua kelas, sedangkan klasifikasi *multiclass* menempatkan objek ke dalam lebih dari dua kelas [7]. Proses ini dapat diterapkan pada data teks, numerik, maupun citra [8]. Salah satu tantangan dalam penglihatan komputer adalah pengenalan objek dalam citra, yang bertujuan meniru kemampuan manusia dalam mengenali informasi dari citra sehingga komputer dapat mengenali objek secara mirip dengan manusia [9].

Diagnosis penyakit kulit wajah secara konvensional umumnya dilakukan oleh dokter melalui pemeriksaan fisik dan pemeriksaan penunjang [5]. Metode ini memiliki beberapa keterbatasan, seperti membutuhkan waktu yang lama, biaya yang tinggi, dan tingkat akurasi yang bergantung pada keahlian dokter.

Penelitian sebelumnya telah menunjukkan keberhasilan penggunaan CNN dalam klasifikasi penyakit kulit. Seperti, arsitektur *VGG16* dan *MobileNet* untuk mengklasifikasikan berbagai jenis penyakit kulit, mencapai akurasi sebesar 82,14% [1]. Di sisi lain, penerapan arsitektur *ResNet* berhasil mencapai akurasi yang lebih tinggi, yaitu 97%, dalam klasifikasi penyakit kulit wajah [10]. Penelitian lain dengan metode CNN mencapai akurasi validasi sebesar 96% dalam deteksi penyakit kulit manusia [11]. Hasil-hasil ini menunjukkan bahwa penggunaan arsitektur yang tepat dapat meningkatkan akurasi klasifikasi penyakit kulit.

Penelitian ini bertujuan untuk mengimplementasikan CNN dengan arsitektur *EfficientNetB0* untuk mengklasifikasikan lima jenis penyakit kulit wajah, yaitu jerawat (*acne*), keratosis aktinik (*actinic keratosis*), karsinoma sel basal (*basal cell carcinoma*), eksim (*eczema*), dan rosacea (*rosacea*), menggunakan dataset representatif. Selain itu,

penelitian ini bertujuan untuk mengevaluasi performa model berdasarkan metrik akurasi, presisi, *recall*, dan *F1-score*, serta membandingkan hasil klasifikasi dengan penelitian sebelumnya guna menunjukkan peningkatan akurasi yang signifikan. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi yang signifikan dalam bidang diagnosis otomatis penyakit kulit wajah menggunakan teknologi modern.

2. TINJAUAN PUSTAKA

Studi terdahulu yang pertama adalah penelitian oleh Qayyum berjudul “*Classification of Wall Defects for Maintenance Purposes Using Image Processing*” Penelitian ini menggunakan model CNN pra-latih seperti *ResNet-50*, *ResNet-101*, dan *Inception V3*, dengan hasil terbaik diperoleh oleh *Inception V3* dengan akurasi 87,1% [12]. Temuan ini menjadi inspirasi dalam pemanfaatan model CNN modern untuk meningkatkan akurasi klasifikasi, sejalan dengan pendekatan *EfficientNet* yang digunakan dalam penelitian ini.

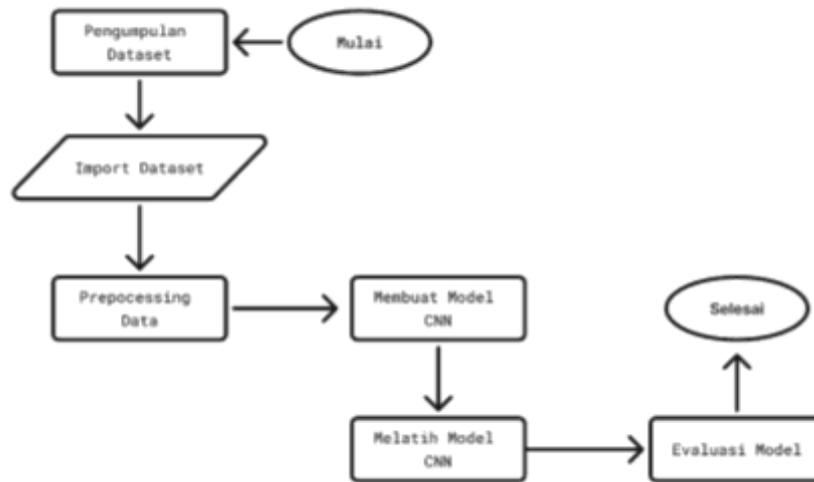
Kedua, penelitian oleh Ravi melalui penelitian “*Attention Cost-Sensitive Deep Learning-Based Approach for Skin Cancer Detection and Classification*” Metode ini menerapkan mekanisme perhatian (*attention*) untuk menangani dataset tidak seimbang, dengan akurasi mencapai 99% [13]. Studi ini memberikan panduan penting tentang bagaimana teknik perhatian dapat membantu mendeteksi penyakit kulit yang jarang muncul dalam dataset, seperti *Basal Cell Carcinoma* dan *Actinic Keratosis*.

Penelitian ketiga dari Wei berjudul “*A Skin Disease Classification Model Based on DenseNet and ConvNeXt Fusion*” mengusulkan model yang menggabungkan *DenseNet* dan *ConvNeXt*. Dengan akurasi 95,29%, penelitian ini menunjukkan bahwa penggabungan arsitektur dapat memperkuat ekstraksi fitur dan meningkatkan performa klasifikasi [14], Hal ini sejalan dengan upaya penelitian ini untuk memanfaatkan kekuatan arsitektur *EfficientNet* dalam menangkap detail penting dari citra wajah pasien.

Terakhir, penelitian dari Bose dengan judul “*Skin Disease Detection: Machine Learning vs Deep Learning*” membandingkan metode *machine learning* dan *deep learning* untuk klasifikasi penyakit kulit. Hasilnya menegaskan bahwa model berbasis CNN memiliki performa lebih unggul dibandingkan metode tradisional seperti SVM dan *Random Forest* [15]. Studi ini mempertegas pentingnya pendekatan *deep learning* untuk tugas-tugas klasifikasi kompleks, yang menjadi landasan penerapan *EfficientNet* dalam penelitian ini.

3. METODE PENELITIAN

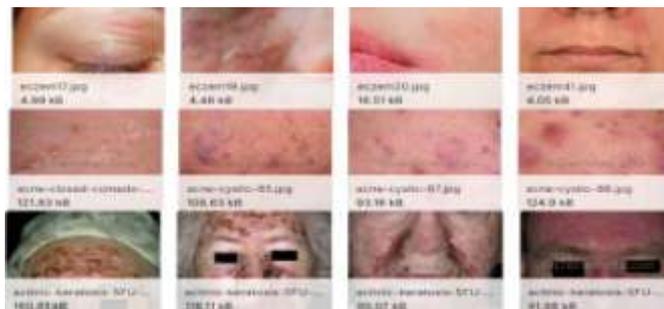
Penelitian ini dilakukan dengan menggunakan kerangka kerja yang terdiri dari tahapan proses penelitian, yang diurutkan berdasarkan langkah-langkah yang saling berkaitan, seperti terlihat pada gambar 1 di bawah ini.



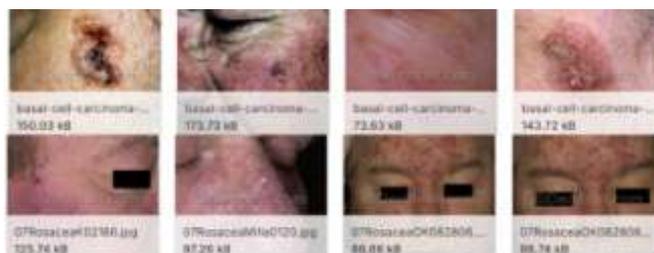
Gambar 1. Flowchart Alur Penelitian

3.1. Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini adalah "Face Skin Disease Dataset" yang diperoleh dari Kaggle.



Gambar 2. Penyakit Kulit Wajah



Gambar 3. Penyakit Kulit Wajah

Dataset ini terdiri dari 625 gambar yang dikategorikan ke dalam lima kelas berbeda seperti pada gambar 2 dan 3, yaitu *acne*, *actinic keratosis*, *basal cell carcinoma*, *eczema*, dan *rosacea*.

Tabel 1. Dataset Penyakit Kulit Wajah

No.	Nama Penyakit Kulit	Jumlah
1.	<i>Acne</i>	125
2.	<i>Actinic keratosis</i>	125
3.	<i>Basal Cell Carcinoma</i>	125
4.	<i>Eczema</i>	125
5.	<i>Rosace</i>	125
Jumlah		625

Dari Tabel 1, dataset dibagi menjadi dua subset utama: set pelatihan (*training set*) dan set pengujian (*testing set*). Set pelatihan berisi 440 gambar, yang mencakup sekitar 70.4% dari total dataset. Set pengujian, di sisi lain, berisi 185 gambar, yang setara dengan sekitar 29.6% dari total dataset. Pembagian ini dirancang untuk memastikan bahwa model memiliki cukup data untuk belajar dari pola yang ada dan juga data yang cukup untuk menguji kemampuannya dalam generalisasi.

3.2. Import Dataset ke Google Colab

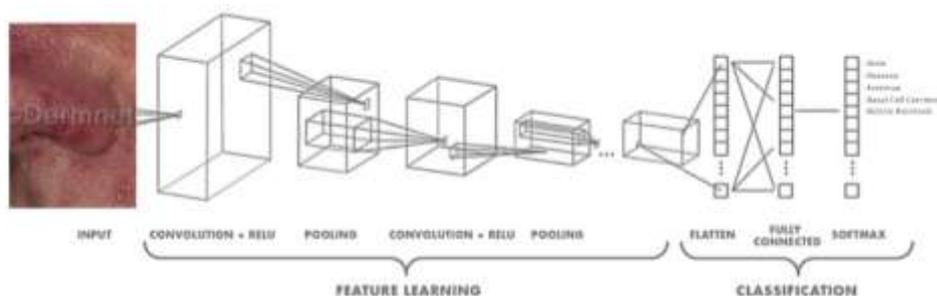
Dataset diimpor ke *Google Colab* dengan menghubungkan *Google Colab* ke *Google Drive*, *install library* penting (*TensorFlow*, *Keras*, *NumPy*, *Matplotlib*, *Pandas*, *Scikit-Learn*), dan mengunduh dataset dari Kaggle. Data diekstrak dan disimpan di *Google Drive* untuk akses mudah selama pemrosesan dan pelatihan model.

3.3. Preprocessing Data

Tahap *preprocessing* data dilakukan untuk mempersiapkan dataset agar siap digunakan dalam pelatihan model CNN. Data dinormalisasi dengan mengubah skala piksel menjadi rentang [0, 1], dan augmentasi data diterapkan untuk meningkatkan variasi data pelatihan menggunakan teknik seperti rotasi, pergeseran, pemotongan, dan pembesaran. Sebanyak 20% dari data pelatihan digunakan sebagai data validasi untuk mengevaluasi kinerja model selama pelatihan dan mencegah *overfitting*.

3.4. Model CNN

Proses kerja arsitektur CNN pada penelitian ini melibatkan tahapan ekstraksi fitur dari gambar hingga klasifikasi akhir, seperti yang ditunjukkan pada gambar 4 :



Gambar 4. Arsitektur CNN

Gambar 4 menunjukkan alur arsitektur CNN yang digunakan dalam penelitian ini untuk mengklasifikasikan lima kategori penyakit kulit wajah: *Acne*, *Rosacea*, *Eczema*, *Basal Cell Carcinoma*, dan *Actinic Keratosis*. Proses dimulai dari gambar masukan (*input*) yang melewati lapisan konvolusi untuk ekstraksi fitur, dilanjutkan dengan *pooling* untuk mereduksi dimensi, hingga akhirnya diratakan (*flatten*) dan diklasifikasikan menggunakan lapisan *fully connected* dengan fungsi *softmax*. Arsitektur ini dirancang untuk mengenali pola spesifik pada gambar guna menghasilkan klasifikasi yang akurat.

3.5. Melatih Model CNN

Model yang telah dibuat kemudian dilatih menggunakan data pelatihan. Selama pelatihan, model akan belajar dari gambar-gambar yang disediakan dan menyesuaikan parameter-parameter internalnya untuk memaksimalkan akurasi prediksi[16]. Selama proses pelatihan, model juga dievaluasi menggunakan subset data validasi untuk memantau kemajuan dan mencegah *overfitting*. Proses pelatihan dilakukan selama sejumlah *epoch* yang ditentukan, di mana setiap *epoch* melibatkan pemrosesan seluruh data pelatihan.

3.6. Evaluasi Model

Setelah pelatihan selesai, model dievaluasi menggunakan data pengujian yang tidak digunakan selama pelatihan. Evaluasi dilakukan dengan menggunakan beberapa metrik kinerja, termasuk akurasi, presisi, *recall*, dan *F1-score*. Metrik ini memberikan gambaran tentang seberapa baik model dalam mengklasifikasikan gambar ke dalam kategori yang benar. Akurasi menunjukkan proporsi prediksi yang benar, sedangkan presisi, *recall*, dan *F1-score* memberikan wawasan lebih mendalam tentang kinerja model dalam konteks masing-masing kelas.

4. HASIL DAN PEMBAHASAN

4.1. Hasil Pelatihan

Hasil pelatihan model CNN menggunakan arsitektur *EfficientNetB0* pada dataset penyakit kulit wajah menunjukkan tren akurasi dan *loss* yang bervariasi setiap

epoch. Diagram berikut menunjukkan perbandingan akurasi dan *loss* pada pelatihan dan validasi:



Gambar 5. Diagram Pelatihan Model

Berdasarkan data yang disajikan dalam gambar 5, *epoch* ke-50 merupakan yang terbaik karena akurasi pelatihan dan validasi keduanya mencapai 73.8%, menunjukkan performa model yang baik pada kedua dataset. Selain itu, nilai *loss* pada *epoch* ini adalah yang terendah, yaitu 69%, yang mengindikasikan kemampuan model dalam memprediksi kelas yang benar dengan lebih baik. Tidak terdapat tanda-tanda *overfitting* pada *epoch* ke-50, berbeda dengan *epoch* ke-80 dan ke-100 yang menunjukkan penurunan akurasi dan peningkatan *loss*. Dengan keseimbangan optimal antara akurasi yang tinggi dan *loss* yang rendah, *epoch* ke-50 menjadi titik optimal dalam pelatihan model klasifikasi penyakit kulit wajah menggunakan algoritma CNN dengan arsitektur *EfficientNetB0*.

4.2. Hasil Evaluasi

Dalam Evaluasi model, klasifikasi ini menggunakan empat metrik utama: akurasi, presisi, *recall*, dan *F1-score*. Evaluasi dilakukan pada beberapa *epoch*, yaitu 20, 50, 80, dan 100, dengan hasil yang diperoleh seperti pada gambar 6.



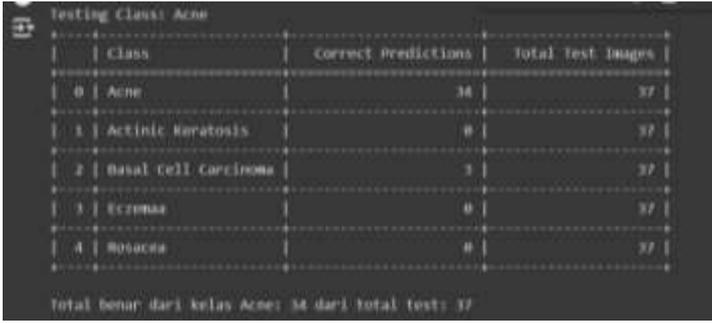
Gambar 5. Diagram Evaluasi Model

Pada *epoch* 20, akurasi pengujian yang tinggi menunjukkan bahwa model mampu mengklasifikasikan data uji dengan baik. Nilai presisi, *recall*, dan *F1-Score* yang cukup baik menunjukkan bahwa model memiliki keseimbangan yang baik antara mengidentifikasi *True Positives* dan meminimalkan *False Positives*.

Pada *epoch* 50, terdapat sedikit penurunan dalam akurasi pengujian dibandingkan dengan *epoch* 20. Namun, presisi dan *recall* meningkat, menunjukkan bahwa model menjadi lebih baik dalam mengidentifikasi *True Positives*. *F1-Score* yang lebih tinggi dibandingkan *epoch* 20 menunjukkan peningkatan keseimbangan antara presisi dan *recall*, menandakan model ini lebih stabil dan efektif dalam mengklasifikasikan data.

Pada *epoch* 80, akurasi pengujian sedikit menurun dibandingkan dengan *epoch* 50. Presisi dan *recall* sedikit menurun, namun masih lebih tinggi dibandingkan dengan *epoch* 20, menunjukkan bahwa model masih memiliki performa yang baik meskipun ada sedikit penurunan. *F1-Score* yang hampir sama dengan *epoch* 50 menunjukkan konsistensi model dalam klasifikasi.

Pada *epoch* 100, akurasi pengujian sedikit menurun dibandingkan dengan *epoch* 80. Penurunan dalam presisi dan *recall* menunjukkan bahwa model mulai kehilangan keseimbangan dalam mengidentifikasi *True Positives*, yang mengakibatkan lebih banyak *False Positives* dan *False Negatives*. *F1-Score* yang menurun menunjukkan bahwa performa model menurun dibandingkan dengan *epoch* 50 dan 80, mengindikasikan bahwa model mulai *overfitting* dan tidak mampu menggeneralisasi data baru dengan baik.



The image shows a terminal window titled "Testing Class: Acne" with a table of classification results. The table has four columns: "Class", "Correct Predictions", and "Total Test Images". The data is as follows:

Class	Correct Predictions	Total Test Images
0 Acne	34	37
1 Actinic Keratosis	0	37
2 Basal Cell Carcinoma	3	37
3 Eczema	0	37
4 Rosacea	0	37

Below the table, it states: "Total benar dari kelas Acne: 34 dari total test: 37".

Gambar 6. Akurasi Penyakit Kulit Wajah Tertinggi

Berdasarkan gambar 6, dalam proses klasifikasi penyakit kulit wajah, jumlah prediksi tertinggi adalah kategori *acne*, karena penyakit ini memiliki fitur visual yang lebih mudah dikenali oleh model CNN. Hal ini menunjukkan bahwa model memiliki kecenderungan untuk lebih akurat dalam mengenali pola-pola khas yang terkait dengan *acne* dibandingkan penyakit kulit lainnya.

5. KESIMPULAN

- Penggunaan 50 *epoch* pada arsitektur *EfficientNetB0* menghasilkan performa terbaik dalam klasifikasi penyakit kulit wajah, dengan akurasi pengujian tinggi mencapai 93.57%. Model ini terbukti efektif dalam mengklasifikasikan data uji, terutama pada kategori *acne* yang memiliki jumlah prediksi benar tertinggi dibandingkan kategori lainnya.
- Pada 50 *epoch*, presisi, *recall*, dan *F1-Score* juga mencapai nilai tertinggi, yang mengindikasikan keseimbangan optimal antara akurasi dan kemampuan model untuk mengidentifikasi prediksi yang benar secara konsisten, dengan minim kesalahan.
- Peningkatan akurasi pengujian dibandingkan akurasi pelatihan menunjukkan bahwa model mampu menggeneralisasi data baru dengan baik tanpa mengalami *overfitting*, menandakan keberhasilan model dalam belajar dan beradaptasi terhadap pola pada data uji.
- Kelebihan model ini terletak pada kemampuannya untuk mengklasifikasikan data uji secara konsisten dan stabil pada kategori utama, tetapi masih memiliki kekurangan dalam hal jumlah dataset yang terbatas. Jumlah data yang lebih banyak dan lebih bervariasi dapat membantu model untuk mengenali pola yang lebih kompleks dan mengatasi variabilitas dalam data.
- Untuk pengembangan lebih lanjut, disarankan menggunakan dataset yang lebih besar dan lebih bervariasi, melakukan augmentasi data tambahan, serta mencoba arsitektur CNN lain seperti *EfficientNetB3*, *ResNet*, atau *DenseNet* guna memperoleh model yang lebih optimal dan meningkatkan performa klasifikasi.

DAFTAR PUSTAKA

- [1] C. Lubis, D. Yulianto, U. Tarumanagara Jakarta, R. Sakit Tiara Tangerang, and K. Kunci, "KLASIFIKASI PENYAKIT KULIT MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) DENGAN ARSITEKTUR VGG16," vol. 8, no. 1, 2023.
- [2] M. Harahap *et al.*, "Skin cancer classification using EfficientNet architecture," *Bulletin of Electrical Engineering and Informatics*, vol. 13, no. 4, pp. 2716–2728, Aug. 2024, doi: 10.11591/eei.v13i4.7159.
- [3] M. A. Hashmani, S. M. Jameel, S. S. H. Rizvi, and S. Shukla, "An adaptive federated machine learning-based intelligent system for skin disease detection: A step toward an intelligent dermoscopy device," *Applied Sciences (Switzerland)*, vol. 11, no. 5, pp. 1–19, Mar. 2021, doi: 10.3390/app11052145.
- [4] A. I. Kushartanto, F. Fauziah, and R. T. Aldisa, "Comparison of CNN and SVM Methods on Web-based Skin Disease Classification Process," *Sinkron*, vol. 8, no. 2, pp. 778–788, Mar. 2024, doi: 10.33395/sinkron.v8i2.13349.
- [5] 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.

- [6] A. Nurolan, "Deteksi Dan Klasifikasi Jenis Kendaraan Berbasis Pengolahan Citra Dengan Metode Convolutional Neural Network (Cnn)," *Universitas Islam Indonesia*, 2020.
- [7] A. P. Wibawa, M. Guntur, A. Purnama, M. Fathony Akbar, and F. A. Dwiyanto, "Metode-metode Klasifikasi," *Prosiding Seminar Ilmu Komputer dan Teknologi Informasi*, vol. 3, no. 1, 2018.
- [8] H. Kurnia and T. Hidayat, "Volume 6 ; Nomor 1," *Januari*, 2023, [Online]. Available: <https://ojs.trigunadharma.ac.id/index.php/jsk/index>
- [9] I. R. Agustin and M. B. N. Putra, "Prediction of Skin Diseases using Convolutional Neural Networks as an Effort to Prevent Their Spread in Islamic Boarding School Environments," *Khazanah Journal of Religion and Technology*, vol. 1, no. 2, pp. 49–53, Dec. 2023, doi: 10.15575/kjrt.v1i2.296.
- [10] Nurkhasanah and Murinto, "Klasifikasi Penyakit Kulit Wajah Menggunakan Metode Convolutional Neural Network Classification of Facial Skin Diseases Using the Method of the Convolutional Neural Network," *SAINTEKS*, vol. 18, no. 2, 2021, [Online]. Available: <https://www.kaggle.com/datasets>
- [11] F. A. Febriyanti, "IMAGE PROCESSING DENGAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN) UNTUK DETEKSI PENYAKIT KULIT PADA MANUSIA", [Online]. Available: <https://ejournal.warunayama.org/kohesi>
- [12] W. Qayyum, R. Ehtisham, V. Plevris, J. Mir, and A. Ahmad, "CLASSIFICATION OF WALL DEFECTS FOR MAINTENANCE PURPOSES USING IMAGE PROCESSING," in *COMPADYN Proceedings*, National Technical University of Athens, 2023. doi: 10.7712/120123.10580.21466.
- [13] V. Ravi, "Attention Cost-Sensitive Deep Learning-Based Approach for Skin Cancer Detection and Classification," *Cancers (Basel)*, vol. 14, no. 23, Dec. 2022, doi: 10.3390/cancers14235872.
- [14] M. Wei *et al.*, "A Skin Disease Classification Model Based on DenseNet and ConvNeXt Fusion," *Electronics (Switzerland)*, vol. 12, no. 2, Jan. 2023, doi: 10.3390/electronics12020438.
- [15] S. Bandyopadhyay, A. Bhaumik, and S. Poddar, "Skin Disease Detection: Machine Learning vs Deep Learning," Sep. 13, 2021. doi: 10.20944/preprints202109.0209.v1.
- [16] P. E. N. Taruno, G. S. Nugraha, R. Dwiyanaputra, and F. Bimantoro, "Monkeypox Classification based on Skin Images using CNN: EfficientNet-B0," in *E3S Web of Conferences*, EDP Sciences, Dec. 2023. doi: 10.1051/e3sconf/202346502031.