



Deteksi Dini Penyakit Kulit Pada Wajah Berdasarkan Citra Dengan Pendekatan Convolutional Neural Network (CNN)

Sisi Apriyani^{1*}, Novi Lestari², Tri Hasanah Bimastari Aviani³, Nelly Kahirani Daulay⁴

^{1,2,3,4} Prodi Informatika, Fakultas Teknik, Universitas Bina Insan, Indonesia

Info Artikel

Riwayat Artikel:

Diterima : **12 Mei 2025**

Direvisi : **10 Juni 2025**

Diterbitkan : **30 Juni 2025**

Kata Kunci:

CNN,

Deteksi Dini,

Citra Wajah,

Penyakit Kulit,

Deep Learning

ABSTRAK

Penyakit kulit wajah seperti jerawat dan melasma dapat memengaruhi kesehatan serta kepercayaan diri seseorang. Deteksi dini sangat penting untuk mendukung penanganan yang lebih cepat dan efektif. Penelitian ini bertujuan mengembangkan sistem klasifikasi penyakit kulit wajah berbasis citra digital menggunakan pendekatan Convolutional Neural Network (CNN). Model dikembangkan untuk mengklasifikasikan lima kategori: jerawat, flek hitam, herpes, kutil, dan tahi lalat, dengan total 380 citra. Data melalui tahapan pra-pemrosesan seperti pengubahan ukuran, normalisasi, dan augmentasi. Arsitektur CNN terdiri dari dua lapisan konvolusi, dua max pooling, dan dua fully connected. Hasil evaluasi menunjukkan akurasi rata-rata sebesar 90,58%, presisi 82,28%, recall 76%, dan F1-score 74,82%. Meskipun model menunjukkan performa baik pada beberapa kelas, masih ditemukan indikasi overfitting dan kesalahan klasifikasi antar kategori. Keterbatasan utama terletak pada jumlah data dan kemampuan generalisasi model. Dengan demikian, model CNN memiliki potensi dalam mendukung diagnosis awal penyakit kulit wajah, namun masih memerlukan pengembangan lanjutan melalui penggunaan dataset yang lebih besar dan arsitektur yang lebih kompleks.

Keywords:

CNN,

Early Detection,

Facial Image,

Skin Disease,

Deep Learning

ABSTRACT

Facial skin conditions such as acne and melasma can significantly affect a person's health and self-confidence. Early detection is essential to ensure timely treatment and prevent worsening symptoms. This study aims to develop a digital image-based facial skin disease classification system using a Convolutional Neural Network (CNN) approach. The model is designed to classify five categories: acne, dark spots, herpes, warts, and moles, using a dataset of 380 images. The data underwent preprocessing steps including resizing, normalization, and augmentation. The CNN architecture consists of two convolutional layers, two max-pooling layers, and two fully connected layers. Evaluation results show an average accuracy of 90.58%, precision of 82.28%, recall of 76%, and F1-score of 74.82%. While the model performs well on certain classes, indications of overfitting and misclassification across categories are observed. The main limitations lie in the limited dataset size and the model's generalization capability. Overall, the proposed CNN model demonstrates potential for assisting in the early diagnosis of facial skin conditions, but further development is needed, particularly through larger datasets and more advanced architectures.

Penulis Korespondensi:

Sisi Apriyani,

Program Studi Informatika,

Universitas Bina Insan

Email: sisiapriyani145@gmail.com

This is an open access article under the [CC BY-SA](#) license



1. PENDAHULUAN

Convolutional Neural Network (CNN) adalah salah satu metode yang terbukti efektif dalam memproses data berbasis citra [1]. Teknologi ini telah banyak dimanfaatkan untuk berbagai keperluan, seperti klasifikasi gambar, deteksi objek, hingga segmentasi citra, menjadikannya salah satu teknologi terdepan di bidang *computer vision*. Kemampuan CNN dalam mengenali pola dan fitur kompleks pada gambar menjadikannya solusi yang andal, terutama dalam aplikasi deteksi penyakit berbasis citra [2], [3].

Kulit merupakan organ terbesar dalam tubuh manusia dan berfungsi sebagai pelindung utama terhadap berbagai faktor eksternal [4]. Kesehatan kulit, khususnya kulit wajah, perlu dijaga karena sifatnya yang sensitif dan paparan langsung terhadap sinar matahari serta polusi udara [5]. Di negara tropis seperti Indonesia, paparan sinar ultraviolet (UV) dan kelembapan yang tinggi sepanjang tahun menjadikan kulit wajah lebih rentan mengalami gangguan [6], [7].

Gangguan kulit wajah dapat mencakup berbagai kondisi seperti jerawat, flek hitam, tahi lalat, kutil, dan herpes. Penyebabnya bisa berasal dari faktor hormonal, lingkungan, serta paparan sinar UV yang memicu produksi minyak berlebih [8]. Upaya menjaga kesehatan kulit wajah melibatkan sejumlah langkah preventif, seperti penggunaan tabir surya, pembersihan wajah secara rutin, pemakaian pelembap, pola makan sehat yang kaya antioksidan, konsumsi air yang cukup, serta menghindari paparan langsung sinar matahari pada waktu tertentu [9]. Langkah-langkah ini penting untuk mencegah kerusakan kulit, menjaga kelembapan, dan mengurangi risiko gangguan kulit akibat lingkungan. Sayangnya, masih banyak individu yang tidak menyadari gejala awal gangguan kulit dan cenderung mengabaikannya. Ketidaktahuan ini seringkali disebabkan oleh keterbatasan akses terhadap metode deteksi dini yang cepat dan akurat [10], [11]. Padahal, jika tidak segera ditangani, penyakit kulit pada wajah dapat berdampak serius, baik secara fisik maupun psikologis, seperti turunya rasa percaya diri.

Dalam konteks ini, penerapan *Convolutional Neural Network* (CNN) menjadi pendekatan yang menjanjikan. CNN mampu menganalisis citra wajah dan mengenali karakteristik visual yang mengindikasikan adanya gangguan kulit tertentu. Teknologi ini memungkinkan proses deteksi dilakukan secara otomatis melalui citra, sehingga dapat membantu masyarakat maupun tenaga medis dalam mengidentifikasi jenis penyakit kulit dan memberikan penanganan yang sesuai.

Beberapa penelitian sebelumnya telah menerapkan *Convolutional Neural Network* (CNN) dalam klasifikasi penyakit kulit. [12] menggunakan berbagai arsitektur CNN untuk mendeteksi penyakit kulit umum seperti kurap dan scabies, namun penelitian ini tidak secara spesifik menargetkan kulit wajah. [13] menggunakan arsitektur CNN untuk klasifikasi kulit wajah, namun nilai akurasi yang didapatkan masih dibawah 80%. Oleh karena itu, penelitian ini difokuskan untuk mengembangkan model CNN yang diarahkan secara khusus pada deteksi dini berbagai jenis penyakit kulit wajah, dengan pendekatan yang diharapkan lebih efektif dalam mengolah dan mengenali pola pada citra kulit wajah.

2. METODE PENELITIAN

2.1 Data Collection

Tahapan ini merupakan langkah awal dalam pengumpulan data berupa gambar wajah. Dataset diambil pada website penyedia dataset *public* yaitu kaggle serta pengambilan data pada RZ Dermatology & Aesthetic Clinic. Dataset terdiri dari 380 gambar dan terdiri atas 5 (Lima) kelas antara lain: Flek Hitam, Herpes, Jerawat, Kutil, dan Tahi Lalat.

2.2 Preprocessing

Data yang telah terkumpul kemudian melalui tahap *preprocessing* untuk meningkatkan kualitas input yang akan diberikan ke model. Pada proses *preprocessing*, seluruh citra terlebih dahulu dinormalisasi dengan mengubah skala piksel menjadi 0-1 untuk mempercepat proses pelatihan dan meningkatkan stabilitas model. Ukuran citra di resize menjadi 224×224 piksel agar sesuai dengan kebutuhan arsitektur model. Selain itu, dilakukan augmentasi berupa pembalikan citra secara horizontal (*horizontal flip*) guna memperkaya variasi data.

2.3 Split Data

Dataset yang telah diproses dibagi menjadi dua subset yaitu data train (latih) dan data test (uji). Data train digunakan untuk melatih model CNN, sedangkan data test digunakan untuk mengevaluasi performa model. Proporsi umum pembagian data adalah 80% untuk pelatihan dan 20% untuk pengujian.

2.4 Training Model dengan CNN

Pada tahap ini, data train digunakan untuk melatih model CNN. Struktur CNN terdiri dari tahap ekstraksi fitur, yang mencakup *convolutional layer* yang biasanya diikuti oleh *pooling layer* dan fungsi aktivasi *softmax*. Lapisan konvolusional berfungsi mengekstraksi fitur dari citra, sedangkan *pooling layer* berfungsi untuk mengurangi dimensi dan waktu komputasi. [14]. Fitur yang telah diekstraksi kemudian dimasukkan ke dalam fungsi aktivasi *softmax* untuk menjalani proses klasifikasi [15]. Parameter model seperti jumlah *epoch*, *batch size*, *learning rate*, dan jenis *optimizer* ditetapkan untuk mendukung proses pembelajaran model secara optimal, yakni dengan menggunakan 20 *epoch*, *batch size* sebesar 32, *optimizer* Adam, dan *learning rate* sebesar 0.001. Model CNN dibangun menggunakan Keras dengan backend TensorFlow di lingkungan pengembangan Google Colab berbasis Python. Struktur model pada penelitian ini dapat dilihat pada Gambar 1.

<i>Layer (type)</i>	<i>Output Shape</i>	<i>Parameter</i>
<i>conv2d (Conv2D)</i>	<i>(None, 224, 224, 64)</i>	832
<i>max_pooling2d (MaxPooling2D)</i>	<i>(None, 112, 112, 64)</i>	0
<i>conv2d_1 (Conv2D)</i>	<i>(None, 112, 112, 32)</i>	8,224
<i>max_pooling2d_1 (MaxPooling2D)</i>	<i>(None, 56, 56, 32)</i>	0
<i>flatten (Flatten)</i>	<i>(None, 100352)</i>	0
<i>dense (Dense)</i>	<i>(None, 256)</i>	25,690,368
<i>dropout (Dropout)</i>	<i>(None, 256)</i>	0
<i>dense_1 (Dense)</i>	<i>(None, 5)</i>	1,285

Gambar 1. Struktur Model CNN

Berdasarkan Gambar 1. arsitektur CNN yang digunakan terdiri dari dua lapisan konvolusional. Lapisan pertama menggunakan 64 filter dengan ukuran kernel 2×2, padding 'same', dan fungsi aktivasi ReLU, dilanjutkan dengan *max pooling* berukuran 2×2. Lapisan kedua memiliki 32 filter dengan kernel 2×2, padding 'same', dan juga diikuti oleh *max pooling* serupa. Setelah ekstraksi fitur, hasilnya diratakan menggunakan *flatten layer* dan dilanjutkan ke lapisan *dense* dengan 256 unit neuron dan fungsi aktivasi ReLU. Untuk mencegah overfitting, diterapkan teknik *dropout* dengan rasio 0.2 sebelum masuk ke lapisan output. Lapisan output terdiri dari 5 neuron dan menggunakan fungsi aktivasi *softmax* untuk melakukan klasifikasi multi-kelas.

2.5 Evaluasi Model

Evaluasi model dalam penelitian ini menggunakan *Confusion Matrix*. *Confusion Matrix* bertujuan untuk menggambarkan performa model atau algoritma secara spesifik. [16]. *Confusion matrix* dapat dilihat pada table 1.

Tabel 1. Metode Pengujian Sistem

	<i>Predicted Negative</i>	<i>Predicted Positive</i>
Actual Negative	<i>True Negative (TN)</i>	<i>False Positive (FP)</i>
Actual Positive	<i>False Negative (FN)</i>	<i>True Positive (TP)</i>

Berdasarkan tabel 1. dapat diperoleh data data lain untuk mengukur performa sebuah model, yaitu [17].

- a) *Accuracy*, mengukur seberapa sering model memberikan hasil klasifikasi yang benar secara keseluruhan. Rumus untuk menghitung accuracy dapat dituliskan dalam bentuk persamaan (1).

$$\frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

- b) *Precision*, mengukur seberapa sering prediksi positif yang dilakukan model benar. Rumus untuk menghitung precision dapat dituliskan dalam bentuk persamaan (2).

$$\frac{TP}{FP+TP} \quad (2)$$

- c) *Recall (Sensitivity)*, mengukur seberapa sering model memprediksi positif ketika kondisi sebenarnya memang positif. Rumus untuk menghitung recall dapat dituliskan dalam persamaan (3).

$$\frac{TP}{FN+TP} \quad (3)$$

- d) *F1-Score*, Mengukur seberapa sering model menghasilkan klasifikasi yang benar secara menyeluruh. Rumus untuk menghitung accuracy dapat dituliskan dalam persamaan (4).

$$2 * \frac{\text{precision} * \text{recall}}{\text{precision} + \text{recall}} \quad (4)$$

3. HASIL DAN ANALISIS


Hasil pelatihan pada saat 5 epoch terakhir dapat dilihat hasilnya pada Tabel 2, tampilan 5 terakhir dari hasil pelatihan model.

Tabel 2. Hasil Penelitian Model


<i>Epoch</i>	<i>Akurasi Training</i>	<i>Loss Training</i>	<i>Akurasi Validasi</i>	<i>Los Validasi</i>
1	0.9729	0.1392	0.8533	0.6012
2	0.9342	0.1559	0.7467	0.7991
3	0.9797	0.1212	0.8000	0.6549
4	0.9887	0.0941	0.8267	0.7315
5	0.9799	0.0807	0.8133	0.8546

Berdasarkan tabel 2. hasil pelatihan selama 5 epoch, model menunjukkan akurasi training yang tinggi dan meningkat secara konsisten, mencapai 97.99% pada epoch ke-5. Nilai *loss* training juga mengalami penurunan stabil, dari 0.1392 menjadi 0.0807, yang menunjukkan bahwa model berhasil mempelajari pola pada data latih dengan baik. Namun, performa pada data validasi terlihat fluktuatif. Akurasi validasi sempat menurun pada epoch ke-2 (74.67%) dan kembali meningkat hingga 81.33% di akhir epoch. Sementara itu, *loss* validasi tidak menunjukkan tren penurunan yang konsisten dan bahkan meningkat pada epoch ke-5 (0.8546), yang mengindikasikan adanya potensi *overfitting*, di mana model terlalu menyesuaikan diri terhadap data pelatihan dan kurang optimal dalam melakukan generalisasi terhadap data validasi. Grafik perubahan akurasi dan loss selama proses pelatihan dan validasi dapat dilihat pada Gambar 2 dan Gambar 3.

Gambar 2 memperlihatkan perkembangan akurasi model selama proses pelatihan (*training*) dan validasi (*validation*) dalam 20 epoch. Kurva akurasi pelatihan, yang ditampilkan dalam warna biru, menunjukkan peningkatan yang konsisten dari awal hingga akhir proses pelatihan, dimulai dari sekitar 0.2 pada epoch pertama hingga mendekati 1.0 pada epoch terakhir. Hal ini mengindikasikan bahwa model secara bertahap mempelajari pola-pola yang terdapat dalam data pelatihan. Sementara itu, kurva akurasi validasi, yang ditampilkan dalam warna oranye, menunjukkan peningkatan signifikan pada beberapa epoch awal, mulai dari sekitar 0.2 hingga mencapai sekitar 0.7 pada epoch kelima. Namun setelahnya, kurva validasi menunjukkan fluktuasi dan tidak mengalami peningkatan yang sebanding dengan akurasi pelatihan. Pola ini merupakan indikasi awal *overfitting*, yaitu kondisi di mana model terlalu menyesuaikan diri dengan data pelatihan, namun kurang mampu melakukan generalisasi terhadap data yang tidak pernah dilihat sebelumnya (data validasi).



Gambar 2. Hasil Akurasi Pelatihan



Gambar 3. Hasil Loss Pelatihan

Gambar 3 menampilkan perubahan nilai *loss* selama proses pelatihan dan validasi dalam 20 epoch menggunakan metrik *cross-entropy*. Kurva *loss* pelatihan (garis biru) menunjukkan tren penurunan yang konsisten, dari sekitar 0.9 hingga mendekati 0.1 pada akhir pelatihan. Sebaliknya, kurva *loss* validasi (garis oranye) menunjukkan penurunan pada awal pelatihan namun kemudian mengalami fluktuasi dan bahkan cenderung meningkat di epoch-epoch akhir. Perbedaan yang cukup mencolok antara *loss* pelatihan dan validasi memperkuat indikasi bahwa model mengalami *overfitting*.

Permasalahan *overfitting* ini dapat diatasi dengan beberapa strategi yang dapat dipertimbangkan dalam pengembangan model pada penelitian selanjutnya. Di antaranya adalah penerapan teknik regularisasi (seperti *L2 regularization*), penambahan rasio *dropout*, augmentasi data secara lebih variatif, atau penggunaan metode *early stopping* untuk menghentikan pelatihan saat performa validasi mulai menurun. Selain itu, penyesuaian arsitektur model atau pengurangan kompleksitas jaringan juga dapat menjadi solusi untuk meningkatkan kemampuan generalisasi model. Untuk pengujian model secara actual menggunakan gambar atau citra langsung dapat dilihat pada gambar 4.


Berdasarkan Gambar 4. hasil pengujian model untuk klasifikasi penyakit kulit pada wajah berbasis citra, menunjukkan hasil prediksi model yang digunakan untuk mendeteksi jenis penyakit kulit berdasarkan citra yang diberikan. Dalam kasus ini, model berhasil mengidentifikasi penyakit sebagai "kutil" dengan tingkat

keyakinan sebesar 100%. Tingkat keyakinan ini menunjukkan bahwa model sangat percaya pada hasil prediksinya.



Gambar 4. Testing Actual Model

Berdasarkan Gambar 4, ditampilkan hasil pengujian model dalam mengklasifikasikan jenis penyakit kulit berbasis citra. Pada contoh ini, model berhasil mengidentifikasi citra input sebagai penyakit "kutil" sesuai dengan label yang benar. Hasil ini menunjukkan bahwa model mampu mengenali karakteristik visual dari citra uji secara tepat. Namun, keberhasilan pada satu sampel uji belum cukup untuk menyimpulkan performa model secara keseluruhan. Untuk itu, dilakukan analisis menggunakan *confusion matrix* yang menggambarkan jumlah prediksi benar dan salah pada masing-masing kelas. *Confusion matrix* tersebut dapat dilihat pada Gambar 5.



Gambar 5. Confusion Matrix

Berdasarkan Gambar 5, confusion matrix menunjukkan performa model dalam mengklasifikasikan lima jenis penyakit kulit wajah. Model berhasil mengklasifikasikan seluruh citra untuk kelas *kutil* dan *tahi lalat* dengan benar, masing-masing sebanyak 10 citra. Kelas *jerawat* juga menunjukkan hasil yang baik dengan 9 prediksi benar dari 10, dan hanya satu kesalahan prediksi ke kelas *herpes*. Sebaliknya, kesalahan klasifikasi cukup terlihat pada kelas *flek hitam*, di mana hanya 4 dari 10 citra berhasil diklasifikasikan dengan benar, sedangkan 5 citra justru salah diklasifikasikan sebagai *kutil*. Untuk kelas *herpes*, terdapat 3 kesalahan prediksi ke *jerawat* dan 2 ke *kutil*. Hasil ini menunjukkan bahwa meskipun model menunjukkan akurasi tinggi pada beberapa kelas, namun terdapat kebingungan antara beberapa kelas tertentu yang dapat memengaruhi performa keseluruhan model. Evaluasi kinerja model klasifikasi dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score berdasarkan confusion matrix lima kelas: flek hitam, herpes, jerawat, kutil, dan tahi lalat. Hasil evaluasi menunjukkan bahwa rata-rata akurasi sebesar 90,58%, presisi 82,28%, recall 76%, dan F1-score 74,82%.

4. KESIMPULAN

Hasil penelitian ini menunjukkan bahwa model Convolutional Neural Network (CNN) yang dirancang mampu mengklasifikasikan penyakit kulit wajah berbasis citra dengan performa yang cukup baik. Berdasarkan evaluasi menggunakan confusion matrix lima kelas, model mencapai rata-rata akurasi sebesar 90,58%, presisi 82,28%, recall 76%, dan F1-score 74,82%. Model menunjukkan kemampuan klasifikasi yang tinggi pada beberapa kelas tertentu seperti kutil dan tahi lalat, meskipun pada beberapa kelas lainnya seperti flek hitam dan herpes masih ditemukan kesalahan prediksi. Namun demikian, hasil grafik akurasi dan loss selama pelatihan menunjukkan adanya indikasi overfitting, di mana akurasi pelatihan meningkat secara signifikan sementara akurasi validasi mengalami fluktuasi dan tidak mengikuti tren yang sama. Hal ini menunjukkan bahwa meskipun model efektif dalam mengenali pola dari data pelatihan, kemampuannya dalam menangani data baru masih perlu ditingkatkan.

Keterbatasan utama dalam penelitian ini terletak pada jumlah data yang terbatas dan daya generalisasi model yang belum optimal. Kurangnya keragaman dalam data latih berpotensi menyebabkan bias dan berdampak pada akurasi saat diterapkan pada kondisi nyata. Untuk penelitian selanjutnya, disarankan untuk menggunakan dataset yang lebih besar dan lebih bervariasi guna meningkatkan kemampuan generalisasi model. Selain itu, gunakan arsitektur CNN yang lebih kompleks seperti ResNet, VGG16, atau EfficientNet,

REFERENSI

- [1] A. Maya, K. Putri, and A. F. Rozi, "Implementasi Convolutional Neural Network Dalam Menentukan Tingkat Kematangan Mentimun dan Tomat Berdasarkan Warna Kulit," *JATI (Jurnal Mhs. Tek. Inform.,* vol. 8, no. 5, pp. 10388–10394, 2024.
- [2] Y. J. Krisnawan and W. Setiawan, "Implementasi Convolutional Neural Network (CNN) untuk Deteksi Katarak pada Citra Mata," *J. Ekon. Manaj. Sist. Inf.,* vol. 6, no. 1, pp. 443–450, 2024.
- [3] R. Triginandri and E. R. Subhiyakto, "Deteksi Dini Cacar Monyet menggunakan Convolutional Neural Network (CNN) dalam Aplikasi Mobile," *Edumatic J. Pendidik. Inform.,* vol. 8, no. 2, pp. 516–525, 2024, doi: 10.29408/edumatic.v8i2.27625.
- [4] I. W. Prastika *et al.*, "Deteksi Penyakit Kulit Wajah Menggunakan Tensorflow Dengan Metode Convolutional Neural Network," *MISI (Jurnal Manaj. Inform. Sist. Informasi),* vol. 4, no. 2, pp. 84–91, 2021.
- [5] Nurkhasanah and Murinto, "Klasifikasi Penyakit Kulit Wajah Menggunakan Metode Convolutional Neural Network," *SAINTEKS,* vol. 18, no. 2, pp. 183–190, 2021.
- [6] I. Purwati, A. Bayu, D. Nandiyanto, and T. Kurniawan, "Jurnal Pengabdian Isola Education About the Importance of Maintaining and Care for Health of Facial Skin in Generation Z Community Through Digital Based Media," *J. Pengabd. Isola,* vol. 1, no. 229, pp. 1–8, 2022.
- [7] Z. Mustafidah and A. Utami, "Sistem Pakar Identifikasi Masalah Kulit Wajah Menggunakan Metode Case Based Reasoning," *J. Komtika (Komputasi dan Inform.,* vol. 8, no. 2, pp. 190–199, 2024.
- [8] WHO, "Skin Diseases and Public Health," *World Health Organization,* 2021. .

- [9] M. Sander, M. S. Dmd, T. Burbidge, and J. Beecker, "The Efficacy and Safety of Sunscreen Use For the Prevention of Skin Cancer," *C. Med. Assoc. J.*, vol. 192, no. 50, pp. 1802–1808, 2020, doi: 10.1503/cmaj.201085.
- [10] S. S. Thiansin, P. Hasan, and A. F. Maulana, "Sistem Pakar Diagnosa Penyakit Kulit Manusia Menggunakan Metode Backward Chaining Berbasis Website," *J. Tek. Inform. dan Sist. Inf.*, vol. 11, no. 4, pp. 449–462, 2024.
- [11] N. I. Khani and S. Rakasiwi, "Penerapan Convolutional Neural Network dengan ResNet-50 untuk Klasifikasi Penyakit Kulit Wajah Efektif," *Edumatic J. Pendidik. Inform.*, vol. 9, no. 1, pp. 217–225, 2025, doi: 10.29408/edumatic.v9i1.29572.
- [12] A. N. A. Thohari, L. Triyono, I. Hestningsih, B. Suyanto, and A. Yobioktobera, "Performance Evaluation of Pre-Trained Convolutional Neural Network Model for Skin Disease Classification," *JUITA J. Inform.*, vol. 10, no. 1, pp. 9–18, 2022.
- [13] K. V. Prakusa, S. S. P. R, and T. D. Putra, "STUDI ANALITIS KLASIFIKASI PENYAKIT KULIT WAJAH MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN)," in *SEMINAR NASIONAL AMIKOM SURAKARTA (SEMNAS)*, 2024, no. ovember, pp. 191–200.
- [14] M. Akbar, S. Nurmaini, and R. U. Partan, "The deep convolutional networks for the classification of multi-class arrhythmia," *Bull. Electr. Eng. Informatics*, vol. 13, no. 2, pp. 1325–1333, 2024, doi: 10.11591/eei.v13i2.6102.
- [15] A. R. Pratama and A. F. Cobantoro, "Klasifikasi Citra Pneumonia Menggunakan Arsitektur Concolutional Neural Network (CNN)," *J. Ilm. NERO*, vol. 8, no. 2, pp. 133–144, 2023.
- [16] N. Fadhilah and A. Desiani, "Klasifikasi Nyeri Punggung Bawah Menggunakan Algoritma K-Nearest Neighbor Dan Support Vector Machine," *J. Tek. Elektro dan Komputasi Vol.*, vol. 7, no. 1, pp. 91–98, 2025.
- [17] A. Fahrizal, D. Rusirawan, and L. Lidyawati, "Pemodelan Produksi Energi Pembangkit Listrik Tenaga Surya 1000 WP dengan Algoritma Naive Bayes," *J. Tekno Insentif*, vol. 16, no. 2, pp. 105–118, 2022.