



SNESTIK

Seminar Nasional Teknik Elektro, Sistem Informasi,
dan Teknik Informatika

<https://ejurnal.itats.ac.id/snestik> dan <https://snestik.itats.ac.id>



Informasi Pelaksanaan :

SNESTIK V - Surabaya, 26 April 2025

Fakultas Teknik Elektro dan Teknologi Informasi, Institut Teknologi Adhi Tama Surabaya

Informasi Artikel:

DOI : 10.31284/p.snestik.2025.7647

Prosiding ISSN 2775-5126

Fakultas Teknik Elektro dan Teknologi Informasi-Institut Teknologi Adhi Tama Surabaya
Gedung A-ITATS, Jl. Arief Rachman Hakim 100 Surabaya 60117 Telp. (031) 5945043
Email : snestik@itats.ac.id

Penerapan *Transfer Learning* pada Arsitektur DenseNet121 dan ResNet50 untuk Deteksi Penyakit Kulit Berbasis Citra dengan *Explainable AI*

Dionisius Indra Raditya, Isnandar Slamet, dan Yuliana Susanti

Universitas Sebelas Maret

e-mail: indradionisius2710@student.uns.ac.id

ABSTRACT

Skin diseases are common health issues in Indonesia, influenced by its tropical climate and low public awareness of hygiene. Manual diagnosis is often subjective and requires medical expertise, making an accurate automated system necessary. Convolutional Neural Network (CNN) is chosen for its strong capability in visual pattern recognition and proven effectiveness in medical image classification. This study aims to develop a skin disease classification system using transfer learning with CNN architectures—DenseNet121 and ResNet50—and to evaluate their performance and interpretability. A total of 2,344 images from 11 skin disease classes were collected from two public datasets, followed by preprocessing and model training with data augmentation. Results show that DenseNet121 outperformed ResNet50 with 95% accuracy and 96% macro F1-score, compared to 91% accuracy and 94% F1-score. Confusion matrix evaluation and Grad-CAM visualization revealed that DenseNet121 more consistently focused on key lesion areas, particularly in visually similar classes. These findings suggest that the model is not only accurate but also interpretable, making it suitable for implementation as a computer-aided diagnosis system for skin diseases.

Keywords: CNN, Transfer Learning, DenseNet121, ResNet50, Grad-CAM

ABSTRAK

Penyakit kulit merupakan masalah kesehatan yang umum di Indonesia, dipengaruhi oleh iklim tropis dan rendahnya kesadaran kebersihan. Diagnosis secara manual bersifat subjektif dan membutuhkan keahlian medis, sehingga diperlukan sistem otomatis yang akurat. *Convolutional Neural Network (CNN)* dipilih karena kemampuannya dalam mengenali pola visual dan efektivitasnya dalam klasifikasi citra medis. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi penyakit kulit menggunakan *transfer*

learning dengan arsitektur CNN, yaitu DenseNet121 dan ResNet50, serta mengevaluasi performa dan interpretabilitas model. Sebanyak 2.344 citra dari 11 kelas penyakit kulit diambil dari dua dataset publik, kemudian diproses melalui augmentasi dan pelatihan model. Hasil menunjukkan bahwa DenseNet121 unggul dengan akurasi 95% dan *macro* F1-score 96%, sedangkan ResNet50 memperoleh akurasi 91% dan F1-score 94%. Evaluasi *confusion matrix* dan visualisasi Grad-CAM menunjukkan bahwa DenseNet121 lebih konsisten dalam mengenali area lesi utama, terutama pada kelas dengan kemiripan visual tinggi. Hasil ini menunjukkan bahwa model tidak hanya akurat, tetapi juga interpretatif, sehingga layak digunakan sebagai sistem pendukung diagnosis penyakit kulit berbasis citra.

Kata kunci: CNN, Transfer Learning, DenseNet121, ResNet50, Grad-CAM

PENDAHULUAN

Indonesia sebagai negara beriklim tropis memiliki kelembapan tinggi dan kondisi sosial ekonomi yang beragam, yang turut berkontribusi pada tingginya angka kasus penyakit kulit. Faktor lingkungan seperti lahan basah dan suhu lembap menjadi pemicu utama, ditambah rendahnya kesadaran akan kebersihan diri dan praktik [1]. Menurut WHO, penyakit kulit infeksi menyumbang sekitar 300 juta kasus per tahun di seluruh dunia. Di Indonesia, prevalensinya berkisar antara 4,60% hingga 12,95%, menjadikan penyakit kulit sebagai salah satu penyakit terbanyak di layanan kesehatan nasional [2].

Proses diagnosis penyakit kulit umumnya bersifat visual dan sangat bergantung pada keahlian tenaga medis. Metode ini tidak hanya memakan waktu, tetapi juga rentan terhadap subjektivitas dan kesalahan, terutama di daerah dengan keterbatasan sumber daya. Oleh karena itu, penerapan teknologi kecerdasan buatan, khususnya *computer vision* dengan pendekatan *deep learning*, menjadi solusi potensial. Salah satu metode yang banyak digunakan adalah *Convolutional Neural Network* (CNN), yang terbukti efektif dalam klasifikasi citra medis [3] dan telah banyak diterapkan pada deteksi penyakit kulit berbasis gambar klinis secara otomatis [4].


Keberhasilan CNN sangat bergantung pada ketersediaan data pelatihan yang besar. Untuk mengatasi keterbatasan ini, pendekatan *transfer learning* digunakan, di mana model pra-trlatih seperti ImageNet dapat dimanfaatkan kembali pada dataset khusus dengan jumlah data terbatas. Lebih lanjut, untuk meningkatkan transparansi sistem, *Explainable AI* (XAI) seperti Grad-CAM digunakan untuk memberikan interpretasi visual terhadap hasil prediksi, yang dapat membantu tenaga medis memahami alasan di balik keputusan model.

Beberapa penelitian sebelumnya telah menunjukkan keberhasilan CNN dalam mendeteksi penyakit kulit, seperti studi oleh Nurkhasanah dan Murinto [5] yang menggunakan arsitektur VGG16 untuk klasifikasi penyakit kulit wajah. Penelitian lainnya oleh Mohan et al. [6] menggabungkan CNN dan *Vision Transformer* dengan pendekatan XAI. Meskipun demikian, penerapan metode interpretatif seperti Grad-CAM (*Gradient-weighted Class Activation Mapping*) dalam konteks penyakit kulit di Indonesia masih belum banyak dijelajahi.

Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi penyakit kulit berbasis CNN dengan dukungan transfer learning dan Grad-CAM sebagai metode interpretasi visual. Kebaruan dari penelitian ini terletak pada integrasi arsitektur CNN modern dengan Grad-CAM untuk menginterpretasikan klasifikasi citra penyakit kulit. Diharapkan hasil penelitian ini dapat berkontribusi dalam meningkatkan akurasi diagnosis serta mendukung transparansi dan kepercayaan dalam pengambilan keputusan medis.

METODE

Metode dalam penelitian ini disusun untuk menggambarkan alur tahapan yang dilakukan dalam proses klasifikasi penyakit kulit menggunakan model CNN berbasis *transfer learning* dan XAI. Gambar 1 menunjukkan *flowchart* tahapan metode yang digunakan dalam penelitian ini.



Gambar 1. Tahapan Penelitian


Penjelasan mengenai tahapan penelitian pada Gambar 1 adalah sebagai berikut:

1. *Pengumpulan Data*
Data diperoleh dari dua dataset publik di Kaggle. Total data yang diperoleh sebanyak 2.344 gambar yang mencakup 11 kategori penyakit kulit, antara lain *Athlete's Foot*, *Basal Cell Carcinoma*, *Cellulitis*, *Chickenpox*, *Impetigo*, *Keratosis*, *Melanoma*, *Nail Fungus*, *Melanocytic Nevus (NV)*, *Ringworm*, dan *Herpes Zoster*. Pendekatan penggunaan dataset publik semacam ini juga telah diterapkan dalam penelitian oleh Febriyanti [7] dan Pangestu [8].
2. *Data Preprocessing*
Seluruh gambar diubah ukurannya menjadi 224x224 piksel, distandarkan skala warnanya dalam rentang [0, 1], serta dilakukan encoding label ke bentuk numerik. Selain itu, data dibagi menjadi tiga subset, yaitu data latih sebesar 70%, validasi sebesar 15%, dan data uji sebesar 15%. Untuk meningkatkan performa model, diterapkan augmentasi data pada data latih, seperti rotasi, *flipping*, dan *zooming*.
3. *Penerapan Model Transfer Learning*
Penelitian ini menggunakan dua arsitektur model *pre-trained* CNN, yaitu ResNet50 dan DenseNet121. Kedua model dimodifikasi pada bagian FCL (*Fully Connected Layer*) agar dapat disesuaikan dengan tugas klasifikasi 11 kelas penyakit kulit. FCL terdiri dari *Global Average Pooling*, *Dense Layer* dengan aktivasi ReLU, *Batch Normalization*, *Dropout*, dan *Output Layer Softmax*.
4. *Pelatihan Model*
Model dilatih menggunakan fungsi loss *Sparse Categorical Crossentropy* dan optimizer Adam dengan learning rate sebesar 0.001, batch size 32 selama 100 epoch. Untuk mencegah *overfitting*, diterapkan *callback* berupa *EarlyStopping* untuk menghentikan pelatihan lebih awal jika akurasi validasi telah mencapai 94% dan *ModelCheckpoint* untuk menyimpan bobot terbaik selama pelatihan.
5. *Evaluasi dan Validasi Model*
Evaluasi model dilakukan menggunakan data uji dengan metrik evaluasi berupa akurasi, *precision*, *recall*, dan *F1-score*. Visualisasi grafik akurasi dan loss digunakan untuk memantau proses pelatihan, dan confusion matrix digunakan untuk menilai performa per kelas. Evaluasi semacam ini telah digunakan secara luas dalam penelitian klasifikasi berbasis CNN seperti oleh Nurkhasanah dan Murinto [5] dan Siregar et al. [9].
6. *Visualisasi Interpretasi Model dengan Grad-CAM*
Untuk meningkatkan interpretabilitas hasil klasifikasi, digunakan metode Grad-CAM. Grad-CAM menghitung gradien dari output model terhadap peta aktivasi pada lapisan konvolusi akhir, menghasilkan *heatmap* yang menunjukkan bagian citra yang paling memengaruhi prediksi. Interpretasi model menggunakan Grad-CAM telah terbukti

relevan untuk aplikasi medis seperti yang dibahas dalam Khare et al. [10] dan Mohan et al. [6]

HASIL DAN PEMBAHASAN

Kedua arsitektur model CNN dilatih dengan *hyperparameter* yang sama selama 100 *epochs*. Hasil *training* dari kedua model dapat dilihat pada Gambar 2.




Gambar 2. a) Hasil *Training* Model ResNet50, b) Hasil *Training* Model DenseNet121

Hasil pelatihan menunjukkan bahwa ResNet50 mengalami *overfitting*, terlihat dari adanya celah yang cukup besar antara akurasi pelatihan dan validasi, serta *validation loss* yang tidak stabil. Model ini mencapai performa terbaik pada *epoch* ke-29. Sebaliknya, DenseNet121 menunjukkan pelatihan yang lebih stabil, dengan akurasi validasi yang mendekati akurasi pelatihan dan *validation loss* yang cenderung menurun. Titik optimal tercapai pada *epoch* ke-38 untuk akurasi, dan ke-18 untuk *loss*. Secara keseluruhan, DenseNet121 menunjukkan kemampuan generalisasi yang lebih baik dibandingkan ResNet50. Berikut pada tabel 1 merupakan hasil *training* dari kedua model berdasarkan akurasi dan *macro F1-score*.

Tabel 1. Hasil Evaluasi Pelatihan Model Transfer Learning

Model	Akurasi	Macro F1-score
DenseNet121	95%	96%
ResNet50	91%	94%

Evaluasi dilakukan berdasarkan metrik *precision*, *recall* dan *F1-score*. Perhitungan metrik tersebut didasarkan pada *confusion matrix* yang dihasilkan dari pengujian model, sebagaimana ditampilkan pada Gambar 3.




Gambar 3. Confusion Matrix Model ResNet50

Berdasarkan *confusion matrix*, model ResNet50 mampu mengklasifikasikan sebagian besar citra secara akurat. Seluruh citra kelas *Athlete's Foot*, *Cellulitis*, dan *Chickenpox* berhasil dikenali dengan benar. Model juga menunjukkan performa tinggi pada kelas *Melanoma*, dengan 57 dari 66 citra terklasifikasi tepat. Namun, kesalahan klasifikasi masih terjadi, terutama pada kelas dengan karakteristik visual yang mirip. Misalnya, enam citra *Keratosi* diklasifikasikan sebagai BCC, serta empat lainnya keliru sebagai *Melanoma* dan NV. Tiga citra NV salah diklasifikasikan sebagai *Melanoma* dan dua lainnya sebagai *Keratosi*. Meskipun akurasi *Melanoma* cukup tinggi, masih ada kesalahan ke kelas BCC, *Cellulitis*, dan *Keratosi*. Kesalahan ini umumnya terjadi antar kelas dengan tampilan lesi kulit yang serupa. Nilai metrik akurasi, *precision*, dan *F1-score* model ResNet50 ditampilkan pada Tabel 2.

Tabel 2. Metrik *Precision*, *Recall* dan *F1-score* Model ResNet50

Label	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Athlete Foot</i>	1,00	1,00	1,00
<i>BCC</i>	0,85	0,94	0,89
<i>Cellulitis</i>	1,00	1,00	1,00
<i>Chickenpox</i>	0,96	1,00	0,98
<i>Impetigo</i>	1,00	1,00	1,00
<i>Keratosi</i>	0,84	0,79	0,82
<i>Melanoma</i>	0,95	0,86	0,90
<i>NV</i>	0,79	0,86	0,83
<i>Nail Fungus</i>	1,00	1,00	1,00
<i>Ringworm</i>	0,89	1,00	0,94
<i>Shingles</i>	1,00	0,92	0,96

Pengujian menggunakan model DenseNet121 menghasilkan *confusion matrix* yang diperoleh diberikan oleh Gambar 4.



Gambar 4. Confusion Matrix Model DenseNet121

Confusion matrix menunjukkan bahwa model DenseNet121 mampu mengklasifikasikan sebagian besar citra dengan baik. Seluruh citra kelas *Athlete's Foot*, *Chickenpox*, *Cellulitis*, *Impetigo*, *Nail Fungus*, *Ringworm*, dan *Shingles* berhasil diklasifikasikan dengan akurasi tinggi tanpa kesalahan signifikan. Namun, masih terdapat beberapa kesalahan klasifikasi, terutama antara kelas-kelas yang memiliki kemiripan visual. Beberapa citra BCC diklasifikasikan sebagai *Keratosi*, dan sebaliknya, serta satu citra *Keratosi* diprediksi sebagai *Melanoma*. Pada kelas NV, beberapa citra salah diklasifikasikan sebagai *Keratosi* dan satu sebagai *Melanoma*. Kesalahan juga terjadi pada kelas *Melanoma*, dengan satu citra diklasifikasikan sebagai BCC dan satu lainnya sebagai NV. Nilai *precision*, *recall*, dan *F1-score* disajikan pada Tabel 3.


Tabel 3. Metrik *Precision*, *Recall* dan *F1-score* Model DenseNet121

Label	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Athlete Foot</i>	1,00	1,00	1,00
<i>BCC</i>	0,91	0,91	0,91
<i>Cellulitis</i>	1,00	0,96	0,98
<i>Chickenpox</i>	1,00	1,00	1,00
<i>Impetigo</i>	1,00	1,00	1,00
<i>Keratosi</i>	0,83	0,92	0,88
<i>Melanoma</i>	0,97	0,97	0,97
<i>NV</i>	0,97	0,81	0,88
<i>Nail Fungus</i>	1,00	1,00	1,00
<i>Ringworm</i>	0,94	1,00	0,97
<i>Shingles</i>	1,00	1,00	1,00

Evaluasi menggunakan metrik *precision* dan *F1-score* menunjukkan bahwa kedua model, ResNet50 dan DenseNet121, memiliki performa klasifikasi yang sangat baik pada sebagian besar kelas penyakit kulit. Keduanya mencatat *precision* sempurna (1.0) pada kelas *Athlete's Foot*, *Chickenpox*, *Impetigo*, *Nail Fungus*, *Ringworm*, dan *Shingles*, menandakan akurasi tinggi dalam mengklasifikasikan citra-citra tersebut. Perbedaan performa muncul pada beberapa kelas lain. ResNet50 lebih unggul pada kelas *Melanoma* dan *Keratosi* dengan jumlah prediksi benar yang lebih tinggi dan kesalahan lebih sedikit, sementara DenseNet121

menunjukkan performa lebih baik pada kelas *Melanocytic Nevi* (NV). Pada metrik *F1-score*, kedua model menunjukkan pola performa yang seimbang. DenseNet121 unggul pada kelas *Cellulitis*, *Chickenpox*, *Impetigo*, *Nail Fungus*, dan *Shingles*, sedangkan ResNet50 menunjukkan keunggulan pada kelas *Keratosis* dan *Melanoma*. Secara keseluruhan, kedua model memiliki kelebihan masing-masing tergantung pada kategori penyakit yang diklasifikasikan.

Sebagai pelengkap evaluasi kuantitatif, interpretasi visual dengan Grad-CAM dilakukan untuk memahami area citra yang menjadi fokus utama model saat membuat prediksi. Grad-CAM menghasilkan *heatmap* yang menyoroti bagian paling berkontribusi dalam klasifikasi, sangat relevan dalam konteks medis karena membantu menjelaskan keputusan model. Hasil visualisasi Grad-CAM untuk kedua model dapat dilihat pada Gambar 5.



Gambar 5. Visualisasi Grad-CAM

Visualisasi menunjukkan bahwa DenseNet121 lebih konsisten dan relevan dalam memusatkan perhatian pada area kritis citra, seperti lesi khas pada kasus *Impetigo*, pola melingkar pada *Ringworm*, dan lesi gelap pada *Keratosis*. Sementara itu, ResNet50 juga menunjukkan fokus yang baik, terutama pada *Impetigo* dan *Ringworm*, namun pada beberapa kasus seperti *Keratosis*, atensinya terlihat lebih menyebar sehingga menyebabkan kesalahan klasifikasi. Secara keseluruhan, Grad-CAM memperkuat hasil evaluasi sebelumnya, di mana DenseNet121 tidak hanya unggul dalam metrik kuantitatif, tetapi juga lebih akurat dalam mengidentifikasi area penting pada citra. Interpretasi ini menunjukkan bahwa model benar-benar memahami fitur visual yang relevan, menjadikan Grad-CAM alat penting dalam meningkatkan transparansi dan akuntabilitas sistem deteksi berbasis citra.

KESIMPULAN

Penerapan transfer learning dengan arsitektur CNN efektif dalam klasifikasi citra penyakit kulit. Model DenseNet121 menunjukkan performa terbaik dengan akurasi sebesar 95% dan *macro F1-score* 96%, sedangkan ResNet50 memperoleh akurasi 91% dan *macro F1-score* 94%. DenseNet121 juga lebih konsisten dalam mengklasifikasikan kelas-kelas yang memiliki kemiripan visual tinggi, seperti *Keratosis*, *Melanoma*, dan *Melanocytic Nevi*. Hasil ini diperkuat oleh analisis *confusion matrix* dan evaluasi metrik per kelas. Selain itu, visualisasi Grad-CAM menunjukkan bahwa DenseNet121 memiliki fokus perhatian yang lebih relevan terhadap area lesi utama pada citra, dibandingkan ResNet50 yang fokusnya cenderung lebih menyebar. Dengan demikian, DenseNet121 tidak hanya unggul secara kuantitatif, tetapi juga secara interpretatif, sehingga berpotensi kuat untuk diterapkan sebagai sistem pendukung diagnosis penyakit kulit berbasis citra dalam praktik medis.

DAFTAR PUSTAKA

- [1] R. Alfadli and S. Khairunisa, "Prevalensi Penyakit Kulit Infeksi dan Non-infeksi di Poliklinik Kulit dan Kelamin RSUD Jagakarsa Periode Februari 2023 - Januari 2024 Prevalence of Infectious and Non-infectious Skin Diseases in the Dermatology and Venereology Outpatient Department at Jagakarsa Regional Hospital between February 2023 - January 2024," vol. 30, no. 3, pp. 151–156, 2024.
- [2] N. S. Rahayu, A. D. Puteri, and L. M. A. Isnaeni, "Hubungan Perilaku Masyarakat Dan Penggunaan Air Sungai Dengan Gangguan Penyakit Kulit Di Desa Kampung Pinang Wilayah Kerja Puskesmas Pantai Raja," *J. Impliah Ilmu Kesehat.*, vol. 1, no. 3, p. 2023, 2023.
- [3] I. W. Prastika and E. Zuliarso, "Deteksi Penyakit Kulit Wajah Menggunakan Tensorflow Dengan Metode Convolutional Neural Network," *J. Manaj. Inform. dan Sist. Inf.*, vol. 4, no. 2, pp. 84–91, 2021, doi: 10.36595/misi.v4i2.418.
- [4] M. R. Efrian and U. Latifa, "Image Recognition Berbasis Convolutional Neural Network (Cnn) Untuk Mendeteksi Penyakit Kulit Pada Manusia," *Power Elektron. J. Orang Elektro*, vol. 11, no. 2, p. 276, 2022, doi: 10.30591/polektro.v12i1.3874.
- [5] 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, pp. 183–190, 2021, [Online]. Available: <https://www.kaggle.com/datasets>
- [6] J. Mohan, A. Sivasubramanian, V. Sowmya, and R. Vinayakumar, "Enhancing Skin Disease Classification Leveraging Transformer-based Deep Learning Architectures and Explainable AI," pp. 1–17, 2024, [Online]. Available: <http://arxiv.org/abs/2407.14757>
- [7] F. A. Febriyanti, "Image Processing Dengan Metode Convolutional Neural Network (Cnn) Untuk Deteksi Penyakit Kulit Pada Manusia," *Kohesi J. Sains Dan Teknol.*, vol. 3, no. 10, pp. 21–30, 2024, [Online]. Available: <https://ejournal.warunayama.org/kohesi>
- [8] Handoko Adji Pangestu and Kusri, "Peningkatan kinerja arsitektur ResNet50 untuk Menangani Masalah Overfitting dalam Klasifikasi Penyakit Kulit," *Tematik*, vol. 11, no. 1, pp. 65–71, 2024, doi: 10.38204/tematik.v11i1.1876.
- [9] M. M. Siregar, R. Hizria, and D. Pardede, "Perbandingan Kinerja Kernel SVM dalam Klasifikasi Kategori Kanker Kulit Menggunakan Transfer Learning," vol. 4, no. 1, pp. 83–90, 2024.
- [10] S. K. Khare, V. Blanes-Vidal, E. S. Nadimi, and U. R. Acharya, "Emotion recognition and artificial intelligence: A systematic review (2014–2023) and research recommendations," *Inf. Fusion*, vol. 102, no. August 2023, p. 102019, 2024, doi: 10.1016/j.inffus.2023.102019.