

KLASIFIKASI PENYAKIT KULIT WAJAH MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK EFFICIENTNET-B3

Riko Angga Bayu Kusuma^{1*}, Bambang Irawan², Abdul Khamid³

^{1,2,3}Universitas Muhadi Setiabudi; Brebes; Indonesia; 02836199000

Keywords:

Klasifikasi penyakit kulit wajah, Convolutional Neural Network, EfficientNet-B3, Pengolahan citra, Fine-tuning.

Corespondent Email:

rikokusuma098@gmail.com

Penyakit kulit wajah merupakan masalah kesehatan yang umum terjadi dan memengaruhi kualitas hidup individu secara signifikan. Deteksi dini melalui pengolahan citra menjadi langkah penting untuk penanganan yang tepat waktu. Penelitian ini menerapkan Convolutional Neural Network dengan arsitektur EfficientNet-B3 untuk mengklasifikasikan lima jenis penyakit kulit wajah, yaitu acne, actinic keratosis, basal cell carcinoma, eczema, dan rosacea. Model dikembangkan melalui proses fine-tuning pada dataset citra yang telah diaugmentasi, dengan pembagian data pelatihan dan pengujian. Hasil evaluasi menunjukkan akurasi pengujian mencapai 96,61 persen, disertai nilai precision, recall, dan F1-score rata-rata 0,97. Confusion matrix mengindikasikan performa klasifikasi yang tinggi dengan kesalahan minimal antar kelas. Pendekatan ini terbukti efektif dalam meningkatkan ketepatan deteksi, sehingga berpotensi mendukung tenaga medis dalam diagnosis awal.



Copyright © **JITET** (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

Facial skin diseases are a common health issue that significantly affect an individual's quality of life. Early detection through image processing is a crucial step for timely treatment. This study applies Convolutional Neural Network with EfficientNet-B3 architecture to classify five types of facial skin diseases, namely acne, actinic keratosis, basal cell carcinoma, eczema, and rosacea. The model was developed through fine-tuning on an augmented image dataset, with training and testing data splits. Evaluation results show a testing accuracy of 96.61 percent, accompanied by average precision, recall, and F1-score values of 0.97. The confusion matrix indicates high classification performance with minimal errors between classes. This approach proves effective in improving detection accuracy, thus potentially supporting medical personnel in early diagnosis.

1. PENDAHULUAN

Penyakit kulit merupakan salah satu permasalahan kesehatan yang masih banyak dijumpai di Indonesia, terutama di wilayah beriklim tropis. Faktor lingkungan, tingkat kebersihan, serta kurangnya akses ke layanan kesehatan berdampak pada tingginya kasus penyakit kulit. Data nasional menunjukkan bahwa prevalensi penyakit kulit di Indonesia mencapai sekitar 12,95% dari total populasi, sehingga deteksi dini menjadi langkah penting

dalam upaya penanganan dan pencegahan komplikasi lebih lanjut [1]. Tingginya prevalensi tersebut menunjukkan bahwa penyakit kulit bukan hanya permasalahan estetika, tetapi juga isu kesehatan masyarakat yang memerlukan penanganan serius.

Pada area wajah, penyakit kulit memiliki dampak yang lebih kompleks karena selain menimbulkan keluhan fisik, kondisi ini juga dapat memengaruhi aspek psikologis, kepercayaan diri, dan kualitas hidup

penderitanya. Beberapa penyakit kulit wajah yang umum dijumpai meliputi acne (jerawat), *eczema*, *actinic keratosis*, *basal cell carcinoma*, serta *rosacea*. Tantangan utama dalam diagnosis penyakit-penyakit tersebut terletak pada kemiripan karakteristik visual, terutama pada tahap awal, seperti kesamaan warna, tekstur, dan bentuk lesi, sehingga menyulitkan proses identifikasi jika hanya mengandalkan pengamatan visual secara manual. Dalam praktik klinis, diagnosis penyakit kulit umumnya dilakukan melalui pemeriksaan visual langsung oleh dokter atau dermatolog. Meskipun metode ini merupakan standar medis, tingkat akurasi diagnosis sangat dipengaruhi oleh pengalaman dan subjektivitas tenaga medis. Selain itu, distribusi tenaga dermatolog yang belum merata di berbagai wilayah Indonesia menyebabkan keterbatasan layanan diagnosis dini, khususnya di daerah dengan fasilitas kesehatan terbatas. Kondisi tersebut mendorong perlunya sistem pendukung diagnosis berbasis teknologi yang mampu memberikan hasil lebih objektif dan konsisten [2].

Perkembangan kecerdasan buatan, khususnya dalam bidang *deep learning*, telah membuka peluang besar dalam analisis citra medis. Salah satu metode yang paling banyak digunakan adalah *Convolutional Neural Network* (CNN), yang terbukti efektif dalam mengekstraksi fitur visual secara otomatis dan mendalam dari citra digital. CNN telah banyak diterapkan dalam klasifikasi penyakit kulit dan menunjukkan performa yang lebih baik dibandingkan metode konvensional dalam mengenali pola kompleks pada citra medis [3]. Berbagai arsitektur CNN telah digunakan dalam klasifikasi penyakit kulit. Penelitian oleh Supirman *et al.* menunjukkan bahwa arsitektur VGG16 mampu memberikan performa klasifikasi yang cukup baik, namun memiliki jumlah parameter yang besar sehingga membutuhkan sumber daya komputasi yang tinggi [4]. Penelitian lain oleh Wijaya *et al.* menyatakan bahwa penerapan CNN berbasis sistem cerdas dapat meningkatkan efisiensi diagnosis penyakit kulit, meskipun masih menghadapi kendala dalam membedakan kelas penyakit dengan karakteristik visual yang serupa [2].

Arsitektur ResNet-50 menjadi salah satu pendekatan yang banyak digunakan karena

kemampuannya mengatasi permasalahan *vanishing gradient* melalui mekanisme *residual connection*. Penelitian oleh Khani dan Rakasiwi menunjukkan bahwa penerapan ResNet-50 pada klasifikasi penyakit kulit wajah mampu mencapai tingkat akurasi sebesar 94%, namun masih ditemukan kesulitan dalam membedakan kelas penyakit yang memiliki kemiripan visual tinggi [1]. Temuan serupa juga dilaporkan oleh Pangestu dan Kusrini, yang menyatakan bahwa optimalisasi lebih lanjut masih diperlukan untuk meningkatkan generalisasi model ResNet-50 pada citra penyakit kulit [5].

EfficientNet diperkenalkan sebagai solusi dengan pendekatan penskalaan terintegrasi yang mempertimbangkan kedalaman jaringan, lebar, dan resolusi input secara seimbang. Penelitian menunjukkan bahwa penggunaan teknik seperti *Global Average Pooling* dan *transfer learning* pada CNN mampu mengurangi jumlah parameter serta meningkatkan stabilitas dan performa model, bahkan pada dataset dengan jumlah terbatas [6], [7]. Meskipun berbagai penelitian telah mengkaji klasifikasi penyakit kulit menggunakan CNN, sebagian besar masih berfokus pada penyakit kulit secara umum dan belum secara khusus menargetkan penyakit kulit wajah dengan kelas-kelas yang memiliki kemiripan visual tinggi. Selain itu, pemanfaatan arsitektur EfficientNet-B3 dengan pendekatan fine-tuning untuk klasifikasi penyakit kulit wajah masih relatif terbatas dibandingkan penggunaan arsitektur CNN konvensional seperti ResNet-50.

Berdasarkan celah penelitian tersebut, penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit kulit wajah berbasis CNN menggunakan arsitektur EfficientNet-B3 dengan pendekatan transfer learning dan fine-tuning. Model yang dihasilkan diharapkan mampu memberikan akurasi tinggi dan efisiensi komputasi yang baik, serta berpotensi digunakan sebagai sistem pendukung diagnosis dini penyakit kulit wajah, khususnya pada fasilitas kesehatan dengan keterbatasan sumber daya medis.

2. TINJAUAN PUSTAKA

2.1. *Penyakit Kulit Wajah*

Penyakit kulit wajah merupakan gangguan pada jaringan kulit di area wajah yang ditandai

oleh perubahan warna, tekstur, maupun struktur kulit. Kondisi ini dapat bersifat akut ataupun kronis dan memerlukan penanganan yang tepat untuk mencegah perburukan klinis. Dalam praktik dermatologi, penyakit kulit pada area wajah sering menjadi perhatian karena memiliki variasi manifestasi klinis yang luas serta kemiripan tampilan morfologis antar kondisi kulit, sehingga proses diagnosis memerlukan ketelitian dan pendekatan yang cermat agar tidak terjadi kesalahan identifikasi [8].

2.2. Karakteristik Penyakit Kulit Wajah

Setiap jenis penyakit kulit wajah memiliki karakteristik visual tertentu, seperti kemerahan, pembentukan lesi, sisik, maupun perubahan pigmentasi kulit. Meskipun demikian, pada banyak kasus, karakteristik visual antar penyakit kulit dapat saling tumpang tindih, khususnya pada fase awal perkembangan penyakit. Kondisi tersebut menyebabkan proses identifikasi berbasis pengamatan visual menjadi lebih kompleks dan berpotensi menimbulkan kesalahan diagnosis. Studi dermatologi menunjukkan bahwa kemiripan pola warna, tekstur, dan morfologi lesi merupakan salah satu faktor utama yang menyulitkan pembedaan antar penyakit kulit, sehingga diperlukan kehati-hatian dan pendekatan diagnostik yang lebih sistematis dalam praktik klinis [9].

2.3. Citra Digital

Citra digital merupakan representasi visual dalam bentuk matriks dua dimensi yang tersusun atas elemen-elemen piksel, di mana setiap piksel menyimpan informasi intensitas cahaya atau warna. Pada citra berwarna, informasi visual umumnya direpresentasikan melalui tiga kanal utama, yaitu merah (Red), hijau (Green), dan biru (Blue), yang secara bersama-sama membentuk variasi warna dan detail objek secara lebih kaya. Representasi berbasis kanal RGB memungkinkan citra digital menampilkan karakteristik visual objek secara lebih akurat, sehingga banyak digunakan dalam analisis citra medis, termasuk sebagai data utama dalam proses klasifikasi penyakit kulit wajah [10].

2.4. Pengolahan Citra Digital

Pemrosesan gambar digital merupakan serangkaian proses yang bertujuan untuk

meningkatkan kualitas citra serta mengekstraksi informasi yang relevan dari gambar digital. Secara umum, tahapan dalam pemrosesan gambar meliputi proses akuisisi citra, *preprocessing* untuk memperbaiki kualitas dan keseragaman data, serta tahap analisis atau klasifikasi. Pada tahap *preprocessing*, teknik seperti normalisasi nilai piksel dan penyesuaian ukuran citra berperan penting dalam menyiapkan data agar sesuai dengan kebutuhan model pembelajaran mesin. Beberapa studi menunjukkan bahwa tahapan *preprocessing* yang tepat dapat meningkatkan stabilitas pelatihan dan kinerja sistem klasifikasi berbasis citra secara signifikan [11].

2.5. Deep Learning

Deep learning merupakan cabang dari kecerdasan buatan yang memanfaatkan jaringan saraf tiruan berlapis untuk mempelajari representasi data secara hierarkis dan kompleks. Pendekatan ini sangat efektif dalam pengolahan data visual karena mampu mengekstraksi fitur secara otomatis langsung dari data mentah tanpa bergantung pada proses ekstraksi fitur manual. Dalam konteks analisis citra, deep learning terbukti memberikan kinerja yang lebih stabil dan akurat karena model dapat menyesuaikan representasi fitur secara adaptif terhadap karakteristik data gambar yang beragam [12].

2.6. Convolution Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu arsitektur dalam deep learning yang dirancang khusus untuk pemrosesan dan analisis citra digital. CNN tersusun atas beberapa lapisan utama, yaitu lapisan konvolusi, lapisan pooling, dan lapisan *fully connected*, yang bekerja secara hierarkis untuk mengekstraksi fitur visual dari tingkat sederhana hingga kompleks. Melalui mekanisme tersebut, CNN mampu mengenali pola spasial seperti tepi, tekstur, dan bentuk objek secara efektif. Berbagai penelitian menunjukkan bahwa CNN memiliki kemampuan yang sangat baik dalam mengenali pola visual yang kompleks, sehingga banyak dimanfaatkan dalam klasifikasi citra medis, termasuk pada analisis dan diagnosis berbasis gambar [13].

2.7. Transfer Learning

Transfer learning merupakan pendekatan dalam pembelajaran mesin yang memanfaatkan model yang telah dilatih sebelumnya pada dataset berskala besar untuk diterapkan pada permasalahan baru dengan ketersediaan data yang terbatas. Melalui pendekatan ini, model dapat menggunakan kembali fitur-fitur dasar yang telah dipelajari, seperti pola visual umum, sehingga proses pelatihan menjadi lebih efisien dan konvergensi model dapat dicapai lebih cepat. Dalam konteks analisis citra, khususnya citra medis, transfer learning terbukti mampu meningkatkan akurasi klasifikasi sekaligus mengurangi kebutuhan pelatihan model dari awal, sehingga banyak digunakan dalam pengembangan sistem klasifikasi berbasis deep learning [14].

2.8. Arsitektur EfficientNet-B3

EfficientNet merupakan arsitektur *Convolutional Neural Network* yang dikembangkan untuk mencapai keseimbangan optimal antara tingkat akurasi dan efisiensi komputasi melalui pendekatan *compound scaling*, yaitu penskalaan kedalaman jaringan, lebar, dan resolusi input secara terintegrasi. Salah satu variannya, yaitu EfficientNet-B3, memiliki konfigurasi jaringan yang lebih dalam serta resolusi input yang lebih tinggi dibandingkan varian dasar, sehingga mampu mengekstraksi fitur visual dengan detail yang lebih kaya. Dalam berbagai studi pengenalan citra, EfficientNet-B3 dilaporkan mampu menghasilkan kinerja klasifikasi yang lebih baik dibandingkan arsitektur CNN konvensional, khususnya pada data dengan kompleksitas visual tinggi seperti citra medis [15]. Selain itu, penerapan transfer learning menggunakan EfficientNet-B3 juga menunjukkan performa yang sangat baik pada domain non-medis, sebagaimana ditunjukkan oleh Herlangga *et al.* yang berhasil memperoleh kinerja klasifikasi yang sangat tinggi pada tugas pengenalan citra senjata tradisional. Temuan tersebut mengindikasikan bahwa arsitektur EfficientNet-B3 bersifat adaptif terhadap perbedaan karakteristik visual data dan memiliki potensi untuk digeneralisasikan pada berbagai domain klasifikasi citra, termasuk citra medis [16].

2.9. Augmentasi Data

Augmentasi data merupakan teknik yang digunakan untuk meningkatkan jumlah serta keragaman data pelatihan dengan cara memodifikasi citra asli melalui berbagai transformasi, seperti rotasi, pembalikan, perubahan skala, dan penyesuaian intensitas warna. Penerapan teknik ini bertujuan untuk mengurangi risiko *overfitting* serta meningkatkan kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya. Dalam konteks klasifikasi citra medis, augmentasi data terbukti efektif dalam meningkatkan kinerja model, khususnya ketika jumlah dataset terbatas, karena model dapat belajar dari variasi representasi visual yang lebih beragam [17].

2.10. Fine-Tuning

Penyesuaian halus (*fine-tuning*) merupakan tahap lanjutan dalam transfer learning yang dilakukan dengan melatih ulang sebagian lapisan pada model pralatih menggunakan dataset target. Melalui proses ini, bobot jaringan dapat disesuaikan agar lebih relevan dengan karakteristik data yang digunakan dalam penelitian, sehingga model tidak hanya bergantung pada fitur umum yang dipelajari sebelumnya. Dalam konteks klasifikasi citra medis, fine-tuning memungkinkan model untuk mempelajari fitur visual yang lebih spesifik sesuai dengan domain permasalahan, yang pada akhirnya dapat meningkatkan kinerja dan akurasi klasifikasi secara signifikan [18].

3. METODE PENELITIAN

Penelitian ini menggunakan metode transfer learning, dengan memanfaatkan model EfficientNet-B3 yang telah dilatih sebelumnya sebagai dasar untuk mengembangkan model klasifikasi penyakit kulit wajah. Penelitian ini dimulai dengan pengumpulan dataset gambar penyakit kulit wajah, yang kemudian diproses melalui tahap preprocessing, pelatihan model, dan evaluasi kinerja. Hasil uji coba dievaluasi menggunakan skor evaluasi yang menggambarkan kemampuan model dalam mengklasifikasikan setiap kelas penyakit kulit wajah. Adapun tahapan penelitian yang dilakukan dijelaskan sebagai berikut.

3.1. Dataset Pengujian

Dataset yang digunakan dalam penelitian ini merupakan dataset publik yang diperoleh dari

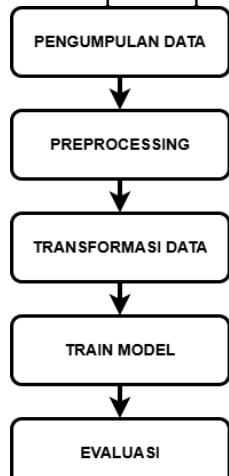
Kaggle, berisi citra penyakit kulit wajah. Dataset terdiri dari lima kelas penyakit, yaitu *acne*, *actinic keratosis*, *basal cell carcinoma*, *eczema*, dan *rosacea*. Seluruh citra telah diberi label sesuai dengan jenis penyakitnya dan memiliki format gambar digital. Total dataset yang digunakan berjumlah 14.950 citra, dengan distribusi data yang relatif seimbang pada setiap kelas. Dataset ini dipilih karena memiliki jumlah data yang memadai dan variasi citra yang cukup untuk melatih model klasifikasi berbasis *deep learning*.

Tabel 3. 1 Jumlah Dataset

No	Kelas Penyakit	Jumlah Citra
1	Acne	2.992
2	Actinic Keratosis	2.987
3	Basal Cell Carcinoma	2.991
4	Eczema	2.986
5	Rosacea	2.994
	Total	14.950

3.2. Rancangan Pengujian

Rancangan pengujian pada penelitian ini disusun dalam bentuk alur proses klasifikasi penyakit kulit wajah menggunakan EfficientNet-B3. Proses dimulai dari pengambilan dataset, dilanjutkan dengan tahap praproses citra, transformasi data, pelatihan model, dan diakhiri dengan evaluasi performa model. Rancangan ini bertujuan untuk memastikan setiap tahapan penelitian berjalan secara sistematis dan dapat direproduksi.



Gambar 3. 1 Alur Rancangan Pengujian

3.2.1. Pengumpulan Data

Tahap pengumpulan data merupakan tahap awal penelitian yang sesuai dengan blok pertama pada diagram alur penelitian, yaitu pengambilan dataset. Dataset dikumpulkan dari platform Kaggle yang menyediakan dataset citra penyakit kulit wajah secara terbuka. Seluruh data diunduh dalam bentuk folder terstruktur berdasarkan kelas penyakit, sehingga memudahkan proses pemuatannya ke dalam sistem pembelajaran mesin. Dataset yang diperoleh tidak mengalami modifikasi label dan digunakan sebagaimana tersedia pada sumber aslinya.

3.2.2. Preprocessing

Tahap preprocessing bertujuan untuk mempersiapkan citra agar sesuai dengan kebutuhan model CNN. Pada tahap ini, seluruh citra diubah ke ukuran 224×224 piksel, menyesuaikan dengan input standar arsitektur EfficientNet. Selain itu, dilakukan normalisasi nilai piksel agar berada pada rentang yang seragam. Proses preprocessing ini penting untuk meningkatkan stabilitas pelatihan model serta mempercepat konvergensi selama proses pembelajaran.

3.2.3. Transformasi Data

Transformasi data dilakukan dengan membagi dataset ke dalam tiga bagian, yaitu data latih (training), data validasi (validation), dan data uji (testing). Pembagian data dilakukan menggunakan rasio 80% untuk data latih dan 20% untuk data validasi dan pengujian, yang selanjutnya dibagi sama rata. Pembagian data ini bertujuan untuk memastikan bahwa model dapat dilatih secara optimal serta dievaluasi secara objektif menggunakan data yang tidak pernah dilihat sebelumnya.

3.2.4. Train Model

Tahap pelatihan model dilakukan menggunakan arsitektur EfficientNet-B3 sebagai model dasar. Model dilatih menggunakan data latih yang telah diproses sebelumnya. Selama proses pelatihan, diterapkan teknik augmentasi data untuk meningkatkan variasi data dan mengurangi risiko *overfitting*. Selain itu, dilakukan fine-tuning pada beberapa lapisan akhir EfficientNet agar model dapat menyesuaikan fitur-fitur yang dipelajari dengan karakteristik citra penyakit

kulit wajah. Proses pelatihan dilakukan hingga model mencapai performa yang stabil berdasarkan nilai akurasi dan *loss*.

3.2.5. Evaluasi

Tahap evaluasi bertujuan untuk mengukur kinerja model klasifikasi yang telah dilatih. Evaluasi dilakukan menggunakan data uji dengan beberapa metrik, yaitu akurasi, precision, recall, dan F1-score. Selain itu, performa model juga dianalisis menggunakan confusion matrix untuk melihat kesalahan klasifikasi pada setiap kelas penyakit. Grafik akurasi dan *loss* selama proses pelatihan juga digunakan untuk mengevaluasi kestabilan dan konvergensi model.

4. HASIL DAN PEMBAHASAN

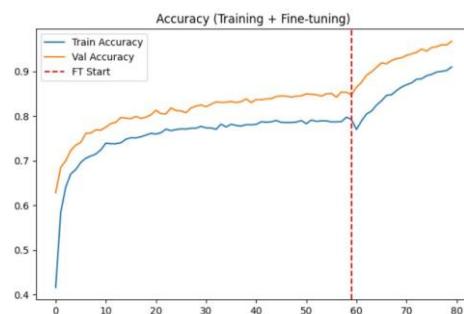
4.1. Hasil Pelatihan Model

Proses pelatihan model dilakukan menggunakan dataset citra penyakit kulit wajah yang telah melalui tahap praproses dan transformasi data. Model dilatih menggunakan pendekatan transfer learning serta fine-tuning pada beberapa lapisan akhir EfficientNet-B3. Selama proses pelatihan, diterapkan augmentasi data untuk meningkatkan variasi citra dan mengurangi risiko overfitting.

Hasil pelatihan ditunjukkan melalui grafik perubahan nilai akurasi dan *loss* pada data latih dan data validasi. Grafik tersebut memperlihatkan bahwa nilai akurasi meningkat seiring bertambahnya epoch, sementara nilai *loss* cenderung menurun hingga mencapai kondisi stabil. Hal ini menunjukkan bahwa model mampu mempelajari pola data dengan baik tanpa indikasi overfitting yang signifikan.

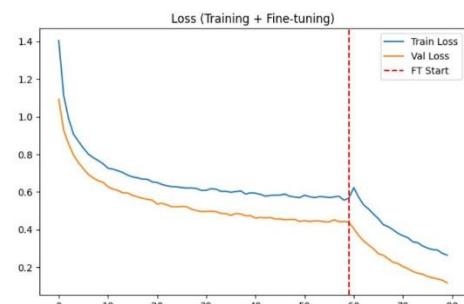
4.1.1. Hasil Pelatihan dan Fine-Tuning

Proses pelatihan dilakukan dalam dua tahap, yaitu pelatihan awal (*feature extraction*) dan fine-tuning. Grafik akurasi dan *loss* menunjukkan bahwa pada tahap awal pelatihan, peningkatan akurasi terjadi secara bertahap hingga mencapai kondisi relatif stabil. Setelah memasuki tahap fine-tuning (ditandai dengan garis vertikal pada epoch ke-60), terjadi peningkatan performa yang signifikan baik pada data pelatihan maupun data validasi.



Gambar 4. 1 Grafik Accuracy

Pada tahap fine-tuning, akurasi validasi meningkat secara konsisten hingga mencapai nilai di atas 0,95. Hal ini menunjukkan bahwa pembaruan bobot pada lapisan akhir jaringan mampu menyesuaikan fitur-fitur pralatih dengan karakteristik spesifik citra penyakit kulit wajah. Tidak ditemukan indikasi *overfitting* yang signifikan, yang ditunjukkan oleh jarak kurva akurasi pelatihan dan validasi yang relatif kecil.



Gambar 4. 2 Grafik Loss

Penurunan nilai *loss* yang konsisten setelah fine-tuning menandakan bahwa model semakin mampu meminimalkan kesalahan prediksi. Nilai *loss* validasi yang lebih rendah dibandingkan *loss* pelatihan mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik terhadap data baru.

4.1.2. Evaluasi Model Pada Data Uji

Evaluasi akhir dilakukan menggunakan data uji sebanyak 14.950 citra. Hasil pengujian menunjukkan bahwa model mencapai tingkat akurasi pengujian sebesar 96,61% dengan nilai *loss* sebesar 0,129. Selain itu, akurasi keseluruhan (*overall accuracy*) yang diperoleh mencapai 97%, yang menunjukkan bahwa model memiliki kemampuan klasifikasi yang sangat baik dan stabil pada data uji.

Hasil ini menunjukkan bahwa model memiliki tingkat ketepatan yang sangat tinggi

dalam mengklasifikasikan penyakit kulit wajah. Nilai akurasi yang tinggi disertai *loss* yang rendah mengindikasikan bahwa model tidak hanya akurat tetapi juga stabil secara numerik.

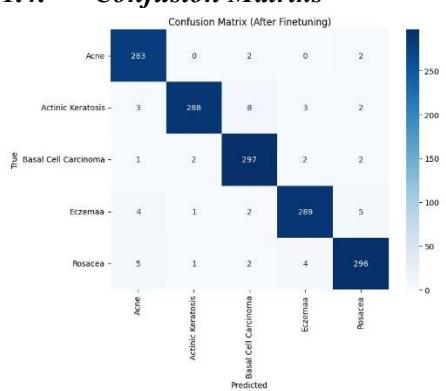
4.1.3. Classification Report

		precision	recall	f1-score	support
	Acne	0.96	0.99	0.97	287
	Actinic Keratosis	0.99	0.95	0.97	304
	Basal Cell Carcinoma	0.95	0.98	0.97	304
	Eczema	0.97	0.96	0.96	301
	Rosacea	0.96	0.96	0.96	308
				accuracy	0.97
				macro avg	0.97
				weighted avg	0.97
					1504

Gambar 4. 3 Classification Report

Evaluasi lebih rinci dilakukan menggunakan metrik precision, recall, dan F1-score untuk setiap kelas penyakit kulit wajah. Berdasarkan hasil classification report, seluruh kelas memperoleh nilai F1-score di atas 0,96, yang menunjukkan performa klasifikasi yang sangat baik. Kelas acne memiliki nilai recall tertinggi sebesar 0,99, yang menandakan kemampuan model dalam mengenali hampir seluruh kasus acne secara tepat. Kelas actinic keratosis dan basal cell carcinoma menunjukkan keseimbangan yang baik antara precision dan recall, mencerminkan kemampuan model dalam meminimalkan kesalahan prediksi positif maupun negatif. Sementara itu, kelas eczema dan rosacea juga memperlihatkan performa yang stabil dengan nilai precision dan recall yang relatif seimbang. Selain itu, nilai macro average dan weighted average yang sama-sama mencapai 0,97 mengindikasikan bahwa model memiliki performa yang konsisten pada seluruh kelas dan tidak menunjukkan kecenderungan bias terhadap kelas tertentu.

4.1.4. Confusion Matriks



Gambar 4. 4 Confusion Matriks

Confusion matrix menunjukkan bahwa sebagian besar prediksi berada pada diagonal utama, yang berarti mayoritas data uji berhasil diklasifikasikan dengan benar. Kesalahan klasifikasi yang terjadi relatif kecil dan umumnya muncul antar kelas dengan kemiripan visual, seperti antara *Acne* dan *Rosacea* atau *Actinic Keratosis* dan *Basal Cell Carcinoma*. Namun, jumlah kesalahan tersebut tidak signifikan dan tidak memengaruhi performa keseluruhan model.

4.2. Pembahasan

Hasil penelitian menunjukkan bahwa penerapan CNN dengan pendekatan transfer learning dan fine-tuning mampu menghasilkan performa klasifikasi penyakit kulit wajah yang sangat baik. Peningkatan performa yang signifikan setelah fine-tuning membuktikan bahwa adaptasi bobot pada lapisan akhir jaringan berperan penting dalam menyesuaikan fitur pralatih dengan karakteristik citra medis yang digunakan.

Nilai akurasi pengujian sebesar 96,61% menunjukkan bahwa model memiliki kemampuan generalisasi yang kuat. Hal ini diperkuat oleh nilai *loss* yang rendah serta kestabilan kurva pelatihan dan validasi. Tidak ditemukannya overfitting menunjukkan bahwa strategi pelatihan yang diterapkan sudah tepat. Jika dibandingkan dengan penelitian rujukan yang menggunakan arsitektur ResNet-50 untuk klasifikasi penyakit kulit wajah dengan akurasi sebesar 94%, hasil penelitian ini menunjukkan peningkatan performa yang cukup signifikan. Peningkatan ini diduga dipengaruhi oleh proses fine-tuning yang lebih optimal serta distribusi data yang relatif seimbang antar kelas.

Selain itu, penggunaan confusion matrix dan classification report memberikan gambaran yang lebih komprehensif dibandingkan hanya menggunakan metrik akurasi. Model tidak hanya mampu mencapai akurasi tinggi, tetapi juga menunjukkan keseimbangan antara precision dan recall pada seluruh kelas, yang sangat penting dalam konteks aplikasi medis. Kesalahan klasifikasi yang minim menunjukkan potensi model untuk digunakan sebagai sistem pendukung keputusan dalam deteksi dini penyakit kulit.

Secara teoretis, hasil ini memperkuat konsep bahwa transfer learning pada CNN mampu meningkatkan efisiensi dan efektivitas

pelatihan model pada dataset citra medis yang terbatas. Dari sisi implementasi, model yang dikembangkan berpotensi diterapkan dalam sistem diagnosis berbasis web atau aplikasi klinis untuk membantu tenaga medis dalam melakukan skrining awal secara cepat dan akurat..

5. KESIMPULAN

- a. Model Convolutional Neural Network dengan arsitektur EfficientNet-B3 yang diterapkan pada penelitian ini mampu mengklasifikasikan lima jenis penyakit kulit wajah, yaitu acne, actinic keratosis, basal cell carcinoma, eczema, dan rosacea, dengan performa yang sangat baik. Hasil pengujian menunjukkan tingkat akurasi pengujian yang tinggi disertai nilai loss yang rendah, yang menandakan bahwa model memiliki kemampuan klasifikasi yang akurat dan stabil
- b. Penerapan pendekatan transfer learning dan fine-tuning memberikan kontribusi signifikan terhadap peningkatan performa model. Hal ini ditunjukkan oleh peningkatan akurasi setelah tahap fine-tuning serta tidak ditemukannya indikasi overfitting selama proses pelatihan, sehingga model mampu melakukan generalisasi dengan baik pada data uji.
- c. Kelebihan dari penelitian ini terletak pada penggunaan arsitektur EfficientNet-B3 yang efisien dalam mengekstraksi fitur citra penyakit kulit wajah serta strategi pelatihan yang mampu menghasilkan performa tinggi meskipun menggunakan dataset terbatas. Selain itu, hasil evaluasi yang komprehensif melalui confusion matrix dan classification report memberikan gambaran performa model yang lebih menyeluruh.
- d. Adapun keterbatasan penelitian ini adalah ketergantungan pada dataset publik yang memiliki variasi kondisi pengambilan citra tertentu, sehingga kemungkinan masih terdapat perbedaan performa jika diterapkan pada citra klinis dengan kondisi pencahayaan dan perangkat yang berbeda. Selain itu, penelitian ini masih terbatas pada klasifikasi citra tanpa mempertimbangkan aspek segmentasi lesi kulit.
- e. Pengembangan selanjutnya dapat dilakukan dengan memperluas variasi dataset, mengintegrasikan metode segmentasi lesi

sebelum proses klasifikasi, serta mengimplementasikan model ke dalam sistem berbasis web atau aplikasi klinis untuk mendukung penggunaan secara langsung oleh tenaga medis.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada pihak-pihak terkait yang telah memberi dukungan terhadap penelitian ini.

DAFTAR PUSTAKA

- [1] N. I. Khani and S. Rakasiwi, "Penerapan Convolutional Neural Network dengan ResNet-50 untuk Klasifikasi Penyakit Kulit Wajah Efektif," *Edumatic: Jurnal Pendidikan Informatika*, vol. 9, no. 1, pp. 217–225, 2025.
- [2] D. A. Wijaya, A. Triayudi, and A. Gunawan, "Penerapan Artificial Intelligence untuk Klasifikasi Penyakit Kulit dengan Metode CNN," *Journal of Computer System and Informatics*, vol. 4, no. 3, pp. 685–692, 2023.
- [3] S. N. Ria, M. Walid, and B. A. Umam, "Pengolahan Citra Digital untuk Identifikasi Penyakit Kulit Menggunakan CNN," *Energy: Jurnal Ilmiah Ilmu Teknik*, vol. 12, no. 2, pp. 9–16, 2022.
- [4] Supirman, C. Lubis, D. Yuliarto, and N. J. Perdana, "Klasifikasi Penyakit Kulit Menggunakan Convolutional Neural Network dengan Arsitektur VGG16," *Simtek: Jurnal Sistem Informasi dan Teknik Komputer*, vol. 8, no. 1, pp. 135–140, 2023.
- [5] Pangestu and Kusrini, "Peningkatan Kinerja Arsitektur ResNet-50 untuk Menangani Overfitting dalam Klasifikasi Penyakit Kulit," *Tematik*, vol. 11, no. 1, pp. 65–71, 2024.
- [6] R. A. Mas'ud and J. Zeniarja, "Optimasi CNN untuk Deteksi Citra Medis Menggunakan Global Average Pooling," *Edumatic: Jurnal Pendidikan Informatika*, vol. 8, no. 1, pp. 310–318, 2024.
- [7] N. B. Pamungkas and A. Suhendar, "Penerapan Transfer Learning pada CNN untuk Klasifikasi Citra," *Edumatic: Jurnal Pendidikan Informatika*, vol. 8, no. 2, pp. 675–684, 2024.
- [8] W. D. James, T. G. Berger, and D. M. Elston, *Andrews' Diseases of the Skin: Clinical Dermatology*. Elsevier, 2016.
- [9] H. Kittler, H. Pehamberger, K. Wolff, and M. Binder, "Diagnostic accuracy of dermoscopy," *Lancet Oncol*, 2002.
- [10] R. C. Gonzalez and R. E. Woods, *Digital Image Processing*. Pearson Education, 2018.

- [11] C. Shorten and T. M. Khoshgoftaar, “A survey on image data augmentation for deep learning,” *J Big Data*, 2019.
- [12] A. S. Lundervold and A. Lundervold, “An overview of deep learning in medical imaging focusing on MRI,” *Z Med Phys*, 2019.
- [13] A. Hosny, C. Parmar, J. Quackenbush, L. H. Schwartz, and H. J. W. L. Aerts, “Artificial intelligence in radiology,” *Nat Rev Cancer*, 2018.
- [14] V. Cheplygina, M. de Bruijne, and J. P. W. Pluim, “Not-so-supervised: a survey of semi-supervised, weakly supervised and transfer learning in medical image analysis,” *Med Image Anal*, 2019.
- [15] M. Tan and Q. V. Le, “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks,” *ICML*, 2019.
- [16] A. Herlangga, R. R. Karim, and M. K. Nurwijaya, “Penerapan Transfer Learning EfficientNetB3 untuk Pengenalan Senjata Tradisional Sumatera Barat Menggunakan CNN,” *JITET*, 2024.
- [17] L. Perez and J. Wang, “The Effectiveness of Data Augmentation in Image Classification using Deep Learning,” *arXiv preprint*, 2017.
- [18] N. Tajbakhsh, J. Y. Shin, and S. R. Gurudu, “Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning?,” *IEEE Trans Med Imaging*, 2016.