

Klasifikasi Jenis Jerawat Berdasarkan Citra Menggunakan Convolutional Neural Network dengan Arsitektur MobileNetV2

Virna Dalira Br Sebayang¹, I Gusti Ngurah Lanang Wijaya Kusuma²

^{1,2}Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Udayana

¹virnadalira051@student.unud.ac.id*, ²lanang_wijaya@unud.ac.id

Abstract

Among teenagers and adults worldwide, acne ranks as one of the most frequent skin concerns where each type of acne requires specific treatments. This study proposes a deep learning method for classifying five types of acne using Convolutional Neural Network (CNN) architecture. The research explores three different dataset splitting scenarios: 70:30, 80:20, and 90:10 to evaluate model performance and generalization. The methodology adopts the MobileNetV2 architecture with transfer learning, comprising layers including MobileNetV2 as the base model, Global Average Pooling, Flatten, Dense Layer, Dropout, and Softmax classification. The total dataset consists of 350 images representing five acne types: Acne Fulminans, Acne Nodules, Papule, Pustule, and Fungal Acne, with 70 samples per class. K-fold cross-validation was employed to assess model robustness across different data splits. Challenges in the research include managing image lighting variations, image quality, and data limitations. Experimental results demonstrate varying model performances across scenarios, with classification accuracies ranging from 60% to 89% in training and 51% to 80% in testing. The third scenario (90:10 split) demonstrated superior performance, particularly in Fold-5, achieving the highest performance rates of 89% for training and 80% for testing. The results demonstrate that the proposed architecture can classify acne types with a reasonably good accuracy level, although there is room for improvement in model generalization. The study highlights the importance of dataset splitting strategies in improving acne classification model performance and suggests potential avenues for future research in medical image classification.

Keywords: Acne Classification, Convolutional Neural Network, MobileNetV2, Transfer Learning, Computer Vision

Abstrak

Jerawat merupakan permasalahan kulit yang kerap dihadapi remaja hingga orang dewasa secara global, di mana setiap jenis acne memerlukan penanganan yang spesifik. Metode yang diusulkan dalam penelitian ini mengklasifikasikan lima jenis jerawat menggunakan Arsitektur Convolutional Neural Network. Penelitian ini mengeksplorasi tiga skenario pembagian dataset berbeda: 70/30, 80/20, 90/10 untuk mengevaluasi kinerja dan generalisasi model. Metodologi mengadopsi arsitektur MobileNetV2 dengan transfer learning, yang terdiri dari lapisan termasuk MobileNetV2 sebagai model dasar, Global Average Pooling, Flatten, Dense Layer, Dropout, dan klasifikasi Softmax. Total dataset terdiri dari 350 gambar yang mewakili lima jenis jerawat: Acne Fulminans, Acne Nodules, Papule, Pustule, dan Fungal Acne, dengan 70 sampel per kelas. K-fold cross-validation digunakan untuk menilai performa model pada berbagai pembagian data. Hasil eksperimen menunjukkan kinerja model yang bervariasi di berbagai skenario, dengan akurasi klasifikasi berkisar dari 60% hingga 89% pada pelatihan dan 51% hingga 80% pada pengujian. Skenario ketiga (pembagian 90/10) menunjukkan performa superior yaitu pada Fold-5, mencapai akurasi pengujian tertinggi sebesar 89% untuk pelatihan dan 80% akurasi pengujian. Tantangan dalam penelitian ini meliputi pengelolaan variasi pencahayaan gambar, kualitas gambar, dan keterbatasan data. Hasil menunjukkan bahwa arsitektur yang diusulkan dapat mengklasifikasikan jenis jerawat dengan tingkat akurasi yang cukup baik, meskipun masih terdapat ruang untuk perbaikan dalam generalisasi model.

Kata kunci: Klasifikasi Jerawat, Convolutional Neural Network, MobileNetV2, Transfer Learning, Computer Vision

©This work is licensed under a Creative Commons Attribution - ShareAlike 4.0 International.

1. Pendahuluan

Berdasarkan data epidemiologi, acne vulgaris terkonfirmasi sebagai salah satu dari delapan kondisi dermatologis dengan prevalensi mencapai 9.38% pada seluruh rentang usia [1]. Jerawat adalah kondisi kulit yang disebabkan oleh produksi sebum berlebih, perubahan hormon, infeksi bakteri dan keratinisasi folikular yang abnormal. Kondisi ini dipengaruhi oleh faktor individu seperti riwayat genetik, jenis kelamin, dan variabel usia, bersamaan dengan faktor lingkungan dan gaya hidup seperti diet, polusi dan stress. Interaksi kompleks antara faktor-faktor ini menjadikan jerawat masalah kesehatan yang memerlukan pemahaman

mendalam untuk pengobatan dan pencegahan yang tepat [2]. Jerawat biasanya mulai muncul pada usia muda dan dapat bertahan selama bertahun-tahun, mempengaruhi area yang terlihat seperti wajah, dada, bahu dan punggung. Berbagai jenis jerawat bisa muncul bersamaan di wajah dan area lain yang rentan [3]. Jerawat tidak hanya berpengaruh pada aspek fisik tetapi juga dapat mengganggu kehidupan sosial individu, harga diri bahkan seringkali disertai dengan gangguan psikologis seperti depresi dan kecemasan [4], [5]. Beberapa studi telah mengidentifikasi pengaruh jerawat dengan peningkatan tingkat kecemasan, depresi, dan penurunan kepercayaan diri yang dapat mempengaruhi kualitas hidup secara

keseluruhan [6][7][8].

Memahami dan menangani setiap jenis jerawat dengan tepat sangat penting untuk menentukan obat dan perawatan yang sesuai [9]. Banyak dari kalangan remaja yang memilih untuk melakukan pengobatan mandiri tanpa konsultasi medis untuk menangani jerawat mereka [7]. Penelitian menekankan bahwa pengobatan jerawat harus disesuaikan dengan jenis jerawat [9]. Klasifikasi jerawat menjadi sangat relevan dalam konteks perawatan dermatologis yang lebih tepat dan efektif.

Dengan kemajuan teknologi, khususnya dalam bidang pembelajaran mesin dan pengolahan citra, metode seperti Convolutional Neural Network (CNN) telah membuktikan diri sebagai model yang sangat efektif dalam tugas pemahaman dan klasifikasi citra. Keunggulan utama CNN adalah kemampuannya untuk mempelajari dan mengekstraksi fitur secara otomatis tanpa memerlukan ekstraksi fitur manual yang kompleks. Hal ini sangat relevan dalam konteks klasifikasi jenis jerawat dimana variasi bentuk, ukuran dan karakteristik visual jerawat membutuhkan sistem yang dapat mengenali pola-pola secara kompleks [10]

Penelitian terdahulu terkait klasifikasi citra menggunakan metode Convolutional Neural Networks (CNN) telah menunjukkan hasil yang menjanjikan dalam berbagai bidang. Penelitian [11] mengenai klasifikasi lubang pada permukaan jalan menggunakan CNN menunjukkan akurasi yang sangat tinggi, mencapai 99% pada konfigurasi optimal. Dalam studi tersebut, CNN digunakan untuk mengekstraksi fitur dari citra lubang dengan memanfaatkan beberapa lapisan konvolusi dan pooling untuk mengatasi variasi citra seperti ukuran, tekstur dan pencahayaan yang berbeda. Penelitian ini juga menyarankan penggunaan metode augmentasi citra untuk meningkatkan akurasi lebih lanjut di masa depan.

Penelitian [12] membahas perbandingan metode klasifikasi penyakit kulit manusia menggunakan CNN dengan arsitektur MobileNet dan kombinasi CNN-SVM. Sebanyak 21.000 citra digunakan dalam penelitian ini yang dikelompokkan dalam tujuh jenis penyakit kulit. Penelitian ini menunjukkan bahwa model CNN mencapai akurasi yang lebih tinggi, yaitu 93.47% dibandingkan dengan CNN-SVM yang memiliki performa yang bervariasi tergantung jenis kernel yang digunakan. Hasil penelitian ini memberikan wawasan penting dalam mengembangkan model diagnosis penyakit kulit berbasis citra medis dan menunjukkan bahwa CNN memiliki potensi besar dalam klasifikasi gambar medis secara akurat.

Penelitian mengenai klasifikasi jerawat juga telah dilakukan pada penelitian [13], namun pada penelitian ini jerawat diklasifikasikan berdasarkan tingkat keparahan jerawat. Penelitian [13] membahas

penggunaan penggunaan Convolutional Neural Network (CNN) untuk mengklasifikasikan tingkat keparahan jerawat. Penelitian ini menggunakan tiga label tingkat keparahan jerawat, yaitu level 0,1 dan 2, dengan dataset berjumlah 1500 gambar. Melalui penggunaan optimasi Adam dan pengujian jumlah epoch, penelitian ini mencapai akurasi 92.34% pada epoch 100.

Penelitian [14] mengembangkan metode otomatis untuk mengidentifikasi jenis jerawat menggunakan teknik pemrosesan citra dengan Gray Level Co-occurrence Matrix (GLCM) dan Extreme Learning Machine (ELM) dan dataset yang digunakan terdiri dari 100 gambar yang terbagi menjadi kelas Acne Nodules, Papules dan Pustules. Hasil penelitian menunjukkan akurasi tertinggi sebesar 95.24% untuk klasifikasi dua kelas dan 80% untuk klasifikasi 3 kelas. Berbeda dengan penelitian [14], penelitian ini menggunakan arsitektur MobileNetV2 dengan Convolutional Neural Network (CNN) untuk mengklasifikasi jenis jerawat dengan cakupan 5 kelas jerawat yaitu Acne fulminans, Acne Nodules, Papule, Pustule dan Fungal acne. Penelitian ini juga menggunakan dataset berjumlah 350 citra.

Penelitian [15] dilakukan untuk klasifikasi otomatis 4 jenis penyakit kulit termasuk jerawat menggunakan arsitektur CNN. Penelitian tersebut menggunakan dataset dari DermNet dengan total 174 gambar yang terbagi menjadi 105 data training dan 69 data testing. Hasil penelitian menunjukkan akurasi klasifikasi untuk jerawat mencapai 87% dengan learning rate 0.01. Penelitian ini membuktikan bahwa CNN dapat digunakan secara efektif untuk mengklasifikasikan berbagai jenis penyakit kulit termasuk jerawat.

Penelitian [16] menggunakan Convolutional Neural Network (CNN) untuk mengembangkan sistem pendeteksi penyakit kulit. Penelitian tersebut menggunakan data DermNet dengan 500 gambar untuk mengklasifikasikan 6 jenis penyakit kulit yaitu dermatitis tangan, eksim tangan, eksim subakut, lichen simplex, statis dermatitis dan ulkus. Hasil penelitian menunjukkan akurasi klasifikasi mencapai 73% yang menunjukkan potensi CNN dalam mengklasifikasi berbagai jenis penyakit kulit.

Penelitian sebelumnya umumnya tidak melakukan klasifikasi yang spesifik terhadap berbagai jenis jerawat. Fokus utama studi-studi tersebut lebih kepada deteksi penyakit kulit secara umum, identifikasi keberadaan jerawat atau klasifikasi jerawat berdasarkan tingkat keparahan. Meskipun ada beberapa usaha untuk mengklasifikasikan jerawat, label yang digunakan masih terbagi dalam kategori yang terbatas. Berdasarkan studi-studi sebelumnya juga menunjukkan bahwa metode Convolutional Neural Network (CNN) efektif dalam mendeteksi citra, oleh karena itu,

penerapan CNN untuk melakukan klasifikasi jenis jerawat menjadi fokus dalam penelitian ini.

2. Metode Penelitian

Penelitian ini menggunakan metode klasifikasi citra dengan menerapkan Convolutional Neural Network berbasis arsitektur MobileNetV2 untuk mengklasifikasikan jenis jerawat. Tahapan penelitian mencakup pengumpulan dan pengolahan dataset, desain arsitektur model CNN, proses pelatihan dan evaluasi kinerja model. Metode yang ditetapkan dirancang untuk memastikan bahwa model dapat secara efektif mengenali dan mengklasifikasi berbagai jenis jerawat.

2.1. Pengumpulan Dataset

Pada penelitian ini, digunakan dataset berupa citra jerawat dengan lima jenis label yaitu Papule, Pustule, Acne Fulminans, Fungal acne dan Acne nodules. Dengan masing-masing kelas memiliki jumlah citra yaitu Papule 70 citra, Pustule 70 citra, Acne Fulminans 70 citra, Jerawat fungal 70 citra dan Jerawat Nodule 71 citra, sehingga dataset berjumlah 351 citra. Dataset ini diperoleh dari Kaggle yang dapat diakses di [DatasetLink](#) dan diambil dalam format JFIF. Gambar 1 memperlihatkan sampel data dari dataset citra yang mencakup 5 kelas jerawat.



Gambar 1. Sampel data citra jerawat

Penelitian [17] sebelumnya juga menggunakan dataset serupa untuk mengklasifikasikan jenis jerawat wajah yang terbagi menjadi 5 kelas yaitu Acne Fulminans, Pustula, Papula, Acne fulminans, dan Fungal acne. Penelitian tersebut menggunakan arsitektur InceptionV3 yang diimplementasikan berbasis website. Hasilnya menunjukkan akurasi tertinggi 0.9956 pada tahap training dengan akurasi testing 0.8333, presisi 0.8555, recall 0.8333, dan f1-score 0.8386. Dibandingkan dengan penelitian ini, perbedaan utama terletak pada penggunaan arsitektur jaringan dan strategi optimasi yang digunakan dimana arsitektur yang digunakan dalam penelitian ini adalah arsitektur MobileNetV2.

2.2. Preprocessing Data

Tahap preprocessing bertujuan untuk menyiapkan dataset agar sesuai dengan masukan model CNN [18]. Tahapan preprocessing data yang diterapkan pada penelitian ini mencakup:

2.2.1. Data Cleaning

Tahap data cleaning bertujuan untuk memastikan bahwa dataset yang digunakan berkualitas baik dan siap untuk tahap preprocessing serta pelatihan model. Pada tahap ini, dilakukan beberapa langkah untuk membersihkan data dari potensi masalah yang dapat mempengaruhi performa model. Setiap citra diperiksa untuk memastikan bahwa file gambar tidak rusak dan dapat dibaca oleh sistem. Gambar-gambar yang tidak valid, rusak atau mengalami kerusakan file dihapus dari dataset. Pada dataset yang digunakan dalam penelitian ini, ditemukan ketidakseimbangan data, dimana citra pada kelas Acne Nodules memiliki 71 citra sedangkan kelas lainnya hanya memiliki 70 citra sehingga dilakukan penghapusan data yang berlebih pada kelas Acne Nodules. Selanjutnya data yang berformat citra ini dikonversi menjadi array dan ditambahkan label.

2.2.2. Rescale

Setiap citra mengalami serangkaian transformasi preprocessing yang sistematis. Proses ini dimulai dengan pembacaan citra menggunakan OpenCV, dilanjutkan dengan konversi ruang warna citra dari BGR ke RGB untuk memastikan representasi warna akurat. Proses rescaling citra dilakukan untuk mengubah ukuran citra menjadi dimensi yang seragam, yaitu 224 x 224 piksel. Ukuran ini dipilih karena kompatibel dengan arsitektur MobileNetV2 dan memastikan konsistensi input model. Teknik interpolasi yang digunakan adalah metode interpolasi bawaan OpenCV.

2.2.3. Split Dataset

Pada tahapan pembagian dataset, dilakukan pembagian data menjadi dua bagian yaitu data training dan data testing dengan 3 skenario. Skenario pertama data dibagi dengan rasio 70:30 untuk training dan testing, kemudian pada skenario kedua data dibagi dengan rasio 80:20 dan skenario ketiga data dibagi menjadi 90:10. Transformasi data selanjutnya dilakukan dengan mengonversi list citra menjadi numpy array multidimensi, dengan setiap citra direpresentasikan sebagai matriks 3 dimensi berukuran 224 x 224 x 3. Label kategori jerawat diubah menjadi representasi numerik berdasarkan indeks dalam daftar kategori dimana indeks 0,1,2,3, secara berurutan merepresentasikan Acne fulminans, Acne Nodules, Papule, Pustule dan Fungal Acne yang selanjutnya akan digunakan untuk pengkodean one-hot.

2.2.4. K-Fold Cross-Validation

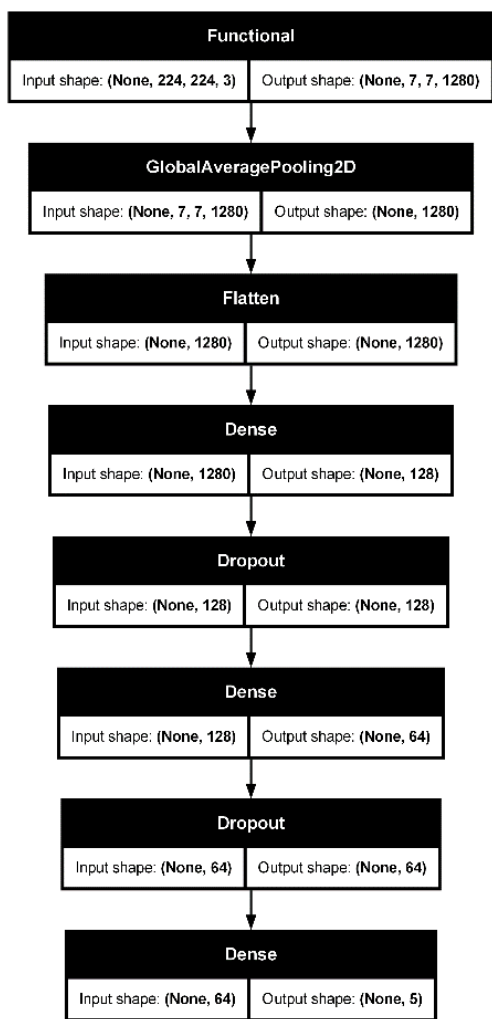
Untuk mengevaluasi model, penelitian ini mengaplikasikan metode K-Fold Cross-Validation. Data dibagikan secara random (acak) menjadi 5 bagian dengan ukuran yang sama. Metode K-Fold Cross-Validation ini memiliki keunggulan dalam mengurangi bias yang mungkin terjadi akibat pembagian data yang tidak seimbang, serta memberikan gambaran komprehensif tentang performa model pada berbagai subset data.

2.2.5. Normalisasi

Normalisasi piksel dilakukan dengan membagi nilai setiap piksel dengan 255.0, sehingga rentang nilai diubah dari 0-255 menjadi 0-1. Proses ini bertujuan untuk menstandarisasi rentang nilai input, mempercepat konvergensi selama pelatihan model, dan mengurangi dampak variasi intensitas pencahayaan pada citra [19].

2.3. Perancangan Model

Penelitian ini menggunakan model Convolutional Neural Network (CNN) berbasis transfer learning



Gambar 2. Arsitektur Model

dengan arsitektur MobileNetV2, yang efisien untuk dataset kecil dan membutuhkan komputasi lebih ringan dibandingkan CNN konvensional [20]. Mengingat hal tersebut maka penelitian ini mengambil fokus untuk mengeksplorasi kemampuan generalisasi model dalam klasifikasi jenis jerawat tanpa menggunakan data augmentasi. Pendekatan ini memungkinkan evaluasi langsung performa arsitektur pada dataset medis dengan mempertahankan karakteristik citra asli, sekaligus memanfaatkan keunggulan MobileNetV2 dalam efisiensi komputasi dan representasi fitur. Gambar 2 menunjukkan arsitektur model yang

digunakan dalam penelitian ini. Model ini dilengkapi lapisan GlobalAveragePooling2D untuk mereduksi dimensi fitur, diikuti lapisan Dense dengan 128 unit dan aktivasi ReLU, serta Dropout untuk mencegah overfitting [21]. Lapisan Dense berikutnya memiliki 64 unit dengan aktivasi ReLU, diakhiri dengan lapisan output berisi 5 unit dengan aktivasi softmax untuk menghasilkan probabilitas kelas. Tabel 1 memperlihatkan rincian parameter yang digunakan dalam model.

Tabel 1. Tabel Parameter Model

Layer (type)	Output Shape	Param #
mobilenetv2_1.00_224 (Functional)	(None, 7, 7, 1280)	2, 257, 984
global_average_pooling2d_47 (GlobalAveragePooling2D)	(None, 1280)	0
flatten_44 (Flatten)	(None, 1280)	0
dense_151 (Dense)	(None, 128)	163,968
dropout_88 (Dropout)	(None, 128)	0
dense_152 (Dense)	(None, 64)	8,256
dropout_89 (Dropout)	(None, 64)	0
dense_153 (Dense)	(None, 5)	325

2.3.1. Hyperparameter

Model dalam penelitian ini dilatih dengan beberapa parameter, diantaranya adalah optimizer Adam dengan learning rate sebesar 0.0001 untuk mempercepat proses konvergensi model. Model menggunakan loss function Categorical-Crossentropy yang relevan dengan masalah klasifikasi multi-kelas. Proses pelatihan juga dilakukan dengan ukuran batch sebesar 16, selama 50 epoch. Untuk memastikan performa model, diterapkan metode K-Fold Cross-Validation. Langkah konfigurasi yang digunakan yaitu data dibagi ke dalam lima lipatan (folds).

2.5. Confusion Matrix

Metode evaluasi sangat krusial dalam pengukuran kinerja model [22]. Confusion matrix digunakan sebagai metode evaluasi dalam penelitian ini. Confusion matrix terdiri dari 4 komponen utama. True Positive (TP) menunjukkan jumlah kasus positif yang berhasil diidentifikasi, True Negative (TN) menunjukkan jumlah kasus negatif yang dikategorikan dengan akurat, False Positive (FP) mengindikasikan jumlah kasus negatif yang diklasifikasikan sebagai positif oleh model; dan False Negative (FN), yang merujuk pada jumlah kasus yang sebenarnya positif tetapi diidentifikasi sebagai negatif oleh model [23]. Untuk menghitung confusion matrix, digunakan rumus accuracy, precision, recall, dan F1-score :

$$accuracy = \frac{TN+TP}{TN+TP+FN+FP} \times 100\% \tag{1}$$

$$precision = \frac{TN}{TN+FN} \times 100\% \tag{2}$$

$$recall = \frac{TN}{TN+FP} \times 100\% \tag{3}$$

$$F1 - score = 2 \times \frac{recall \times presisi}{recall + presisi} \times 100\% \tag{4}$$

Formula ini akan digunakan setelah testing model.

3. Hasil dan Pembahasan

Pelatihan dan pengujian pada penelitian ini dilakukan dengan menerapkan metode 5-fold cross-validation beserta parameter yang sebelumnya telah ditentukan. Hasil pengujian telah dicatat menggunakan tabel untuk pengamatan hasil. Tabel 2 menunjukkan skor akurasi pelatihan dan pengujian pada skenario pertama.

Tabel 2. Hasil Pengujian Pada Skenario Pertama

Fold	Training Accuracy	Validation Accuracy	Testing Accuracy
Fold-1	0.61	0.59	0.62
Fold-2	0.67	0.59	0.57
Fold-3	0.65	0.69	0.54
Fold-4	0.66	0.73	0.53
Fold-5	0.69	0.73	0.58

Analisis hasil k-fold cross-validation menunjukkan variabilitas performa model klasifikasi jerawat pada lima fold berbeda. Hasil pengujian pada skenario pertama mencapai akurasi training berkisar antara 0.61-0.69 dan akurasi testing antara 0.53-0.62. Variasi kecil antara akurasi training, validasi, dan testing mengindikasikan bahwa model memiliki konsistensi yang cukup baik, namun masih memerlukan perbaikan untuk meningkatkan kemampuan generalisasi. Fold-5 menunjukkan performa sedikit lebih baik dengan akurasi validasi 0.73 dan akurasi testing 0.58.

Tabel 3. Hasil Pengujian Pada Skenario Kedua

Fold	Training Accuracy	Validation Accuracy	Testing Accuracy
Fold-1	0.71	0.60	0.55
Fold-2	0.76	0.67	0.61
Fold-3	0.74	0.78	0.51
Fold-4	0.78	0.71	0.66
Fold-5	0.72	0.71	0.64


Pada tabel 3 menunjukkan pengujian pada skenario kedua. Akurasi training relatif konsisten berkisar antara 0.71-0.78, sementara akurasi validasi berkisar 0.60-0.78 dan akurasi testing bervariasi dari 0.51-0.66. Fold-4 menunjukkan performa relatif paling baik dengan akurasi training tertinggi 0.78, akurasi validasi 0.71, dan akurasi testing 0.66.

Tabel 4. Hasil Pengujian Pada Skenario Ketiga

Fold	Training Accuracy	Validation Accuracy	Testing Accuracy
Fold-1	0.93	0.71	0.74
Fold-2	0.90	0.69	0.60
Fold-3	0.89	0.74	0.62
Fold-4	0.86	0.74	0.66
Fold-5	0.89	0.80	0.80

Tabel 4 menunjukkan rangkuman hasil akhir akurasi

pengujian dari data citra pada masing-masing fold pada skenario ketiga. Dari ketiga skenario yang telah diuji skenario ketiga dengan pembagian dataset 90:10 menampilkan karakteristik performa yang lebih baik dengan akurasi terbaik dicapai di fold-5. Berikut grafik yang menampilkan accuracy dan loss dari masing-masing fold pada skenario ketiga.




Gambar 3. Grafik Accuracy Masing-masing Fold Skenario Ketiga

Grafik accuracy dan loss memberikan gambaran mengenai kinerja model selama proses training dan validation untuk setiap fold pada skema 5-fold-cross-validation. Gambar 3 menunjukkan grafik akurasi (accuracy). Grafik akurasi menggambarkan tren peningkatan performa model terhadap data pelatihan dan validasi seiring bertambahnya jumlah epoch. Pada fold pertama hingga kelima, model menunjukkan peningkatan akurasi pelatihan yang konsisten, meskipun akurasi validasi cenderung berfluktuasi setelah mencapai optimal pada sejumlah epoch. Gambar 4 menunjukkan grafik kehilangan (loss) selama proses pelatihan dan validasi.

Pada grafik loss, terlihat bahwa nilai training loss terus menurun pada semua fold, yang mengindikasikan bahwa model semakin baik dalam meminimalkan kesalahan prediksi pada data pelatihan. Sebaliknya, validation loss pada beberapa fold cenderung mengalami stagnan atau peningkatan kecil setelah beberapa epoch, menunjukkan adanya potensi overfitting pada data pelatihan.

Pada fold kelima, model mencapai performa terbaik



Gambar 4. Grafik Loss Masing-masing Fold

dengan akurasi validasi tertinggi yaitu 80% yang sejalan dengan evaluasi secara keseluruhan. Hal ini menunjukkan bahwa arsitektur model dan parameter pelatihan sudah cukup baik untuk menangkap pola dari dataset, meskipun terdapat indikasi keterbatasan seperti jumlah dataset yang kecil yang dapat mempengaruhi kestabilan performa validasi antar fold.

Tabel 3. Tabel Classification Report Fold-5

Class	Precision	Recall	F1-score
Acne fulminans	0.88	1.00	0.93
Acne nodules	0.67	0.86	0.75
Papule	0.80	0.57	0.67
Pustule	1.00	0.86	0.93
Fungal acne	0.71	0.71	0.71

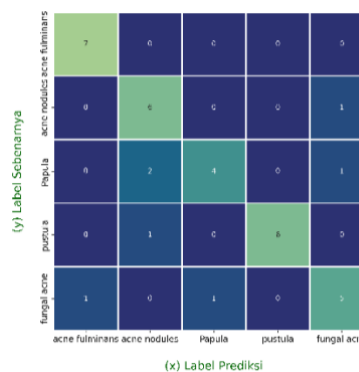
Berdasarkan analisis classification report yang ditampilkan pada tabel 3, pelatihan pada fold 5 mencapai 80% akurasi dengan loss sebesar 0.80 dengan precision 0.81, recall 0.80 dan f1-score 0.80. model ini menunjukkan performa yang kuat pada beberapa kelas seperti acne fulminans dan Pustule, tetapi memiliki kelemahan pada kelas seperti papule.

Hasil pengujian menggunakan model yang dilatih pada fold ke-5 pada gambar 5 menunjukkan prediksi dan nilai benar dari klasifikasi pada 5 kelas jerawat oleh model pada data testing. Nilai pada “Pred”



Gambar 5. Hasil Prediksi Model Terhadap Data Testing

menunjukkan prediksi model, sedangkan “True” menunjukkan nilai benar dari gambar. Secara keseluruhan, sebagian besar jenis jerawat sudah diprediksi baik oleh model, namun masih terdapat beberapa kesalahan prediksi, salah satunya terjadi pada data citra Papule dan Acne fulminans. Gambar 6 menampilkan plot confusion matrix dari hasil pengujian. confusion matrix menampilkan seluruh jumlah citra yang diprediksi benar dan jumlah prediksi yang salah untuk setiap kelas dan memberikan gambaran jelas mengenai seberapa baik Model dapat membedakan kelima jenis jerawat.



Gambar 6. Confusion Matrix Fold-5

4. Kesimpulan

Berdasarkan hasil pengujian yang telah dilakukan dapat disimpulkan bahwa penelitian ini berhasil menerapkan model Convolutional Neural Network (CNN) berbasis arsitektur MobilNetV2 untuk mengembangkan sistem klasifikasi jerawat. Mengingat keterbatasan dataset yang hanya berisi 351 citra jerawat, maka digunakan metode K-Fold Cross-Validation sebagai strategi kritis untuk mengatasi tantangan data yang terbatas.

K-fold Cross-Validation memiliki peran fundamental dalam penelitian ini untuk memaksimalkan penggunaan data yang tersedia, dengan eksplorasi tiga skenario pembagian dataset: 70:30, 80:20, dan 90:10. Analisis menyeluruh menunjukkan bahwa skenario ketiga (90:10) memberikan performa paling unggul, khususnya pada Fold-5. Analisis detail dari kelima fold menunjukkan variasi performa yang signifikan. Dari hasil pengujian fold pertama mencapai akurasi validasi sebesar 0.71%, fold kedua 0.69%, fold ketiga dan keempat masing-masing 0.74%, dengan fold kelima mencatat performa paling optimal dengan akurasi validasi tertinggi 80%, akurasi testing 80%, disertai precision 81%, recall 80% dan f1-score 80%. Hasil ini menunjukkan bahwa pembagian dataset 90:10 secara signifikan mengoptimalkan kinerja model klasifikasi jerawat menggunakan arsitektur MobileNetV2, menawarkan pendekatan yang menjanjikan dalam klasifikasi citra medis dengan dataset terbatas.

Penelitian ini menekankan pentingnya klasifikasi jerawat untuk menentukan pengobatan yang tepat, sehingga pasien dapat mengobati jerawat secara mandiri. Dengan kemajuan dalam pembelajaran mesin dan pengolahan citra, pendekatan ini tidak hanya meningkatkan akurasi diagnosis tetapi juga membuka peluang untuk pengembangan aplikasi teknologi yang membantu pasien mengidentifikasi kondisi kulit mereka sendiri.

Penelitian ini juga mencatat keterbatasan, seperti ukuran dataset yang kecil, yang dapat mempengaruhi stabilitas performa model. Sebagai saran untuk penelitian masa depan, eksplorasi arsitektur model lain dan pengujian dengan augmentasi data. Hal ini diharapkan dapat membantu meningkatkan akurasi dan keandalan model klasifikasi.

Daftar Rujukan

- [1] A. H. S. Heng and F. T. Chew, "Systematic review of the epidemiology of acne vulgaris," *Sci Rep*, vol. 10, no. 1, Dec. 2020, doi: 10.1038/s41598-020-62715-3.
- [2] J. Yang, H. Yang, A. Xu, and L. He, "A Review of Advancement on Influencing Factors of Acne: An Emphasis on Environment Characteristics," Sep. 17, 2020, *Frontiers Media S.A.* doi: 10.3389/fpubh.2020.00450.
- [3] M. A. Kayıran *et al.*, "Use of Complementary and Alternative Medicine among Patients with Acne Vulgaris and Factors Perceived to Trigger the Disease," *Indian J Dermatol*, vol. 67, no. 3, p. 311, May 2022, doi: 10.4103/ijd.ijd_745_21.
- [4] A. Alqahtani, W. I. Alsaab, and B. Altulahi, "Psychological Impact of Acne Vulgaris on the Young Saudi Population," *Cureus*, Dec. 2021, doi: 10.7759/cureus.20509.
- [5] K. A. Habeshian and B. A. Cohen, "Current issues in the treatment of acne vulgaris," *Pediatrics*, vol. 145, no. 2, May 2020, doi: 10.1542/PEDS.2019-2056L.
- [6] K. Tayel, M. Attia, N. Agamia, and N. Fadl, "Acne vulgaris: prevalence, severity, and impact on quality of life and self-esteem among Egyptian adolescents," *Journal of the Egyptian Public Health Association*, vol. 95, no. 1, Dec. 2020, doi: 10.1186/s42506-020-00056-9.
- [7] S. Voidazan, R. Toth, and T. Varo, "Factors Involved in the Pathogenesis of Acne and Its Psycho-Social Impact," *Acta Marisensis - Seria Medica*, vol. 66, no. 1, pp. 15–18, Mar. 2020, doi: 10.2478/amma-2020-0001.
- [8] Z. Rashid *et al.*, "ASSESSMENT OF PSYCHO-SOCIAL IMPACT OF ACNE AMONG YOUNG ADULTS - A CROSS SECTIONAL STUDY AT A TERTIARY CARE HOSPITAL OF RAWALPINDI," *PAFMJ*, vol. 71, no. 4, pp. 1171–74, Aug. 2021, doi: 10.51253/pafmj.v71i4.3906.
- [9] H. J. Kim and Y. H. Kim, "Exploring Acne Treatments: From Pathophysiological Mechanisms to Emerging Therapies," *Int J Mol Sci*, vol. 25, no. 10, p. 5302, May 2024, doi: 10.3390/ijms25105302.
- [10] D. R. Sarvamangala and R. V. Kulkarni, "Convolutional neural networks in medical image understanding: a survey," *Evol Intell*, vol. 15, no. 1, pp. 1–22, Mar. 2022, doi: 10.1007/s12065-020-00540-3.
- [11] N. Nyoman, C. Sumartha, G. Pasek, S. Wijaya, F. Bimantoro, and G. Satya Nugraha, "Klasifikasi Citra Lubang Pada Permukaan Jalan Beraspal dengan Metode Convolutional Neural Networks Potholes Recogniton on Paved Road Surfaces using Convolutional Neural Networks." [Online]. Available: <http://jcosine.if.unram.ac.id/>

- [12] D. Anggriandi, E. Utami, and D. Ariatmanto, "Comparative Analysis of CNN and CNN-SVM Methods For Classification Types of Human Skin Disease," *sinkron*, vol. 8, no. 4, pp. 2168–2178, Oct. 2023, doi: 10.33395/sinkron.v8i4.12831.
- [13] R. Rianto, D. Risdho Listianto, U. Teknologi Yogyakarta Jl Siliwangi Jl Ring Road Utara, and D. Istimewa Yogyakarta, "Convolutional Neural Network untuk mengklasifikasi tingkat keparahan jerawat," *AITI: Jurnal Teknologi Informasi*, vol. 20, no. Agustus, pp. 167–176, 2023, [Online]. Available: www.kaggle.com
- [14] R. L. Hasanah, Y. Rianto, and D. Riana, "Identification of Acne Vulgaris Type in Facial Acne Images Using GLCM Feature Extraction and Extreme Learning Machine Algorithm," vol. 15, no. 2, pp. 204–214, 2022, doi: 10.21107/rekayasa.v15i2.141580.
- [15] T. Shanthi, R. S. Sabeenian, and R. Anand, "Automatic diagnosis of skin diseases using convolution neural network," *Microprocess Microsyst*, vol. 76, Jul. 2020, doi: 10.1016/j.micpro.2020.103074.
- [16] T. A. Rimi, N. Sultana, and Md. F. Ahmed Foysal, "Derm-NN: Skin Diseases Detection Using Convolutional Neural Network," in *2020 4th International Conference on Intelligent Computing and Control Systems (ICICCS)*, IEEE, May 2020, pp. 1205–1209. doi: 10.1109/ICICCS48265.2020.9120925.
- [17] S. Ahla Amaniah, S. Mulyono, S. Farisa Chaerul Haviana, and I. Sultan Agung, "KLASIFIKASI JENIS JERAWAT WAJAH MENGGUNAKAN ARSITEKTUR INCEPTION V3".
- [18] H. Mukhtar, F. Alfanico, H. Fu'adah Amran, F. Handayani, and R. Medikawati Taufiq, "Deep Learning Untuk Klasifikasi Kematangan Buah Mangrove Berdasarkan Warna," *JURNAL FASILKOM*, vol. 13, no. 3, pp. 563–569, Dec. 2023, doi: 10.37859/jf.v13i3.6292.
- [19] C. Garbin, X. Zhu, and O. Marques, "Dropout vs. batch normalization: an empirical study of their impact to deep learning," *Multimed Tools Appl*, vol. 79, no. 19–20, pp. 12777–12815, May 2020, doi: 10.1007/s11042-019-08453-9.
- [20] P. N. Srinivasu, J. G. Sivasai, M. F. Ijaz, A. K. Bhoi, W. Kim, and J. J. Kang, "Classification of skin disease using deep learning neural networks with mobilenet v2 and lstm," *Sensors*, vol. 21, no. 8, Apr. 2021, doi: 10.3390/s21082852.
- [21] S. Mohapatra, N. V. S. Abhishek, D. Bardhan, A. A. Ghosh, and S. Mohanty, "Comparison of MobileNet and ResNet CNN Architectures in the CNN-Based Skin Cancer Classifier Model," in *Machine Learning for Healthcare Applications*, Wiley, 2021, pp. 169–186. doi: 10.1002/9781119792611.ch11.
- [22] D. Cindy Agustin, M. Alfan Rosid, N. Ariyanti, F. Sains dan Teknologi, and U. Muhammadiyah Sidoarjo, "IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK UNTUK DETEKSI KESEGARAN PADA APEL".
- [23] I. P. Kamila, C. A. Sari, E. H. Rachmawanto, and N. R. D. Cahyo, "A Good Evaluation Based on Confusion Matrix for Lung Diseases Classification using Convolutional Neural Networks," *Advance Sustainable Science, Engineering and Technology*, vol. 6, no. 1, p. 0240102, Dec. 2023, doi: 10.26877/asset.v6i1.17330.

