

KLASIFIKASI TIPE DAN KONDISI KULIT WAJAH DENGAN METODE EFFICIENTNET-B0 MENGGUNAKAN GRAD-CAM SEBAGAI INTERPRETASI MODEL

Intan Putri Mansyur Pratama^{1*}, Nada Firda Khofifah², Anggraini Puspita Sari³

^{1,2,3}Informatika, Universitas Pembangunan Nasional "Veteran" Jawa Timur

intanmansyur16@gmail.com¹, nadafirdakhofifah@gmail.com², anggraini.puspita.if@upnjatim.ac.id³

Submitted May 12, 2026; Revised July 24, 2026; Accepted August 1, 2026

Abstrak

Identifikasi tipe dan kondisi kulit wajah merupakan langkah penting dalam menentukan produk perawatan yang sesuai. Namun, banyak masyarakat masih mengalami kesulitan mengenali kondisi kulit secara mandiri, sementara konsultasi langsung memerlukan investasi waktu dan biaya yang cukup besar. Studi ini bertujuan membangun sistem klasifikasi tipe dan kondisi kulit wajah berbasis Convolutional Neural Network menggunakan arsitektur EfficientNet-B0 serta menerapkan Grad-CAM sebagai metode interpretasi model. Penelitian ini menggunakan dataset yang mencakup 3.500 citra digital yang terbagi ke dalam tujuh kelas, yang terdiri dari tipe kulit (berjerawat, berminyak, kering, dan normal) serta kondisi kulit (dermatitis perioral, penuaan, dan vitiligo). Tahapan penelitian meliputi pengumpulan data, preprocessing data, persiapan data, pelatihan model, evaluasi model, dan implementasi Grad-CAM. Model dilatih menggunakan pendekatan transfer learning dengan optimizer Adam selama 5 epoch. Hasil pengujian awal dengan *learning rate* 0.0001 menghasilkan tingkat akurasi 89%. Performa sistem kemudian meningkat signifikan hingga mencapai akurasi final 97,52% setelah dilakukan penyesuaian *learning rate* menjadi 0,001. Visualisasi Grad-CAM menunjukkan bahwa model memfokuskan perhatian pada area wajah yang relevan terhadap masing-masing kelas. Dengan demikian, metode yang diusulkan mampu memberikan performa klasifikasi yang tinggi sekaligus interpretasi visual yang transparan.

Kata Kunci : Klasifikasi Kulit Wajah, EfficientNet-B0, CNN, Grad-CAM, Deep Learning

Abstract

Facial skin type and condition identification is an important step in determining appropriate skincare products. However, many people still face difficulties in recognizing their skin conditions independently, while direct consultation requires significant time and cost. This study aims to develop a classification system for facial skin types and conditions based on a Convolutional Neural Network using the EfficientNet-B0 architecture, as well as to apply Grad-CAM as a model interpretability method. The dataset used consists of 3,500 digital images categorized into seven classes, comprising skin types (acne-prone, oily, dry, and normal) and skin conditions (perioral dermatitis, aging, and vitiligo). The research stages include data collection, data preprocessing, data preparation, model training, model evaluation, and Grad-CAM implementation. The model was trained using a transfer learning approach with the Adam optimizer for 5 epochs. Initial testing with a learning rate of 0.0001 resulted in an accuracy of 89%. The system performance then improved significantly, achieving a final accuracy of 98% after adjusting the learning rate to 0.001. Grad-CAM visualization shows that the model focuses on facial regions relevant to each class. Therefore, the proposed method is capable of delivering high classification performance along with transparent visual interpretation.

Keywords : Facial Skin Classification, EfficientNet-B0, CNN, Grad-CAM, Deep Learning

1. PENDAHULUAN

Perawatan terhadap kulit wajah saat ini menjadi salah satu perhatian penting di kalangan masyarakat modern, terutama

pada remaja dan kalangan dewasa awal. Identifikasi tipe dan kondisi kulit wajah merupakan langkah penting karena dapat membantu dalam pemilihan produk

perawatan, penyesuaian rutinitas skincare, serta penentuan tindakan klinis yang sesuai. Klasifikasi tipe dan kondisi kulit juga bermanfaat bagi konsumen dan tenaga profesional dalam merekomendasikan produk kosmetik maupun protokol perawatan yang tepat[1]. Namun, masyarakat luas masih sering mengalami kesulitan ketika akan mengenali tipe dan kondisi kulit wajah mereka, padahal informasi tersebut sangat penting untuk menentukan produk perawatan yang sesuai [2].

Penggunaan produk perawatan yang tidak sesuai dengan tipe dan kondisi kulit dapat menimbulkan berbagai permasalahan, seperti iritasi, munculnya jerawat, hingga kerusakan pada lapisan kulit [3]. Selain itu, biaya konsultasi yang relatif tinggi, keterbatasan jumlah tenaga profesional, serta waktu antrean yang cukup lama menjadi kendala bagi sebagian masyarakat untuk memperoleh diagnosis awal kondisi kulit[4]. Maka dari itu, kehadiran solusi otomatis yang menawarkan kecepatan, kepraktisan, serta kemudahan akses menjadi kebutuhan yang mendesak.

Adanya kemajuan dalam bidang kecerdasan buatan, terutama pada *deep learning*, membuka potensi besar dalam analisis citra wajah secara otomatis [5]. Algoritma Convolutional Neural Network (CNN) kerap diandalkan dalam bermacam tugas klasifikasi gambar berkat kemampuannya melakukan ekstraksi fitur visual secara mandiri dengan tingkat performa yang memuaskan [6]. Pada penelitian ini digunakan arsitektur EfficientNet-B0, yaitu model CNN yang mengusung konsep *compound scaling* yang memungkinkan pencapaian akurasi maksimal meskipun beroperasi dengan parameter yang lebih efisien. Dibandingkan arsitektur CNN konvensional, EfficientNet-B0 memiliki jumlah parameter yang lebih ringan namun tetap mampu menghasilkan akurasi tinggi [7], sehingga cocok

digunakan untuk klasifikasi citra kulit wajah yang melibatkan beberapa kategori dengan karakteristik visual yang beragam.

Untuk mendukung kebutuhan klasifikasi yang lebih menyeluruh, penelitian ini menggunakan tujuh kategori tipe dan kondisi kulit wajah, yaitu berjerawat, berminyak, dermatitis perioral, kering, normal, penuaan, dan vitiligo. Pemilihan tujuh kelas ini didasarkan pada kombinasi antara tipe kulit dasar dan kondisi kulit wajah yang umum dijumpai. Secara umum, tipe kulit diklasifikasikan menjadi beberapa kategori seperti normal, kering, dan berminyak [8], sedangkan kondisi kulit seperti jerawat, dermatitis, penuaan, dan vitiligo merupakan permasalahan kulit yang sering terjadi serta memiliki karakteristik visual yang berbeda. Hal ini sejalan dengan informasi yang menyatakan bahwa gangguan kulit mencakup berbagai kondisi umum seperti jerawat, dermatitis, dan vitiligo dengan variasi gejala serta penyebab yang beragam [9]. Oleh karena itu, integrasi kedua aspek tersebut ke dalam tujuh kelas diharapkan mampu merepresentasikan tipe dan kondisi kulit wajah secara lebih luas sekaligus meningkatkan relevansi sistem yang dikembangkan dalam penggunaan nyata.

Namun demikian, beberapa penelitian sebelumnya masih memiliki keterbatasan dalam jumlah kelas maupun transparansi model. Penelitian oleh [10] yang menggunakan EfficientNet-B3 mampu mencapai akurasi 96,61%, tetapi klasifikasinya masih terbatas pada lima penyakit kulit. Penelitian lain [11] berbasis ResNet50 juga hanya mencakup empat kategori umum. Selain keterbatasan jumlah kelas, sebagian besar model sebelumnya masih bersifat black box sehingga tidak memberikan penjelasan mengenai area wajah yang menjadi dasar keputusan model. Di sisi lain, penggunaan arsitektur yang relatif besar seperti ResNet50 maupun EfficientNet-B3 juga memerlukan sumber


daya komputasi yang lebih tinggi [12], sehingga kurang efisien untuk implementasi yang lebih luas.

Penggunaan arsitektur EfficientNet-B0 pada penelitian ini menjadi keunggulan karena mampu mengekstraksi fitur visual seperti tekstur, warna, dan pola kulit secara efektif dengan jumlah parameter yang efisien [7], sehingga sangat sesuai untuk tugas klasifikasi tipe dan jenis kulit berbasis citra digital yang memiliki variasi karakteristik yang kompleks. Selain itu, penelitian ini mengintegrasikan metode Grad-CAM (*Gradient-weighted Class Activation Mapping*) sebagai pendekatan interpretasi model guna menampilkan visualisasi area wajah yang memengaruhi hasil prediksi. Dengan demikian, penelitian ini memiliki tujuan yaitu mengembangkan sistem yang tidak hanya berfokus pada akurasi, tetapi juga memberikan transparansi visual yang dapat membantu pengguna memahami tipe dan kondisi kulit wajah secara lebih jelas [13].

Kebaruan penelitian ini terletak pada integrasi arsitektur EfficientNet-B0 yang efisien dari sisi jumlah parameter dengan kemampuan klasifikasi tujuh kategori tipe dan kondisi kulit wajah yang lebih komprehensif, serta penerapan Grad-CAM untuk meningkatkan hasil transparansi hasil prediksi. Kombinasi ketiga aspek tersebut mampu menghasilkan sistem klasifikasi kulit wajah yang tidak hanya akurat dan ringan secara komputasi, tetapi juga lebih mudah dipahami dan memiliki potensi implementasi yang lebih luas dibandingkan penelitian-penelitian sebelumnya. Manfaat dari studi ini diharapkan mampu memberikan kontribusi ilmiah bagi pembangunan model AI yang berperforma tinggi, hemat sumber daya, serta memiliki sifat transparansi (*explainable Deep Learning*).

2. METODE PENELITIAN

Metode penelitian disusun sebagai acuan dalam pelaksanaan setiap proses penelitian sebagaimana ditunjukkan pada Gambar 1. Setiap tahapan dilaksanakan secara sistematis sesuai dengan pokok permasalahan yang telah ditetapkan dan diselesaikan dengan baik.



Gambar 1. Alur Penelitian

Pengumpulan Data


Studi ini memanfaatkan sumber data sekunder berupa citra wajah yang diperoleh dari platform Kaggle [14]. Dataset ini berjumlah 1.537 gambar dan memiliki tujuh kategori kelas, yaitu berjerawat, berminyak, dermatitis perioral, kering, normal, penuaan, dan vitiligo. Rincian kuantitas data untuk tiap-tiap kelas dapat dilihat pada Tabel 1. Jumlah tersebut merupakan jumlah dataset awal sebelum dilakukan proses *data augmentation*. Untuk memperoleh distribusi data yang seimbang, pada penelitian ini dilakukan proses *data augmentation* sehingga jumlah data meningkat menjadi 3.500 citra. Proses *data augmentation* dijelaskan lebih lanjut pada subbab *Data Augmentation*.

Tabel 1. Distribusi Jumlah Data Setiap Kelas

No	Kelas	Jumlah Data
1.	Berjerawat	244
2.	Berminyak	228
3.	Dermatitis Perioral	209
4.	Kering	178
5.	Normal	232
6.	Penuaan	226
7.	Vitiligo	220

Sumber : Kaggle


Beberapa contoh citra yang terdapat pada dataset penelitian ditampilkan pada Gambar 2.



Gambar 2. Contoh Citra Dataset Tipe Kulit Wajah

Preprocessing Data

Tahap selanjutnya dalam penelitian ini adalah *preprocessing* data. Tahap ini bertujuan untuk mentransformasi data mentah ke dalam format yang lebih sistematis dan bersih sehingga layak diolah lebih lanjut pada proses pelatihan model [15]. Alur proses *preprocessing* data pada studi ini divisualisasikan pada Gambar 3.



Gambar 3. Diagram Preprocessing Data

1. Cleaning

Tahap selanjutnya yaitu *cleaning* data yang dilakukan dengan menghapus data duplikat, data kosong, dan outlier untuk memastikan kualitas dataset yang digunakan [16].

2. Cropping

Pada tahap *cropping*, citra dipotong pada area wajah untuk menghilangkan bagian tidak relevan sehingga model lebih fokus mengenali karakteristik kulit wajah.

3. Resize

Pada proses *resize*, citra pada dataset memiliki resolusi yang beragam, dengan jumlah sebanyak 969 ukuran resolusi yang berbeda seperti 460×482 , 1472×750 , 480×480 , dan 1599×899 piksel, diseragamkan ke ukuran 224×224 piksel guna

menyesuaikan dengan dimensi input arsitektur CNN [17].

4. Konversi Format Warna

Tahap berikutnya, citra yang semula BGR diubah ke ruang warna YcrCb karena ruang warna ini memisahkan komponen pencahayaan (luminansi) dan warna (krominansi), agar peningkatan kualitas citra dapat dilakukan tanpa mengubah warna kulit secara signifikan.

5. CLAHE

Setelah konversi format warna, metode CLAHE digunakan pada dataset karena efisien secara komputasi dan mampu meningkatkan kontras citra secara lokal tanpa meningkatkan noise secara berlebihan, sehingga detail tekstur kulit menjadi lebih jelas [18].

6. Data Augmentation

Selanjutnya, *data augmentation* dilakukan sebagai tahap *preprocessing* dengan menerapkan transformasi seperti *rescaling*, rotasi, dan *flipping* [19] pada dataset dengan target 500 citra per kelas agar distribusi data lebih seimbang serta meningkatkan kemampuan generalisasi model. Beberapa contoh citra hasil proses *data augmentation* ditampilkan pada Gambar 4.




Gambar 4. Contoh Hasil Data Augmentation

Setelah melalui tahap *preprocessing*, diperoleh total 3.500 citra yang telah siap digunakan pada proses selanjutnya.

Persiapan Data

Tahap selanjutnya dalam studi ini yaitu persiapan data. Adapun urutan prosedur persiapan data tersebut dapat dilihat pada visualisasi Gambar 5.



Gambar 5. Diagram Persiapan Data

Tahap split data melibatkan pemisahan dataset ke dalam tiga bagian: data pelatihan (*training*), validasi (*validation*), serta pengujian (*testing*). Distribusi data dilakukan dengan rasio 70:15:15, yaitu 2450 citra untuk data latih (70%), 525 citra untuk data validasi (15%), dan 525 citra untuk data uji (15%).

1. Label Encoding

Tahap *label encoding* dilakukan dengan mengubah label kategori pada dataset yang berbasis tekstual menjadi format angka (numerik) sehingga kompatibel dengan pemrosesan model *machine learning*. Proses ini dilakukan dengan memberikan kode angka unik pada setiap kelas tipe dan kondisi kulit wajah yang dipaparkan pada Tabel 2.

Tabel 2. Label Encoding Kelas

Label	Kelas
0	Berjerawat
1	Berminyak
2	Dermatitis Perioral
3	Kering
4	Normal
5	Penuaan
6	Vitiligo

2. Normalisasi Data

Selanjutnya tahap normalisasi data, yang dilakukan dengan menggunakan fungsi *preprocessing input* dari EfficientNet-B0 untuk menyelaraskan distribusi nilai piksel dengan spesifikasi masukan yang diperlukan oleh model. Proses ini dilakukan pada seluruh citra sebelum data dimasukkan ke tahap pelatihan model.

Pelatihan Model

Proses pelatihan model dalam studi ini mengimplementasikan kerangka kerja EfficientNet-B0 melalui pendekatan transfer learning berbobot pralatih ImageNet. Seluruh layer *feature extractor* dipertahankan dalam kondisi beku (*freeze*), sehingga hanya lapisan klasifikasi tambahan yang dilatih menggunakan data latih dan validasi. Pada studi ini dilakukan perbandingan performa model berdasarkan

dua nilai *learning rate*, yaitu 0.001 dan 0.0001. Kedua skenario pelatihan menggunakan *optimizer* Adam selama 5 epoch dengan batch size 32. Pemilihan *optimizer* Adam didasarkan pada efektivitasnya dalam mengatur bobot secara adaptif untuk kasus klasifikasi gambar [20]. Arsitektur model dilengkapi dengan *Global Average Pooling*, *Batch Normalization*, *Dense layer*, dan *Dropout* untuk mengurangi overfitting. Pada bagian *output*, fungsi aktivasi yang diterapkan yaitu *softmax* dengan 7 kelas, serta fungsi *loss categorical crossentropy*. Perbandingan kedua *learning rate* tersebut dimaksudkan untuk meninjau korelasi antara *learning rate* dengan akselerasi konvergensi serta hasil akhir performa model dalam mengklasifikasikan citra kulit wajah.

Evaluasi Model

Tahap evaluasi model dilakukan guna memvalidasi tingkat efektivitas dan keberhasilan sistem [21] saat mengklasifikasikan tipe dan kondisi kulit wajah menggunakan data uji yang belum pernah dilihat sebelumnya. Evaluasi dilakukan dengan menggunakan beberapa metrik penilaian, yaitu *accuracy*, *precision*, *recall*, dan *F1-score* untuk mengetahui performa model secara menyeluruh pada setiap kelas. Selain itu, confusion matrix digunakan untuk menganalisis tingkat kesalahan klasifikasi dan melihat sebaran prediksi model dibandingkan dengan label sebenarnya.

Implementasi Grad-CAM

Pada tahap ini, dilakukan implementasi metode Grad-CAM untuk memberikan interpretasi visual terhadap hasil prediksi model EfficientNet-B0. Grad-CAM digunakan untuk menghasilkan heatmap yang menunjukkan area pada citra wajah yang paling berpengaruh terhadap keputusan klasifikasi model [13]. Dengan demikian, pengguna dapat mengetahui bagian citra mana yang menjadi dasar pertimbangan model dalam menentukan

kelas prediksi. Selain itu, tingkat keyakinan model terhadap hasil prediksi ditunjukkan melalui nilai *confidence* yang diperoleh dari probabilitas output *softmax*, yang dirumuskan sebagai berikut:

$$\text{Confidence} = \max(p_1, p_2, \dots, p_n) \quad (1)$$


Di mana p_i merupakan probabilitas dari masing-masing kelas hasil keluaran model. *Explainable Deep Learning* diperlukan untuk memberikan penjelasan terhadap keputusan yang dihasilkan oleh model, sehingga proses klasifikasi tidak sepenuhnya bersifat black box dan dapat meningkatkan tingkat kepercayaan terhadap hasil model [13].

3. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan performa model dari CNN dengan arsitektur EfficientNet-B0 dalam klasifikasi tipe dan kondisi kulit wajah. Model dilatih menggunakan data yang telah dilakukan *preprocessing*, kemudian dilakukan pelatihan dan evaluasi model dengan penerapan Grad-CAM untuk mendukung interpretasi hasil klasifikasi.

Hasil Pelatihan Model

Penelitian ini melakukan eksperimen dengan membandingkan dua nilai *learning rate*, yaitu 0.001 dan 0.0001, untuk mengevaluasi dampaknya terhadap performa model CNN berbasis EfficientNet-B0 dalam proses klasifikasi tipe dan kondisi kulit wajah. Model dikembangkan menggunakan pendekatan transfer learning dengan bobot prelatih ImageNet, dimana sebagian besar layer pada EfficientNet-B0 dibekukan (*freeze*) dan hanya layer klasifikasi akhir yang dilatih ulang. Pada proses pelatihan, model dikompilasi menggunakan fungsi *loss categorical_crossentropy* dan *optimizer Adam* untuk mendukung klasifikasi multi-kelas secara optimal.



Gambar 6. Grafik Accuracy dan Loss Learning Rate 0.001

Gambar 6 memperlihatkan grafik *accuracy* dan *loss* hasil pelatihan model menggunakan *learning rate* 0.001 selama 5 epoch. Untuk memperjelas perkembangan performa model pada setiap epoch, nilai *accuracy* dan *loss* juga disajikan pada Gambar 7.

Epoch 1/5	354s 4s/step - accuracy: 0.5837 - loss: 1.2704 - val_accuracy: 0.8248 - val_loss: 0.7039
77/77	
Epoch 2/5	292s 4s/step - accuracy: 0.8376 - loss: 0.4824 - val_accuracy: 0.9352 - val_loss: 0.2808
77/77	
Epoch 3/5	277s 4s/step - accuracy: 0.8947 - loss: 0.3330 - val_accuracy: 0.9581 - val_loss: 0.1413
77/77	
Epoch 4/5	279s 4s/step - accuracy: 0.9273 - loss: 0.2228 - val_accuracy: 0.9608 - val_loss: 0.1472
77/77	
Epoch 5/5	278s 4s/step - accuracy: 0.9582 - loss: 0.1401 - val_accuracy: 0.9733 - val_loss: 0.0714
77/77	

Gambar 7. Accuracy dan Loss Learning Rate 0.001

Berdasarkan Gambar 7, akurasi data latih meningkat dari 58,37% pada epoch pertama menjadi 95,02% pada epoch terakhir, diikuti dengan penurunan nilai *loss* dari 1,2704 menjadi 0,1401. Peningkatan nilai akurasi yang diikuti dengan penurunan *loss* menunjukkan bahwa model semakin baik dalam memahami pola data pada setiap epoch. Sedangkan akurasi validasi sejak awal sudah relatif tinggi dan terus meningkat dari 82,48% menjadi 97,33%, diikuti dengan penurunan *loss* dari 0.7039 menjadi 0.0714. Meskipun terjadi penurunan nilai *loss* secara keseluruhan,

pada epoch keempat terlihat adanya peningkatan nilai *loss* dari 0.1413 menjadi 0.1472, tetapi akurasi validasi tetap meningkat. Fenomena ini disebut fluktuasi yang disebabkan proses optimasi model yang masih menyesuaikan bobot pada setiap iterasi. Namun demikian, pada epoch berikutnya nilai *loss* kembali menurun disertai dengan akurasi yang meningkat. Hal ini menunjukkan bahwa model kembali meningkat dan masih berada dalam proses konvergensi menuju performa optimal. Selain itu, nilai *validation loss* yang lebih rendah dibandingkan *training loss* dapat terjadi karena adanya perbedaan mekanisme pada tahap *training* dan *validation*. Pada tahap *training*, model menggunakan data hasil augmentasi yang lebih bervariasi serta mengaktifkan lapisan *Dropout*, sehingga *training loss* cenderung lebih tinggi. Sebaliknya, pada tahap *validation*, data hanya melalui proses *preprocessing* tanpa augmentasi dan *Dropout* dinonaktifkan, sehingga prediksi model menjadi lebih stabil. Oleh karena itu, *validation loss* yang lebih rendah daripada *training loss* merupakan kondisi yang wajar dan menunjukkan bahwa model memiliki kemampuan generalisasi yang baik tanpa indikasi *overfitting*.

Tahap berikutnya dilakukan penggunaan *learning rate* 0.0001 dengan konfigurasi model yang sama. Pada tahap ini, model tetap menggunakan arsitektur EfficientNet-B0 berbasis transfer learning dengan *optimizer* Adam dan fungsi *loss categorical crossentropy*. Penggunaan *learning rate* yang lebih kecil bertujuan untuk menganalisis pengaruh perubahan *learning rate* terhadap performa model dalam proses klasifikasi.



Gambar 8. Grafik Accuracy dan Loss Learning Rate 0.0001

Gambar 8 memperlihatkan grafik *accuracy* dan *loss* hasil pelatihan model menggunakan *learning rate* 0.0001 selama 5 epoch. Pelatihan model dibatasi hingga 5 epoch karena penelitian ini menggunakan pendekatan *transfer learning* dengan EfficientNet-B0 yang telah memiliki *pre-trained weights* dari ImageNet, sehingga model tidak memulai pembelajaran dari awal dan umumnya memerlukan lebih sedikit epoch untuk mencapai performa yang baik. Selain itu, jumlah 5 epoch ini diseragamkan agar perbandingan pengaruh *learning rate* 0,001 dan 0,0001 dilakukan pada kondisi pelatihan yang sama. Meskipun akurasi validasi masih meningkat dan *loss* masih menurun hingga epoch kelima, penambahan epoch berpotensi meningkatkan performa model dan dapat menjadi pengembangan pada penelitian selanjutnya. Untuk memperjelas perkembangan performa model pada setiap epoch, nilai *accuracy* dan *loss* juga disajikan pada Gambar 9.


Epoch 1/5	363s 4s/step - accuracy: 0.2649 - loss: 2.1956 - val_accuracy: 0.5295 - val_loss: 1.5665
77/77	
Epoch 2/5	306s 4s/step - accuracy: 0.4731 - loss: 1.4595 - val_accuracy: 0.7162 - val_loss: 1.1455
77/77	
Epoch 3/5	318s 4s/step - accuracy: 0.5820 - loss: 1.0973 - val_accuracy: 0.8134 - val_loss: 0.8155
77/77	
Epoch 4/5	316s 4s/step - accuracy: 0.6947 - loss: 0.8565 - val_accuracy: 0.8533 - val_loss: 0.5847
77/77	
Epoch 5/5	312s 4s/step - accuracy: 0.7286 - loss: 0.7629 - val_accuracy: 0.8781 - val_loss: 0.4284
77/77	

Gambar 9. Accuracy dan Loss Learning Rate 0.0001

Berdasarkan Gambar 9, model juga mengalami peningkatan performa pada setiap epoch, namun dengan laju yang lebih lambat dibandingkan penggunaan learning rate 0.001. Akurasi data latih meningkat dari 26,49% pada epoch pertama menjadi 72,86% pada epoch kelima, sedangkan nilai loss menurun dari 2,1956 menjadi 0,7629. Pada data validasi, akurasi meningkat dari 52,95% menjadi 87,81% dengan penurunan *validation loss* dari 1,5665 menjadi 0,4284. Peningkatan performa ini menunjukkan bahwa model tetap mampu mempelajari karakteristik data, namun proses konvergensi berlangsung lebih lambat akibat penggunaan *learning rate* yang lebih kecil. Berdasarkan hasil dari kedua percobaan tersebut, *learning rate* sebesar 0.001 memberikan kinerja yang lebih unggul dibandingkan 0.0001 pada tahap transfer learning. Hal ini ditunjukkan oleh nilai *accuracy* yang lebih tinggi serta nilai *loss* yang lebih rendah baik pada data latih maupun data validasi. *Learning rate* 0.001 memungkinkan model melakukan pembaruan bobot secara lebih optimal sehingga proses pelatihan berlangsung lebih cepat dan stabil dalam jumlah epoch yang sama. Sementara itu, *learning rate* 0.0001 menghasilkan proses pelatihan yang lebih lambat sehingga model belum mencapai performa optimal dalam 5 epoch pelatihan.

Evaluasi Model

Evaluasi model menggunakan data uji dilakukan untuk menganalisis pengaruh penggunaan learning rate terhadap performa model CNN berbasis EfficientNet-B0 dalam proses klasifikasi tipe dan kondisi kulit wajah. Hasil evaluasi ditunjukkan pada Gambar 10, di mana model dengan *learning rate* 0.001 memperoleh hasil yang lebih optimal dibandingkan model dengan *learning rate* 0.0001.



Gambar 10. Grafik Test Accuracy dan Loss

Pada penggunaan *learning rate* 0.001, model memperoleh akurasi sebesar 97,52% dengan nilai *loss* sebesar 0,0885. Sementara itu, model dengan *learning rate* 0.0001 memperoleh akurasi sebesar 88,76% dengan nilai *loss* sebesar 0,4191. Perbedaan hasil tersebut menunjukkan bahwa penggunaan *learning rate* 0.001 memperoleh hasil yang lebih optimal dibandingkan *learning rate* 0.0001. Kondisi ini terlihat dari akurasi yang meningkat serta nilai *loss* yang menurun, sehingga model dapat mengklasifikasikan data dengan lebih tepat dan mengurangi kesalahan prediksi. Sebaliknya, *learning rate* 0.0001 menghasilkan proses pembelajaran yang lebih lambat sehingga model belum mencapai performa optimal dalam jumlah epoch yang sama. Secara keseluruhan, hasil evaluasi menunjukkan bahwa pemilihan *learning rate* berpengaruh terhadap performa model dalam klasifikasi tipe dan kondisi kulit wajah.

Confusion Matrix:

```
[[74  0  0  0  0  0]
 [ 0 75  0  0  0  0]
 [ 1  0 74  0  0  0]
 [ 0  0 75  0  0  0]
 [ 0  7  0 26  1  0]
 [ 0  0  0 75  0  0]
 [ 1  0  0  0  0 74]]
```

Classification Report:

	precision	recall	f1-score	support
berjerawat	0.97	0.99	0.98	75
berminyak	0.91	1.00	0.96	75
dermatitis_perioral	0.99	0.99	0.99	75
kering	0.97	1.00	0.99	75
normal	1.00	0.87	0.93	75
penuaan	0.99	1.00	0.99	75
vitiligo	1.00	0.99	0.99	75
accuracy			0.98	525
macro avg	0.98	0.98	0.97	525
weighted avg	0.98	0.98	0.97	525

Gambar 11. Confusion Matrix dan Classification Report Learning Rate 0.001

Berdasarkan Gambar 11, model menunjukkan performa klasifikasi yang optimal pada 525 data uji dari 7 kelas. Pada kelas berjerawat, sebanyak 74 data berhasil terklasifikasi dengan tepat, sementara 1 data

salah diprediksi sebagai dermatitis perioral. Kelas berminyak, kering, dan penuaan berhasil diklasifikasikan seluruhnya dengan benar sebanyak 75 data tanpa kesalahan prediksi. Pada kelas dermatitis perioral, sebanyak 74 data berhasil terklasifikasi dengan tepat, sementara 1 data salah diprediksi sebagai berjerawat. Selanjutnya, kelas normal menjadi kelas dengan jumlah kesalahan prediksi terbanyak, yaitu 65 data berhasil terklasifikasi dengan tepat, sedangkan 7 data salah diprediksi sebagai berminyak, 2 data sebagai kering, dan 1 data sebagai penuaan. Sementara itu, pada kelas vitiligo terdapat 74 data berhasil terklasifikasi dengan tepat, dan 1 data salah diprediksi sebagai berjerawat. Secara umum, *classification report* menunjukkan bahwa model memiliki kinerja yang sangat baik dengan tingkat akurasi mencapai 97,52%, serta nilai *precision*, *recall*, dan *f1-score* yang tinggi pada setiap kelas.

```
Confusion Matrix:
[[70  0  1  1  0  1  2]
 [ 0 53  4  4  8  2  4]
 [ 4  0 70  0  0  0  1]
 [ 0  0 175  0  1  0  0]
 [ 0  7  0 263  0  3]
 [ 0  0  0  1 70  3]
 [ 0  1  2  0  3 267]]
```

		precision	recall	f1-score	support
	berjerawat	0.95	0.93	0.94	75
	berminyak	0.87	0.71	0.78	75
	dermatitis_perioral	0.90	0.93	0.92	75
	kering	0.90	0.97	0.94	75
	normal	0.84	0.84	0.84	75
	penuaan	0.92	0.93	0.93	75
	vitiligo	0.84	0.89	0.86	75
	accuracy			0.89	525
	macro avg	0.89	0.89	0.89	525
	weighted avg	0.89	0.89	0.89	525

Gambar 12. Confusion Matrix dan Classification Report Learning Rate 0.0001

Berdasarkan Gambar 12, jumlah kesalahan prediksi *learning rate* 0.0001 lebih banyak dibandingkan model dengan *learning rate* 0.001. Pada kelas berjerawat, terdapat 70 data berhasil terklasifikasi dengan tepat dan 5 data salah diprediksi ke kelas dermatitis perioral, kering, penuaan, dan vitiligo. Kelas berminyak menjadi kelas dengan jumlah kesalahan tertinggi, dimana hanya 53 data berhasil terklasifikasi dengan tepat, sedangkan data lainnya salah diprediksi sebagai dermatitis perioral, kering, normal, penuaan, dan vitiligo. Pada kelas dermatitis perioral dan penuaan, terdapat 70 data benar dan 5 data salah prediksi ke beberapa kelas

lain. Kelas kering menunjukkan performa yang baik dengan 73 data benar dan hanya 2 data salah diprediksi sebagai dermatitis perioral dan penuaan. Sementara itu, pada kelas normal terdapat 63 data benar dan 12 data salah diprediksi sebagai berminyak, kering, dan vitiligo, sedangkan kelas vitiligo memiliki 67 data benar dan 8 data salah prediksi ke kelas berminyak, dermatitis perioral, normal, dan penuaan. Secara keseluruhan, hasil *classification report* menunjukkan accuracy sebesar 89% dengan nilai *precision*, *recall*, dan *f1-score* yang cukup baik pada sebagian besar kelas.

Hasil Implementasi Penggunaan Grad-CAM

Implementasi Grad-CAM dilakukan untuk menginterpretasikan hasil prediksi model berdasarkan evaluasi model sebelumnya.



Gambar 13. Implementasi Grad-CAM

Gambar 13 menunjukkan hasil Grad-CAM pada dua kelas, yaitu kulit berminyak dan dermatitis perioral. Pada kelas berminyak, model menghasilkan *confidence* 99,96% dengan fokus pada area T-zone yang sesuai dengan karakteristik kulit berminyak. Sementara pada kelas dermatitis perioral, model memberikan *confidence* 99,98% dengan perhatian pada area bercak khas dermatitis perioral. Hal ini menunjukkan bahwa model mampu menangkap fitur spesifik yang menjadi indikator utama dalam proses klasifikasi. Dengan demikian, hasil ini mengindikasikan bahwa model memiliki tingkat interpretabilitas yang baik karena mampu menunjukkan area yang menjadi dasar pengambilan keputusan.

4. SIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi tipe dan kondisi kulit wajah menggunakan EfficientNet-B0 berbasis transfer learning dengan membandingkan penggunaan *learning rate* 0.001 dan 0.0001. Hasil evaluasi menunjukkan bahwa *learning rate* 0.001 menghasilkan *accuracy* sebesar 97,52% sedangkan *learning rate* 0.0001 memperoleh *accuracy* sebesar 88,76%. Hasil *confusion matrix* dan *classification report* juga menunjukkan bahwa model dengan *learning rate* 0.001 memberikan prediksi yang lebih akurat dengan kesalahan lebih sedikit, sehingga *learning rate* berpengaruh signifikan terhadap performa model. Implementasi Grad-CAM juga menunjukkan bahwa model mampu berfokus pada area wajah yang relevan dalam pengambilan keputusan, sehingga mendukung interpretabilitas hasil prediksi. Untuk pengembangan lebih lanjut, peningkatan performa dapat dilakukan melalui penerapan teknik *hyperparameter tuning* yang lebih sistematis serta eksplorasi arsitektur model yang berbeda yang dapat membantu meningkatkan kemampuan model dalam mengekstraksi fitur dan melakukan generalisasi.

DAFTAR PUSTAKA

- [1] D. Aura, A. Sujjada, and I. Lucia, "Implementasi MobileNet dalam Klasifikasi Jenis Kulit Wajah untuk Penentuan Kandungan Skincare," *Jurnal Restikom: Riset Teknik Informatika dan Komputer*, vol. 7, no. 1, pp. 17–24, 2025.
- [2] R. Efata, W. I. Loka, N. Wijaya, and D. Suhartono, "Facial Skin Type Prediction Based on Baumann Skin Type Solutions Theory Using Machine Learning," *TEM Journal*, vol. 12, no. 1, pp. 96–103, 2023, doi: 10.18421/TEM121.
- [3] G. Wibisono, J. Setiawan, and A. Sulaiman, "Skinophile : The Art Of Skincare Selection With Haar Wavelet," *International Journal of Science Technology & Management*, vol. 4, no. 6, pp. 1574–1580, 2023.
- [4] S. Cahyaningsih, A. Triayudi, and I. D. Sholihati, "Kombinasi Metode Certainty Factor dan Forward Chaining untuk Identifikasi Jenis Kulit Wajah Berbasis Android," *Jurnal Media Informatika Budidarma*, vol. 5, pp. 74–82, 2021, doi: 10.30865/mib.v5i1.2591.
- [5] B. Yanto, E. Rouza, L. Fimawahib, B. H. Hayadi, and R. R. Pratama, "Penerapan Algoritma Deep Learning Convolutional Neural Network Dalam Menentukan Kematangan Buah Jeruk Manis Berdasarkan Citra Red Green Blue (RGB)," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 10, no. 1, pp. 59–66, 2023, doi: 10.25126/jtiik.2023105695.
- [6] A. P. Gani and E. Poerwandono, "Pengembangan Aplikasi Android Berbasis Machine Learning untuk Pendeteksi Jenis Kulit Wajah Menggunakan Deep Learning," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 6, pp. 9551–9557, 2025.
- [7] W. P. Ching, S. S. Abdullah, M. I. Shapiai, and A. K. M. M. Islam, "Transfer Learning for Alzheimer ' s Disease Diagnosis Using EfficientNet-B0 Convolutional Neural Network," *Journal of Advanced Research in Applied Sciences and Engineering Technology*, vol. 1, no. 1, pp. 181–191, 2024.
- [8] Cleveland Clinic, "Understanding Skin Types." Accessed: May 03, 2026. [Online]. Available: <https://health.clevelandclinic.org/understanding-skin-types>
- [9] Healthline, "Skin Disorders:

- Pictures, Causes, Symptoms, and Treatment.” Accessed: May 03, 2026. [Online]. Available: <https://www.healthline.com/health/skin-disorders>
- [10] R. Angga, B. Kusuma, B. Irawan, and A. Khamid, “Klasifikasi Penyakit Kulit Wajah Menggunakan Convolutional Neural Network EfficientNet-B3,” *JITET (Jurnal Informatika dan Teknik Elektro Terapan)*, vol. 14, no. 1, 2026.
- [11] A. Y. I. Prayoga and D. T. D. Perdana, “Sistem Klasifikasi Tipe Kulit Wajah Menggunakan Convolutional Neural Network dengan Rekomendasi Tahap Perawatan Kulit,” *Pros. Seminar Nasional Teknologi Dan Sains*, vol. 5, pp. 255–268, 2026.
- [12] M. H. Rahmatullah and I. N. S. Budi Darma Setiawan, “Analisis Komparatif Arsitektur CNN untuk Klasifikasi Sampah: Studi Trade-Off Efisiensi Vs Akurasi (Studi pada MobileNetV3, ResNet50, dan EfficientNetB3),” *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 10, no. 2, 2026.
- [13] A. Bastian *et al.*, “Explainable Deep Learning for Beef Freshness Classification Using Grad-CAM Visualization,” *Infotech Journal*, vol. 11, no. 2, pp. 495–500, 2025.
- [14] IGecko, “Dataset Klasifikasi Kulit Wajah,” Kaggle. Accessed: Mar. 07, 2026. [Online]. Available: <https://www.kaggle.com/datasets/igeko/dataset-klasifikasi-kulit-wajah>
- [15] N. F. Khofifah, I. P. M. Pratama, A. A. Khairunnisa, and A. P. Sari, “Analisis Sentimen terhadap Gerakan Boikot di X #Boycott Menggunakan Support Vector Machine,” *JIP (Jurnal Informatika Polinema)*, vol. 11, no. 4, pp. 407–416, 2024.
- [16] N. H. Reiza Dwi Karunia, “Analisis Data dan Visualisasi Pola Ancaman Siber Global (2015 - 2024),” *DINAMIK*, vol. 30, no. 2, pp. 203–211, 2025.
- [17] R. Aulia and W. Husna, “Klasifikasi Jenis Buah Mangga Menggunakan Convolutional Neural Network (CNN) Berbasis Citra Digital,” *JITSI: Jurnal Ilmiah Teknologi Sistem Informasi*, vol. 6, no. 4, pp. 417–421, 2025, doi: 10.62527/jitsi.
- [18] S. Aulia and D. Rahmat, “Brain Tumor Identification Based on VGG-16 Architecture and CLAHE Method,” *JOIV: International Journal on Informatics Visualization*, vol. 6, pp. 96–102, 2022.
- [19] Y. Miftahuddin and F. Z. S, “Perbandingan Metode Efficientnet-B3 dan Mobilenet-V2 Untuk Identifikasi Jenis Buah-buahan Menggunakan Fitur Daun,” *Jurnal Ilmiah Teknologi Informasi Terapan*, vol. 9, no. 1, pp. 1–11, 2022.
- [20] A. R. Dianto, F. T. Anggraeny, and H. Maulana, “Analisis Efektivitas Algoritma MobileNetV3-Large dan EfficientNet-B0 untuk Klasifikasi Citra Penyakit Daun Jeruk,” *JITET (Jurnal Informatika dan Teknik Elektro Terapan)*, vol. 13, no. 3, 2025.
- [21] A. P. Sari, A. A. Widoretno, F. P. Aditiawan, and A. M. Rizki, “Peningkatan Ekonomi Digital pada Usaha Kerajinan Kulit melalui Optimalisasi Teknologi Informasi,” *Jurnal Pengabdian kepada Masyarakat Nusantara (JPkMN)*, vol. 6, pp. 397–402, 2024.