

KLASIFIKASI JENIS KULIT WAJAH MANUSIA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK DENGAN ARSITEKTUR MOBILENETV3-LARGE

Zuhri Halim^{1*}, Abdul Fadlil², Herman Yuliansyah³

^{1,3}Program Studi Informatika, Universitas Ahmad Dahlan, Yogyakarta, Indonesia

²Program Studi Teknik Elektro, Universitas Ahmad Dahlan, Yogyakarta, Indonesia

Correspondence email: 2537083009@webmail.uad.ac.id

Article history: Revised: May 8, 2026

Accepted: May 12, 2026

Published: June 7, 2026

ABSTRACT

Facial skin type determination is a critical aspect in the development of digital skincare recommendation systems and technology-based dermatological services. However, skin identification methods that rely on manual assessment still present several limitations, as they are subjective, time-consuming, and highly dependent on the observer's expertise. To address these issues, this study proposes an automated approach for facial skin type classification using Convolutional Neural Networks (CNNs) with a transfer learning scheme. Three computationally efficient CNN architectures MobileNet, MobileNetV2, and MobileNetV3-Large were employed and evaluated comparatively. This study utilized a dataset consisting of 2,250 facial images categorized into five skin types, namely Combination, Dry, Normal, Oily, and Sensitive. The dataset was divided into 1,800 images for training, 225 images for validation, and 225 images for testing to ensure objective performance evaluation. All images were normalized and resized to 224×224 pixels prior to model processing. Model training was conducted using two epoch configurations, specifically 5, 10, 20, 30, 50 and 100 epochs, to examine the effect of training duration on classification performance. The experimental results indicate that increasing the number of training epochs has a positive impact on the accuracy of all evaluated models. Among the three architectures, MobileNetV3-Large achieved the best performance, attaining a test accuracy of 100% at 100 epochs and demonstrating superior generalization capability, particularly in distinguishing skin types with similar visual characteristics, such as Sensitive and Combination. These findings confirm that appropriate CNN architecture selection and training configuration play a crucial role in enhancing facial skin type classification performance and highlight the potential applicability of the proposed approach in mobile-based applications.

Keywords: Facial Skin Type Classification, Convolutional Neural Network, Mobilenet, Transfer Learning, Facial Images.

ABSTRAK

Penentuan jenis kulit wajah merupakan aspek penting dalam pengembangan sistem rekomendasi perawatan kulit serta layanan dermatologi berbasis teknologi digital. Namun, metode identifikasi yang masih dilakukan secara manual memiliki keterbatasan karena bersifat subjektif, memerlukan waktu, dan sangat bergantung pada pengalaman pengamat. Untuk mengatasi permasalahan tersebut, penelitian ini mengusulkan pendekatan otomatis dalam mengklasifikasikan jenis kulit wajah menggunakan *Convolutional Neural Network* (CNN) dengan skema transfer learning. Tiga arsitektur CNN yang berorientasi pada efisiensi komputasi, yaitu MobileNet, MobileNetV2, dan MobileNetV3-Large, digunakan dan dianalisis kinerjanya secara komparatif. Penelitian ini memanfaatkan dataset sebanyak 2.250 citra wajah yang dikelompokkan ke dalam lima kategori jenis kulit, meliputi *Combination*, *Dry*, *Normal*, *Oily*, dan *Sensitive*. Dataset tersebut dibagi menjadi 1.800 citra untuk pelatihan, 225 citra untuk validasi, dan 225 citra untuk pengujian guna menjaga objektivitas evaluasi. Seluruh citra dinormalisasi dan diubah ukurannya menjadi 224×224 piksel sebelum diproses oleh model. Proses pelatihan dilakukan dengan dua variasi jumlah epoch, yaitu 5, 10, 20, 30, 50, dan 100 epoch, untuk mengamati pengaruh durasi pelatihan terhadap performa model. Hasil pengujian menunjukkan bahwa peningkatan jumlah epoch berdampak positif terhadap akurasi ketiga model. MobileNetV3-Large menghasilkan kinerja terbaik dengan akurasi data uji sebesar 100% pada 100 epoch dan menunjukkan kemampuan generalisasi yang lebih baik, terutama dalam membedakan jenis kulit yang memiliki kemiripan karakteristik visual, seperti *Sensitive* dan *Combination*. Temuan ini menegaskan bahwa pemilihan arsitektur



CNN serta pengaturan pelatihan yang tepat sangat berpengaruh terhadap keberhasilan sistem klasifikasi jenis kulit wajah dan memiliki potensi untuk diterapkan pada aplikasi berbasis *mobile*.

Kata Kunci: Klasifikasi Jenis Kulit Wajah, *Convolutional Neural Network*, *MobileNet*, *Transfer Learning*, Citra Wajah.

PENDAHULUAN

Perkembangan teknologi kecerdasan buatan (*Artificial Intelligence/AI*) telah mendorong kemajuan signifikan dalam bidang pengolahan citra digital, khususnya melalui pendekatan *deep learning* (Zhang et al., 2021). Salah satu arsitektur *deep learning* yang banyak digunakan dalam analisis citra adalah *Convolutional Neural Network* (CNN), yang mampu mengekstraksi fitur secara otomatis dan hierarkis langsung dari data citra mentah. Kemampuan ini menjadikan CNN unggul dibandingkan metode konvensional yang masih bergantung pada perancangan fitur secara manual (Maulana & Rochmawati, 2020).

Penerapan CNN pada citra wajah menunjukkan kinerja yang menjanjikan dalam berbagai tugas klasifikasi. Penelitian Tinaliah, (2021) membuktikan bahwa CNN mampu mengklasifikasikan ekspresi wajah manusia secara akurat berdasarkan karakteristik visual pada citra. Hal ini menunjukkan bahwa CNN memiliki kemampuan representasi fitur yang kuat untuk menangkap variasi tekstur dan pola visual yang kompleks pada citra wajah.

Dalam konteks dermatologi dan perawatan kulit, identifikasi jenis kulit wajah merupakan aspek penting untuk menentukan rekomendasi perawatan yang tepat. Jenis kulit wajah umumnya diklasifikasikan ke dalam lima kategori, yaitu normal, kering, berminyak, kombinasi, dan sensitif (Mosca & Morrone, 2023; Ran et al., 2024). Namun, proses identifikasi yang masih dilakukan secara manual cenderung bersifat subjektif dan bergantung pada pengalaman pengamat, sehingga berpotensi menghasilkan ketidakkonsistenan hasil. Kondisi ini mendorong perlunya sistem otomatis berbasis citra digital yang mampu mengklasifikasikan jenis kulit wajah secara objektif dan konsisten.

Pendekatan CNN memungkinkan sistem untuk mempelajari karakteristik visual kulit wajah secara langsung dari data citra (Abdul Aziz et al., 2024). Penelitian Farokhah, (2017) menunjukkan bahwa CNN efektif dalam mengenali variasi intensitas dan pola visual pada citra, yang relevan untuk membedakan karakteristik antar kelas yang memiliki kemiripan visual. Selain itu, penelitian Agustina, (2024) menyatakan bahwa penggunaan CNN mampu menghasilkan kinerja klasifikasi yang baik dalam pengenalan jenis kulit wajah

berbasis citra digital, sehingga memperkuat potensi penerapan CNN pada domain ini.

Meskipun CNN memiliki performa yang baik, arsitektur CNN konvensional umumnya memiliki kompleksitas komputasi yang tinggi (Anton et al., 2021). Tantangan ini menjadi penting ketika sistem dirancang untuk diimplementasikan pada aplikasi berbasis *mobile* yang memiliki keterbatasan sumber daya. Oleh karena itu, pemilihan arsitektur CNN yang efisien serta pengaturan parameter pelatihan, seperti jumlah epoch, menjadi faktor krusial dalam meningkatkan kinerja model tanpa meningkatkan beban komputasi secara berlebihan (Dewi & Ismawan, 2021).


Penelitian Saiwaeo et al., (2023) menunjukkan bahwa CNN mampu mengklasifikasikan jenis kulit manusia secara efektif menggunakan pendekatan *image processing* dan *deep learning*. Penelitian tersebut menegaskan bahwa CNN termasuk arsitektur yang memiliki kemampuan yang baik dalam mengekstraksi fitur tekstur kulit dan membedakan karakteristik visual antar jenis kulit normal, *oily* dan *dry*.

Berdasarkan uraian tersebut, penelitian ini bertujuan untuk menerapkan dan mengevaluasi kinerja *Convolutional Neural Network* dalam klasifikasi jenis kulit wajah berbasis citra digital dengan mempertimbangkan aspek akurasi dan efisiensi komputasi. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem identifikasi jenis kulit wajah normal, kering (*dry*), berminyak (*oily*), kombinasi (*Combination*) dan sensitif (*Sensitive*) yang objektif dan berpotensi untuk diimplementasikan pada aplikasi berbasis *mobile*.

METODE PENELITIAN

Penelitian ini menerapkan metodologi pengembangan sistem berbasis *deep learning* dengan menggunakan *Convolutional Neural Network* (CNN) dapat dilihat pada Gambar 1, untuk mengklasifikasikan jenis kulit wajah manusia. Arsitektur utama yang digunakan adalah *MobileNet* sebagai *baseline* model, dengan analisis perbandingan kinerja terhadap *MobileNetV2* dan *MobileNetV3-Large* (A. Howard et al., 2019). Pendekatan ini dipilih untuk memperoleh model klasifikasi yang memiliki tingkat akurasi yang baik, efisiensi komputasi yang tinggi, serta sesuai untuk

diimplementasikan pada perangkat dengan sumber daya komputasi terbatas, khususnya perangkat bergerak.



Gambar 1. Diagram Alur Proses Penelitian

Tahapan penelitian diawali dengan identifikasi permasalahan dalam klasifikasi jenis kulit wajah, yang selama ini masih banyak bergantung pada observasi manual dan bersifat subjektif, sehingga berpotensi menimbulkan ketidakkonsistenan dalam penentuan jenis kulit. Oleh karena itu, penelitian ini mengusulkan pendekatan berbasis CNN untuk meningkatkan objektivitas, konsistensi, dan efisiensi proses klasifikasi. Selanjutnya, tahapan penelitian diuraikan sebagai berikut.

A. Pengumpulan dan Praproses Data (Sesuai Implementasi Kode)

Tahap pengumpulan dan praproses data pada penelitian ini dilakukan dengan pendekatan berbasis direktori (*directory-based dataset loading*) menggunakan framework TensorFlow. Dataset citra kulit wajah disusun dalam struktur folder yang terpisah untuk data pelatihan (*Train*), validasi (*Validation*), dan pengujian (*Test*) (Akbar et al., 2024; Sunnam & Obulesh, 2022). Setiap folder utama berisi subfolder yang merepresentasikan kelas

jenis kulit wajah, yaitu normal, kering, berminyak, kombinasi dan sensitif sehingga proses pelabelan dapat dilakukan secara otomatis berdasarkan nama direktori (Farage, 2019; Irwansyah et al., 2025).

1. Pemisahan dan Struktur Dataset

Dataset dibagi ke dalam tiga subset dengan tujuan yang berbeda:

- Data pelatihan (*training*) digunakan untuk melatih bobot model CNN (S et al., 2022).
- Data validasi (*validation*) digunakan untuk memantau kinerja model selama proses pelatihan dan mencegah *overfitting*.
- Data pengujian (*testing*) digunakan untuk mengevaluasi performa akhir model terhadap data yang belum pernah dilihat sebelumnya (Fadlil et al., 2025).

Struktur direktori dataset dirancang agar kompatibel dengan fungsi `'image_dataset_from_directory'`, yang memungkinkan pemuatan data secara efisien dan terintegrasi langsung dengan *pipeline* TensorFlow.

2. Pra-pemrosesan Data (*Pre-processing*)

Sebelum digunakan dalam proses pelatihan, seluruh citra melalui tahap pra-pemrosesan untuk menyeragamkan format dan meningkatkan variasi data. Tahapan pra-pemrosesan yang dilakukan meliputi:

- Resizing*: Seluruh citra diubah ukurannya menjadi 224×224 piksel agar sesuai dengan ukuran input model MobileNet.
- Konversi RGB: Citra dikonversi ke format warna RGB untuk memastikan konsistensi jumlah kanal warna pada seluruh data (Khoirunnisa et al., 2025).
- Rotasi 90° : Citra diputar sebesar 90 derajat untuk meningkatkan variasi orientasi objek.
- Rotasi 180° : Citra diputar sebesar 180 derajat sebagai bentuk augmentasi data.
- Flip Horizontal*: Citra dibalik secara horizontal untuk menambah variasi data pelatihan.
- Flip Vertical*: Citra dibalik secara vertikal guna meningkatkan kemampuan model dalam mengenali objek dari berbagai posisi.

3. Pemrosesan dan Pelabelan Otomatis Data

Pemuatan dataset dilakukan menggunakan fungsi `'tf.keras.utils.image_dataset_from_directory'`. Pada tahap ini, citra kulit wajah dimuat secara otomatis dari folder, kemudian:

- Ukuran citra diseragamkan menjadi 224×224 piksel, sesuai dengan spesifikasi *input* arsitektur MobileNet, MobileNetV2, dan

- MobileNetV3-Large (A. G. Howard et al., 2017; Sandler et al., 2018).
- b. Pelabelan data dilakukan secara otomatis dengan mode `'label_mode='int'`, di mana setiap kelas direpresentasikan dalam bentuk bilangan bulat (*integer encoding*).
 - c. Ukuran *batch* (*batch size*) ditetapkan sebesar 32 untuk menyeimbangkan efisiensi komputasi dan stabilitas proses pelatihan.
 - d. Pengacakan data (*shuffle*) diterapkan pada data pelatihan dan validasi untuk meningkatkan generalisasi model, sementara data pengujian tidak diacak agar hasil evaluasi bersifat konsisten dan dapat direproduksi.
 - e. Kelas jenis kulit wajah diekstraksi secara otomatis dari struktur direktori dan disimpan dalam variabel `'class_names'`, yang kemudian digunakan untuk menentukan jumlah kelas (*num_classes*) pada lapisan keluaran model CNN.
4. Optimalisasi Pipeline Data
- Untuk meningkatkan efisiensi proses pelatihan, dataset yang telah dimuat dioptimalkan menggunakan teknik *prefetching* dengan parameter `'AUTOTUNE'`. Teknik ini memungkinkan TensorFlow memuat *batch* data berikutnya secara paralel selama proses pelatihan berlangsung, sehingga waktu tunggu antara iterasi pelatihan dapat diminimalkan. Optimalisasi ini diterapkan pada seluruh subset dataset, yaitu data pelatihan, validasi, dan pengujian, guna memastikan pemanfaatan sumber daya komputasi yang lebih efektif.
- B. Keterkaitan Praproses Data dengan Implementasi Model
- Praproses data yang dilakukan secara otomatis melalui *pipeline* TensorFlow memastikan bahwa seluruh citra yang masuk ke dalam model CNN telah memiliki ukuran yang seragam, label yang terstruktur, serta format batch yang konsisten. Hal ini mendukung penerapan *transfer learning* pada arsitektur MobileNet, MobileNetV2, dan MobileNetV3-Large yang membutuhkan input citra berukuran tetap (Kara et al., 2023).
- Ketiga model tersebut dipilih karena memiliki kompleksitas yang relatif rendah namun tetap mampu menghasilkan performa klasifikasi yang baik pada perangkat dengan sumber daya komputasi terbatas. Proses optimasi parameter model dilakukan menggunakan optimizer Adam dengan learning rate sebesar 1×10^{-4} (0,0001) (Raza et al., 2025).
- Untuk menganalisis pengaruh jumlah iterasi pelatihan terhadap performa model, eksperimen dilakukan pada beberapa variasi jumlah epoch, yaitu: 5, 10, 20, 30, 50, dan 100 epoch.
- C. Arsitektur dan Perancangan Model CNN Berbasis MobileNet
- Pada penelitian ini, perancangan model CNN dilakukan dengan memanfaatkan arsitektur MobileNet, MobileNetV2, dan MobileNetV3-Large sebagai model dasar (*base model*) yang telah dilatih sebelumnya pada dataset ImageNet. Ketiga arsitektur tersebut digunakan untuk melakukan klasifikasi jenis kulit wajah dengan pendekatan *transfer learning*, yang bertujuan untuk memanfaatkan kemampuan ekstraksi fitur visual yang telah dipelajari dari dataset berskala besar.
1. Struktur Dasar Model (*Base Model*)
- Setiap model CNN dibangun dengan menghilangkan lapisan klasifikasi bawaan (`include_top = False`) pada arsitektur MobileNet, sehingga model hanya berfungsi sebagai ekstraktor fitur. Bobot pada seluruh lapisan konvolusi pada base model dibekukan (*freeze*) dengan menetapkan `'trainable' = False`. Pendekatan ini bertujuan untuk:
- a) Mengurangi beban komputasi selama pelatihan,
 - b) Mencegah terjadinya *overfitting* akibat jumlah data yang terbatas,
 - c) Mempertahankan representasi fitur visual umum yang telah dipelajari dari ImageNet.
2. Lapisan *Input* dan Praproses Citra
- Setiap model menerima masukan berupa citra wajah berukuran 224×224 piksel dengan tiga kanal warna (RGB). Sebelum diproses oleh base model, citra masukan terlebih dahulu melalui fungsi `'preprocess_input'` yang spesifik untuk masing-masing arsitektur MobileNet (Yuliansyah et al., 2026). Tahap praproses ini bertujuan untuk menyesuaikan distribusi nilai piksel citra agar konsisten dengan kondisi pelatihan awal model pada dataset ImageNet.
3. Perancangan Lapisan Klasifikasi (*Classification Head*)
- Setelah melalui base model, fitur hasil ekstraksi diproses oleh lapisan klasifikasi yang dirancang khusus untuk kebutuhan penelitian ini. Lapisan klasifikasi tersebut terdiri dari:
- a) *Global Average Pooling* 2D, yang berfungsi untuk mereduksi dimensi fitur dan mengurangi jumlah parameter model.
 - b) *Dropout* dengan tingkat 0,3, yang diterapkan sebagai mekanisme regularisasi untuk mengurangi risiko *overfitting*.

- c) Lapisan Dense dengan jumlah neuron sesuai dengan jumlah kelas jenis kulit wajah dan fungsi aktivasi Softmax, yang digunakan untuk melakukan klasifikasi multikelas.
 - d) Lapisan klasifikasi ini ditambahkan di atas base model tanpa mengubah struktur konvolusi utama, sehingga karakteristik *transfer learning* tetap terjaga.
4. Perbandingan Arsitektur Model
- Ketiga model CNN dibangun menggunakan skema arsitektur yang serupa pada bagian classification head, sehingga perbedaan kinerja yang dihasilkan terutama berasal dari perbedaan desain internal masing - masing *base model*. Dengan pendekatan ini, perbandingan performa antara MobileNet, MobileNetV2, dan MobileNetV3-Large dapat dilakukan secara adil dan sistematis berdasarkan arsitektur ekstraksi fitur yang digunakan (Helmawati et al., 2025).
- D. Pengujian Model Menggunakan Sampel Citra Per Kelas
- Setelah proses pelatihan dan evaluasi kuantitatif selesai, dilakukan pengujian tambahan secara kualitatif dengan menampilkan satu citra per kelas dari data pengujian (*test dataset*). Pengujian ini bertujuan untuk memverifikasi kemampuan model dalam mengklasifikasikan jenis kulit wajah secara visual serta memastikan konsistensi antara proses praproses data pada tahap pelatihan dan pengujian.
1. Pemilihan Data Uji
- Pada tahap ini, satu citra dipilih secara acak dari masing masing kelas jenis kulit wajah pada folder *Test*, yaitu normal, berminyak, kering, kombinasi dan sensitif (Xie et al., 2025). Pemilihan dilakukan secara acak untuk menghindari bias pemilihan sampel dan memastikan bahwa citra yang digunakan belum pernah dilihat oleh model selama proses pelatihan.
2. Praproses Citra pada Tahap Pengujian
- Setiap citra yang dipilih diproses menggunakan tahapan praproses yang identik dengan proses pelatihan model, sesuai dengan implementasi kode. Tahapan praproses tersebut meliputi:
- a) Citra dibaca menggunakan pustaka *Python Imaging Library* (PIL) dalam format RGB.
 - b) Ukuran citra disesuaikan menjadi 224×224 piksel, sesuai dengan spesifikasi input arsitektur MobileNet, MobileNetV2, dan MobileNetV3-Large.
 - c) Nilai piksel citra dipertahankan dalam rentang 0–255, sehingga konsisten dengan konfigurasi praproses pada tahap pelatihan.
 - d) Citra kemudian diubah menjadi bentuk batch dengan dimensi `(1, 224, 224, 3)` sebelum diberikan sebagai masukan ke model.
- Pendekatan ini memastikan bahwa perbedaan hasil prediksi tidak dipengaruhi oleh ketidaksesuaian praproses antara data pelatihan dan data pengujian.
3. Proses Prediksi Model
- Citra uji yang telah diproses selanjutnya diberikan sebagai masukan ke tiga model CNN yang digunakan dalam penelitian, yaitu MobileNet, MobileNetV2, dan MobileNetV3-Large (Khoirunnisa et al., 2026). Masing - masing model menghasilkan vektor probabilitas untuk setiap kelas jenis kulit wajah. Kelas prediksi ditentukan berdasarkan nilai probabilitas tertinggi (*argmax*) dari keluaran Softmax. Selain label prediksi, nilai probabilitas juga ditampilkan untuk menunjukkan tingkat kepercayaan model terhadap hasil klasifikasi.
4. Visualisasi dan Analisis Hasil
- Hasil pengujian divisualisasikan dengan menampilkan citra asli beserta label kelas sebenarnya. Selanjutnya, hasil prediksi dari ketiga model ditampilkan dalam bentuk teks yang mencakup:
- a) Nama file citra uji,
 - b) Label prediksi dari MobileNet, MobileNetV2, dan MobileNetV3-Large.
 - c) Nilai probabilitas prediksi dari masing - masing model.
- Visualisasi ini digunakan sebagai alat bantu analisis kualitatif untuk membandingkan konsistensi dan perbedaan prediksi antar model, serta untuk mengidentifikasi potensi kesalahan klasifikasi pada jenis kulit tertentu.

HASIL DAN PEMBAHASAN

Dataset yang digunakan dalam penelitian ini terdiri dari 2.250 citra wajah yang terbagi ke dalam lima kelas jenis kulit, yaitu *Combination*, *Dry*, *Normal*, *Oily*, dan *Sensitive* dapat dilihat pada Gambar 2. Pada Tabel 1, dataset dibagi ke dalam tiga subset utama, yaitu data latih sebanyak 1.800 citra, data validasi sebanyak 225 citra, dan data uji sebanyak 225 citra (https://figshare.com/articles/dataset/Skin_Type_Identification/29634428?file=56519258).



Tabel 1. Distribusi Dataset Berdasarkan Subset dan Jenis Kulit

Subset Dataset	Jumlah Citra	Jumlah Kelas	Jenis Kulit
Data Latih (Training)	1.800	5	Combination, Dry, Normal, Oily, Sensitive
Data Validasi (Validation)	225	5	Combination, Dry, Normal, Oily, Sensitive
Data Uji (Testing)	225	5	Combination, Dry, Normal, Oily, Sensitive
Total	2.250	5	Combination, Dry, Normal, Oily, Sensitive

Jenis kulit wajah yang digunakan pada penelitian ini ada 5 yaitu: *Combination*, *Dry*, *Normal*, *Oily*, dan *Sensitive*.



Gambar 2. Lima Jenis Kulit: *Combination*, *Dry*, *Normal*, *Oily*, dan *Sensitive*

Secara keseluruhan, ketiga model menunjukkan karakteristik yang berbeda:

- MobileNet unggul dalam kesederhanaan arsitektur dan stabilitas pelatihan dapat dilihat pada Gambar 3.
- MobileNetV2 memberikan parameter paling tinggi dengan kapasitas fitur yang besar dapat dilihat pada Gambar 4.
- MobileNetV3-Large memberikan kompromi antara kompleksitas dan performa melalui optimasi arsitektur modern dapat dilihat pada Gambar 5.

Penggunaan *Global Average Pooling* dan *Dropout* pada ketiga model terbukti efektif dalam menekan risiko *overfitting*, terutama mengingat jumlah data yang terbatas. Perbedaan jumlah dan dimensi fitur akhir mempengaruhi kemampuan masing-masing model dalam mempelajari karakteristik visual jenis kulit wajah, yang selanjutnya tercermin pada perbedaan kinerja akurasi dan generalisasi model.

Model: "MobileNet"		
Layer (type)	Output Shape	Param #
input_layer_1 (InputLayer)	(None, 224, 224, 3)	0
true_divide (TrueDivide)	(None, 224, 224, 3)	0
subtract (Subtract)	(None, 224, 224, 3)	0
mobilenet_1.00_224 (Functional)	(None, 7, 7, 1024)	3,228,864
global_average_pooling2d (GlobalAveragePooling2D)	(None, 1024)	0
dropout (Dropout)	(None, 1024)	0
dense (Dense)	(None, 5)	5,125
Total params: 3,233,989 (12.34 MB)		
Trainable params: 5,125 (20.02 KB)		
Non-trainable params: 3,228,864 (12.32 MB)		

Gambar 3. Arsitektur Model MobileNet *Pre-trained*

Model: "MobileNetV2"		
Layer (type)	Output Shape	Param #
input_layer_3 (InputLayer)	(None, 224, 224, 3)	0
true_divide_1 (TrueDivide)	(None, 224, 224, 3)	0
subtract_1 (Subtract)	(None, 224, 224, 3)	0
mobilenetv2_1.00_224 (Functional)	(None, 7, 7, 1280)	2,257,984
global_average_pooling2d_1 (GlobalAveragePooling2D)	(None, 1280)	0
dropout_1 (Dropout)	(None, 1280)	0
dense_1 (Dense)	(None, 5)	6,405
Total params: 2,264,389 (8.64 MB)		
Trainable params: 6,405 (25.02 KB)		
Non-trainable params: 2,257,984 (8.61 MB)		


Gambar 4. Arsitektur Model MobileNetV2 *Pre-trained*

Model: "MobileNetV3Large"		
Layer (type)	Output Shape	Param #
input_layer_5 (InputLayer)	(None, 224, 224, 3)	0
MobileNetV3Large (Functional)	(None, 7, 7, 960)	2,996,352
global_average_pooling2d_2 (GlobalAveragePooling2D)	(None, 960)	0
dropout_2 (Dropout)	(None, 960)	0
dense_2 (Dense)	(None, 5)	4,805
Total params: 3,001,157 (11.45 MB)		
Trainable params: 4,805 (18.77 KB)		
Non-trainable params: 2,996,352 (11.43 MB)		

Gambar 5. Arsitektur Model MobileNetV3-Large *Pre-trained*

Pengujian pada citra uji dari tiap kelas jenis kulit menunjukkan bahwa MobileNet, MobileNetV2, dan MobileNetV3-Large mampu melakukan klasifikasi secara konsisten, meskipun terdapat perbedaan probabilitas antar arsitektur.

Pada Gambar 6 Grafik perbandingan akurasi uji pada rentang 5 ke 100 epoch menganalisis konvergensi, stabilitas pelatihan, dan kemampuan generalisasi model MobileNetV3-Large menunjukkan performa terbaik dengan akurasi uji mencapai 100%.




Gambar 6. Perbandingan Akurasi Model Terhadap Epoch

Pengujian dilakukan dengan jumlah epoch pelatihan, yaitu 5, 10, 20, 30, 50, dan 100 epoch, terhadap ketiga arsitektur model MobileNet, MobileNetV2, dan MobileNetV3-Large. 5-100 epoch dilakukan untuk menganalisis pengaruh jumlah iterasi pelatihan terhadap kemampuan generalisasi model dalam mengklasifikasikan lima jenis kulit wajah. Hasil perbandingan akurasi uji pada setiap konfigurasi epoch disajikan pada Tabel 2.

Tabel 2. Perbandingan Akurasi Test Epoch

Epoch	MobileNet	MobileNetV2	MobileNetV3-Large
5	0.755556	0.791111	0.800000
10	0.875556	0.875556	0.888889
20	0.933333	0.915556	0.946667
30	0.946667	0.942222	0.960000
50	0.964444	0.955556	0.986667
100	0.977778	0.968889	1.000000

Gambar 7 menampilkan *confusion matrix* tiga model CNN (MobileNet, MobileNetV2, MobileNetV3-Large) untuk klasifikasi 5 kelas kulit. Nilai tinggi pada diagonal utama menunjukkan prediksi yang benar dan dominan, sehingga ketiga model memiliki akurasi tinggi. Kesalahan klasifikasi relatif sangat sedikit dan umumnya terjadi antar kelas yang mirip. Secara keseluruhan, MobileNetV3-Large tampak paling konsisten dengan kesalahan paling minimal dibanding dua model lainnya.



Gambar 7. *Confusion Matrix CNN Models*

Evaluasi performa model klasifikasi dilakukan menggunakan *confusion matrix* untuk mengukur tingkat akurasi prediksi pada data uji. Akurasi dihitung berdasarkan perbandingan antara jumlah prediksi yang benar terhadap total keseluruhan data uji. Secara umum, rumus akurasi dinyatakan sebagai berikut.

$$Accuracy = (TP + TN) / (TP + TN + FP + FN) \dots (1)$$

Karena penelitian ini menggunakan klasifikasi multi-kelas dengan lima kategori jenis kulit wajah, yaitu *Combination* (C), *Dry* (D), *Normal* (N), *Oily* (O), dan *Sensitive* (S), maka rumus akurasi diekspansi untuk setiap kelas sebagaimana ditunjukkan pada persamaan berikut.

$$Accuracy = \frac{(TP+TN)_C + (TP+TN)_D + (TP+TN)_N + (TP+TN)_O + (TP+TN)_S}{(TP+TN+FP+FN)_C + (TP+TN+FP+FN)_D + (TP+TN+FP+FN)_N + (TP+TN+FP+FN)_O + (TP+TN+FP+FN)_S} \dots (2)$$

Pada *confusion matrix* multi-kelas, nilai TP+TN per kelas setara dengan elemen diagonal *confusion matrix*, sehingga dapat disederhanakan menjadi persamaan berikut.

$$Accuracy = \frac{\sum \text{Diagonal Confusion Matrix}}{N} \times 100\% \dots (3)$$


Di mana N adalah total data uji. Nilai diagonal diperoleh dari elemen diagonal pada *confusion matrix* yang merepresentasikan jumlah prediksi benar untuk masing-masing kelas.

Pengujian dilakukan terhadap 225 data uji yang terdiri dari lima kelas kulit wajah. Berdasarkan hasil *confusion matrix* pada Gambar 7, MobileNet menghasilkan 220 prediksi benar dari 225 data uji ($44 + 45 + 45 + 42 + 44$), sehingga diperoleh akurasi sebesar 97,78%. MobileNetV2 menghasilkan 218 prediksi benar ($42 + 45 + 44 + 44 + 43$) dengan akurasi sebesar 96,89%. Adapun MobileNetV3-Large berhasil mengklasifikasikan seluruh 225 data uji dengan benar ($45 + 45 + 45 + 45 +$

45), sehingga menghasilkan akurasi sempurna sebesar 100,00%.

Hasil tersebut menunjukkan bahwa ketiga model mampu melakukan klasifikasi jenis kulit wajah dengan tingkat akurasi yang tinggi. MobileNetV3-Large menunjukkan performa terbaik dibandingkan MobileNet dan MobileNetV2, yang mengindikasikan bahwa arsitektur yang lebih dalam dan kompleks memberikan kemampuan ekstraksi fitur yang lebih baik dalam membedakan kelima jenis kulit wajah.

Pada Gambar 8 ditunjukkan kurva akurasi dan loss model MobileNetV3-Large selama 100 epoch. Kurva akurasi pelatihan dan validasi meningkat secara cepat pada epoch awal, kemudian stabil mendekati nilai maksimum, menunjukkan konvergensi yang baik. Sementara itu, kurva loss pelatihan dan validasi menurun secara konsisten hingga mendekati nol dengan jarak yang kecil, menandakan proses pelatihan yang stabil tanpa indikasi *overfitting* serta kemampuan generalisasi model yang sangat baik.



Gambar 8. Kurva akurasi dan loss model MobileNetV3-Large 100 Epoch

KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi jenis kulit wajah berbasis *Convolutional Neural Network* (CNN) dengan pendekatan transfer learning menggunakan tiga arsitektur, yaitu MobileNet, MobileNetV2, dan MobileNetV3-Large. Model dilatih menggunakan 2.250 citra wajah yang diklasifikasikan ke dalam lima kategori (*Combination*, *Dry*, *Normal*, *Oily*, dan *Sensitive*), dengan pembagian 1.800 data latih, 225 data validasi, dan 225 data uji. Hasil pengujian menunjukkan bahwa peningkatan jumlah epoch dari 5 hingga 100 secara konsisten meningkatkan performa seluruh model. MobileNet menunjukkan akurasi 97,78%, MobileNetV2 menunjukkan akurasi 96,89% pada 100 epoch dan MobileNetV3-Large menunjukkan akurasi uji mencapai 100,00% pada 100 epoch. Berdasarkan hasil ini, dapat disimpulkan bahwa

MobileNetV3-Large dengan 100 epoch menunjukkan performa terbaik dengan akurasi uji mencapai 100% pada penelitian ini. Kontribusi utama penelitian ini adalah pembuktian MobileNet untuk klasifikasi jenis kulit wajah dengan dataset yang terbatas, sehingga dapat menjadi fondasi pengembangan aplikasi perawatan kulit berbasis kecerdasan buatan.

Penelitian ini memiliki keterbatasan pada jumlah dan keberagaman dataset yang digunakan. Oleh karena itu, penelitian selanjutnya disarankan untuk memperluas dataset dengan variasi lainnya seperti usia, etnis atau yang lebih beragam, serta mengeksplorasi model arsitektur lain untuk membandingkan performa secara lebih komprehensif.

DAFTAR PUSTAKA

- Abdul Aziz, Abdul Fadlil, & Tole Sutikno. (2024). Optimization of Convolutional Neural Network (CNN) Using Transfer Learning for Disease Identification in Rice Leaf Images. *Jurnal E-Komtek (Elektro-Komputer-Teknik)*, 8(2), 504–515. <https://doi.org/10.37339/e-komtek.v8i2.2132>
- Akbar, S. A., Hassan, S. M. J., Raoof, Z. M., & Saeed, M. M. M. (2024). Personalized Skincare: Correlating Genetics with Skin Phenotypes through DNA Analysis. *UHD Journal of Science and Technology*, 8(1), 151–163. <https://doi.org/10.21928/uhdjst.v8n1y2024.pp151-163>
- Anton, A., Nissa, N. F., Janiati, A., Cahya, N., & Astuti, P. (2021). Application of Deep Learning Using Convolutional Neural Network (CNN) Method For Women's Skin Classification. *Scientific Journal of Informatics*, 8(1), 144–153. <https://doi.org/10.15294/sji.v8i1.26888>
- Dewi, N., & Ismawan, F. (2021). Implementasi Deep Learning Menggunakan Cnn Untuk Sistem Pengenalan Wajah. *Faktor Exacta*, 14(1), 34. <https://doi.org/10.30998/faktorexacta.v14i1.8989>
- Dian Anisa Agustina. (2024). Klasifikasi Citra Jenis Kulit Wajah Dengan Algoritma Convolutional Neural Network (CNN) Resnet-50. *Jurnal Riset Sistem Informasi*, 1(3), 01–07. <https://doi.org/10.69714/13sbb24>
- Fadlil, A., M, D. P., Ma'ruf, M., & Furizal. (2025). Machine Learning-Based Early Prediction of Stunting Risk: A Comparative Study. *Methods in Science and Technology Studies*, 1(1), 24–31. <https://doi.org/10.64539/msts.v1i1.2025.351>

- Farage, M. A. (2019). The Prevalence of Sensitive Skin. *Frontiers in Medicine*, 6, 98. <https://doi.org/10.3389/fmed.2019.00098>
- Farokhah, L. (2017). Implementasi Convolutional Neural Network untuk Klasifikasi Variasi Intensitas Emosi pada Dynamic Image Sequence. *Masa Berlaku Mulai*, 1(3), 1070–1076.
- Helmawati, N., Buana, Y. T., Darmawan, E. R., & Kusriani, K. (2025). Deep Learning-Based Soybean Leaf Disease Classification Using DenseNet121, Xception, and MobileNetV2. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 9(6), 1339–1346. <https://doi.org/10.29207/resti.v9i6.6271>
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications* (Version 1). arXiv. <https://doi.org/10.48550/ARXIV.1704.04861>
- Howard, A., Sandler, M., Chen, B., Wang, W., Chen, L.-C., Tan, M., Chu, G., Vasudevan, V., Zhu, Y., Pang, R., Adam, H., & Le, Q. (2019). Searching for MobileNetV3. *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, 1314–1324. <https://doi.org/10.1109/ICCV.2019.00140>
- Irwansyah, I., Yudhana, A., & Fadlil, A. (2025). Klasifikasi Jenis Kulit Wajah Menggunakan Algoritma Random Forest. *Infotech: Journal of Technology Information*, 11(2), 229–236. <https://doi.org/10.37365/jti.v11i2.423>
- Kara, F. B., Kara, R., & Sakaci ÇeliK, S. (2023). Skin Type Detection with Deep Learning: A Comparative Analysis. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 11(2), 729–742. <https://doi.org/10.29130/dubited.930096>
- Khoirunnisa, I. I., Fadlil, A., & Yuliansyah, H. (2025). MoLLe: A Hybrid Model for Classifying Diseases in Chili Plants Using Leaf Images. *Scientific Journal of Informatics*, 12(3), 453–464. <https://doi.org/10.15294/sji.v12i3.29071>
- Khoirunnisa, I. I., Fadlil, A., & Yuliansyah, H. (2026). Perbandingan Kinerja MobileNetV2 dan VGG16 dalam Klasifikasi Penyakit pada Citra Daun Tanaman Cabai. *JISKA (Jurnal Informatika Sunan Kalijaga)*, 11(1), 70–82. <https://doi.org/10.14421/jiska.5075>
- Maulana, F. F., & Rochmawati, N. (2020). Klasifikasi Citra Buah Menggunakan Convolutional Neural Network. *Journal of Informatics and Computer Science (JINACS)*, 1(02), 104–108. <https://doi.org/10.26740/jinacs.v1n02.p104-108>
- Mosca, S., & Morrone, A. (2023). Human Skin Pigmentation: From a Biological Feature to a Social Determinant. *Healthcare*, 11(14), 2091. <https://doi.org/10.3390/healthcare11142091>
- Ran, J., Dong, G., Yi, F., Li, L., & Wu, Y. (2024). Automatic Measurement of Comprehensive Skin Types Based on Image Processing and Deep Learning. *Electronics*, 14(1), 49. <https://doi.org/10.3390/electronics14010049>
- Raza, A., Ali, A., Ullah, S., Anjum, Y. N., & Rehman, B. (2025). Optimizing skin cancer screening with convolutional neural networks in smart healthcare systems. *PLOS ONE*, 20(3), e0317181. <https://doi.org/10.1371/journal.pone.0317181>
- S, G., S, N., & S, N. (2022). Skin Disease Classification using Convolutional Neural Network. *2022 International Conference on Applied Artificial Intelligence and Computing (ICAAIC)*, 177–182. <https://doi.org/10.1109/ICAAIC53929.2022.9792785>
- Saiwaco, S., Arwatchananukul, S., Mungmai, L., Preedalikit, W., & Aunsri, N. (2023). Human skin type classification using image processing and deep learning approaches. *Heliyon*, 9(11). <https://doi.org/10.1016/j.heliyon.2023.e21176>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). *MobileNetV2: Inverted Residuals and Linear Bottlenecks*. <https://doi.org/10.48550/ARXIV.1801.04381>
- Sunnam, S., & Obulesh, A. (2022). Classification Facial Skin and Treatment Suggestions for Good Skin Using Deep Learning with Region of Interest (ROI) Patches. *International Journal of Engineering Research in Computer Science and Engineering*, 9(9), 47–53. <https://doi.org/10.36647/IJERCSE/09.09.Art013>
- Tinaliah, T. (2021). Penerapan Convolutional Neural Network Untuk Klasifikasi Citra Ekspresi Wajah Manusia Pada MMA Facial Expression Dataset. *JATISI (Jurnal Teknik Informatika Dan Sistem Informasi)*, 8(4), 2051–2059. <https://doi.org/10.35957/jatisi.v8i4.1437>
- Xie, A., Zhang, X., Huang, Q., & Wu, J. (2025). Utilizing Untargeted Lipidomics Technology to Elucidate Differences in Lipid Compositions Among Sensitive Dry, Sensitive Oily and Healthy Skin Types. *Metabolites*, 15(5), 292. <https://doi.org/10.3390/metabo15050292>



- Yuliansyah, H., Saputro, R. A., Khoirunnisa, I. I., Ali, W. N. S. W., Nur, Y. S. R., & Radzuan, N. F. M. (2026). Plastic bottle defect detection based on convolutional neural network with MobileNetV2 architecture. *Franklin Open*, 14, 100522.
<https://doi.org/10.1016/j.fraope.2026.100522>
- Zhang, A., Lipton, Z. C., Li, M., & Smola, A. J. (2021). *Dive into Deep Learning* (Version 5). arXiv.
<https://doi.org/10.48550/ARXIV.2106.11342>