# PENERAPAN CNN ARSITEKTUR MOBILENETV2 UNTUK KLASIFIKASI PENYAKIT KULIT BERBASIS CITRA DIGITAL

Deny Rochman Arifatno, Rizky Eka Fachrudin dan Swelandiah Endah Pratiwi*

Universitas Gunadarma
Jl. Margonda Raya No. 100, Depok, Jawa Barat, 16424
deny@uca.ac.id, rizkiekafachrudin@gmail.com, swelandiah@staff.gunadarma.ac.id
*Corresponding Author

**ABSTRAK**

*Penyakit kulit merupakan salah satu masalah kesehatan umum di Indonesia yang diagnosisnya memerlukan kecepatan dan akurasi tinggi. Diagnosis konvensional oleh tenaga medis seringkali bergantung pada pemeriksaan visual yang membutuhkan keahlian khusus, waktu, dan biaya. Perkembangan teknologi kecerdasan buatan, khususnya Convolutional Neural Network (CNN), menawarkan potensi besar untuk membantu proses diagnosis melalui analisis citra medis secara otomatis. Namun, banyak arsitektur CNN memiliki komputasi yang berat sehingga kurang cocok untuk implementasi pada perangkat mobile. Oleh karena itu, penelitian ini bertujuan untuk membangun model klasifikasi penyakit kulit berbasis citra digital menggunakan metode CNN dengan arsitektur MobileNetV2 yang efisien dan dapat diimplementasikan pada aplikasi mobile. Dataset yang digunakan terdiri dari lima jenis penyakit kulit (cellulitis, impetigo, ringworm, athlete's foot, dan chickenpox) serta satu kelas kulit normal. Model dikembangkan melalui tahapan pra-pemrosesan, augmentasi data, dan transfer learning dari MobileNetV2. Evaluasi performa menggunakan berbagai metrik menunjukkan hasil akurasi sebesar 99,15% pada data uji.*

**Kata Kunci**: *CNN, Deep Learning, Klasifikasi, MobileNetV2, Penyakit Kulit*

## PENDAHULUAN

Lapisan terluar dari tubuh manusia yang berfungsi untuk memproteksi dari patogen seperti jamur, bakteri dan virus disebut dengan kulit [1]. Mikroorganisme patogen seperti virus, bakteri, jamur, maupun parasit yang berkoloni pada permukaan kulit berpotensi menimbulkan penyakit kulit atau infeksi sistemik apabila terjadi kerusakan pada lapisan pelindung kulit [2]. Berdasarkan data epidemiologis, yang merupakan disiplin ilmu dalam bidang kesehatan masyarakat yang berfokus pada analisis pola, distribusi, serta determinan berbagai masalah kesehatan dalam suatu populasi tertentu, penyakit kulit di Indonesia mencapai 97% dari 389 kasus yang dilaporkan, dengan dermatitis kontak sebagai kasus yang paling sering terjadi, menunjukkan tantangan kesehatan kulit yang signifikan di negara ini [3]. Berdasarkan data dari Kementerian Kesehatan tahun 2023 bahwa penyakit kulit masuk dalam sepuluh besar penyakit terbanyak yang diderita masyarakat [4]. Diagnosis penyakit kulit biasanya dilakukan secara visual oleh dokter melalui pemeriksaan langsung terhadap lesi kulit [5] [6]. Dalam beberapa kasus, dibutuhkan pemeriksaan tambahan seperti tes laboratorium atau biopsi. Diagnosis yang cepat dan akurat sangat penting untuk mencegah komplikasi, namun proses ini membutuhkan keahlian khusus, waktu, dan biaya yang tidak sedikit [6].

Seiring berkembangnya teknologi, pemanfaatan kecerdasan buatan (AI) di bidang kesehatan semakin banyak dilakukan, terutama dalam analisis citra medis. Salah satu metode yang populer digunakan adalah Convolutional Neural Network (CNN) [7] [8] [9]. Convolutional Neural Network adalah salah satu teknik pada bidang kecerdasan buatan yang telah terbukti efektif dalam mengklasifikasikan gambar [10]. Metode ini telah digunakan dalam berbagai aplikasi, termasuk dalam bidang kesehatan untuk klasifikasi penyakit kulit [11] [12].

Beberapa penelitian telah membuktikan efektivitas CNN untuk mengklasifikasikan penyakit kulit wajah

menggunakan CNN dengan arsitektur VGG16 menghasilkan akurasi sebesar 90%. VGG16 cenderung memiliki jumlah parameter besar dan waktu komputasi yang lama, sehingga kurang cocok untuk implementasi pada perangkat mobile [13].

Penelitian juga telah dilakukan menggunakan arsitektur MobileNetV2 untuk mendeteksi objek melanoma pada perangkat Android dengan akurasi sebesar 93%, tetapi penelitian ini menghasilkan akurasi 70% untuk klasifikasinya [14] . Arsitektur MobileNetV2 dan LSTM telah digunakan untuk mengklasifikasikan penyakit kulit psoriasis, eksem dan melanoma menghasilkan akurasi 85,34% [15],

Dalam penelitian ini akan menggunakan dataset gambar penyakit kulit yang diperoleh dari platform Kaggle, mencakup beberapa jenis penyakit kulit seperti cellulitis, impetigo, ringworm, athlete foot, chickenpox dan normal (kulit sehat). Model yang dikembangkan akan dilatih untuk mengklasifikasikan gambar-gambar tersebut secara otomatis, kemudian dievaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score. Diharapkan, hasil dari penelitian ini dapat mendukung pengembangan sistem screening penyakit kulit yang cepat, akurat, dan efisien.

## METODE PENELITIAN

Penelitian ini dilakukan dengan 5 tahap yaitu Pengumpulan data, Pra-pemrosesan data, Ekstraksi fitur, Pelatihan Model dan Pengujian model. Proses penelitian ini dapat dilihat pada Gambar 1.

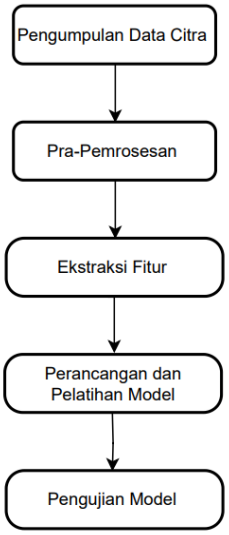


**Gambar 1**. *Metode Penelitian*

1. Pengumpulan Data Citra

Pengumpulan data citra penyakit kulit diperoleh dari Kaggle dengan total 2216 citra penyakit, yang terdiri dari 400 gambar untuk penyakit *Cellulitis*, 246 gambar *Impetigo*, 258 gambar penyakit *Athlete-foot*, 336 gambar penyakit *Ringworm*, 426 gambar penyakit *Chickenpox* dan 426 gambar kondisi kulit normal.

Citra digital untuk dataset memiliki karakteristik yang bervariasi meliputi perbedaan resolusi, kondisi pencahayaan, dan sudut pandang. Gambar yang terkumpul berformat JPG, JPEG dan PNG yang menampilkan *lesi* kulit dari berbagai bagian tubuh sesuai dengan manifastasi klinis masing-masing jenis penyakit.

2. Pra-Pemrosesan

Tahap Pra-pemrosesan data merupakan langkah fundamental yang bertujuan untuk mengubah data citra mentah menjadi format yang optimal untuk tahap proses pelatihan model. Tahap ini akan menghasilkan konsistensi data masukan sekaligus dapat meningkatkan performa model, mempercepat konvergensi dan mengurangi resiko *overfitting*.

Tahap ini dilakukan secara otomatis menggunakan ImageDataGenerator dari Keras yang mencakup beberapa proses terlihat pada Gambar 2.

**Gambar 2.** *Tahapan Pra-Pemrosesan*

Tahap Pra-pemrosesan diawali dengan membaca setiap citra masukan, lalu merubah ukuran citra menjadi 224x224 piksel. Proses selanjutnya adalah Augmentasi data yaitu proses memperluas jumlah dan variasi data dengan memodifikasi data citra tanpa merubah label dan makna dari citra tersebut [16]. Penelitian ini menerapkan rotasi citra hingga 40 derajat, flip, pergeseran lebar dan tinggi citra hingga 20%, pemiringan citra hingga 20% dan pembesaran citra hingga 20% bertujuan untuk memperbanyak variasi data latih. Parameter teknik Augmentasi data dapat terlihat pada Tabel 1. Setelah proses Augmentasi selanjutnya melakukan proses normalisasi yaitu merubah rentang nilai piksel citra ke skala tertentu agar seragam. Penelitian ini merubah nilai piksel 0 - 255 menjadi rentang [-1, 1] agar sesuai dengan kebutuhan model MobileNetV2. Hasil citra dari proses tersebut dikelompokkan kedalam batch menggunakan Image Data Generator.

**Tabel 1**. *Parameter Augmentasi Data (lihat pada lamnpiran)*

3. Ekstraksi Fitur dan Perancangan Model

Tahap ini merupakan proses inti dalam Computer Vision yaitu untuk mencari ciri dari citra digital yang telah dihasilkan dari proses sebelumnya. Proses ekstraksi fitur pada model deep learning dilakukan secara otomatis yaitu dengan mengidentifikasi dan mengkonversi pola-pola visual yang relevan dari citra digital menjadi representasi numerik yang dapat diproses untuk tahap selanjutnya.

Pada penelitian ini untuk tahap ekstraksi fitur menggunakan metode transfer learning yang secara spesifik dijalankan oleh model dasar (base model) MobileNetV2. Alur proses ekstraksi fitur pada penelitian ini dapat dilihat pada Gambar 3.

**Gambar 3.** *Alur Proses Ekstraksi Fitur*

Proses dimulai dengan input citra penyakit kulit yang telah dilakukan pra-pemrosesan dengan ukuran 224x224 piksel dengan nilai piksel ternormalisai ke rentang [-1,1]. Citra tersebut kemudian melalui lapisan konvolusi yang terdapat pada arsitektur MobileNetV2. Proses selanjutnya adalah melakukan proses forward propagation pada masing-masing lapisan konvolusi. Lapisan-lapisan awal mendeteksi fitur tingkat rendah (sederhana) seperti tepi, sudut, dan gradasi warna. Seiring data bergerak lebih dalam, lapisan-lapisan berikutnya mengombinasikan fitur-fitur sederhana tersebut untuk mengenali fitur tingkat menengah yang lebih kompleks, seperti tekstur ruam atau pola bintik. Lapisan-lapisan terakhir dari base model mengenali fitur tingkat tinggi (abstrak) yang merepresentasikan bagian-bagian penting dari objek pada citra.

4. Perancangan dan Pelatihan Model

Metode yang digunakan untuk klasifikasi pada penelitian ini adalah Convolutional Neural Network (CNN) dengan arsitektur MobileNetV2 (Transfer Learning). Perancangan arsitektur detail setiap lapisan pada model ini dapat dilihat pada Gambar 4.

Arsitektur terdiri dari Lapisan Input (Input layer), Convolutional layer (klasifikasi) dan output layer yang terdiri dari 6 kelas.

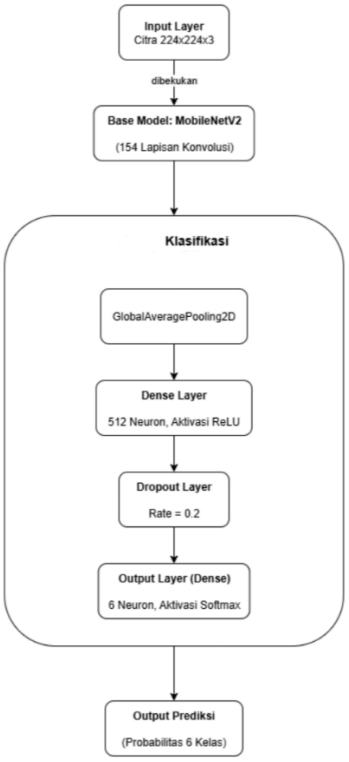


**Gambar 4.** *Detail Lapisan Arsitektur Model*

Input layer pada model ini diperoleh dari hasil akhir tahap ekstraksi fitur yang telah memiliki pengetahuan dari dataset ImageNet dan tersimpan dalam Base model : MobileNetV2 berupa Features Map. Features map diproses pada lapisan GlobalAveragePooling2D untuk merangkum informasi spasial menjadi sebuah vektor fitur tunggal yang lebih ringkas. Vektor inilah yang menjadi masukkan untuk hidden layer (Dense layer) dengan 512 neuron. Pada lapisan ini fitur yang masuk belajar untuk menemukan dan mengkombinasikan pola-pola linier sebagai indikator untuk menentukan jenis penyakit. Vektor fitur inilah yang kemudian digunakan oleh lapisan *Dropout* dan *Dense* akhir (Softmax) untuk membuat keputusan klasifikasi akhir ke dalam salah satu dari enam kelas. *Dropout* merupakan teknik regulasi yang menonaktifkan sebagian *neuron* secara acak pada proses pelatihan model. Penelitian ini menggunakan *Dropout rate* 0.2 yang berarti akan menonaktifkan 20% *neuron* setiap literasi pelatihan. Salah satu tujuannya adalah mencegah *overfitting*.

Tahap pelatihan model dilakukan untuk melihat performa model yang digunakan pada penelitian ini. Alur proses pada tahap pelatihan model dapat dilihat pada Gambar 5. Tahap pelatihan model dimulai dengan input data citra dengan membagi 2 dataset yaitu data latih dan data validasi. Model akan belajar secara langsung dari Data Latih untuk menyesuaikan

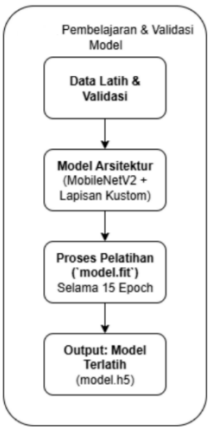


**Gambar 5.** *Proses Pelatihan model*

Proses pelatihan menggunakan fungsi model.fit, model akan melalui proses pelatihan sebanyak 15 *epoch.* Dalam setiap *epoch*, model akan terus- menerus mencoba meminimalkan kesalahan (loss) prediksinya pada data latih. Konfigurasi pelatihan model dapat dilihat pada Tabel 2.

**Tabel 2**. *Parameter Pelatihan Model*

| No | Parameter Pelatihan | Nilai |
|---|---|---|
| 1 | Optimizer | Adam |
| 2 | Learning Rate | 0.001 |
| 3 | *Loss Function* | Categorical Cross-Entropy |
| 4 | Jumlah *Epoch* | 15 |
| 5 | *Batch Size* | 32 |

1. Pengujian Model

Tahap pengujian bertujuan untuk menguji model yang telah dirancang dan telah dilakukan pembelajaran. Pengujian model dilakukan dengan perbandingan 80:20, 80% data dari keseluruhan data digunakan untuk pembelajaran / pelatihan dan validasi, sedangkan 20% digunakan untuk pengujian model. Alur proses dari pengujian model dapat dilihat pada Gambar 6.

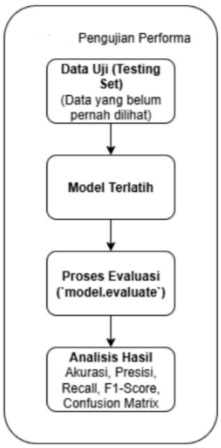


**Gambar 6.** *Proses Pengujian Model*

Hasil pengujian model digunakan untuk mengukur kinerja dari model, metode yang digunakan dalam penelitian ini dengan cara mencari Akurasi, Presisi, Recall, F1 Score dan divisualisasikan ke dalam Confusion Matrix.

Akurasi (Accuracy) mengukur proporsi total prediksi yang benar terhadap total jumlah sample. Rumus akurasi dapat dilihat pada persamaan 1.

$$Accuracy = \frac{Jumlah\ Prediksi\ Benar}{Total\ Sample} \quad (1)$$

Presisi (*precision*) mengukur proporsi kasus positif yang diprediksi dengan benar dari semua kasus yang diprediksi sebagai positif. Presisi(*precision*) dapat diperoleh dengan menggunakan persamaan 2.

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

*Recall* (atau Sensitivitas) mengukur proporsi kasus positif aktual yang berhasil diidentifikasi dengan benar oleh model. *Recall* dapat diperoleh dengan menggunakan persamaan 3.

$$Recall = \frac{TF}{TP+FN} \quad (3)$$

*F1-Score* adalah rata-rata harmonis dari Presisi dan *Recall*. Metrik ini sangat berguna ketika terdapat *imbalance* kelas, karena memberikan keseimbangan antara Presisi dan *Recall*, sehingga lebih akurat dalam merepresentasikan kinerja model secara keseluruhan dibandingkan hanya akurasi. Penghitungan *F1-Score* menggunakan persamaan 4

$$F1 - Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} \quad (4)$$

## HASIL DAN PEMBAHASAN

### 1. Hasil Pengumpulan Data Citra

Data citra yang digunakan dalam penelitian ini diambil dari platform Kaggle dengan total sebanyak 2216 gambar. Citra tersebut terdiri dari 5 jenis penyakit (Cellulitis, Impetigo, Athlete's Foot, Ringworm, dan Chickenpox). Contoh masing-masing citra penyakit kulit yang dikumpulkan dapat dilihat pada Tabel 4.

**Tabel 4**. *Contoh Citra dari setiap Kelas*

| Cellulitis | Impetigo | Ringworm | Athele's Foot | Chickenpox | Normal |
|---|---|---|---|---|---|
| | | | | | |

Tabel 4 merupakan contoh dari citra dari setiap kategori dalam dataset penelitian. Pada kelas Cellulitis, tampak peradangan kulit dengan ciri kemerahan, adanya pembengkakan, serta tekstur kulit yang terlihat lebih tebal dan berkilau. Kondisi ini jelas berbeda dengan kulit normal yang umumnya rata dan tidak mengalami pembengkakan. Sementara itu, pada kelas Impetigo, terlihat lesi kecil pada area wajah yang ditutupi kerak berwarna kuning. Gambaran ini menunjukkan karakteristik khas impetigo yang mudah menular dan sering dijumpai pada anak-anak.

Untuk kelas Ringworm, gejala tampak berupa ruam berbentuk lingkaran

dengan tepi yang menonjol dan bagian tengah lebih pucat. Pola melingkar ini menjadi ciri visual yang membedakan ringworm dengan jenis penyakit kulit lainnya. Pada Athlete's Foot, gejala ditunjukkan dengan kulit yang tampak kering, pecah-pecah, bersisik, serta kemerahan di sela-sela jari kaki. Kondisi tersebut biasanya terjadi akibat lingkungan kaki yang lembap, sehingga mendukung pertumbuhan jamur.

Selanjutnya, kelas Chickenpox memperlihatkan ruam yang menyebar di seluruh tubuh anak, berupa bintik merah kecil yang kemudian berkembang menjadi lenting berisi cairan. Pola sebaran lesi yang meluas menjadi ciri khas penyakit ini. Sementara itu, pada kelas Normal, kulit terlihat bersih, rata, dan tidak menunjukkan tanda-tanda ruam, bercak, maupun peradangan. Adanya kelas normal ini sangat penting karena berfungsi sebagai pembanding dalam proses klasifikasi, sehingga model dapat membedakan dengan jelas antara kulit sehat dan kulit yang terinfeksi penyakit.

2. Hasil Pra-Pemrosesan

Tahap pra-pemrosesan diterapkan pada keseluruhan 2216 citra dalam dataset. Untuk meningkatkan variasi pada data latih dan membuat model lebih tangguh (robust) terhadap perbedaan orientasi dan kondisi gambar, teknik augmentasi data diterapkan secara acak. Proses ini menciptakan versi baru dari citra asli dengan menerapkan transformasi geometris seperti rotasi, flip, geser, shear, dan zoom. Hasil augmentasi dapat dilihat pada Gambar 6.

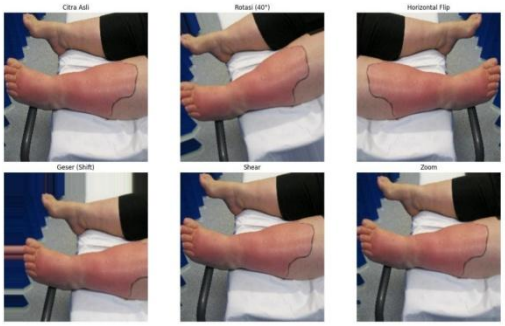


**Gambar 7**. *Hasil Proses Augmentasi*

Gambar 7 memperlihatkan contoh penerapan teknik augmentasi pada citra kulit penderita cellulitis. Citra asli pada bagian kiri atas kemudian dimodifikasi dengan beberapa transformasi untuk meningkatkan variasi data. Teknik rotasi sebesar 40° menghasilkan pergeseran orientasi gambar tanpa mengubah karakteristik utama dari lesi. Sementara itu, pada horizontal flip, posisi citra dipantulkan ke arah berlawanan, sehingga pola visual dapat dikenali dari sisi berbeda.

Transformasi berikutnya adalah shift (geser), yang mengubah letak objek pada bidang gambar sehingga memperkaya representasi posisi. Selanjutnya, shear memberikan efek miring pada citra, sehingga bentuk objek tampak sedikit terdistorsi namun tetap mempertahankan ciri khas penyakit. Terakhir, teknik zoom memperbesar area tertentu dari gambar, yang memungkinkan model lebih fokus pada detail tekstur kulit.

3. Hasil Ekstraksi Fitur

Tahap ekstraksi fitur adalah proses di mana base model MobileNetV2 mengidentifikasi dan mengekstrak pola-pola visual penting dari citra masukan. Fitur yang diperoleh dari proses ekstraksi pada lapisan konvolusi MobileNetV2 merepresentasikan karakteristik visual penting dari citra kulit, seperti tekstur permukaan, variasi warna, serta bentuk kontur lesi. Pada lapisan awal, jaringan mengenali pola dasar berupa tepi, sudut, dan perubahan intensitas warna. Lapisan-lapisan berikutnya kemudian membangun representasi yang lebih kompleks dengan mendeteksi pola tekstur khas yang membedakan setiap jenis penyakit. Selanjutnya, lapisan akhir mengintegrasikan seluruh informasi visual tersebut menjadi fitur tingkat tinggi yang digunakan sebagai dasar dalam menentukan kategori penyakit kulit. Berdasarkan hasil visualisasi *feature map*, terlihat bahwa area perhatian model berpusat pada bagian kulit yang mengalami kelainan, sehingga fitur yang dihasilkan dapat dianggap relevan dan mendukung proses klasifikasi secara akurat.

Hasil dari proses ini adalah sebuah Peta Fitur (Feature Map), yang merupakan representasi numerik dari apa yang "dilihat" oleh model.

Gambar 7 menampilkan visualisasi dari beberapa kanal pada Peta Fitur yang dihasilkan oleh salah satu lapisan konvolusi (block_1_expand_relu) pada model. Setiap kotak kecil menunjukkan area di mana model mendeteksi pola spesifik, seperti tekstur, tepi, atau gradasi warna dari citra asli Gambar 7.

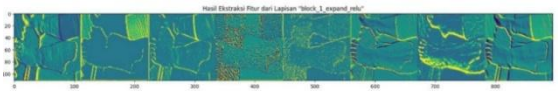

**Gambar 8.** *Hasil Ekstraksi Fitur*

Gambar 8 menampilkan hasil ekstraksi fitur dari lapisan block_1_expand_relu pada arsitektur MobileNetV2. Setiap tampilan merupakan *feature map* yang dihasilkan oleh filter konvolusi, di mana masing-masing filter berfungsi menyoroti aspek visual tertentu dari citra masukan. Warna kuning menunjukkan area dengan tingkat aktivasi tinggi, menandakan adanya pola visual yang dianggap penting oleh model, seperti tepi, kontur, atau tekstur pada area kulit. Sementara itu, warna biru hingga hijau menunjukkan aktivasi rendah, yang berarti bagian tersebut kurang relevan bagi proses klasifikasi.

Variasi pola yang terlihat pada tiap *feature map* memperlihatkan bagaimana CNN mampu memecah citra kompleks menjadi representasi visual yang lebih sederhana, mulai dari garis, tekstur, hingga pola distribusi bercak pada kulit. Tahap ini sangat penting karena menjadi dasar untuk lapisan-lapisan selanjutnya dalam mengidentifikasi ciri khas penyakit kulit, misalnya pola melingkar pada ringworm atau bercak merata pada chickenpox.

4. Hasil Pelatihan Model

Arsitektur yang digunakan adalah MobileNetV2 sebagai base model yang dibekukan, dengan kepala klasifikasi kustom yang terdiri dari lapisan GlobalAveragePooling2D, Dense(512), Dropout(0.2), dan Dense(6) sebagai output. Proses pelatihan dijalankan selama 15 *epoch* dengan optimizer Adam dan loss function Categorical Cross-Entropy. Hasil visualisasi pelatihan model dalam bentuk grafik dapat dilihat pada Gambar 8.

**Gambar 9.** *Grafik hasil Pelatihan Model*

Gambar 9 terdapat 2 grafik pelatihan model, yaitu :

Grafik akurasi (*training and validation accuracy*) dan grafik *loss* (*training dan validation loss*). Berdasarkan grafik hasil pelatihan yang diperoleh dapat disimpulkan bahwa model belajar dengan baik dan stabil serta menghasilkan akurasi lebih dari 95% dan loss yang rendah. Perbedaan antara training loss dan validatioan loss kecil pertanda tidak ada indikasi *overviting.*

5. Hasil Pengujian Model

Hasil pengujian disajikan dalam bentuk *Confusion Matrix,* memberikan rincian visual mengenai performa klasifikasi model untuk setiap kelas. Confusion matrix dari hasil pengujian model dapat dilihat pada Gambar 9.

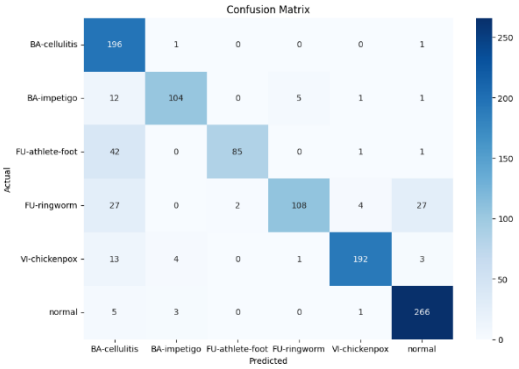


**Gambar 10**. *Confusion Matrix*

Akurasi hasil pengujian model diperolah sebesar 99.15% dengan penghitungan sebagai berikut :

$$Akurasi = \frac{125 + 123 + 128 + 83 + 153 + 211}{830} \times 100\%$$

$$= \mathbf{99.15}\%$$

Hasil perhitungan metrik kinerja dari *confusion matrix* dirangkum dalam Tabel 3 untuk memberikan gambaran yang komprehensif mengenai performa model pada setiap kelas.

**Tabel 3.** *Hasil Pengujian Model (lihat pada lampiran)*

Model klasifikasi berbasis MobileNetV2 pada penelitian ini memperoleh tingkat akurasi sebesar 99,15%, yang menunjukkan kemampuan sangat baik dalam mengenali pola visual berbagai jenis penyakit kulit. Hasil tersebut kemungkinan dipengaruhi oleh karakteristik dataset yang relatif mudah dibedakan, di mana setiap kategori penyakit memiliki ciri visual yang kontras, seperti perbedaan warna, tekstur, dan bentuk lesi. Selain itu, penerapan transfer learning dari model MobileNetV2 yang sebelumnya dilatih pada dataset ImageNet turut meningkatkan efisiensi proses pembelajaran, karena model sudah memiliki pengetahuan dasar mengenai pola visual umum.

Nilai akurasi yang tinggi tidak selalu menjadi indikator bahwa model memiliki kemampuan generalisasi yang baik. Faktor ketidakseimbangan jumlah data antar kelas berpotensi memengaruhi hasil, karena model dapat lebih fokus pada kelas dengan data yang lebih banyak. Teknik *augmentasi* data memang membantu menambah variasi gambar, namun belum tentu menambah tingkat kompleksitas pola yang harus dipelajari, sehingga model tetap dapat mencapai akurasi tinggi dengan tingkat kesalahan yang sangat kecil.

Selain itu, kemungkinan terjadinya overfitting juga perlu diwaspadai, mengingat jumlah data yang digunakan masih terbatas dan berasal dari satu sumber yang sama. Walaupun telah diterapkan teknik regularisasi seperti dropout dan augmentasi, model tetap mungkin terlalu menyesuaikan diri terhadap pola data latih. Oleh sebab itu, diperlukan pengujian lanjutan menggunakan metode seperti *k-fold cross validation*, uji pada dataset eksternal, atau visualisasi fitur dengan Grad-CAM untuk memastikan bahwa performa tinggi yang diperoleh benar-benar merepresentasikan kemampuan model dalam mengenali data baru secara umum.

## PENUTUP

Berdasarkan hasil perancangan dan pengujian yang telah dilakukan, dapat disimpulkan bahwa penelitian ini telah berhasil merancang dan mengembangkan sebuah model klasifikasi penyakit kulit berbasis citra menggunakan arsitektur Convolutional Neural Network (CNN) MobileNetV2 dengan menerapkan metode transfer learning. Arsitektur MobileNetV2 terbukti efisien dan andal untuk klasifikasi penyakit kulit berbasis citra digital. Struktur jaringan yang ringan melalui penerapan depthwise separable convolution dan inverted residual block mampu menurunkan jumlah parameter serta beban komputasi tanpa mengurangi akurasi. Kompleksitas algoritma yang rendah menjadikan proses pelatihan dan inferensi lebih cepat, dengan konsumsi memori dan sumber daya yang minimal. Dukungan framework TensorFlow–Keras dan konversi ke TensorFlow Lite memungkinkan model berjalan optimal pada perangkat mobile tanpa ketergantungan pada hardware berperforma tinggi. Hasil akurasi 99,15% menunjukkan bahwa efisiensi arsitektur tidak mengurangi kemampuan generalisasi model, sehingga MobileNetV2 layak digunakan sebagai solusi cerdas dalam sistem diagnosis otomatis berbasis perangkat mobile.

## DAFTAR PUSTAKA

[1] T. Yulianti, B. Imanni, F. Findari, R. Prabasakti, E. Meylani dan Z. Adhisa, “Edukasi Pengetahuan Swamedika Penyakit Kulit Sebagai Upaya Untuk Meningkatkan Kesehatan Di Lingkungan Panti

Asuhan Wilayah Kartasura.," *EJOIN: Jurnal Pengabdian Masyarakat,* vol. 2, no. 2, pp. 302-308, 2024.

[2] A. L. Byrd, Y. Belkaid dan J. A. Segre, "The human skin microbiome," *Nature Reviews Microbiology,* vol. 16, pp. 143-155, 2018.

[3] A. R. Sanggul, "Penyuluhan dan Pencegahan Penyakit Mengenai Kulit, Kuku dan Rambut. In: Dermatologi. Eureka Media Aksara, Kecamatan Bojongsari Kabupaten Purbalingga," Jakarta, Universitas Kristen Indonesia, 2024, pp. 32-46.

[4] K. K. R. Indonesia, "Laporan Kinerja Kementerian Kesehatan Republik Indonesia," Kementerian Kesehatan RI, Jakarta, 2023.

[5] J. Zhang, F. Zhong, K. He, M. Ji, S. Li dan C. Li, "Recent Advancements and Perspectives in the Diagnosis of Skin Diseases Using Machine Learning and Deep Learning: A Review," *Diagnostics (Basel),* vol. 13, no. 23, 2023.

[6] F. Krefting, M. Moelleken, S. Hölsken, J.-M. Placke, R. T. Eisenburger, L. J. Albrecht, A. Tasdogan, D. Schadendorf, S. Ugurel, J. Dissemond dan W. Sondermann, "Comparison of visual diagnostic accuracy of dermatologists practicing in Germany in patients with light skin and skin of color," Scientific Reports, German, 2024.

[7] G. Kourounis, A. Elmahmudi, B. Thomson, J. Hunter, H. Ugail dan W. C, "Computer image analysis with artificial intelligence: a practical introduction to convolutional neural networks for medical professionals," *Postgrad Med J,* vol. 99, no. 1178, pp. 1287-1294, 2023.

[8] I. D. Mienye, T. G. Swart, G. Obaido, M. Jordan dan P. Ilono, "Deep Convolutional Neural Networks in Medical Image Analysis: A Review.," *Information,,* vol. 16, no. 3, p. 195, 2025.

[9] C. Chen, N. A. M. Isa dan X. Liu, "A review of convolutional neural network based methods for medical image classification,," *Computers in Biology and Medicine,* vol. 185, 2025.

[10] L. Chen, S. Li, Q. Bai, J. Yang, S. Jiang dan Y. Miao, "Review of Image Classification Algorithms Based on Convolutional Neural Networks.," *Remote Sensing,* vol. 13, no. 22, p. 4712, 2021.

[11] R. Sadik, A. Majumder, A. A. Biswas, B. Ahammad dan M. M. Rahman, "An in-depth analysis of Convolutional Neural Network architectures with transfer learning for skin disease diagnosis," *Healthcare Analytics,* vol. 3, 2023.

[12] M. M. A. Wona, W. Rahayu dan U. Wirantasa, "Klasifikasi Dan Deteksi Penyakit Kulit Melalui Pengolahan Citra dengan Metode CNN," *Jurnal Riset dan Aplikasi Mahasiswa Informatika (JRAMI),* vol. 06, pp. 43-51, 2025.

[13] N. Nurkhasanah dan M. Murinto, "Klasifikasi penyakit kulit wajah menggunakan metode convolutional neural network.," *Sainteks,* vol. 18, no. 2, pp. 183-190, 2021.

[14] A. Wibowo, C. A. Hartanto dan P. W. Wirawan, "Android skin cancer detection and classification based on MobileNet v2 model," *International Journal of Advances in Intelligent Informatics,* vol. 6, no. 2, pp. 135-148, 2020.

[15] P. N. Srinivasu, J. G. SivaSai, M. F. Ijaz, A. K. Bhoi, W. Kim dan J. J. Kang, "Classification of Skin Disease Using Deep Learning Neural Networks with MobileNet V2 and LSTM," *Sensors,* vol. 21, no. 8, 2021.

[16] C. Shorten dan T. Khoshgoftaar, "A survey on image data augmentation

for deep learning," *Journal of big data,* vol. 6, no. 1, pp. 1-48, 2019.

Lampiran :

**Tabel 1.** *Parameter Augmentasi Data*

| No | Teknik Augmentasi | Parameter | Nilai |
|---|---|---|---|
| 1 | Rotasi | rotation_range | 40 |
| 2 | Horizontal Flip | Horizontal_flip | True |
| 3 | Pergeseran Lebar | Width_shift_range | 0.2 |
| 4 | Shear (Pencar) | Shear_range | 0.2 |
| 5 | Zoom | zoom_range | 0.2 |
| 6 | Normalisasi Piksel | Fungsi Pra-pemrosesan | Rentang [-1,1] |
| 7 | Ukuran Citra | target_size | (224,224) |

**Tabel 3.** *Hasil Pengujian Model*

| Kelas | TP | FP | FN | Precision (%) | Recall (%) | F1-Score (%) |
|---|---|---|---|---|---|---|
| BA-Cell | 125 | 1 | 0 | 99.2 | 100 | 99.6 |
| BA-Imp | 123 | 0 | 0 | 100 | 100 | 100 |
| FU-Ath | 128 | 1 | 1 | 99.2 | 99.2 | 99.2 |
| FU-Ring | 83 | 1 | 2 | 98.8 | 97.6 | 98.2 |
| VI-Chick | 153 | 2 | 2 | 98.7 | 98.7 | 98.7 |
| Normal | 211 | 2 | 2 | 99.0 | 99.0 | 99.0 |
| **Rata-rata** | | | | **99.1** | **99.1** | **99.1** |