



DETEKSI PENYAKIT KULIT DENGAN METODE *CONVOLUTIONAL NEURAL NETWORK* MENGGUNAKAN ARSITEKTUR VGG19

Ainunnisa Indah Rizqya¹, Nanda Martyan Anggadimas², Muhammad Misdram³

^{1,2,3} Informatika, Teknologi Informasi, Universitas Merdeka Pasuruan

Pasuruan, Jawa Timur, Indonesia 67126

ainunnisa.indah.r@gmail.com, nandama@unmerpas.ac.id, misdram@unmerpas.ac.id

Abstract

Early detection of skin diseases remains a major challenge, particularly in regions with limited access to dermatological services. This issue is further exacerbated by the shortage of medical specialists and the widespread presence of inaccurate health information online. This study aims to develop an automated image-based classification system capable of identifying five types of skin diseases: Eczema, Melanocytic Nevus, Melanoma, Benign Keratosis, and Basal Cell Carcinoma. The proposed method utilizes a Convolutional Neural Network (CNN) with the VGG19 architecture, enhanced through transfer learning and partial fine-tuning at the block4_conv1 layer. A dataset of 10,000 JPG images was used, with preprocessing steps including normalization, data augmentation, edge detection, and class balancing. Model performance was evaluated using accuracy, precision, recall, F1-score, and confusion matrix. Experimental results show that the model achieved an accuracy of up to 84% in the best scenario, with balanced performance across other metrics, indicating strong multiclass classification capabilities. These findings demonstrate the effectiveness of VGG19 in detecting skin diseases from images. The results also suggest the potential development of mobile-based early detection systems to support communities in underserved areas.

Keywords: CNN, Deep Learning, Skin Disease Detection, Image Classification, VGG19

Abstrak

Deteksi dini penyakit kulit merupakan tantangan signifikan, khususnya di daerah dengan keterbatasan layanan medis dermatologis. Masalah ini diperparah oleh kurangnya tenaga medis spesialis serta maraknya informasi kesehatan yang tidak akurat di internet. Tujuan dari penelitian ini adalah mengembangkan sistem klasifikasi otomatis berbasis citra digital guna mengidentifikasi lima jenis penyakit kulit: *Eczema, Melanocytic Nevus, Melanoma, Benign Keratosis, dan Basal Cell Carcinoma*. Metode yang digunakan adalah *Convolutional Neural Network* (CNN) dengan arsitektur VGG19 melalui pendekatan *transfer learning* dan *fine-tuning* parsial pada *layer block4_conv1*. *Dataset* terdiri dari 10.000 gambar berformat .jpg yang telah melalui tahap normalisasi, augmentasi, deteksi tepi, dan penyeimbangan kelas. Evaluasi dilakukan menggunakan metrik akurasi, presisi, *recall*, *F1-score*, dan *confusion matrix*. Hasil eksperimen menunjukkan bahwa model mencapai akurasi hingga 84% pada skenario terbaik, dengan keseimbangan metrik lainnya yang menunjukkan kinerja klasifikasi multi-kelas yang andal. Kesimpulan dari penelitian ini menunjukkan bahwa arsitektur VGG19 efektif untuk mendeteksi berbagai penyakit kulit berbasis citra. Implikasi dari hasil ini membuka peluang pengembangan sistem deteksi awal berbasis aplikasi *mobile*, terutama untuk membantu masyarakat di daerah dengan keterbatasan layanan medis.

Kata kunci: CNN, Deep Learning, Deteksi Penyakit Kulit, Klasifikasi Citra, VGG19

1. PENDAHULUAN

Masalah kulit merupakan gangguan kesehatan yang kerap terjadi di berbagai kalangan masyarakat dan dapat muncul akibat infeksi mikroorganisme, reaksi alergi, atau kondisi lingkungan yang tidak mendukung [1], [2], [3]. Walaupun tidak bersifat fatal, gejala yang ditimbulkan seperti gatal, nyeri, atau perubahan tampilan kulit bisa berdampak negatif

terhadap kenyamanan dan kepercayaan diri penderitanya [4], [5]. Di sisi lain, keterbatasan akses terhadap layanan dermatologi sering kali mendorong individu untuk mencari tahu kondisinya secara mandiri melalui internet [6], yang informasi di dalamnya belum tentu dapat dipercaya [7]. Oleh sebab itu, diperlukan sebuah sistem cerdas berbasis citra digital yang dapat memberikan analisis awal secara

otomatis dan objektif, sehingga mampu membantu proses identifikasi dini terhadap penyakit kulit sekaligus meminimalisir kesalahan dalam penentuan diagnosis secara pribadi [8].

Beberapa metode telah digunakan dalam klasifikasi kasus tersebut seperti *Convolutional Neural Network* (CNN), *Support Vector Machine* (SVM), dan *K-Nearest Neighbour* (K-NN) telah digunakan untuk mengenali pola visual dan melakukan klasifikasi secara otomatis [9], [10]. Salah satu studi menggabungkan CNN dan SVM, CNN yang sebagai ekstraksi fitur dengan arsitektur VGG-19 dan *ResNet50*. SVM digunakan sebagai pengklasifikasi dengan menggunakan *kernel* linear dan RBF kemudian dioptimasi menggunakan *random* dan *grid*. Studi ini menunjukkan bahwa kombinasi CNN dan *kernel* linear menghasilkan akurasi sebesar 65,33%, dengan *precision* 68,51% dan *f1-score* 65,77% [11]. CNN sendiri memiliki keunggulan dalam mengekstraksi pola spasial secara hierarkis tanpa perlu ekstraksi fitur manual, menjadikannya pendekatan yang efisien dan relevan dalam pengembangan sistem klasifikasi penyakit kulit [12], [13][14].

Salah satu penelitian sebelumnya juga menerapkan metode CNN dengan pendekatan *hybrid preprocessing* yang mengombinasikan CLAHE, *morphological closing*, dan median filter untuk meningkatkan kualitas citra sebelum proses klasifikasi. Penelitian tersebut berhasil mengklasifikasikan kanker kulit menjadi dua kelas, yaitu jinak dan ganas, dengan akurasi sebesar 78,19% [15].

Penelitian ini mengembangkan sistem klasifikasi otomatis berbasis CNN dengan arsitektur VGG19, yang terdiri dari 16 lapisan konvolusi dan 3 lapisan *fully connected*, serta fungsi aktivasi *softmax* untuk klasifikasi multi-kelas. Model yang digunakan merupakan versi pralatih dari *ImageNet* dan disesuaikan dengan karakteristik *dataset* melalui proses *fine-tuning* dari lapisan *block4_conv1*, agar tetap mempertahankan fitur umum sekaligus mampu belajar dari pola visual spesifik pada citra dermatologis.

Untuk meningkatkan generalisasi model, dilakukan augmentasi data secara sistematis seperti rotasi, *flipping*, *zoom*, dan perubahan warna. Di samping itu, distribusi kelas diseimbangkan agar model tidak bias terhadap kelas mayoritas. Hal ini memastikan bahwa proses pelatihan dan pengujian dilakukan dalam kondisi yang setara antar kelas, sehingga performa model dapat diukur secara seimbang.

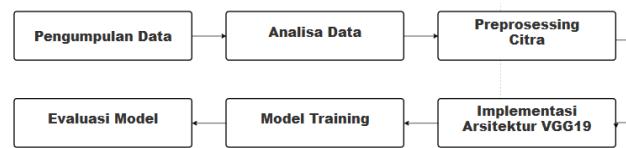
Berbeda dari studi sebelumnya yang menggunakan CNN-SVM tanpa penyesuaian arsitektur atau distribusi data yang jelas, penelitian ini menggunakan pendekatan *end-to-end* berbasis VGG19 dengan *fine-tuning* parsial, augmentasi sistematis, serta distribusi data yang seimbang guna meningkatkan akurasi dan daya generalisasi model dalam klasifikasi penyakit kulit multi-kelas.

Model dilatih menggunakan *Adam optimizer* dan *loss function categorical crossentropy*, serta dievaluasi

menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score* untuk mengukur konsistensi dan ketepatan klasifikasi lima jenis penyakit kulit. Dengan pendekatan ini, sistem yang dikembangkan diharapkan mampu memberikan hasil klasifikasi awal yang akurat sebagai dukungan dalam identifikasi dini penyakit kulit berbasis citra digital [16]. Sistem ini tidak dimaksudkan untuk menggantikan peran profesional medis, tetapi sebagai alat bantu yang meningkatkan kesadaran masyarakat serta mengurangi potensi salah diagnosis secara mandiri [17].

2. METODE PENELITIAN

Penelitian ini mengadopsi metode pengembangan sistem identifikasi penyakit kulit berbasis citra menggunakan algoritma CNN dengan arsitektur VGG19. Proses penelitian ini dijabarkan secara sistematis melalui alur kerja yang dapat dilihat pada Gambar 1.



Gambar 1. Diagram Alur Penelitian

2.1 Pengumpulan Data

Penelitian ini menggunakan *dataset* dari *Kaggle* yang disediakan oleh akun bernama *Ismail Hossain*, yang berisi kumpulan gambar penyakit kulit yang dapat digunakan untuk pengujian dan pelatihan model deteksi [18]. *Dataset* tersebut berisi 10.000 gambar yang diklasifikasikan ke dalam 5 kategori penyakit kulit, yaitu *Eczema* (*Eczema*), *Melanocytic Nevus*, *Melanoma*, *Benign Keratosis*, *Basal Cell Carcinoma* yang disimpan dalam dokumen *file* dengan format *.jpg*. Contoh data dari masing-masing kategori dapat dilihat pada Tabel 1.

Tabel 1. Contoh *Dataset* Penyakit Kulit

| <i>Melanoma</i> | <i>Melanocytic nevus</i> | <i>Eczema</i> | <i>Benign keratosis</i> | <i>Basal cell carcinoma</i> |
|-----------------|--------------------------|---------------|-------------------------|-----------------------------|
| | | | | |
| | | | | |

2.2 Analisis Data

Penelitian ini diawali dengan analisis terhadap *dataset* citra kulit guna mengevaluasi kualitas visual, keragaman kelas, serta proporsi data yang seimbang.

a) Keseimbangan Data Gambar (*Imbalance data*)

Dataset keseluruhan dipisahkan ke dalam tiga kelompok utama, yakni data pelatihan (*train*), data pengujian (*test*),

dan data valid. Jumlah gambar yang tersedia untuk masing-masing kategori penyakit kulit dalam ketiga folder tersebut dirangkum dan dapat dilihat pada Tabel 2.

Tabel 2. Total Gambar Train dan Test

| No | Kategori Penyakit Kulit | Train | Test | Valid | Total |
|----|-----------------------------|-------|------|-------|-------|
| 1. | <i>Melanoma</i> | 1.600 | 200 | 200 | 2.000 |
| 2. | <i>Melanocytic nevus</i> | 1.600 | 200 | 200 | 2.000 |
| 3. | <i>Ekzama</i> | 1.600 | 200 | 200 | 2.000 |
| 4. | <i>Benign keratosis</i> | 1.600 | 200 | 200 | 2.000 |
| 5. | <i>Basal cell carcinoma</i> | 1.600 | 200 | 200 | 2.000 |

b) Kelengkapan Data (*Missing Data*)

Hasil pemeriksaan menunjukkan bahwa *dataset* tidak mengandung *missing data*, seluruh gambar berformat .JPG dapat diakses dengan baik dan telah terklasifikasi secara rapi berdasarkan kategori penyakit kulit masing-masing. Dengan struktur yang terorganisir, *dataset* siap digunakan dalam proses pelatihan dan pengujian model.

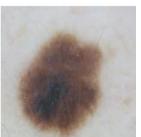
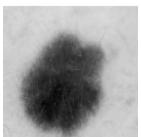
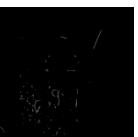
c) Format dan Resolusi Gambar

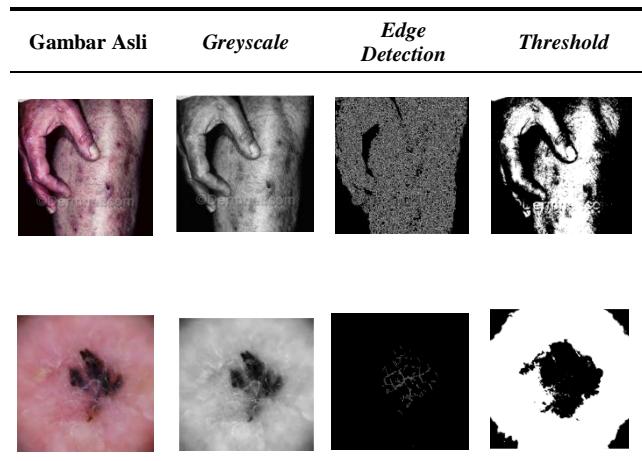
Seluruh gambar dalam *dataset* telah diformat dalam ekstensi .JPG, berukuran 224×224 piksel, dan menggunakan skema warna RGB, sesuai standar input VGG19. Standarisasi ini memastikan kompatibilitas dengan *framework deep learning* seperti *TensorFlow* dan *Keras*, serta mendukung efisiensi dan konsistensi selama pelatihan model.

2.3 Preprocessing Citra

Tahapan *preprocessing* citra pada penelitian ini mencakup pembersihan data gambar, normalisasi, *augmentasi*, pembagian *dataset*, dan penanganan ketidakseimbangan kelas. Proses pembersihan data dilakukan untuk memastikan kualitas dan relevansi gambar dalam *dataset*, termasuk penghapusan duplikat menggunakan metode *image hashing*, eliminasi gambar buram melalui *Laplace variance*, serta penerapan deteksi tepi menggunakan *Canny Edge Detection* untuk menjaga ketajaman fitur visual. Ilustrasi dari tahapan *preprocessing* tersebut dapat dilihat pada Tabel 3.

Tabel 3. Visualisasi Tahapan *Preprocessing* Citra Kulit

| Gambar Asli | Greyscale | Edge Detection | Threshold |
|---|---|---|---|
|  |  |  |  |



Setiap gambar menunjukkan empat tahap *preprocessing*: citra asli, citra *grayscale*, hasil deteksi tepi (*Canny*), dan hasil *thresholding* yang digunakan untuk menyoroti fitur penting sebelum pelatihan model CNN.

Selanjutnya, dilakukan normalisasi dengan mengonversi nilai piksel dari rentang 0–255 ke 0–1 menggunakan fungsi *Rescaling* dari *TensorFlow*, guna meningkatkan stabilitas pelatihan dan menghindari permasalahan seperti *gradient explosion* atau *vanishing*. Mengingat potensi berkurangnya jumlah data akibat pembersihan, diterapkan teknik *augmentasi* untuk memperkaya keragaman data menggunakan parameter seperti *random brightness* (± 0.1), *random flip* (horizontal dan vertikal), *random rotation* (hingga 20°), serta *random zoom* dan *translation* guna meningkatkan ketahanan model terhadap variasi visual. Dalam kasus ketidakseimbangan jumlah gambar antar kelas, diterapkan strategi *oversampling* pada kelas minoritas, *undersampling* pada kelas mayoritas, serta *class weighting* saat pelatihan guna menjaga akurasi prediksi pada seluruh kategori penyakit kulit secara adil.

2.4 Implementasi Arsitektur VGG19

Pada penelitian ini, arsitektur VGG19 digunakan sebagai dasar dalam membangun model klasifikasi citra penyakit kulit dengan memanfaatkan teknik *transfer learning*. Model VGG19 yang telah dilatih sebelumnya menggunakan dataset *ImageNet* dimuat ulang untuk mempercepat proses pelatihan dan meningkatkan efisiensi, tanpa perlu melatih model dari awal. Beberapa lapisan awal model dikunci (*non-trainable*) agar bobot aslinya tetap digunakan dalam mengenali fitur visual dasar seperti tepi dan tekstur.

Penyesuaian lanjutan dilakukan melalui proses *fine-tuning* pada lapisan atas, dimulai dari *block4_conv1*, sehingga model dapat menyesuaikan diri dengan karakteristik spesifik dari data citra penyakit kulit. Keluaran dari lapisan konvolusional terakhir diratakan menggunakan lapisan *Flatten*, kemudian dihubungkan ke lapisan *Dense* berjumlah 512 *neuron* dengan aktivasi *ReLU*, dan dilanjutkan dengan lapisan *Dropout* sebesar 60% untuk mengurangi risiko *overfitting*.

Bagian akhir dari jaringan merupakan *output layer* dengan jumlah *neuron* yang sesuai dengan jumlah kelas, menggunakan aktivasi *Softmax* untuk menghasilkan prediksi multi-kelas. Model dikompilasi menggunakan *optimizer Adam* dengan *learning rate 1e-5*, fungsi *loss categorical crossentropy*, serta metrik evaluasi *accuracy*.

Agar pelatihan berjalan lebih optimal, dua *callback* turut digunakan: *EarlyStopping*, untuk menghentikan pelatihan jika tidak ada peningkatan pada data validasi dalam 8 *epoch* berturut-turut, serta *ModelCheckpoint*, untuk menyimpan bobot terbaik selama proses pelatihan. Dengan konfigurasi ini, model diharapkan mampu menghasilkan performa klasifikasi yang akurat dan stabil pada data yang belum pernah dikenali sebelumnya.

2.5 Model Training

Setelah proses kompilasi dan konfigurasi *callback* selesai, model dilatih menggunakan fungsi *model.fit()* dengan memanfaatkan data latih dan data validasi. Selama pelatihan berlangsung, penyesuaian bobot dilakukan secara bertahap melalui mekanisme *fine-tuning* dan penyesuaian pada lapisan klasifikasi tambahan agar model mampu mengenali pola visual dari citra penyakit kulit secara optimal. Kinerja model selama proses pelatihan dimonitor menggunakan metrik akurasi dan *loss*, yang disimpan dalam objek *history* untuk keperluan evaluasi lebih lanjut. Rincian terkait skenario pelatihan ditampilkan pada Tabel 4.

Tabel 4. Skenario Pengujian

| Skenario | Keterangan |
|----------------|--|
| Pembagian Data | <ul style="list-style-type: none"> • 80% <i>Train</i> : 10% validasi : 10% <i>Test</i> • 70% <i>Train</i> : 20% validasi : 10% <i>Test</i> |
| Kelas | <i>Eczema, Melanocytic nevus, Melanoma, Benign Keratosis, Basal Cell Carcinoma.</i> |
| Ukuran Data | 224 × 224 piksel |
| Batch Size | 32 |
| Epoch | 20, 50, 100 |

Parameter yang ditetapkan dalam Tabel 4 dirancang berdasarkan pertimbangan metodologis yang umum digunakan dalam pelatihan model *deep learning*, khususnya arsitektur *VGG19*. Ukuran citra 224 × 224 piksel dipilih karena merupakan format masukan standar dari *VGG19*, yang memastikan kompatibilitas struktural dan memungkinkan model menangkap fitur visual penting dari lesi kulit secara efisien.

Penggunaan *batch size* sebesar 32 ditujukan untuk mencapai efisiensi dalam pelatihan model sambil tetap menjaga kestabilan proses optimasi. Nilai ini juga dinilai ideal untuk perangkat keras umum yang memiliki keterbatasan kapasitas memori, seperti *GPU* kelas menengah.

Untuk mempelajari pengaruh durasi pelatihan terhadap performa model, jumlah *epoch* divariasikan menjadi 20, 50, dan 100. Perbandingan ini dilakukan untuk mengamati seberapa cepat model mencapai *konvergensi*, sekaligus mengidentifikasi potensi terjadinya *overfitting* ketika pelatihan berlangsung terlalu lama.

Dalam hal pembagian data, dua rasio digunakan, yaitu 80% untuk pelatihan, 10% untuk validasi, dan 10% untuk pengujian, serta 70% pelatihan, 20% validasi, dan 10% pengujian. Tujuan dari penggunaan dua skema ini adalah untuk melihat dampak perubahan alokasi data validasi terhadap hasil pelatihan. Rasio pertama lebih mengutamakan kapasitas pembelajaran dengan jumlah data pelatihan yang lebih besar, sedangkan rasio kedua memberikan ruang validasi yang lebih luas untuk pemantauan performa selama proses pelatihan berlangsung. Adapun data uji tetap dijaga sebesar 10% pada kedua skenario guna menjamin evaluasi akhir yang seimbang dan tidak bias terhadap data yang telah dilatih.

2.6 Evaluasi Model

Setelah proses pelatihan selesai, evaluasi performa model dilakukan terhadap data validasi dan data uji menggunakan fungsi *model.evaluate()*, yang menghitung nilai *loss* dan akurasi untuk menilai sejauh mana model mampu mempelajari pola dari data pelatihan serta menggeneralisasikannya terhadap data yang belum pernah dilihat sebelumnya, di mana hasil evaluasi berupa akurasi validasi dan akurasi uji memberikan indikator seberapa tepat model dalam mengklasifikasikan citra penyakit kulit, dengan akurasi tinggi pada kedua jenis data yang menunjukkan kemampuan model yang andal dan aplikatif dalam konteks nyata. Untuk mengevaluasi performa model dalam mendeteksi dan mengklasifikasikan citra penyakit kulit, digunakan sejumlah metrik evaluasi, yaitu *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Metrik-metrik ini memberikan gambaran menyeluruh terhadap kemampuan model dalam mengenali pola dan menghindari kesalahan klasifikasi, terutama pada data yang belum pernah dilihat sebelumnya.

a) Accuracy

$$\text{Accuracy} = \frac{TP}{\text{total data}}$$

b) Precision

$$\text{Precision} = \frac{TP}{TP + FP}$$

c) Recall

$$\text{Recall} = \frac{TP}{TP + FN}$$

d) *F1-score*

$$F1 - Score = 2 \times \frac{TP}{TP + FN}$$

e) *Confusion Matrix*

Rincian tabel *confusion matrix* dapat dilihat pada tabel 5 berikut.

Tabel 5. *Confusion Matrix*

| | <i>Predicted Positif</i> | <i>Predicted Negatif</i> |
|-------------------------|--------------------------|--------------------------|
| <i>Actually Positif</i> | TP | FN |
| <i>Actually Negatif</i> | FP | TN |

Confusion Matrix memiliki empat komponen utama yang mencakup kemungkinan hasil dari prediksi klasifikasi. Struktur umum *Confusion Matrix* tersebut ditampilkan pada Tabel 5, yang menjelaskan hubungan antara prediksi model dan kondisi aktual dari data. Penjelasan masing-masing komponen adalah sebagai berikut:

- True Positive (TP)*: Kasus positif yang berhasil diklasifikasikan secara benar sebagai positif oleh model.
- True Negative (TN)*: Kasus negatif yang diklasifikasikan secara tepat sebagai negatif oleh sistem.
- False Positive (FP)*: Kasus negatif yang secara keliru terdeteksi sebagai positif oleh model.
- False Negative (FN)*: Kasus positif yang gagal dikenali dan justru diklasifikasikan sebagai negatif.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Training Model

Sebelumnya, metode *Convolutional Neural Network* (CNN) digunakan sebagai pendekatan utama dalam membangun model klasifikasi citra penyakit kulit. Model ini terdiri dari sejumlah komponen penting, seperti *convolution layer*, *pooling layer*, *flatten layer*, dan *dense layer* yang berperan dalam mengekstraksi dan mengklasifikasikan fitur visual dari citra kulit. Dalam penelitian ini, model CNN yang telah dilatih mampu melakukan prediksi dan deteksi penyakit kulit berdasarkan kategori yang telah ditentukan. Hasil ini dibuktikan melalui performa model terhadap data pelatihan dan validasi yang menunjukkan kemampuan dalam mengenali pola-pola visual secara efektif.

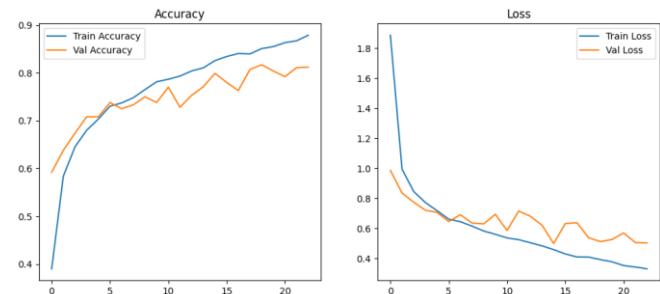
Setelah model selesai dikonstruksi, tahap selanjutnya adalah melakukan proses pelatihan (*training*). Sebelum pelatihan dimulai, jumlah *epoch* yang akan digunakan harus ditentukan terlebih dahulu. Penentuan jumlah *epoch* merupakan aspek penting karena berpengaruh langsung terhadap kemampuan model dalam belajar dari data. Namun, berdasarkan kajian dari beberapa penelitian

terdahulu, tidak terdapat ketentuan baku mengenai jumlah *epoch* yang ideal. Hal ini bergantung pada berbagai faktor, seperti jumlah data latih, kompleksitas kelas, serta arsitektur model yang digunakan. Oleh karena itu, dalam penelitian ini dilakukan beberapa percobaan pelatihan dengan variasi jumlah *epoch* dan rasio pembagian data. Tujuannya adalah untuk mengevaluasi kombinasi konfigurasi yang dapat menghasilkan performa model paling optimal. Rincian dari konfigurasi pelatihan tersebut ditampilkan pada Tabel 6.

Tabel 6. Percobaan Model *Train*

| Rasio | Epoch | Train | | Validasi | | Test | |
|-------|-------|---------|------|----------|------|---------|------|
| | | Akurasi | Loss | Akurasi | Loss | Akurasi | Loss |
| 70:30 | 20 | 0.87 | 0.34 | 0.78 | 0.65 | 0.80 | 0.54 |
| 70:30 | 50 | 0.87 | 0.36 | 0.81 | 0.50 | 0.79 | 0.59 |
| 70:30 | 100 | 0.88 | 0.31 | 0.83 | 0.51 | 0.80 | 0.58 |
| 80:20 | 20 | 0.87 | 0.35 | 0.82 | 0.55 | 0.80 | 0.57 |
| 80:20 | 50 | 0.88 | 0.31 | 0.80 | 0.50 | 0.86 | 0.38 |
| 80:20 | 100 | 0.89 | 0.28 | 0.84 | 0.60 | 0.80 | 0.59 |

Setelah dilakukan beberapa percobaan dalam proses pelatihan, konfigurasi model yang memberikan hasil terbaik menggunakan rasio data 80:20 untuk validasi, dengan jumlah iterasi sebanyak 50 *epoch*. Pada konfigurasi ini, model berhasil mencapai tingkat akurasi sebesar 0.88 pada data pelatihan, 0.81 pada data validasi, dan 0.86 pada data uji. Perbandingan hasil akurasi ini divisualisasikan pada Gambar 2 sebagai bagian dari evaluasi performa model.



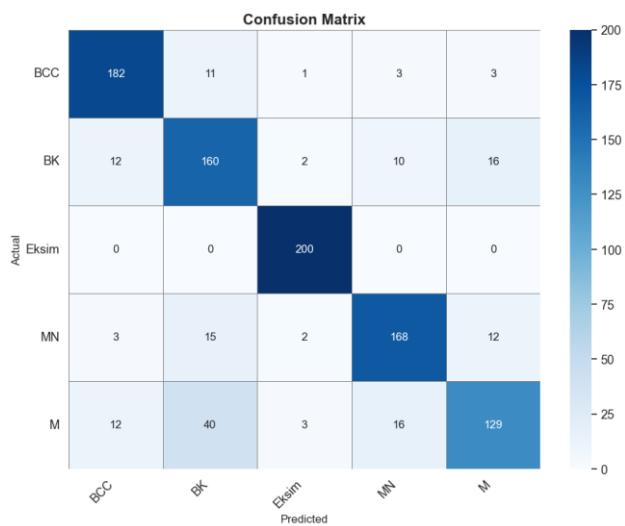
Gambar 2. Grafik Akurasi dan *Loss* selama *Training* dan *Validation*

Gambar 2 menggambarkan tren kinerja model selama proses pelatihan. Akurasi pada data pelatihan meningkat secara bertahap dan konsisten, menunjukkan bahwa model mampu mempelajari representasi fitur secara progresif. Akurasi validasi juga menunjukkan pola kenaikan meskipun disertai fluktuasi ringan, yang mencerminkan adanya variasi kompleksitas antar kelas citra kulit. Sementara itu, nilai *loss* pada data pelatihan menurun secara signifikan, diikuti oleh *loss* validasi yang juga menurun di awal pelatihan dan kemudian stabil. Tidak ditemukannya lonjakan tajam pada *loss* validasi mengindikasikan bahwa model tidak mengalami *overfitting* yang signifikan, dan proses pelatihan berlangsung dengan stabil serta konvergen secara optimal.

3.2 Pengujian Model

Setelah proses pengembangan sistem diselesaikan, tahap selanjutnya adalah melakukan evaluasi untuk mengukur kinerja serta efektivitas model yang telah dibangun. Evaluasi ini berperan penting dalam menentukan kemampuan model dalam melakukan klasifikasi data sesuai dengan sasaran penelitian. Pada studi ini, proses pengujian dilakukan dengan memanfaatkan *confusion matrix* yang diimplementasikan melalui *Visual Studio Code*. Melalui *confusion matrix* tersebut, sejumlah metrik evaluasi seperti akurasi, presisi, *recall*, dan *f1-score* dapat dihitung secara akurat dan komprehensif.

Dataset uji yang digunakan untuk pengujian terdiri dari 2000 gambar yang terbagi merata ke dalam lima kategori penyakit kulit, yaitu 200 gambar untuk kelas *Eczema*, 200 gambar untuk *Melanocytic Nevus*, 200 gambar untuk *Melanoma*, 200 gambar untuk Benign Keratosis, serta 200 gambar untuk *Basal Cell Carcinoma*. Dengan menggunakan data ini, model diuji untuk mengetahui kemampuannya dalam mengenali dan mengklasifikasikan masing-masing kelas penyakit kulit tersebut. Hasil dari pengujian ini divisualisasikan dalam bentuk *confusion matrix* yang dapat memberikan gambaran mendetail mengenai jumlah prediksi benar dan salah dari setiap kelas. Visualisasi hasil tersebut dapat dilihat pada Gambar 3.



Gambar 3. *Confusion Matrix*

Gambar 3 menunjukkan bahwa sebagian besar prediksi benar berada pada diagonal utama, menandakan keberhasilan model dalam mengklasifikasikan gambar secara tepat. Namun, masih terjadi kesalahan klasifikasi antar kelas dengan kemiripan visual tinggi, khususnya antara *Melanoma* dan *Melanocytic Nevus*, serta *Eczema* dan *Benign Keratosis*. Hal ini kemungkinan disebabkan oleh tekstur dan warna lesi yang serupa. Meski demikian, distribusi kesalahan tetap merata tanpa dominasi kelas tertentu, menandakan kinerja model yang seimbang.

Model klasifikasi yang dikembangkan menunjukkan tingkat kinerja yang cukup optimal, dengan *accuracy*, *precision*, *recall*, *F1-score* masing-masing mencapai 84%. Nilai-nilai ini mencerminkan bahwa model memiliki kemampuan yang konsisten dalam membedakan berbagai jenis penyakit kulit, termasuk *Basal cell carcinoma*, *Benign keratosis*, *Eczema*, *Melanocytic nevus*, dan *Melanoma*.

Keseimbangan antara *precision* dan *recall* menandakan bahwa sistem tidak hanya andal dalam memberikan prediksi yang benar, tetapi juga tanggap dalam mendeteksi seluruh kasus yang relevan. Kemampuan tersebut menjadikan model ini layak untuk dimanfaatkan sebagai bagian dari sistem klasifikasi otomatis berbasis citra, yang berpotensi membantu proses identifikasi penyakit kulit secara lebih cepat dan efisien, terutama di lingkungan medis dengan keterbatasan sumber daya.

4. KESIMPULAN

Penelitian ini berhasil merancang dan mengimplementasikan sistem klasifikasi berbasis citra digital untuk mendeteksi berbagai jenis penyakit kulit menggunakan algoritma *Convolutional Neural Network* (CNN) dengan arsitektur VGG19. Berdasarkan hasil evaluasi, model menunjukkan performa yang konsisten dan memuaskan, dengan perolehan *accuracy*, *precision*, *recall*, *F1-score* masing-masing sebesar 84%. Nilai-nilai tersebut menggambarkan kemampuan model dalam membedakan lima kategori penyakit kulit secara tepat dan konsisten.

Kinerja model yang seimbang antara seluruh metrik evaluasi menunjukkan bahwa sistem tidak hanya akurat dalam memprediksi klasifikasi, tetapi juga sensitif terhadap variasi visual dari masing-masing jenis penyakit. Hal ini memperkuat potensi penerapan model sebagai alat bantu deteksi awal yang berbasis gambar, khususnya untuk mempercepat proses diagnosis di daerah dengan keterbatasan layanan medis.

Ke depan, pengembangan model ini dapat ditingkatkan dengan memperluas variasi data pelatihan, sehingga representasi dari kondisi kulit yang lebih kompleks dapat terakomodasi. Selain itu, pengujian langsung terhadap data riil dari lingkungan klinis dapat meningkatkan keandalan model dalam konteks praktis. Integrasi sistem ke dalam platform aplikasi *mobile* juga menjadi opsi strategis agar teknologi ini dapat menjangkau masyarakat secara luas dan memberikan manfaat sebagai sarana deteksi dini secara mandiri. Selain itu, perbandingan terhadap berbagai arsitektur CNN seperti *ResNet*, *DenseNet*, atau *Inception* dapat dilakukan untuk mengevaluasi keunggulan relatif VGG19 dalam klasifikasi penyakit kulit.

DAFTAR PUSTAKA

- [1] W. A. Ningrum, M. M. Awaludin, and I. Suryani, "Pengaruh Swamedikasi Penyakit Kulit terhadap Tingkat Pengetahuan Siswa di Panti Asuhan Yatim Muhammadiyah Kabupaten Pekalongan," *Sinteza*,

- vol. 4, no. 2, pp. 56–64, Aug. 2024, doi: 10.29408/sinteza.v4i2.20309.
- [2] Y. Widya, A. Rustam, C. Chazar, and M. A. Ramdhani, “INFORMASI (Jurnal Informatika dan Sistem Informasi) Aplikasi Diagnosa Penyakit Kulit Menggunakan dengan Menggunakan Metode Convolutional Neural Networks,” 2023.
- [3] R. P. Yola Hutasoit, M. Khairul Anam, P. Studi Teknik Informatika, and P. Studi Teknologi Informasi, “Implementasi Metode Forward Chaining untuk Identifikasi Penyakit Kulit dan Alternatif Penanganannya,” *JURNAL INOVTEK POLBENG*, vol. 6, no. 1, 2021.
- [4] T. Lestari, E. Maylina, F. Willy Ahzami, F. Nur Fadila, I. Mutiara Sari, and Q. Ayun, “Review: Jurnal Swamedikasi tentang Penyakit Kulit Akibat Bakteri (Bisul dan Jerawat) Review: Journal Of Swamedication on Bacterial Skin Diseases (Boils And Acne),” 2023.
- [5] A. Primadiamanti, R. Erlisa, T. Artianti, U. Sarimanah, and W. Datul Awalliyyah, “Cerdas Memilih Obat dalam Swamedikasi Penyakit Kulit di Posyandu Melati II Puskesmas Tanjung Sari Natar Lampung Selatan,” 2021.
- [6] D. Rizqoh, E. Nugraheni, A. Prihatiningrum, and P. Meidiyanti, “Edukasi Perilaku Hidup Bersih dan Sehat untuk Pencegahan Penyakit Infeksi Kulit,” *Dharma Raflesia Jurnal Ilmiah Pengembangan dan Penerapan IPTEKS*, vol. 22, no. 02, pp. 308–320, 2024, doi: 10.33369/dr.v22i2.37797.
- [7] N. Salari, P. Heidarian, A. Hosseini-Far, F. Babajani, and M. Mohammadi, “Global Prevalence of Anxiety, Depression, and Stress Among Patients with Skin Diseases: A Systematic Review and Meta-analysis,” *Journal of Prevention*, vol. 45, no. 4, pp. 611–649, Aug. 2024, doi: 10.1007/s10935-024-00784-0.
- [8] A. Farnood, B. Johnston, and F. S. Mair, “A Mixed Methods Systematic Review of The Effects of Patient Online Self-Diagnosing in The ‘Smart-Phone Society’ on The Healthcare Professional-Patient Relationship and Medical Authority,” Oct. 06, 2020, *BioMed Central Ltd.* doi: 10.1186/s12911-020-01243-6.
- [9] A. Rushi, B. Sharvani, B. Ajay, and K. Padmaja Devi, “Skin Disease Diagnosis Using CNN with SVM Techniques,” 2023. [Online]. Available: www.ijcrt.org
- [10] E. Tjoa and C. Guan, “A Survey on Explainable Artificial Intelligence (XAI): Toward Medical XAI,” *IEEE Trans Neural Netw Learn Syst*, vol. 32, no. 11, pp. 4793–4813, Nov. 2021, doi: 10.1109/TNNLS.2020.3027314.
- [11] R. , Yohannes and M. Rivan, “Klasifikasi Jenis Kanker Kulit Menggunakan CNN-SVM,” *Jurnal Algoritme*, vol. 2, no. 2, pp. 133–144, 2022.
- [12] G. Yang, S. Luo, and P. Greer, “Advancements in skin cancer classification: a review of machine learning techniques in clinical image analysis,” *Multimed Tools Appl*, vol. 84, no. 11, pp. 9837–9864, Mar. 2025, doi: 10.1007/s11042-024-19298-2.
- [13] Z. H. R. Naji and N. K. El Abbadi, “Skin Diseases Classification using Deep Convolutional Neural Network,” in *2022 Iraqi International Conference on Communication and Information Technologies, IICCIT 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 309–315. doi: 10.1109/IICCIT55816.2022.10010658.
- [14] A. I. Kushartanto, F. Fauziah, and R. T. Aldisa, “Comparison of CNN and SVM Methods on Web-based Skin Disease Classification Process,” *Sinkron*, vol. 8, no. 2, pp. 778–788, Mar. 2024, doi: 10.33395/sinkron.v8i2.13349.
- [15] F. Dartiko, R. J. Pradana, R. E. Sari, W. Syahputra, W. Kz Oktoeberza, and A. W. Artikel, “Klasifikasi Kanker Kulit Berbasis CNN dengan Metode Hybrid Preprocessing INFO ARTIKEL ABSTRAK”, doi: 10.18196/mt.v5i.
- [16] F. D. Wibowo, I. Palupi, and B. A. Wahyudi, “Image Detection for Common Human Skin Diseases in Indonesia Using CNN and Ensemble Learning Method,” *Journal of Computer System and Informatics (JoSYC)*, vol. 3, no. 4, pp. 527–535, Sep. 2022, doi: 10.47065/josyc.v3i4.2151.
- [17] M. Daffa *et al.*, “Sistem Pakar Diagnosa Penyakit Kulit pada Manusia dengan Menerapkan Metode Forward Chaining,” *Jurnal Riset dan Aplikasi Mahasiswa Informatika (JRAMI)*, vol. 05, 2024.
- [18] H. Ismail, “Skin diseases image dataset,” Kaggle. Accessed: Jun. 17, 2025. [Online]. Available: <https://www.kaggle.com/datasets/ismailhossain/sd-260>