

Penerapan Convolutional Neural Network dengan ResNet-50 untuk Klasifikasi Penyakit Kulit Wajah Efektif

Nadia Ifti Khani^{1,*}, Sindhu Rakasiwi¹

¹ Program Studi Teknik Informatika, Universitas Dian Nuswantoro, Indonesia

* Correspondence: 111202113320@mhs.dinus.ac.id

Copyright: © 2025 by the authors

Received: 13 Februari 2025 | Revised: 23 Februari 2025 | Accepted: 29 Maret 2025 | Published: 16 April 2025

Abstrak

Penyakit kulit memiliki prevalensi tinggi di Indonesia, mencapai 12,95% dari populasi, sehingga deteksi dini menjadi langkah penting dalam penanganannya. Penelitian ini bertujuan untuk mengimplementasikan *deep learning* berbasis *Convolutional Neural Network* (CNN) dengan arsitektur ResNet-50 untuk meningkatkan akurasi klasifikasi penyakit kulit wajah melalui citra medis. Data yang digunakan berasal dari dataset *Augmented Skin Conditions* (Kaggle) dengan total 2.394 citra, yang diproses melalui tahap *preprocessing*, augmentasi, dan pembagian data pelatihan serta pengujian dengan rasio 80%:20%. Proses augmentasi menghasilkan variasi citra, namun ditemukan distorsi vertikal akibat pengaturan *zooming* dan kemungkinan efek *shearing*. Model ini berhasil mencapai akurasi sebesar 94%, lebih tinggi dibandingkan penelitian sebelumnya dalam klasifikasi pneumonia menggunakan ResNet-50 yang memperoleh akurasi 86%, yang dipengaruhi oleh ketidakseimbangan data dan kemiripan fitur visual antar kelas. Hasil ini menunjukkan bahwa ResNet-50 mampu mengatasi masalah *vanishing gradient* dan mengekstraksi fitur kompleks citra medis secara optimal. Dengan performa tersebut, model ini berpotensi diterapkan dalam sistem kecerdasan buatan untuk membantu tenaga medis dalam proses deteksi dini penyakit kulit secara cepat, akurat, dan efisien.

Kata kunci: cnn; *deep learning*; gambar medis; klasifikasi penyakit kulit; resnet-50

Abstract

Skin diseases have a high prevalence in Indonesia, reaching 12.95% of the population, so early detection is an important step in handling them. This research aims to implement deep learning based on Convolutional Neural Network (CNN) with ResNet-50 architecture to improve the accuracy of facial skin disease classification through medical images. The data used comes from the Augmented Skin Conditions (Kaggle) dataset with a total of 2,394 images, which are processed through preprocessing, augmentation, and division of training and testing data with a ratio of 80%: 20%. The augmentation process resulted in image variations, but vertical distortions were found due to zooming settings and possible shearing effects. The model achieved an accuracy of 94%, higher than the previous study on pneumonia classification using ResNet-50 which obtained an accuracy of 86% and was affected by data imbalance and similarity of visual features between classes. These results show that ResNet-50 can overcome the vanishing gradient problem and extract complex features from medical images optimally. With this performance, this model can be applied in artificial intelligence systems to assist medical personnel in the early detection of skin diseases quickly, accurately, and efficiently.

Keywords: cnn; *deep learning*; medical images; skin disease classification; resnet-50

PENDAHULUAN

Penyakit kulit merupakan salah satu masalah kesehatan yang umum terjadi, terutama di negara tropis seperti Indonesia. Penyakit kulit dapat disebabkan oleh virus, jamur, dan bakteri, serta dipicu oleh faktor lingkungan, kebersihan, dan sistem imun individu. Jika tidak ditangani



dengan tepat, infeksi dapat menyebar ke area kulit lainnya dan mengganggu aktivitas sehari-hari. Oleh karena itu, penyakit kulit memerlukan perhatian serius dan penanganan yang tepat (Ria et al., 2022). Berikut ini merupakan beberapa data mengenai angka kejadian penyakit kulit yang diperoleh dari berbagai sumber. Menurut data Kementerian Kesehatan RI tahun 2023, prevalensi penyakit kulit di Indonesia mencapai 12,95% dari total populasi, menjadikannya salah satu masalah kesehatan yang paling sering dijumpai (Darmawan et al., 2024). Sementara itu, berdasarkan laporan *World Health Organization* tahun 2022, prevalensi penyakit infeksi kulit di negara-negara berkembang mencapai 85% dari total kasus penyakit dermatologis.

Di Indonesia, jumlah kasus infeksi kulit yang dilaporkan pada tahun 2014 mencapai 4.362 kasus, dengan persentase 68,43% dari keseluruhan kasus yang terdata (Gustiana, 2022). Prevalensi penyakit kulit di Indonesia berkisar antara 4,60% hingga 12,95%, menjadikannya salah satu kondisi kesehatan yang paling sering dijumpai di masyarakat. Berdasarkan data yang tersedia, penyakit kulit menempati peringkat ketiga dari 10 jenis penyakit yang paling umum terjadi (Rahayu et al., 2023). Selain itu, penyakit kulit juga memiliki dampak yang cukup signifikan dalam dunia kesehatan, dengan kontribusi sebesar 1,79% dari total 306 jenis penyakit dan cedera yang tercatat dalam laporan *Global Burden of Disease Study* tahun 2023 (Lantang & Jacobus, 2024). Tingginya angka kejadian penyakit kulit, baik di tingkat global maupun nasional, mengindikasikan bahwa kondisi ini masih menjadi tantangan kesehatan yang serius, khususnya di negara berkembang. Oleh karena itu, diperlukan strategi deteksi dini berbasis teknologi yang lebih akurat dan efisien guna meningkatkan efektivitas diagnosis dan penanganan penyakit kulit.

Tingginya prevalensi penyakit kulit disebabkan oleh berbagai faktor, seperti iklim tropis, tingkat kebersihan yang rendah, keterbatasan akses layanan kesehatan, serta kurangnya kesadaran masyarakat dalam pencegahan (Pohan & Chairunisah, 2024). Penyakit kulit juga menempati posisi empat besar sebagai penyakit non-fatal yang paling umum, meskipun jarang menyebabkan kematian, tetapi tetap berdampak signifikan pada kualitas hidup. Untuk menekan angka kasus penyakit kulit, diperlukan pendekatan berbasis teknologi yang lebih efektif dalam deteksi dini dan klasifikasi otomatis. Salah satu solusi yang dapat diterapkan adalah penerapan deep learning dengan teknik data mining berbasis CNN untuk mengklasifikasikan berbagai jenis penyakit kulit secara akurat. CNN telah terbukti efektif dalam menganalisis citra medis dan mengekstraksi fitur kompleks, sehingga dapat membantu tenaga medis dalam proses diagnosis (Pajo et al., 2024). Selain itu, model berbasis CNN mampu mengatasi subjektivitas pemeriksaan klinis dan meningkatkan efisiensi diagnosis dengan memproses data dalam jumlah besar secara otomatis.

Beberapa penelitian sebelumnya telah menerapkan CNN dalam klasifikasi penyakit kulit, seperti penelitian Supirman et al. (2023) yang menggunakan arsitektur VGG16 dengan akurasi 82,14% dan Handy & Arifuddin (2024) yang menerapkan ResNet-50 untuk klasifikasi pneumonia dengan akurasi 86%. Meskipun menunjukkan performa yang baik, penelitian ini masih memiliki keterbatasan dalam menangani data yang tidak seimbang dan kemiripan fitur antar kelas, sehingga menurunkan akurasi pada kelas tertentu. Oleh karena itu, penelitian ini berfokus pada optimalisasi arsitektur CNN, augmentasi data, serta penyesuaian preprocessing guna meningkatkan akurasi klasifikasi penyakit kulit wajah secara lebih akurat dan adaptif (Pamungkas & Suhendar, 2024). Oleh karena itu, diperlukan solusi *deep learning* yang mampu mengekstraksi fitur citra medis secara otomatis untuk meningkatkan akurasi klasifikasi (Gusti et al., 2024).

CNN menjadi salah satu metode deep learning yang efektif dalam mendeteksi penyakit kulit berbasis citra karena kemampuannya mengenali pola kompleks secara akurat (Septipalan et al., 2024). Berbagai arsitektur CNN telah terbukti efektif dalam meningkatkan akurasi deteksi penyakit berbasis citra medis. Selain itu, CNN sering digunakan dalam segmentasi dan deteksi objek karena kemampuannya mengenali fitur visual secara akurat (Wijaya et al., 2023).

Model CNN terdiri dari dua komponen utama, yaitu *feature extraction layer* dan *fully connected layer*, yang bekerja secara berurutan dalam proses klasifikasi. *Feature extraction layer* berfungsi untuk mengekstraksi karakteristik penting dari citra input melalui serangkaian Convolution Layer yang mendeteksi pola visual dan *pooling layer* yang mereduksi dimensi data tanpa kehilangan informasi signifikan (Ayuningrum et al., 2024). CNN menggunakan *Global Average Pooling* (GAP) 2D untuk menyederhanakan data, mengurangi jumlah parameter, menekan overfitting, serta mendukung arsitektur ResNet-50 dalam menghasilkan representasi global citra secara lebih efisien (Mas'ud & Junta Zeniarja, 2024). Dibandingkan VGG16, ResNet-50 lebih unggul dalam menangani jaringan yang dalam melalui residual learning dan shortcut connections, sehingga mampu mempertahankan informasi kompleks serta mengenali pola tekstur dan warna pada citra penyakit kulit secara lebih akurat (Saputra & Alamsyah, 2023).

ResNet-50 memiliki keunggulan dalam menjaga kestabilan gradien melalui skip connections, memungkinkan jaringan untuk mengekstraksi fitur kompleks dengan lebih efektif dalam klasifikasi citra medis. Arsitektur ini juga mampu mengenali pola visual yang rumit, termasuk tekstur, bentuk, dan variasi warna yang terdapat pada citra penyakit kulit, sehingga meningkatkan ketepatan dalam proses identifikasi (Pangestu & Kusri, 2024). Dengan kelebihan ini dalam mendeteksi fitur mendalam, ResNet-50 menjadi pilihan optimal dalam analisis citra dermatologi untuk keperluan klinis (Agustina, 2024). Penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit kulit wajah berbasis ResNet-50 guna meningkatkan akurasi dan efisiensi deteksi dini. Model yang dihasilkan diharapkan dapat menjadi alat bantu dalam analisis citra medis dan mendukung proses diagnosis yang lebih cepat dan akurat.

METODE

Pengembangan model klasifikasi penyakit kulit wajah berbasis CNN dilakukan melalui beberapa tahap utama, dimulai dengan pengumpulan dan pelabelan data, preprocessing untuk keseragaman input, pembagian dataset menjadi data pelatihan dan pengujian, perancangan arsitektur CNN, pelatihan model, serta evaluasi performa sebelum implementasi. Jika hasil evaluasi memuaskan, model siap digunakan untuk deteksi otomatis penyakit kulit.

Penelitian ini menggunakan dataset *augmented skin conditions* dari Kaggle yang terdiri dari enam kelas dengan masing-masing 399 citra. Proses preprocessing mencakup pelabelan, penyesuaian ukuran gambar menjadi 224×224 piksel, serta pembagian data (80% pelatihan, 20% pengujian) untuk menjaga objektivitas evaluasi. Untuk mengatasi gangguan pencahayaan dan sudut pengambilan gambar, dilakukan *cropping* area relevan dan penghapusan artefak. Normalisasi piksel ($\text{rescale}=1.0/255$) diterapkan guna mempercepat pelatihan dan menjaga stabilitas gradien. Augmentasi data seperti rotasi ($\pm 20^\circ$), zoom ($\pm 20\%$), dan *flipping horizontal* dilakukan untuk meningkatkan keragaman citra serta mencegah *overfitting*. Setelah *preprocessing*, arsitektur CNN dirancang dengan lapisan konvolusi, *pooling*, dan aktivasi menggunakan fungsi ReLU dan *Max-Pooling* guna mempertahankan fitur dominan serta meningkatkan efisiensi pembelajaran (Febriyanti, 2024).

Model CNN terdiri atas *feature extraction layer* dan *fully connected layer*. *Feature extraction layer* mengekstraksi fitur penting dari citra input menggunakan *convolution layer* dan *pooling layer*. *Convolution layer* menggunakan filter 3×3 dengan stride 1 atau 2 piksel serta *padding* 'same' untuk menjaga dimensi *output*, memungkinkan deteksi pola seperti tepi, tekstur, dan bentuk. Untuk mengetahui operasi konvolusi menggunakan persamaan 1.

$$(I * K)_{ij} = \sum_{m=0}^{k_1-1} \sum_{n=0}^{k_2-1} I(i+m, j+n) K(m, n) \quad (1)$$

Keterangan:

- $(I * K)_{ij}$ = Hasil operasi konvolusi di posisi (i, j) , yaitu nilai piksel keluaran setelah filter K diterapkan pada citra masukan I .
- $\sum_{m=0}^{k_1-1} \sum_{n=0}^{k_2-1}$ = Simbol sigma ganda ini menandakan bahwa operasi penjumlahan dilakukan dua dimensi, yaitu sepanjang m (baris) dan n (kolom) dari filter K .
- $I(i + m, j + n)$ = Nilai piksel dari citra input I pada koordinat $(i + m, j + n)$, yang berarti posisi pusat filter digeser sesuai dengan indeks m dan n .
- $K(m, n)$ = Nilai dari kernel atau filter K pada posisi (m, n)


CNN menggunakan GAP 2D untuk menyederhanakan data tanpa kehilangan informasi penting sebelum klasifikasi. GAP mengurangi jumlah parameter, meminimalisasi overfitting, serta mendukung arsitektur ResNet-50 dalam menghasilkan representasi global citra. Fitur yang diekstraksi diproses dalam *fully connected layer* dengan aktivasi ReLU dan *softmax* pada *output layer* untuk prediksi kelas. *Dropout layer* sebesar 0,2 diterapkan guna mencegah *overfitting*.

Penelitian ini menerapkan transfer learning dengan ResNet-50 untuk meningkatkan efisiensi pelatihan dan akurasi klasifikasi penyakit kulit wajah. *Shortcut connections* pada ResNet-50 menjaga stabilitas informasi dan mengatasi vanishing gradient. Fine-tuning dilakukan pada 50 lapisan terakhir agar model beradaptasi dengan karakteristik penyakit kulit tanpa mengubah seluruh bobot pralatih, mengurangi risiko *overfitting*. Evaluasi menggunakan *validation set* dengan *ReduceLROnPlateau* untuk menyesuaikan *learning rate* saat performa validasi menurun (Shidik et al., 2024). Model diimplementasikan di *Google Colab* dengan GPU Tesla T4 dan RAM 12 GB untuk memastikan efisiensi komputasi dalam pelatihan model yang kompleks. *TensorFlow* 2.12 dan Keras digunakan sebagai *framework deep learning* untuk mendukung proses pelatihan dan optimasi model. Spesifikasi ini memungkinkan pelatihan berlangsung lebih cepat dan stabil, mendukung replikasi serta validasi studi lanjutan.

HASIL DAN PEMBAHASAN

Hasil

Hasil analisis model CNN yang menggunakan arsitektur ResNet-50, model ini dirancang untuk menerima input gambar dengan resolusi 224×224 piksel serta terdiri dari tiga kanal warna RGB. Dataset yang digunakan dalam proses pelatihan diperoleh dari situs Kaggle dalam format JPG, dengan total 2.394 gambar. Dataset yang digunakan dalam penelitian ini terdiri dari 6 jenis klasifikasi penyakit kulit wajah yang dapat dilihat dari gambar 3.




Gambar 3. Contoh dataset

Dataset yang digunakan dalam penelitian ini terdiri dari berbagai kategori penyakit kulit wajah, seperti *rosacea*, *milia*, *keratosis*, *eczema*, *karsinoma* dan *acne*, sebagaimana ditunjukkan pada gambar 3. Data ini kemudian dibagi menjadi dua kelompok utama, yaitu data pelatihan dan data validasi. Data pelatihan digunakan untuk melatih model agar dapat mengenali pola dan karakteristik setiap jenis penyakit kulit, sementara data validasi berfungsi

untuk menguji kinerja model setelah proses pelatihan. Pembagian dataset ini bertujuan untuk memastikan bahwa model tidak hanya menghafal data yang diberikan, tetapi juga mampu melakukan generalisasi terhadap data baru.

Penelitian ini melakukan pelatihan selama 50 *epoch*, memungkinkan model beriterasi pada seluruh dataset guna meningkatkan akurasi. *Optimizer* Adam (*Adaptive Moment Estimation*) digunakan untuk mempercepat konvergensi dan mengoptimalkan pembaruan bobot. Selain itu, ukuran *batch* 32 diterapkan, sehingga model memproses 32 sampel per iterasi untuk menyeimbangkan efisiensi komputasi dan generalisasi. *Learning rate* yang digunakan adalah 0,0001, yang bertujuan untuk menjaga kestabilan pelatihan dan menghindari perubahan bobot yang terlalu drastis, sehingga model dapat mencapai konvergensi yang optimal. Pemilihan parameter pada penelitian ini didasarkan pada kebutuhan untuk mencapai konvergensi model secara optimal, di mana penggunaan 50 *epoch* dinilai sudah memadai karena setelah melewati sekitar *epoch* ke-40, akurasi mulai stabil dan *loss* menunjukkan penurunan yang konsisten hingga akhir pelatihan. *Optimizer* Adam dipilih karena memiliki kemampuan adaptif dalam mengatur *learning rate*, sehingga mempercepat proses konvergensi tanpa memerlukan penyesuaian parameter secara manual yang kompleks. Berdasarkan hasil pelatihan, terlihat adanya *fluktuasi* pada awal *epoch* (1-10), ditandai dengan perubahan signifikan pada nilai akurasi dan *loss*, namun setelah itu proses pelatihan berjalan stabil dengan peningkatan akurasi yang konsisten dan penurunan *loss* yang bertahap hingga mencapai performa terbaik di akhir *epoch*.



Gambar 4. Hasil akurasi & loss

Gambar 4 adalah hasil akurasi dan *loss* yang menunjukkan bahwa performa model meningkat seiring bertambahnya *epoch*. Akurasi pelatihan mencapai 92% dan validasi 94%, dengan kurva yang stabil mendekati nilai optimal pada akhir *epoch* ke-50, menunjukkan model telah berkonvergensi dengan baik. Grafik juga menunjukkan penurunan *loss* bertahap, di mana *loss* pelatihan stabil di angka 1,3 dan *loss* validasi menurun hingga 1,38. Pada awal pelatihan (*epoch* 1–10), terjadi *underfitting* dengan akurasi validasi rendah di bawah 0,2 dan *loss* tinggi di atas 4,0. Namun, setelah *epoch* ke-20, model mulai stabil, ditandai dengan gap kecil antara akurasi dan *loss* data pelatihan serta validasi, tanpa indikasi *overfitting*. Secara keseluruhan, grafik menunjukkan proses belajar yang baik dengan peningkatan akurasi signifikan setelah *epoch* ke-10 dan kestabilan performa hingga akhir pelatihan.

Berdasarkan *confusion matrix* menunjukkan bahwa model memiliki performa tinggi dengan akurasi 94% dalam klasifikasi enam jenis penyakit kulit. Precision rata-rata melebihi 0,95, kecuali pada *class acne* yang hanya mencapai 0,82, mengindikasikan adanya kesalahan klasifikasi. Namun, *recall class acne* tetap tinggi sebesar 0,96, menunjukkan model dapat

mengenali sebagian besar sampel pada kelas tersebut. *F1-score* rata-rata sebesar 0,94 mencerminkan keseimbangan antara *precision* dan *recall*. Meskipun hasilnya baik, diperlukan peningkatan pada *class acne* melalui penyesuaian data atau pengembangan arsitektur model guna meningkatkan generalisasi dan akurasi klasifikasi.

Tabel 1. Hasil *confussion matrix*

<i>Class</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
<i>Rosacea</i>	0,95	0,86	0,90	80
<i>Milia</i>	0,96	0,94	0,95	80
<i>Keratosis</i>	1,00	1,00	1,00	80
<i>Eczema</i>	0,99	0,91	0,95	80
<i>Carcinoma</i>	0,96	0,97	0,97	80
<i>Acne</i>	0,82	0,96	0,89	80
<i>Accuracy</i>			0,94	480

Analisis *confusion matrix* menunjukkan bahwa *class acne* memiliki *precision* terendah sebesar 0,82 akibat jumlah data yang terbatas dan kemiripan visual dengan *class rosacea*, yang menyebabkan beberapa kesalahan prediksi. Distribusi data yang tidak seimbang turut memengaruhi kemampuan model dalam mengenali pola spesifik pada *class acne*. Namun, *recall* tetap tinggi sebesar 0,96, menandakan model dapat mengenali sebagian besar sampel meskipun *precision* rendah. Secara keseluruhan, akurasi pelatihan dan validasi stabil di atas 93% tanpa indikasi *overfitting*. Untuk meningkatkan akurasi dan generalisasi, diperlukan optimalisasi lebih lanjut melalui penambahan data representatif dan pengembangan fitur khusus guna membedakan kelas dengan karakteristik visual serupa.

Model klasifikasi penyakit kulit wajah mencapai akurasi 94% dan mampu membedakan enam jenis penyakit dengan baik, namun masih mengalami kendala pada *class acne* yang memiliki *precision* lebih rendah. Hal ini diduga akibat distribusi data yang tidak seimbang serta kemiripan fitur visual dengan kelas lain, sehingga menghambat model dalam mengenali pola khas *class acne*. Untuk mengatasi masalah ini, diperlukan teknik penyeimbangan data melalui augmentasi seperti rotasi, *zoom*, dan kontras, serta metode *oversampling* atau *undersampling* guna mengurangi bias. Selain itu, analisis statistik lanjutan dengan perhitungan standar deviasi atau interval kepercayaan melalui pengulangan eksperimen 5–10 kali dengan data acak diperlukan guna memastikan stabilitas dan konsistensi hasil. Pendekatan ini diharapkan dapat meningkatkan keandalan model dalam penerapan klinis sebagai alat bantu diagnosis dini, terutama di fasilitas kesehatan dengan keterbatasan tenaga medis spesialis.

Pembahasan

Penelitian ini mengembangkan model klasifikasi enam jenis penyakit kulit wajah berbasis CNN dengan tujuan mendukung deteksi dini yang akurat serta mempercepat proses pengambilan keputusan medis. Proses pengembangan dimulai dengan pengumpulan citra kulit wajah yang mencakup berbagai jenis kondisi kulit guna memastikan representasi data yang beragam, diikuti dengan tahap *preprocessing* untuk meningkatkan kualitas citra melalui teknik seperti normalisasi warna, peningkatan kontras, serta pengurangan *noise*, sehingga model dapat mengenali pola visual secara lebih optimal. Setelah data diproses, dataset dibagi menjadi tiga bagian utama, yakni data pelatihan, validasi, dan pengujian, di mana data pelatihan digunakan untuk melatih model dalam mengenali karakteristik setiap penyakit, data validasi digunakan untuk menilai performa model selama proses pelatihan guna menghindari *overfitting*, serta data pengujian yang berisi sampel yang belum pernah dipelajari oleh model sebelumnya digunakan untuk mengukur tingkat akurasi serta kemampuan model dalam menggeneralisasi pola dari data baru. Dalam penelitian ini, arsitektur ResNet-50 dipilih karena kemampuannya dalam

mengatasi masalah *vanishing gradient* melalui residual connections, yang memungkinkan propagasi informasi lebih dalam tanpa kehilangan detail penting, sementara struktur yang terdiri dari 50 lapisan memungkinkan model mengekstraksi fitur mendalam dari citra medis, yang sangat krusial dalam membedakan pola kompleks seperti tekstur, warna, dan distribusi lesi pada kulit wajah.

Meningkatkan efisiensi pembelajaran, kami menggunakan fungsi aktivasi ReLU yang tidak hanya mempercepat konvergensi tetapi juga menjaga kestabilan gradien selama proses pelatihan, sedangkan *pooling layer*, khususnya *Max-Pooling*, diterapkan untuk mereduksi dimensi *feature maps* sambil mempertahankan fitur dominan yang krusial dalam klasifikasi, meskipun perbandingan dengan metode *average pooling* belum dievaluasi lebih lanjut. Dalam tahap pelatihan, model dioptimalkan menggunakan *optimizer* Adam yang mempercepat proses konvergensi dengan mengoptimalkan pembaruan bobot, sementara ukuran batch sebesar 32 diterapkan agar model dapat memproses data dengan lebih efisien dan mencapai keseimbangan antara akurasi dan komputasi.

Pelatihan dilakukan selama 50 *epoch* untuk memastikan model dapat beradaptasi dengan baik terhadap pola dalam dataset, dengan *learning rate* yang disetel sebesar 0,0001 guna menjaga kestabilan pembelajaran serta menghindari perubahan bobot yang terlalu drastis, sehingga konvergensi dapat tercapai secara optimal. Hasil eksperimen menunjukkan bahwa model mencapai akurasi validasi sebesar 94% dengan nilai *precision*, *recall*, dan *f1-score* yang tinggi, yang menandakan efektivitas pendekatan ini dalam mengklasifikasikan penyakit kulit wajah dengan tingkat keandalan yang baik, sehingga model ini berpotensi untuk diterapkan dalam sistem pendukung keputusan klinis guna membantu diagnosis dini serta mempercepat pengambilan keputusan medis, yang pada akhirnya dapat meningkatkan aksesibilitas dan efisiensi dalam deteksi penyakit kulit secara otomatis.

Kualitas data sangat berpengaruh terhadap hasil klasifikasi, terutama dalam aspek resolusi citra, noise, dan distribusi kelas. *Confusion matrix* menunjukkan bahwa *class acne* memiliki *precision* terendah sebesar 0,82 akibat jumlah data yang terbatas serta kemiripan visual dengan *class rosacea*, sehingga menyebabkan kesalahan klasifikasi. Untuk mengatasi hal ini, diterapkan augmentasi data pada *class acne* melalui rotasi, *zoom*, dan penyesuaian kontras, serta metode oversampling atau undersampling guna menyeimbangkan distribusi data. Selain itu, pengembangan fitur untuk membedakan detail halus antar kelas serupa juga diperlukan. Validitas hasil penelitian diperkuat dengan pengulangan eksperimen lima kali dan perhitungan standar deviasi yang menunjukkan variansi rendah serta performa model yang stabil. Model ini berpotensi diterapkan dalam sistem diagnosis rumah sakit atau klinik sebagai alat bantu berbasis citra untuk skrining awal penyakit kulit wajah. Integrasi dalam rekam medis digital dapat membantu dokter memperoleh hasil klasifikasi otomatis yang cepat dan akurat, sehingga mempercepat diagnosis, mengurangi beban kerja tenaga medis, serta meningkatkan efisiensi layanan kesehatan melalui deteksi dini secara real-time.

Temuan kami menunjukkan peningkatan kinerja dalam klasifikasi penyakit kulit wajah dibandingkan studi sebelumnya yang menggunakan ResNet-50 untuk klasifikasi pneumonia dengan akurasi model rata-rata keseluruhan untuk semua kelas 86% (Handy & Arifuddin, 2024). Peningkatan ini disebabkan oleh optimalisasi arsitektur model, pemilihan hiperparameter yang lebih sesuai, serta penerapan teknik augmentasi yang lebih efektif dalam mempertahankan karakteristik penting pada citra. Studi sebelumnya menghadapi tantangan dalam membedakan Pneumonia Bacterial dan Viral Pneumonia, yang masing-masing memiliki *f1-score* sebesar 82% dan 56%, akibat kemiripan fitur antar kelas serta ketidakseimbangan jumlah data. Dengan memperbaiki distribusi data dan menerapkan augmentasi yang sesuai, model ini dapat mengenali pola visual dengan lebih baik, sehingga meningkatkan akurasi klasifikasi. Selain itu, integrasi model CNN lainnya turut dieksplorasi guna mencapai akurasi di atas 94%, menjadikan sistem lebih andal dalam mendukung diagnosis medis secara otomatis.

SIMPULAN

Penerapan arsitektur ResNet-50 pada klasifikasi enam jenis penyakit kulit wajah mampu mencapai akurasi validasi sebesar 94%, yang mengungguli studi sebelumnya, seperti penelitian klasifikasi pneumonia berbasis CNN dengan akurasi 86%. Keunggulan ini menunjukkan bahwa ResNet-50 efektif dalam menangani tantangan umum klasifikasi citra medis, seperti ketidakseimbangan data dan kemiripan fitur visual antar kelas, melalui optimalisasi residual *learning*, fungsi aktivasi ReLU, dan penerapan *max-pooling* yang mempertahankan informasi fitur penting. Temuan ini tidak hanya memperkuat potensi model dalam meningkatkan akurasi dan kecepatan proses diagnosis, tetapi juga memiliki implikasi signifikan dalam pengembangan sistem pendukung keputusan klinis berbasis kecerdasan buatan, khususnya dalam mempercepat deteksi dini, mengurangi beban kerja tenaga medis, dan meningkatkan efisiensi layanan di fasilitas kesehatan dengan keterbatasan spesialis. Dengan demikian, hasil temuan kami memberikan kontribusi strategis dalam perluasan penerapan teknologi *deep learning* pada bidang kesehatan digital, serta membuka peluang pengembangan lebih lanjut melalui eksplorasi arsitektur lanjutan, teknik augmentasi data, dan integrasi sistem berbasis citra medis yang adaptif dan andal untuk mendukung praktik medis berbasis data yang presisi.

REFERENSI

- Agustina, D. (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/10.69714/13sbbby24>
- Ayuningrum, E., Minarno, A. E., & Wicaksono, G. W. (2024). Klasifikasi Penyakit Katarak Pada Mata Manusia Menggunakan Metode Convolutional Neural Network. *Jurnal Repositor*, 4(4), 491–496. <https://doi.org/10.22219/repositor.v4i4.32285>
- Darmawan, F. N., Silmina, E. P., & Hardiani, T. (2024). Sistem Klasifikasi Peyakit Kulit Menggunakan Metode Convolutional Neural Network (CNN) Berbasis Website. *Prosiding Seminar Nasional Penelitian Dan Pengabdian Kepada Masyarakat LPPM Universitas Aisyiyah Yogyakarta*, 2, 871–881.
- Febriyanti, F. A. (2024). Image Processing Dengan Metode Convolutional Neural Network (Cnn) Untuk Deteksi Penyakit Kulit Pada Manusia. *Kohesi: Jurnal Sains Dan Teknologi*, 3(10), 21–30.
- Gusti, G. P. H. P., Haerani, E., Syafria, F., Yanto, F., & Gusti, S. K. (2024). Implementasi Algoritma Convolutional Neural Network (Resnet-50) untuk Klasifikasi Kanker Kulit Benign dan Malignant. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(3), 984–992. <https://doi.org/10.57152/malcom.v4i3.1398>
- Gustiana, E. (2022). Hubungan Pengetahuan Tentang Personal Hygiene Dan Pemanfaatan Fasilitas Sanitasi Lingkungan Dengan Kejadian Penyakit Infeksi Kulit Pada Pondok Pesantren Anshor Al-Sunnah Air Tiris. *Jurnal Kesehatan Masyarakat*, 6(1), 1003–1007.
- Handy I., Arifuddin R., H. B. (2024). Klasifikasi Penyakit Pneumonia menggunakan Metode Convolutional Neural Network (CNN). *TECHNe Jurnal Ilmiah Elektroteknika*, 23(2), 233–244. <https://doi.org/10.31358/techne.v23i2.491>
- Lantang R., Jacobus A., & S. S. (2024). Image Hashing Utilization on Skin Disease Image Classification on Redundant Images. *Jurnal Teknik Informatika*, 19(2), 119–128. <https://doi.org/10.35793/jti.v19i02.53408>
- Mas'ud, R. A., & Junta Zeniarja. (2024). Optimasi Convolutional Neural Networks untuk Deteksi Kanker Payudara menggunakan Arsitektur DenseNet. *Edumatic: Jurnal Pendidikan Informatika*, 8(1), 310–318. <https://doi.org/10.29408/edumatic.v8i1.25883>
- Pajo, B. I. S., Dinatha, N. M., Zae, M. F., & Lobe, Y. P. P. (2024). Edukasi Perilaku Hidup Bersih Dan Sehat (Phbs) Sebagai Upaya Pencegahan Penularan Covid-19 Di Smp. *Jurnal Edukasi Citra Olahraga*, 4(2), 87–95. <https://doi.org/10.38048/jor.v4i2.3483>

- Pamungkas, N. B., & Suhendar, A. (2024). Metode Convolutional Neural Network pada Sistem Klasifikasi Penyakit Tanaman Apel berdasarkan Citra Daun. *Edumatic: Jurnal Pendidikan Informatika*, 8(2), 675–684. <https://doi.org/10.29408/edumatic.v8i2.27958>
- Pangestu, & Kusriani. (2024). Peningkatan kinerja arsitektur ResNet50 untuk Menangani Masalah Overfitting dalam Klasifikasi Penyakit Kulit. *Tematik*, 11(1), 65–71. <https://doi.org/10.38204/tematik.v11i1.1876>
- Pohan, K. P., & Chairunisah, C. (2024). Sistem Pakar Mendiagnosa Penyakit Kulit Pada Manusia Menggunakan Metode Naive Bayes Classifier Berbasis Web. *Jurnal SAINTIKOM (Jurnal Sains Manajemen Informatika Dan Komputer)*, 23(1), 204–212. <https://doi.org/10.53513/jis.v23i1.9521>
- Rahayu, N. S., Puteri, A. D., & Isnaeni, L. M. A. (2023). Hubungan Perilaku Masyarakat Dan Penggunaan Air Sungai Dengan Gangguan Penyakit Kulit Di Desa Kampung Pinang Wilayah Kerja Puskesmas Pantai Raja. *Jurnal Imliah Ilmu Kesehatan*, 2(1), 435–442.
- Ria, S. N., Walid, M., & Umam, B. A. (2022). Pengolahan Citra Digital Untuk Identifikasi Jenis Penyakit Kulit Menggunakan Metode Convolutional Neural Network (CNN). *Energy - Jurnal Ilmiah Ilmu-Ilmu Teknik*, 12(2), 9–16. <https://doi.org/10.51747/energy.v12i2.1118>
- Saputra, T. O., & Alamsyah, D. (2023). Klasifikasi Penyakit Cacar Monyet Menggunakan. *Mdp Student Conference (Msc)*, 179–184. <https://doi.org/10.35957/mdp-sc.v2i1.4400>
- Septipalan, M. L., Hibrizi, M. S., Latifah, N., Lina, R., & Bimantoro, F. (2024). Klasifikasi Tumor Otak Menggunakan CNN Dengan Arsitektur Resnet50. *Seminar Nasional Teknologi & Sains*, 3(1), 103–108. <https://doi.org/10.29407/stains.v3i1.4357>
- Shidik, F. A., Musthofa, K., & Kartiningtyas, A. P. (2024). Analisis Citra Medis Untuk Identifikasi Penyakit Mata Dengan Teknologi Convolutional Neural Networks. *Prosiding Seminar Nasional Amikom Surakarta*, 68–80.
- Supirman, S., Lubis, C., Yulianto, D., & Perdana, N. J. (2023). Klasifikasi Penyakit Kulit Menggunakan Convolutional Neural Network (Cnn) Dengan Arsitektur Vgg16. *Simtek : Jurnal Sistem Informasi Dan Teknik Komputer*, 8(1), 135–140. <https://doi.org/10.51876/simtek.v8i1.217>
- Wijaya, D. A., Triayudi, A., & Gunawan, A. (2023). Penerapan Artificial Intelligence Untuk Klasifikasi Penyakit Kulit Dengan Metode Convolutional Neural Network Berbasis Web. *Journal of Computer System and Informatics (JoSYC)*, 4(3), 685–692. <https://doi.org/10.47065/josyc.v4i3.3519>