

Identifikasi Penyakit Kulit Manusia Menggunakan Arsitektur *Convolution Neural Network* Berbasis Deep Xception

Muhammad Habil Habibi¹, Yuni Yamasari²

^{1,2} Program Studi S1 Teknik Informatika, Universitas Negeri Surabaya

¹muhammadhabil.22015@mhs.unesa.ac.id

²yuniyamasari@unesa.ac.id

Abstrak—Penelitian ini bertujuan untuk mengembangkan sistem identifikasi penyakit kulit manusia (Monkeypox, Herpes, dan Chickenpox) menggunakan arsitektur *Convolutional Neural Network* (CNN). Pendekatan ini memanfaatkan metode *transfer learning* dengan mengevaluasi *backbone* Xception untuk mengekstraksi fitur visual lesi kulit secara efisien. Dataset yang digunakan adalah Dataset Penyakit Kulit bersumber dari platform publik Roboflow Universe terdiri dari 4.423 citra. Hasil penelitian menunjukkan penggunaan arsitektur Xception menghasilkan performa paling optimal pada data uji dengan nilai validasi akurasi mencapai 0,9836 pada skenario pembagian dataset 70:30. Hasil tersebut mencerminkan kemampuan model sangat baik dalam melakukan fit data dan mempertahankan kemampuan generalisasi tinggi. Dibuktikan dengan nilai *precision*, *recall*, dan *F1-score* seimbang secara berturut-turut 0,9836, 0,9836, dan 0,9820, sehingga sistem terbukti tidak memiliki bias pada kelas tertentu dan mumpuni untuk mengklasifikasikan penyakit kulit secara akurat untuk diimplementasikan pada aplikasi berbasis *mobile*.

Kata Kunci— : Identifikasi Penyakit Kulit, *Convolutional Neural Network*, Xception, *Transfer Learning*, *Robotflow Universe*.

I. PENDAHULUAN

Sebagai anatomi terluar dari tubuh manusia, kulit memegang peranan krusial dalam memproteksi organ dalam dari ancaman eksternal, meregulasi temperatur termal, sekaligus menjadi tolok ukur kondisi klinis seseorang [1]. Walau demikian, interaksi konstan dengan lingkungan menjadikan organ ini sangat rentan terhadap berbagai kelainan, mulai dari dermatitis ringan hingga kondisi fatal seperti karsinoma dan *herpes* [2]. Penyakit kulit telah menjadi tantangan kesehatan global yang mendesak. Merujuk pada data American Cancer Society, keterlambatan diagnosis menjadi penyumbang utama tingginya angka mortalitas pada kasus melanoma, sementara identifikasi awal mampu menaikkan persentase harapan hidup penderita secara drastis [3]. Deteksi dini sangat penting karena banyak penyakit kulit pada tahap awal memiliki kemiripan visual yang membuat diagnosis manual menjadi sulit, bahkan bagi dokter spesialis [4]. Tradisi pemeriksaan kulit masih banyak mengandalkan observasi visual melalui dermatoskopi dan biopsi, yang bersifat subjektif, memakan waktu, serta memerlukan tenaga medis

berpengalaman [5]. Kondisi ini mendorong perlunya sistem Computer-Aided Diagnosis (CAD) sebagai solusi untuk membantu proses diagnosis gangguan kulit secara efisien, tepat, dan andal. Perkembangan teknologi Artificial Intelligence (AI), khususnya pada bidang Deep Learning, telah membuka peluang yang luas dalam mendukung kemajuan sektor kesehatan. Salah satu metode yang menunjukkan kinerja unggul dalam pengolahan citra medis adalah *Convolutional Neural Network* (CNN), yang terbukti efektif untuk mendeteksi, mengklasifikasikan, serta mengenali pola pada citra penyakit kulit [6].

Berbagai penelitian terkini bahwa model CNN mampu mencapai tingkat akurasi tinggi, bahkan mendekati atau melebihi kemampuan dermatologi dalam diagnosis kanker kulit dan lesi kulit lainnya [7]. Selain itu, inovasi baru juga diarahkan pada peningkatan efisiensi dan keandalan sistem. Misalnya, pengembangan model CNN dengan fungsi aktivasi non-linear adaptif [8]. Integrasi mekanisme *explainable AI* agar hasil diagnosis lebih transparan.


Hingga penerapan metode *class imbalance handling* untuk mengatasi distribusi data penyakit yang tidak seimbang pada dataset medis [9]. Penelitian lain bahkan berhasil mengimplementasikan model CNN dalam aplikasi berbasis Android untuk mendeteksi penyakit herpes secara *real-time* [10]. Dengan mempertimbangkan urgensi deteksi dini penyakit kulit dan perkembangan teknologi kecerdasan buatan, penelitian ini mengusulkan pengembangan sistem identifikasi penyakit kulit manusia menggunakan arsitektur *Convolutional Neural Network* (CNN) [11]., Diharapkan sistem ini mampu meningkatkan akurasi diagnosis, mempercepat proses pemeriksaan, serta mendukung tenaga medis maupun masyarakat dalam melakukan deteksi dini terhadap penyakit kulit [12].

Meningkatkan penelitian acuan oleh Rasel et al. (2022) yang menunjukkan efektivitas CNN dengan variasi fungsi aktivasi dalam klasifikasi melanoma [13]. serta Sharma et al. (2022) yang berhasil mencapai akurasi tingkat dermatologi melalui ensamble CNN dan fitur buatan, penelitian ini mengidentifikasi celah penting [14]. Meskipun model-model tersebut terbukti efektif, sebagian besar masih menghadapi tantangan berupa kebutuhan data besar, ketidakseimbangan kelas, dan

kompleksitas arsitektur. Oleh karena itu, penelitian ini bertujuan untuk melakukan investigasi empiris terhadap penerapan arsitektur CNN yang dioptimalkan pada dataset penyakit kulit publik. Dengan demikian, penelitian ini akan memberikan perbandingan kinerja yang adil terhadap pendekatan sebelumnya, sekaligus menilai apakah model CNN yang lebih efisien mampu mempertahankan akurasi tinggi tanpa meningkatkan kompleksitas komputasi secara signifikan [15].

II. METODE PENELITIAN

A. Pendekatan Penelitian



Gbr. 1 Diagram Alur Penelitian

Pendekatan yang digunakan adalah *Computer Vision* berbasis *Deep Learning* dengan arsitektur *Convolutional Neural Network* (CNN) untuk mengklasifikasikan penyakit kulit berdasarkan citra. Tujuan utama penelitian ini adalah menguji efektivitas CNN dalam menganalisis dan mengklasifikasikan citra medis. Dataset yang digunakan berasal dari Kaggle dan Roboflow Universe, yang berisi citra penyakit kulit yang telah diberi label.

Model CNN akan dilatih untuk mengekstraksi fitur dari citra kulit dan melakukan klasifikasi penyakit berdasarkan data tersebut. Hasil dari model akan dievaluasi secara kuantitatif menggunakan metrik seperti *accuracy* untuk mengukur kinerja dan keakuratan klasifikasi model. Dengan pendekatan ini, diharapkan penelitian ini dapat memberikan bukti empiris mengenai keunggulan CNN dalam mengklasifikasikan penyakit kulit pada data medis citra.

Berdasarkan alur penelitian yang telah dirancang, proses klasifikasi penyakit kulit dimulai dengan tahap *preprocessing* citra berupa *resize* gambar menjadi 224×224 piksel dan normalisasi nilai piksel menggunakan skala 1/255 untuk menyeragamkan data masukan. Selanjutnya, sistem menerapkan metode *transfer learning* menggunakan arsitektur Xception yang telah menggunakan bobot *pre-trained* ImageNet. Pada tahap ini, lapisan klasifikasi bawaan model dihapus dan lapisan dasar dibekukan untuk mempertahankan kemampuan

ekstraksi fitur yang telah dipelajari sebelumnya. Fitur yang dihasilkan kemudian diteruskan. Pada tahap akhir, digunakan lapisan klasifikasi kustom yang meliputi Global Average Pooling 2D, Dropout sebesar 0,5, lapisan Dense dengan 512 neuron dan fungsi aktivasi ReLU, serta lapisan Dense keluaran dengan 3 neuron dan aktivasi Softmax untuk mengelompokkan citra ke dalam tiga kelas, yaitu Chickenpox, Herpes, dan Monkeypox.

Setiap model pada penelitian ini dilatih dengan optimizer Adam dan fungsi *loss categorical crossentropy* hingga maksimum 20 epoch. Sebagai langkah untuk meminimalkan overfitting, digunakan mekanisme *early stopping* yang secara otomatis menghentikan pelatihan ketika performa validasi tidak lagi menunjukkan perbaikan. Sesudah tahap pelatihan berakhir, performa model dianalisis melalui metrik *accuracy*, *precision*, *recall*, dan *F1-score* guna memilih model yang paling optimal dalam klasifikasi penyakit kulit berdasarkan citra penelitian.

B. Sumber Data dan Pengumpulan Dataset

Dataset yang digunakan adalah "Dataset Penyakit Kulit dari Roboflow Universe" yang berisi gambar penyakit kulit, termasuk Herpes, Monkey Pox, dan Chicken Pox, yang dapat diakses melalui platform Roboflow Universe. Ini memungkinkan penelitian untuk fokus sepenuhnya pada tujuan utama, yaitu evaluasi mendalam terhadap model *Convolutional Neural Network* (CNN) dalam deteksi penyakit kulit. Kedua, dengan menggunakan dataset yang serupa dengan penelitian acuan, hasil performa model CNN yang diusulkan dapat dibandingkan secara langsung dan adil dengan model lain yang telah diuji pada dataset tersebut, memberikan validitas yang kuat pada analisis perbandingan.

TABEL I
TABEL KETERANGAN DATASET

Karakteristik	Deskripsi
Nama Dataset	Dataset Penyakit Kulit - Roboflow Universe
Sumber	Roboflow Universe (Penyakit Kulit - Herpes, Monkeypox, Chickenpox)
Jumlah Kelas	3 (Herpes, Monkeypox, dan Chickenpox)

Berdasarkan Tabel I, dataset ini mencakup tiga kelas penyakit kulit: Monkey Pox, Herpes, dan Chicken Pox. Kelas-kelas ini mencakup berbagai jenis lesi kulit dengan karakteristik visual yang berbeda, termasuk variasi warna, tekstur, dan bentuk. Gambar-gambar dalam dataset dikumpulkan dari berbagai sumber publik melalui platform

Roboflow Universe, sehingga mencakup variasi pencahayaan, sudut pandang, dan resolusi gambar yang berbeda, hal ini penting untuk meningkatkan kemampuan model dalam mengidentifikasi pola penyakit kulit pada situasi nyata. Data dikumpulkan menggunakan berbagai perangkat kamera dermatologi dan dermatoskopi, sesuai dengan gambar yang tersedia di dataset.

C. Prapemrosesan

1) Augmentasi Gambar:

Tahapan ini diaplikasikan guna memperkaya diversitas data latih melalui manipulasi geometris, seperti perputaran (*rotation*) dan pembalikan (*flipping*). Manipulasi ini krusial untuk melatih model agar adaptif terhadap berbagai variasi sudut pengambilan gambar serta menekan potensi *overfitting*.

$$x_{new} = \lambda x_i + (1 - \lambda)x_j \quad (1)$$

$$y_{new} = \lambda y_i + (1 - \lambda)y_j \quad (2)$$

2) Resize Gambar

Untuk menyeragamkan dimensi masukan ke dalam model, seluruh data visual dalam studi ini diskalakan ulang hingga mencapai resolusi 224x224 piksel. Penyeragaman format ini merupakan syarat mutlak agar arsitektur jaringan dapat memproses fitur spasial secara efisien.

$$x_{src} = x_{dst} \cdot S_x \quad (3)$$

$$y_{src} = y_{dst} \cdot S_y \quad (4)$$

3) Normalisasi Data

Agar rentang komputasi lebih stabil, intensitas piksel pada setiap citra dikalibrasi ke dalam skala 0 hingga 1. Proses normalisasi ini terbukti mampu mempercepat fase konvergensi selama pelatihan sekaligus meringankan beban komputasi arsitektur CNN yang digunakan.

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (5)$$

$$X_{norm} = \frac{X}{255} \quad (6)$$

D. Augmentasi

Augmentasi gambar seperti *flip* dan *rotate* merupakan teknik penting dalam meningkatkan kualitas model klasifikasi gambar untuk deteksi penyakit kulit. Teknik ini membantu memperkaya dataset dengan variasi gambar, yang meningkatkan keragaman data pelatihan dan mengurangi risiko *overfitting*.

1. *Flip*: Membalik gambar secara horizontal atau vertikal, berguna untuk mengenali gejala yang muncul pada kedua sisi tubuh atau di area simetris, seperti ruam atau tanda pada kulit.

$$x^1 = W - 1 - x \quad (7)$$

$$y^1 = y \quad (8)$$

2. *Rotate*: Melibatkan rotasi gambar dengan sudut tertentu (misalnya 90° atau 180°), memungkinkan model untuk mengenali gejala meskipun gambar diambil dari berbagai orientasi atau sudut.



$$x^1 = (x - x_c) \cdot \cos(\theta) - (y - y_c) \cdot \sin(\theta) + x_c \quad (9)$$

$$y^1 = (x - x_c) \cdot \sin(\theta) - (y - y_c) \cdot \cos(\theta) + y_c \quad (10)$$

Gbr. 2 Contoh Augmentasi

E. Split Dataset

Dataset dibagi menjadi dua kelompok, yaitu training set dan testing set. Training set digunakan pada tahap pelatihan model Convolutional Neural Network (CNN), sedangkan testing set dimanfaatkan untuk menguji serta mengevaluasi performa model yang telah dilatih. Pembagian data ini dilakukan agar model mampu melakukan generalisasi dengan baik terhadap data yang belum pernah diproses sebelumnya. Dalam penelitian ini, proporsi pembagian dataset adalah 70% untuk training set dan 30% untuk testing set. Komposisi tersebut memberikan jumlah data yang memadai bagi model untuk mempelajari pola, sekaligus menyediakan data uji yang cukup representatif untuk menilai kinerja model pada data baru.

TABEL II
TABEL PEMBAGIAN DATASET

Skenario (%)	Total sampel	Train Sample	Test Sample
80:20	4,423	3,538	885
70:30		3,062	1,361
90:10		3,929	494

E. Konfigurasi Backbone

Pada tahap ini, arsitektur *Convolutional Neural Network* (CNN) akan dikonfigurasi dengan memilih *backbone* yang sesuai untuk ekstraksi fitur citra penyakit kulit, yaitu Xception, *Backbone* dipilih berdasarkan keunggulannya: Xception untuk konvolusi *separable*. Selain itu, *hyperparameter* seperti *learning rate*, *batch size*, *epochs*, dan *optimizer* (misalnya Adam atau SGD) akan dikonfigurasi untuk memaksimalkan kinerja model. Pengaturan yang tepat antara *backbone* dan *hyperparameter* ini akan diuji untuk memperoleh model terbaik dalam klasifikasi penyakit kulit.

III. HASIL DAN PEMBAHASAN

A. Deskripsi Data

Dataset yang digunakan dalam penelitian ini merupakan kombinasi dari beberapa dataset publik yang diperoleh melalui platform Kaggle dan Roboflow Universe. Penggabungan dataset tersebut dilakukan untuk meningkatkan keragaman data serta meminimalkan risiko overfitting pada model.

Data terdiri atas citra RGB penyakit kulit yang dikelompokkan ke dalam tiga kelas, yaitu Monkeypox, Herpes, dan Chickenpox. Setelah proses penggabungan dan penyeragaman label, diperoleh total 4.423 citra yang terdiri dari 1.603 citra Monkeypox (36,2%), 1.481 citra Herpes (33,5%), dan 1.339 citra Chickenpox (30,3%).

TABEL III
TABEL DISTRIBUSI CLASS DATASET

No	Penyakit Kulit	Jumlah Gambar	Persentase (%)
1	MonkeyPox	1.603	36.2%
2	Herpes	1.481	33.5%
3	ChickenPox	1.339	30.3%
Jumlah Total		4.423	100.0%

Dataset yang digunakan berasal dari Skin Disease Dataset, Herpes Class Dataset, Monkeypox Skin Image Dataset, dan Chickenpox Class Dataset. Variasi dataset mencakup perbedaan warna kulit pasien, kondisi pencahayaan, sudut pengambilan gambar, resolusi kamera, serta latar belakang citra sehingga dapat membantu model mempelajari karakteristik visual lesi kulit yang lebih beragam. Karakteristik utama setiap kelas meliputi pola lesi bergerombol pada Herpes, pustula berukuran lebih besar dan terpisah pada Monkeypox, serta ruam kecil yang menyebar pada Chickenpox.

TABEL IV
TABEL GAMBAR CONTOH DATASET

No	Kelas	Gambar
1.	Herpes	
2.	Chickenpox	

3.	Monkeypox	
----	-----------	---

B. Implementasi Code

Implementasi sistem dilakukan menggunakan platform Google Colaboratory (Google Colab) dengan dukungan framework TensorFlow dan Keras untuk membangun model klasifikasi penyakit kulit berbasis Convolutional Neural Network (CNN). Dataset yang digunakan disimpan pada Google Drive dan dihubungkan ke lingkungan Colab melalui proses mounting sehingga seluruh data dapat diakses secara langsung selama proses pelatihan. Selain TensorFlow, penelitian ini juga memanfaatkan beberapa library pendukung seperti NumPy untuk pengolahan numerik, Matplotlib untuk visualisasi hasil pelatihan, serta modul os, shutil, dan random untuk pengelolaan direktori dan pembagian dataset.

```
train_datagen = ImageDataGenerator(
    rescale = 1.0/255.,
    rotation_range=180,
    horizontal_flip=True,
    vertical_flip=True,
    fill_mode='nearest'
)
test_datagen = ImageDataGenerator( rescale =
1.0/255. )
```

Gbr. 3 Image Generator Dataset

Tahap implementasi diawali dengan proses prapemrosesan data yang meliputi ekstraksi dataset, normalisasi nilai piksel menggunakan metode rescaling sebesar 1/255, serta augmentasi data berupa flipping dan rotation untuk meningkatkan variasi citra dan mengurangi risiko overfitting.



Gbr. 4 Contoh Hasil Citra


Selanjutnya, data dibaca menggunakan ImageDataGenerator dan flow_from_directory() sehingga citra dapat dimuat secara efisien tanpa harus disimpan seluruhnya ke memori. Setelah proses prapemrosesan selesai, dataset dibagi menjadi data pelatihan dan data pengujian sesuai skenario penelitian dengan tetap mempertahankan proporsi setiap kelas penyakit. Model klasifikasi dibangun menggunakan pendekatan transfer learning dengan memanfaatkan arsitektur backbone yaitu Xception yang telah dilatih sebelumnya menggunakan dataset ImageNet.

```
from tensorflow.keras.applications import Xception
#base_model = Xception(input_shape=(224, 224, 3),
include_top=False, weights='imagenet')
```

Gbr. 5 Kode Arsitektur Model CNN

Lapisan klasifikasi bawaan dari masing-masing backbone dihapus dan digantikan dengan lapisan kustom yang terdiri atas Global Average Pooling, Dropout sebesar 0,5, Dense layer sebanyak 512 neuron dengan fungsi aktivasi ReLU, serta lapisan output menggunakan aktivasi Softmax untuk menghasilkan prediksi tiga kelas penyakit kulit. Seluruh backbone dibekukan (freeze layer) pada tahap awal pelatihan agar fitur-fitur umum yang telah dipelajari dari ImageNet tetap dapat dimanfaatkan secara optimal.

Model dilatih menggunakan optimizer Adam dengan learning rate 0,001 dan fungsi kerugian categorical crossentropy. Sebagai upaya untuk meminimalkan overfitting, diterapkan metode Early Stopping yang menghentikan pelatihan secara otomatis apabila validation loss tidak mengalami perbaikan dalam beberapa epoch secara berurutan. Selain itu, selama proses pelatihan, kinerja model dipantau melalui beberapa metrik evaluasi, yaitu accuracy, precision, recall, dan F1-score, baik pada data latih maupun data validasi.



Gbr. 6 Visualisasi Grafik Hasil Training dengan Xception

Tahap akhir implementasi dilakukan dengan mengevaluasi performa model menggunakan data pengujian yang tidak dilibatkan dalam proses pelatihan. Hasil evaluasi tersebut kemudian divisualisasikan dalam bentuk grafik perkembangan akurasi dan loss untuk memudahkan analisis terhadap proses pembelajaran model. Model dengan performa terbaik selanjutnya disimpan dalam format HDF5 (.h5) dan dikonversi ke format TensorFlow.js agar dapat diimplementasikan pada aplikasi berbasis web untuk melakukan klasifikasi penyakit kulit secara langsung.

C. Hasil dan Pembahasan


Penelitian ini melakukan pengujian terhadap empat arsitektur Convolutional Neural Network (CNN) berbasis transfer learning yaitu Xception pada tiga skenario pembagian dataset, yaitu 70:30, 80:20, dan 90:10. Seluruh model dilatih menggunakan dataset penyakit kulit yang terdiri dari kelas Herpes, Chickenpox, dan Monkeypox dengan konfigurasi hyperparameter yang sama. Hasil pengujian menunjukkan bahwa terdapat perbedaan performa yang cukup signifikan antar backbone meskipun menggunakan dataset dan parameter pelatihan yang identik. Perbandingan lengkap hasil eksperimen ditunjukkan pada Tabel V

TABEL V

TABEL HASIL METRIK TRAINING SELURUH EKSPERIMEN

Backbone	Split	Akurasi	Loss	F1-Score	Precision	Recall
Xception	80:20	0.9642	0.0705	0.9643	0.9677	0.9613
Xception	70:30	0.9836	0.0473	0.9836	0.9836	0.9820
Xception	90:10	0.9646	0.1038	0.9644	0.9667	0.9630

Berdasarkan hasil pelatihan, arsitektur Xception menunjukkan performa terbaik dibandingkan backbone lainnya. Xception memperoleh hasil tertinggi pada skenario pembagian data 70:30 dengan nilai akurasi pelatihan sebesar 98,36%, F1-Score sebesar 98,36%, precision sebesar 98,36%, recall sebesar 98,20%, serta validation accuracy sebesar 97,81%. Sementara itu, Tingginya nilai akurasi dan rendahnya nilai loss pada kedua model menunjukkan bahwa keduanya mampu melakukan ekstraksi fitur citra penyakit kulit secara efektif serta memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya.



Gbr. 7 Grafik Training dan validasi akurasi dan loss Xception 70;30

Keunggulan model Xception diduga berkaitan dengan penerapan mekanisme depthwise separable convolution, yang mampu menekan kompleksitas komputasi tanpa mengurangi kemampuan model dalam mengekstraksi fitur. Arsitektur tersebut memungkinkan model mengidentifikasi karakteristik visual penyakit kulit, seperti bentuk lesi, pola penyebaran ruam, tekstur luka, dan perubahan warna kulit, secara lebih efisien. Selain mencapai tingkat akurasi yang tinggi, kedua model juga memperlihatkan kurva pelatihan yang stabil dengan perbedaan

yang relatif kecil antara training accuracy dan validation accuracy. Kondisi ini menunjukkan bahwa selama proses pelatihan model tidak mengalami overfitting yang berarti.

Model berhasil di-load



Prediction: Monkeypox
Confidence: 0.9997

Gbr. 8 Hasil Prediksi Gambar Menggunakan Model Terbaik Xception

Dari seluruh eksperimen yang dilakukan, model Xception dengan skenario pembagian data 70:30 merupakan model terbaik dengan validation accuracy sebesar 98,36% dan validation loss sebesar 0,0712. Hasil ini membuktikan bahwa pendekatan transfer learning menggunakan backbone Xception efektif digunakan untuk klasifikasi penyakit kulit berbasis citra dan mampu memberikan performa yang tinggi dalam membedakan kelas Herpes, Chickenpox, dan Monkeypox.

D. Analisis

Berdasarkan hasil penelitian, pemilihan arsitektur backbone CNN terbukti memberikan pengaruh yang signifikan terhadap kinerja klasifikasi penyakit kulit. Xception yang mampu mencapai performa optimal dengan nilai akurasi validasi di atas 95% pada seluruh skenario pembagian data. Temuan ini mengindikasikan bahwa arsitektur dengan tingkat kompleksitas yang lebih tinggi tidak selalu memberikan performa yang lebih baik, khususnya ketika jumlah data pelatihan serta konfigurasi pelatihan yang digunakan masih terbatas.

Berdasarkan hasil pengujian, model terbaik diperoleh pada backbone Xception dengan skenario pembagian data 70:30 yang menghasilkan akurasi sebesar 98,38%, precision sebesar 98,36%, recall sebesar 98,20%, dan F1-Score sebesar 98,36%. Nilai tersebut menunjukkan bahwa model mampu mengenali ketiga kategori penyakit kulit secara konsisten dengan tingkat kesalahan yang sangat rendah. Selain itu, kurva pelatihan menunjukkan pola konvergensi yang stabil pada data training dan validation, sehingga mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik serta tidak mengalami overfitting secara signifikan.

Keunggulan Xception diduga berasal dari penggunaan mekanisme depthwise separable convolution yang mampu mengekstraksi fitur visual secara lebih efisien dibandingkan konvolusi konvensional. Karakteristik ini sangat sesuai dengan dataset penyakit kulit yang memiliki variasi tekstur, warna, dan pola lesi yang cukup kompleks.

Secara umum, hasil penelitian menunjukkan bahwa pendekatan transfer learning berbasis CNN efektif diterapkan untuk klasifikasi penyakit kulit, khususnya Herpes,

Monkeypox, dan Chickenpox. Berdasarkan perbandingan antar backbone, Xception menjadi arsitektur yang paling sesuai untuk dataset yang digunakan karena mampu memberikan keseimbangan performa terbaik pada metrik accuracy, precision, recall, dan F1-score. Temuan ini juga mengindikasikan bahwa ketepatan dalam memilih arsitektur memiliki pengaruh yang lebih besar terhadap kinerja model dibandingkan dengan sekadar meningkatkan kompleksitas jaringan. Oleh karena itu, Xception dapat direkomendasikan sebagai backbone utama dalam pengembangan sistem deteksi penyakit kulit berbasis citra pada penelitian selanjutnya.

IV. KESIMPULAN

Studi ini menegaskan bahwa rangkaian prapemrosesan citra yang mencakup *flipping*, *rotation*, *resizing*, serta penyesuaian resolusi berdampak positif terhadap kualitas input sebelum masuk ke fase pelatihan. Langkah-langkah tersebut berhasil menonjolkan fitur visual krusial dari lesi kulit, seperti distribusi ruam, intensitas warna, hingga morfologi luka, sehingga mempermudah jaringan saraf dalam mengekstraksi representasi data. Penerapan teknik augmentasi juga terbukti memperluas variasi dataset dan memitigasi efek *overfitting* selama proses iterasi.

Evaluasi komparatif terhadap empat arsitektur *Convolutional Neural Network* memperlihatkan bahwa model berarsitektur ringan, yakni *Xception*. *Xception* sebagai model paling optimal dengan perolehan akurasi pelatihan sebesar 98,36% dan akurasi validasi 97,81% menggunakan rasio pembagian data 70:30. Di samping itu, metrik *F1-Score* yang menyentuh angka 98,36% membuktikan keandalan sistem dalam membedakan kelas *Monkeypox*, *Herpes*, dan *Chickenpox* secara tepat dan konsisten.

Pengujian lebih lanjut menunjukkan bahwa kompleksitas model tidak selalu berbanding lurus dengan peningkatan performa. Beberapa model berkapasitas besar mengalami kesulitan dalam melakukan generalisasi dan cenderung menghasilkan bias terhadap kelas tertentu. Selain itu, tingginya kemiripan karakteristik visual antar penyakit kulit menyebabkan masih terdapat kesalahan klasifikasi pada beberapa sampel. Oleh sebab itu, evaluasi model tidak dapat hanya bergantung pada nilai akurasi, tetapi juga perlu didukung oleh metrik lain, seperti precision, recall, dan F1-score, agar kemampuan model dapat dinilai secara lebih komprehensif dan objektif.

REFERENSI

- [1] N. Sarkar, J. Markidan, M. Gibbs, and K. Helm, "Acquired Punctate Palmoplantar Keratoderma Following PD-1 Inhibitor Therapy," *JAAD Case Rep.*, 2025, [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S2352512625005466>
- [2] G. Babino, H. M. Saleh, and B. Richert, "Same inception, divergent fate: Evolving onychoscopic criteria for longitudinal melanonychia suggesting the onset of nail melanoma," *J. Eur. Acad. Dermatol. Venereol.*, 2025, [Online]. Available: <https://onlinelibrary.wiley.com/doi/abs/10.1111/jdv.70025>
- [3] H. Ma et al., "Diagnostic value of 18F-FDG PET/CT in the follow-up of metastatic uveal melanoma," *Cancer Imaging*, 2025, [Online]. Available: <https://link.springer.com/article/10.1186/s40644-025-00945-2>

- [4] A. Singh, A. Khan, and R. Nirala, "A Hybrid CNN-Transformer Model for Multi-Class Classification of Dermatoscopic Lesions for Early Skin Cancer Diagnosis," 2025, [Online]. Available: https://www.researchgate.net/profile/Anjali-Singh-154/publication/395241703_A_Hybrid_CNN-Transformer_Model_for_Multi-Class_Classification_of_Dermatoscopic_Lesions_for_Early_Skin_Cancer_Diagnosis/links/68b8c630653c451cf4741568/A-Hybrid-CNN-Transformer-Model-for-Multi-Class-Classification-of-Dermatoscopic-Lesions-for-Early-Skin-Cancer-Diagnosis.pdf
- [5] F. Al Zegair, "Automated detection and classification of suspicious naevi in dermoscopy images through artificial intelligence," 2025, [Online]. Available: <https://espace.library.uq.edu.au/view/UQ:8a8b8ed>
- [6] M. A. Khan, D. Rastogi, P. Johri, and A. Al-Taani, "Hybrid deep CNN model for multi-class classification of skin lesion," 2025, [Online]. Available: https://www.researchgate.net/profile/Ahmad-Al-Taani/publication/393538016_Hybrid_deep_CNN_model_for_multi-class_classification_of_skin_lesion/links/6875f9894d336a43674738c5/Hybrid-deep-CNN-model-for-multi-class-classification-of-skin-lesion.pdf
- [7] S. A. Shah, S. T. H. Shah, and R. Khaled, "Explainable AI-based skin cancer detection using CNN, particle swarm optimization and machine learning," 2024, [Online]. Available: <https://pmc.ncbi.nlm.nih.gov/articles/PMC11727770/>
- [8] N. Naz, M. H. Mehmood, F. Ahmed, and M. Ahmad, "Privacy preserving skin cancer diagnosis through federated deep learning and explainable AI," 2025, [Online]. Available: <https://www.nature.com/articles/s41598-025-19905-8>
- [9] S. Ahmed, "Artificial Intelligence Mobile Dermoscopy: A Method for Class Imbalance Management," 2022, [Online]. Available: <https://search.proquest.com/openview/fb608a8c857d1ebda22601de6c128502/1?pq-origsite=gscholar&cbl=2026366&diss=y>
- [10] M. W. P. Maduranga and D. Nandasena, "Mobile-based skin disease diagnosis system using convolutional neural networks (CNN)," 2022, [Online]. Available: https://www.researchgate.net/profile/Pasan-Maduranga-2/publication/361022672_Mobile-Based_Skin_Disease_Diagnosis_System_Using_Convolutional_Neural_Networks_CNN/links/6298296da3fe3e3df854f9bc/Mobile-Based-Skin-Disease-Diagnosis-System-Using-Convolutional-Neural-Networks-CNN.pdf
- [11] C. Pallewela, "Skindetective: Machine learning-based android mobile application for automated identification of skin diseases," 2024, [Online]. Available: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=5383734
- [12] M. A. Rasel, Unaizah H. Obaidellah, and Sameem Abdul Kareem, "(Title of the article)," *J. Name*, vol. (Volume number), no. (Issue number), p. (Start page)-(End page), 2022.
- [13] A. K. Sharma *et al.*, "Dermatologist-Level Classification of Skin Cancer Using Cascaded Ensembling of Convolutional Neural Network and Handcrafted Features Based Deep Neural Network," *IEEE Access*, vol. 10, pp. 17920–17932, 2022, doi: 10.1109/ACCESS.2022.3149824.
- [14] V. Aravindhana, V. Commuri, and V. Krishnan, "A Comprehensive Framework for Classifying Skin Lesion Diseases with Class Imbalance Handling," *IEEE Int. Conf. Artif. Intell. Mach. Learn.*, 2025, [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/111821>