

Enhancing Monkeypox Skin Lesion Classification With Resnet50v2: The Impact Of Pre-Trained Models From Medical And General Domains

Saifulloh Azhar ^{*1}, Abdul Syukur², M. Arief Soeleman³, Affandy⁴, Aris Marjuni⁵

^{1,2,3,4,5}Faculty of Computer Science, Universitas Dian Nuswantoro, Semarang, Indonesia

Email: ¹azharnian@gmail.com

Received : Apr 8, 2025; Revised : Jun 11, 2025; Accepted : Jun 12, 2025; Published : Jun 23, 2025

Abstract

The monkeypox outbreak has emerged as a pressing global health concern, as evidenced by the rising number of cases reported in various countries. This rare zoonotic disease, caused by the Monkeypox virus (MPXV) of the Poxviridae family, is commonly found in Africa. However, since 2022, cases have also spread to various countries, including Indonesia. The dermatological symptoms exhibited by affected individuals vary, with the potential for further transmission through contamination. Early and accurate detection of monkey pox disease is therefore essential for effective treatment. The present study aims to improve the classification of Monkey Pox using the modified Resnet50V2 model, trained using pre-training datasets namely ImageNet and HAM10000, where batch size and learning rate parameters were adjusted. The study achieved high accuracy in distinguishing monkeypox cases, with 98.43% accuracy for Resnet50V2 with pretrained ImageNet and 70.57% accuracy for Resnet50V2 with pretrained HAM10000. Future research will focus on refining these models, exploring hybrid approaches incorporating convolutional neural networks, this advancement contributes to the development of automated early diagnosis tools for monkeypox skin conditions, especially in resource-limited clinical settings where access to dermatology experts is limited.

Keywords : Dermatology, HAM10000, ImageNet, Monkeypox, ResNet50v2.

This work is an open access article and licensed under a Creative Commons Attribution-Non Commercial 4.0 International License




1. PENDAHULUAN

Cacar monyet (Mpox) merupakan penyakit zoonosis yang semakin menjadi perhatian global, terutama setelah munculnya wabah di berbagai negara dalam beberapa tahun terakhir [1], [2]. Penyakit endemik yang berasal dari Afrika barat dan Tengah [3] ini disebabkan oleh virus human monkeypox (MPXV) dari genus Orthopoxvirus dari famili poxviridae yang bersifat zoonosis atau penyakit yang menular melalui kontak langsung dengan ruam atau bintik merah di kulit, koreng atau keropeng, maupun cairan tubuh (air kencing atau darah) orang yang terinfeksi virus mpox [4], [5], [6].

Karakteristik lesi dan ruam cacar monyet serupa dengan variola (smallpox), cacar air (chickenpox), campak (Measles), Cacar Sapi (cowpox) dan vaccinia, Kemiripan gejala dan ciri-ciri klinis Cacar monyet dengan penyakit lain sering kali menyebabkan kesulitan dalam diagnosis dini [7], kondisi ini sangat menantang bagi para tenaga kesehatan yang pada akhirnya dapat memperlambat proses pengendalian penyebaran penyakit [8]. Sementara itu, metode diagnostik utama seperti pemeriksaan klinis dan uji laboratorium PCR (Polymerase Chain Reaction) membutuhkan sumber daya yang besar, infrastruktur yang memadai, serta waktu yang cukup lama [9]. Oleh karena itu, diperlukan pendekatan alternatif yang lebih cepat dan efisien untuk membantu dalam proses identifikasi penyakit ini.

Dalam beberapa tahun terakhir pemanfaatan teknologi pembelajaran mesin (Machine Learning) telah membuktikan efektivitasnya dalam berbagai bidang medis, termasuk dalam diagnosis penyakit berbasis citra medis [10]. Seperti pada kasus covid-19 pembelajaran mesin berbasis Resnet50V2 dapat mengidentifikasi virus covid-19 dan pneumonia dengan menggunakan Citra X-Ray [11].

Keberhasilan pembelajaran mesin dalam memanfaatkan data citra untuk membantu mendiagnosa dini covid-19 menjadikan inspirasi bagi banyak peneliti untuk menerapkan pada penyakit cacar monyet. Peneliti [12] memperkenalkan Monkeypox Skin Lesion Dataset (MSLD), dan menggunakan model deep learning seperti VGG16, ResNet50, dan InceptionV3 dengan transfer learning. Hasil menunjukkan ResNet50 memiliki akurasi 82,96%, Peneliti [13] Model deep learning seperti DenseNet121, ResNet50, dan lainnya digunakan dengan transfer learning berbasis dataset IMAGENET menunjukkan akurasi DenseNet121 sebesar 83,59%. Peneliti [14] melakukan fine-tuning pada model InceptionV3 yang diberi nama POXNET22, dilatih serta divalidasi menggunakan dataset [12] dan hasil penelitian menunjukkan bahwa PoxNet22 dapat mencapai akurasi, presisi, dan sensitivitas 100%, mengungguli model lain seperti ResNet50 dan VGG16. Peneliti [15] melakukan pengumpulan data image dan menggunakan Model VGG16 yang di modifikasi untuk melakukan deteksi pada penyakit cacar monyet dengan akurasi sebesar 83%. Peneliti [16] mengimplementasikan model MobileNetV2 menjadi aplikasi mobile dengan mendapatkan nilai akurasi sebesar 91.11%.



Gambar 1 : The CRISP-DM life cycle

Dari pembahasan penelitian terdahulu beberapa peneliti menggunakan ImageNet sebagai sumber pre-trained model dan mencoba melakukan fine-tuning untuk meningkatkan performa model untuk melakukan klasifikasi penyakit cacar monyet.

Dalam penelitian ini peneliti termotivasi dengan keberhasilan Resnet50V2 untuk mengidentifikasi covid-19 sehingga peneliti ingin mencoba mengimplementasikan model Resnet50V2 pada penyakit cacar monyet, dengan menggunakan ImageNet [17][18] dan HAM10000 [19] sebagai sumber pre-trained model serta melakukan fine-tuning dan optimisasi hyperparameter untuk meningkatkan performa.


2. METODE PENELITIAN

Tahapan penelitian menurut Daniel T. Larose [20] mengikuti kerangka kerja yang sangat terkenal dan banyak digunakan dalam data science yaitu CRISP-DM (Cross-Industry Standard Process for Data Mining) yang menawarkan pendekatan terstruktur dan sistematis untuk menjalankan proyek data mining, mulai dari memahami kebutuhan bisnis hingga penerapan solusi. CRISP-DM memiliki enam tahapan seperti pada gambar 1, yaitu business understanding, data understanding, data preparation, modeling, evaluation, dan deployment.

2.1. ALUR METODOLOGI

Pada alur yang diusulkan pada penelitian klasifikasi gambar penyakit kulit cacar monyet dikelompokkan menjadi beberapa bagian yaitu : Eksplorasi Data, Persiapan Data, Pemodelan dan Evaluasi.

Alur penelitian ini dimulai dengan eksplorasi data yaitu mengumpulkan dataset, kemudian tahap selanjutnya persiapan data dengan tahapan preprocessing dan augmentasi dataset seperti mengatur brightness dan scalling kemudian dibagi menjadi dua bagian dengan ratio 80% : 20%, yaitu untuk keperluan training dan validasi. Dataset pelatihan dan validasi akan diterapkan dalam proses pelatihan dengan menggunakan arsitektur yang diusulkan, yaitu Resnet50V2. Sementara itu, pada tahap pemodelan model Resnet50V2 dilakukan pre-trained menggunakan ImageNet dan HAM10000 sebelum diimplementasikan pembekuan dan penambahan layer serta hyperparameter pada learning rate (LR) dan batch size, model yang sudah siap dilakukan pelatihan menggunakan dataset pengujian untuk mengevaluasi hasil pelatihan dan untuk mendapatkan akurasi, presisi, recall, dan metrik f1-score dari model yang dikembangkan ini terjadi pada tahapan evaluasi, secara detail alur diagram penelitian seperti yang terlihat pada Gambar 2.



Gambar 2 : Diagram Alir Kerja Penelitian

2.2. DATASET

Dataset yang digunakan yaitu Dataset “Monkeypox Skin Lesion Dataset (MSLD)” yang tersedia pada website Kaggle dan dapat diakses melalui link website <https://www.kaggle.com/datasets/nafin59/monkeypox-skin-lesion-dataset>, Dataset tersebut dibuat dengan mengumpulkan dan memproses gambar dari berbagai cara web-scrapping, yaitu dari portal berita, situs web, dan laporan kasus yang dapat diakses public [12].

Dataset memiliki 2 kelas yang dianotasi dalam 2 folder berbeda, yaitu “Monkeypox” dan “Other” (Health, chickenpox dan measles), pada dataset MSLD terdapat 3 folder yaitu Folder Original Images berisi 228 gambar dengan jumlah masing-masing kelas Monkeypox 102 gambar dan Others 126 gambar, Folder Augmented Images berisi gambar yang telah di melalui proses augmentasi berupa rotasi,

translation, reflection, shear, hue, saturation, contrast dan brightness jitter, noise dan lain-lain dengan menggunakan MATLAB R2020a, metode ini mencapai peningkatan sekitar 14 kali lipat untuk jumlah gambar dalam folder Augmented Images sehingga total masing-masing kelas Monkeypox 1428 gambar dan Others 1764 gambar, Folder Fold1 merupakan 1 dari 3 set cross validation datasets, dimana Original Images dibagi menjadi pelatihan, validasi, dan uji dengan proporsi 70:10:20.

Gambar 3 menyajikan contoh visual dari data yang digunakan dalam penelitian ini. Gambar tersebut menampilkan beberapa sampel citra dari dataset, yang mencerminkan variasi lesi kulit pada kasus cacar monyet. Representasi ini bertujuan untuk memberikan gambaran umum terhadap karakteristik visual yang dimiliki oleh dataset, yang kemudian digunakan dalam proses pelatihan dan evaluasi model klasifikasi.



Gambar 3 : Dataset Sample

Peneliti menggunakan data gambar pada folder Augmented Images untuk melakukan training dan testing pada penelitian ini, sedangkan untuk evaluasi peneliti menggunakan data uji yang terdapat pada folder fold1.


Tabel 1 : Distribusi Dataset

Kelas	Total
Monkeypox	1428
Other	1764
Total	3192

2.3. DATA PREPROCESSING

Pada tahap data preprocessing, dataset dilakukan proses transformasi dan normalisasi tahap ini merupakan langkah penting dalam tahapan persiapan data, untuk memastikan konsistensi dan mempermudah proses pelatihan model.


Ukuran gambar disesuaikan (resizing) ke dimensi standar yaitu 224 x 224 piksel seperti gambar 4, kemudian gambar dinormalisasi untuk meratakan distribusi nilai piksel dalam gambar dari rentang 0,255 menjadi 0,1.



Gambar 4 : Proses Resizing

Proses dilanjutkan dengan augmentasi data, dimana pada proses ini memungkinkan penambahan keragaman data tanpa perlu mengubah label gambar asli, variable yang peneliti pakai adalah `brightness_range` diatur dengan nilai `[0.5, 1.5]` memungkinkan variasi kecerahan gambar dalam rentang tertentu, yaitu dari 50% hingga 150% dari kecerahan asli, untuk membantu model mengenali objek dalam kondisi pencahayaan yang berbeda. `fill_mode` menentukan metode pengisian piksel kosong yang dihasilkan akibat transformasi dengan menggunakan nilai piksel terdekat.

Selanjutnya, dataset akan dibagi menjadi dua bagian, dengan alokasi 80% untuk dataset training dan 20% untuk dataset validasi [21] seperti yang digambarkan pada gambar 5.




Gambar 5 : Alur Pembagian Dataset

2.4. PEMODELAN

Arsitektur yang diusulkan dalam penelitian adalah Resnet50V2. Resnet50V2 merupakan model jaringan saraf tiruan (artificial neural network) yang dikembangkan untuk tugas pengenalan gambar (image classification) pada deep learning. Model ini merupakan perkembangan dari varian model ResNet yang diperkenalkan oleh Kaiming He dkk pada tahun 2015 [22].

Gambar 6 menyajikan arsitektur dasar ResNet50v2, dimana pada awalnya normalisasi batch dilakukan, diikuti dengan fungsi aktivasi dan bobot yang diperbarui.



Gambar 6 : Arsitektur Dasar Resnet50V2

Keseluruhan sistem yang diusulkan ditunjukkan pada Gambar 7, di mana model ResNet50V2 dilatih menggunakan dua dataset latih. Dataset pertama adalah ImageNet [17], [18], yang merupakan dataset umum dan digunakan dalam tahap pengujian awal. Dataset kedua adalah dataset dermatologi [19], yang lebih spesifik untuk mendeteksi penyakit kulit.

Model Resnet yang telah melalui proses pre-pelatihan, dilakukan pembekuan layers sebesar 20% pada lapisan akhir, dalam hal ini, semua lapisan kecuali 20 lapisan terakhir akan dikunci (*non-trainable*),


sehingga bobotnya tidak akan diperbarui selama proses pelatihan bertujuan untuk mempertahankan pengetahuan umum yang telah dipelajari model dari dataset sebelumnya [23], kemudian dilakukan ekstraksi fitur dengan Convolutional Neural Network (CNN) kemudian hasil ekstraksi dikonversi menjadi vektor satu dimensi sebelum diteruskan ke lapisan Fully Connected Layer.

Lapisan Fully Connected tersebut terdiri dari 256 neuron dengan fungsi aktivasi ReLU, yang berperan dalam meningkatkan kemampuan model dalam menangkap pola yang kompleks. Untuk mencegah overfitting, diterapkan teknik regularisasi dengan Dropout sebesar 0.5, yang secara acak menonaktifkan beberapa neuron selama pelatihan.

Pada tahap hyperparameter, peneliti melakukan fine-tuning berupa learning rate (LR) dengan tujuan menentukan seberapa besar langkah yang diambil oleh algoritma optimisasi saat memperbarui bobot jaringan. Nilai learning rate yang digunakan yaitu 0.01, 0.001, 0.0005. penentuan nilai learning rate 0.01 untuk mengamati kemampuan konvergensi cepat, 0.001 sebagai nilai umum yang stabil dalam banyak eksperimen CNN, 0.0005 untuk memastikan kestabilan pembelajaran saat model menunjukkan overfitting pada nilai LR yang lebih tinggi. Pendekatan ini mengikuti prinsip eksplorasi ruang parameter untuk mengidentifikasi trade-off antara kecepatan konvergensi dan kestabilan model.

Selain learning rate peneliti juga melakukan fine-tuning menggunakan batch size (BS) dengan menentukan jumlah sampel data yang digunakan untuk memperbarui bobot pada setiap iterasi. Nilai batch size yang ditentukan 8 dan 16, dengan nilai batch size kecil yaitu 8 memungkinkan model belajar secara lebih granular, cocok untuk dataset kecil meskipun membutuhkan waktu pelatihan lebih lama, dan sebaliknya batch size yang sedikit lebih besar yaitu 16 meningkatkan efisiensi komputasi dan stabilitas gradien, meskipun berisiko mengurangi generalisasi pada data baru. Dengan menggabungkan berbagai kombinasi Learning Rate dan Batch Size, penelitian ini mengevaluasi performa model dalam berbagai skenario pembelajaran: dari pelatihan agresif dan cepat (misalnya LR=0.01, BS=16) hingga pelatihan hati-hati dan stabil (LR=0.0005, BS=8).

Pada lapisan output, digunakan satu neuron dengan fungsi aktivasi sigmoid, yang memungkinkan model melakukan klasifikasi biner, yakni menentukan apakah suatu gambar tergolong dalam kelas Monkeypox atau Other.



Gambar 7 : Diagram dari model yang diusulkan.

2.5. Evaluasi

Penggunaan metrik evaluasi diperlukan untuk menentukan kemampuan klasifikasi dari model yang dilatih. Metrik evaluasi yang digunakan dalam penelitian ini meliputi akurasi, presisi, recall dan f1-score. Akurasi adalah rasio kelas prediksi yang benar terhadap jumlah total data yang dievaluasi (1). Presisi adalah ketepatan prediksi positif yang benar terhadap semua prediksi positif (2). Recall atau Sensitivitas, mengukur akurasi dalam membuat prediksi positif yang benar terhadap semua prediksi yang benar (3). Dimana TP, FP, TN, dan FN adalah jumlah kasus yang diklasifikasikan sebagai true positive, false positive, true negative, dan false negative. Menurut penelitian Apoorva Gupta [24], Semakin tinggi Recall dapat mencapai sensitivitas yang lebih tinggi, yang penting untuk deteksi dini suatu penyakit dan mengurangi false negative pada prediksi suatu pembelajaran mesin [24]. F1-Score adalah harmonic mean dari recall dan presisi (4) [25].

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

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

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

$$F1\ Score = 2 * \left(\frac{Precision * Recall}{Precision+Recall} \right) \quad (4)$$

3. HASIL DAN PEMBAHASAN

Implementasi dilakukan pada platform Google Colab, menggunakan GPU T4 dengan memori 15 GB dan RAM 12.7 GB untuk mempercepat proses komputasi. Eksperimen dijalankan dalam bahasa pemrograman Python dan didukung oleh berbagai library, seperti TensorFlow dan Keras untuk membangun serta melatih model deep learning, NumPy untuk komputasi numerik, serta scikit-learn untuk evaluasi performa model. Selain itu, Matplotlib dan Pandas digunakan untuk visualisasi data dan analisis eksploratif. Proses eksperimen terdiri dari dua tahap inti dalam tahap implementasi.

Pertama, proses pelatihan dengan menggunakan ImageNet pre-trained dataset dengan epoch 20 dan pembekuan pada semua lapisan kecuali 20% lapisan terakhir. Tahap kedua menggunakan HAM10000 pre-trained dataset dengan epoch 20 dan pembekuan pada semua lapisan. Pada dasarnya tahap kedua ini mengacu pada konsep transfer learning dimana model Resnet50V2 dilatih dengan dataset HAM10000 kemudian dijadikan pre-trained pada penelitian ini seperti pada gambar 7. Dan setiap tahap-tahap pelatihan melibatkan fine-tuning arsitektur, yang meliputi perubahan ukuran batch size seperti {8, 16}, learning rate [26] dengan nilai {0.01, 0.001, 0.0005} dan optimizer yang dipakai adalah Adam Optimizer [27].

Tabel 2 menampilkan hasil implementasi arsitektur yang diusulkan, Resnet50V2 with Imagenet dan Resnet50V2 with HAM10000, pada dataset yang digunakan dalam penelitian ini. Rangkuman hasil epoch terbaik, akurasi pada epoch terbaik dengan meliputi perubahan ukuran batch, dan learning rate untuk kedua skema tersebut dapat dilihat pada tabel.

Model Resnet50V2 with ImageNet dengan parameter learning rate = 0.01 dan batch size = 16 mencapai tingkat akurasi epoch 0.9624 pada epoch ke 6 menjadi capaian akurasi epoch terendah, sedangkan untuk akurasi epoch tertinggi mencapai 0.9843 dengan parameter learning rate = 0.001 dan batch size = 8 pada epoch ke 4.

Sementara Model Resnet50V2 with HAM10000 dengan parameter learning rate = 0.00 dan batch size = 8 mencapai tingkat akurasi epoch 0.5524 pada epoch ke 1 menjadi capaian akurasi epoch


terendah, sedangkan untuk akurasi epoch tertinggi mencapai 0.7057 dengan parameter learning rate = 0.0005 dan batch size = 8 pada epoch ke 9.

Hasil eksperimen menunjukkan bahwa penggunaan ResNet50V2 dengan pre-trained ImageNet menghasilkan akurasi yang lebih tinggi dibandingkan dengan pre-trained HAM10000. Selain itu, model dengan ImageNet cenderung mencapai konvergensi lebih cepat (dalam 4-11 epoch), sementara model dengan HAM10000 membutuhkan lebih banyak epoch untuk mencapai akurasi terbaiknya.

Tabel 2 : Hasil Implementasi Epoch Resnet50V2


Model	Learning Rate (LR)	Batch Size	Best Epoch	Accuracy Epoch
Resnet50V2 With ImageNet	0.01	8	11	0.9763
	0.01	16	6	0.9624
	0.001	8	4	0.9843
	0.001	16	7	0.9812
	0.0005	8	7	0.9749
	0.0005	16	8	0.9796
Resnet50V2 With HAM10000	0.01	8	1	0.6885
	0.01	16	8	0.6807
	0.001	8	1	0.5524
	0.001	16	3	0.6510
	0.0005	8	9	0.7057
	0.0005	16	8	0.7011

Dari analisa rangkuman hasil implementasi epoch model pada table 2, peneliti mengambil grafik loss dan akurasi dari kombinasi paling optimal dari 2 tahap ujicoba, gambar 8, Garis hijau dan merah menunjukkan akurasi training (TA) dan validasi (VA). Keduanya meningkat seiring bertambahnya epoch, lalu stabil setelah beberapa epoch, menandakan bahwa model sudah mulai konvergen, sedangkan Garis biru dan kuning menunjukkan loss training (TL) dan validasi (VL). Nilainya turun drastis di awal, lalu cenderung stabil, menunjukkan bahwa model belajar dengan baik dan mengurangi error seiring waktu. Grafik ini menunjukkan bahwa model mengalami peningkatan performa yang baik selama training, dengan akurasi yang tinggi dan loss yang menurun. Namun, perbedaan antara loss training dan validasi bisa menjadi indikasi overfitting.



Gambar 8 : Grafik Resnet50V2 with ImageNet loss dan akurasi

Grafik loss dan akurasi pada resnet50V2 dengan HAM10000 seperti ditunjukkan Gambar 9, menunjukkan Garis biru (TL) awalnya sangat tinggi, tetapi turun drastis di epoch pertama dan stabil di nilai rendah setelahnya. Ini menandakan bahwa model dengan cepat belajar dari data, garis kuning (VL) cenderung stabil setelah epoch pertama, menunjukkan bahwa model tidak mengalami peningkatan error yang signifikan pada data validasi, garis hijau dan merah (TA & VA) terlihat hampir sejajar dan stabil, yang berarti model mencapai akurasi yang konsisten pada data training dan validasi. Grafik ini menunjukkan bahwa model belajar dengan cepat di awal dan mencapai stabilitas setelah beberapa epoch, tanpa tanda-tanda overfitting yang jelas.



Gambar 9 : Grafik Resnet50V2 with HAM10000 loss dan akurasi

Dari hasil implementasi Epoch pada Model Resnet50V2, kemudian dilakukan evaluasi model menggunakan yang telah dibahas pada section 2.2 dengan distribusi data seperti ringkasan pada table 3.

Tabel 3 : Ringkasan Dataset Evaluasi

Kelas	Total
Monkeypox	168
Other	252
Total	420

Tabel 4 : Hasil Evaluasi

Model	LR	BZ	ACC	PR	RC	FS
Resnet50V2 With ImageNet	0.01	8	98.57	99	99	99
	0.01	16	95.71	96	96	96
	0.001	8	99.05	99	99	99
	0.001	16	98.81	99	99	99
	0.0005	8	98.57	99	99	99
	0.0005	16	99.52	100	100	100
Resnet 50V2	0.01	8	66.43	66	66	66
	0.01	16	72.14	79	72	68
	0.001	8	60.00	36	60	45

0.001	16	67.38	67	67	67
0.0005	8	49.05	57	49	47
0.0005	16	56.67	59	57	57

Keterangan :

- LR = Learning Rate
- BZ = Batch Size
- ACC = Accuracy
- PR = Presision
- RC = Recall
- FS = F1-Score

Table 4 menampilkan hasil akurasi, recall, presision dan f1-score dari implementasi Resnet50V2 with Imaginet dan Resnet50V2 with HAM10000.

Hasil eksperimen pada tabel 4 menunjukkan bahwa ResNet50V2 yang menggunakan ImageNet sebagai pre-trained model memberikan performa yang jauh lebih baik dibandingkan dengan model yang menggunakan HAM10000. Dengan learning rate 0.001 dan batch size 16, model ResNet50V2 dengan ImageNet mencapai accuracy 98.81%, precision dan recall 99%, serta F1-score 99%. Sementara itu, kombinasi terbaik lainnya terjadi pada learning rate 0.0005 dan batch size 16, di mana model mencapai accuracy tertinggi 99.52% dengan precision, recall, dan F1-score sempurna 100%. Hal ini menunjukkan bahwa learning rate kecil dengan batch size lebih besar cenderung menghasilkan kinerja terbaik untuk model yang dilatih dengan ImageNet.

Sebaliknya, ResNet50V2 dengan HAM10000 sebagai pre-trained model menunjukkan performa yang jauh lebih rendah, dengan accuracy berkisar antara 49.05% hingga 72.14%. Kombinasi terbaik ditemukan pada learning rate 0.01 dan batch size 16, dengan accuracy 72.14%, precision 79%, recall 72%, dan F1-score 68%. Namun, kombinasi lainnya, terutama dengan learning rate lebih kecil (0.0005) dan batch size 8, menghasilkan accuracy paling rendah 49.05%. Hal ini mengindikasikan bahwa pre-trained model dari HAM10000 belum cukup optimal untuk mendeteksi cacar monyet dibandingkan dengan ImageNet, sehingga memerlukan strategi peningkatan seperti fine-tuning yang lebih intensif atau penggunaan dataset pre-trained yang lebih relevan dengan domain penyakit kulit lainnya.

4. DISKUSI

Penelitian ini mengevaluasi kinerja arsitektur Resnet50V2, dengan menerapkan metode pembelajaran transfer menggunakan model yang telah dilatih sebelumnya dari ImageNet dan HAM10000 sebagai fondasi dataset penyakit kulit. Eksperimen ini melibatkan penyesuaian parameter dan pembekuan lapisan untuk menyempurnakan arsitektur tersebut. Resnet50V2 dengan ImageNet, ketika menggunakan parameter default, mencapai tingkat akurasi 99.52% dengan precision, recall, dan F1-score sempurna 100% dalam tahap evaluasi model dengan ukuran batch 16, learning rate 0.0005, dan pembekuan 20% lapisan belakang. Sementara itu, Resnet50V2 dengan HAM10000, mencatat accuracy 72.14%, precision 79%, recall 72%, dalam tahap evaluasi model dengan ukuran batch 16, learning rate 0.001. Secara keseluruhan, hasil implementasi menunjukkan bahwa fine-tuning memiliki dampak positif yang signifikan terhadap peningkatan akurasi model.

Membandingkan hasil penelitian ini dengan penelitian terdahulu yang menggunakan dataset MSLD yang sama dengan penelitian ini seperti pada table 5.


Tabel 5 : Perbandingan dengan Penelitian terdahulu

Model	ACC	PR	RC	FS
-------	-----	----	----	----

VGG16 [12]	81.48	0.85	0.81	0.83
ResNet50 [12]	82.96	0.87	0.83	0.84
InceptionV3 [12]	74.07	0.74	0.81	0.78
Ensemble [12]	79.26	0.84	0.79	0.81
MobileNetV2 [16]	91.11	0.90	0.90	0.90
Model Terbaik Penelitian ini	99.52	1.00	1.00	1.00

Keterangan :

- ACC = Accuracy
- PR = Precision
- RC = Recall
- FS = F1-Score



Gambar 10 : Grafik Perbandingan Model

Berdasarkan hasil evaluasi pada table 5 dan divisualisasi pada gambar 10, model terbaik dalam penelitian ini mencapai performa tertinggi dengan akurasi 99.52%, precision 1.00, recall 1.00, dan F1-score 1.00, menunjukkan kemampuan deteksi yang sangat optimal. Dibandingkan dengan model lain, MobileNetV2 memiliki kinerja terbaik di antara model baseline dengan akurasi 91.11%. Sementara itu, ResNet50 menunjukkan akurasi lebih baik (82.96%) dibandingkan VGG16 (81.48%) dan InceptionV3 (74.07%). Model ensemble, yang menggabungkan beberapa arsitektur, memiliki akurasi 79.26%, sedikit lebih rendah dibandingkan ResNet50 dan VGG16. Hasil ini menunjukkan bahwa model yang dikembangkan dalam penelitian ini secara signifikan lebih unggul dalam mendeteksi cacar monyet yang diuji dibandingkan model baseline sebelumnya.

Kontribusi utama dari penelitian ini adalah memperkuat penerapan computer vision dalam bidang health informatics, khususnya dalam pengembangan sistem pengenalan lesi kulit untuk penyakit infeksius baru yang sedang berkembang seperti cacar monyet. Dengan menunjukkan akurasi tinggi pada klasifikasi otomatis berbasis citra, pendekatan ini berpotensi menjadi alat bantu diagnosis dini yang efektif, terutama di wilayah dengan keterbatasan akses ke tenaga medis ahli.

Namun demikian, perlu dicermati bahwa kualitas dan distribusi dataset memiliki potensi bias, seperti ketidakseimbangan jumlah sampel antar kelas atau kurangnya keberagaman demografis dan etnisitas pasien dalam dataset pelatihan. Hal ini dapat memengaruhi generalisasi model pada populasi yang lebih luas. Oleh karena itu, penting untuk mempertimbangkan pengumpulan data tambahan yang lebih representatif guna meningkatkan keandalan sistem dalam implementasi dunia nyata.

5. KESIMPULAN

Dari hasil yang dipaparkan, arsitektur Resnet50V2 dengan menggunakan pre-trained ImageNet lebih baik nilai akurasi dari pada Resnet50V2 dengan menggunakan pre-trained HAM10000, namun pada proses training dan validasi Resnet50V2 dengan menggunakan pre-trained HAM10000 menjadi model belajar dengan cepat di awal dan mencapai stabilitas setelah beberapa epoch, tanpa tanda-tanda overfitting yang jelas, ini memungkinkan bahwasanya Resnet50V2 dengan menggunakan pre-trained HAM10000 dapat dikembangkan lebih lanjut untuk mendapatkan hasil akurasi yang lebih bagus, ini dapat menjadi penelitian untuk tahap selanjutnya.

Selain itu dataset yang ada masih memiliki bias dalam distribusi rasial dan ukuran dataset terbatas penerapan augmentasi canggih seperti StyleGAN atau color-space augmentation dapat meningkatkan robustnes model dan pengujian Ensemble Model Berbasis ResNet50V2 dengan model lain. Ini adalah beberapa pekerjaan yang bisa dilakukan di masa depan.

Penelitian ini diharapkan dapat berkontribusi pada bidang computer science dan bidang kesehatan, khususnya dalam pengidentifikasian awal penyakit cacar monyet, sehingga dapat membantu para profesional medis dalam melakukan penanganan yang cepat dan tepat terhadap pasien. Model yang diusulkan diharapkan mampu mendukung upaya diagnosis dini cacar monyet, terutama di wilayah terpencil atau dengan akses layanan kesehatan yang terbatas.

DAFTAR PUSTAKA

- [1] "Mpox." Accessed: Oct. 07, 2024. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/mpox>
- [2] L. Jarrell and K. Perryman, "Mpox (monkeypox)," *Nurse Pract*, vol. 48, no. 4, pp. 13–20, Apr. 2023, doi: 10.1097/01.NPR.0000000000000025.
- [3] E. Alakunle, U. Moens, G. Nchinda, and M. I. Okeke, "Monkeypox Virus in Nigeria: Infection Biology, Epidemiology, and Evolution," *Viruses*, vol. 12, no. 11, p. 1257, Nov. 2020, doi: 10.3390/v12111257.
- [4] M. E. Wilson, J. M. Hughes, A. M. McCollum, and I. K. Damon, "Human monkeypox," *Clinical Infectious Diseases*, vol. 58, no. 2, pp. 260–267, Jan. 2014, doi: 10.1093/CID/CIT703.
- [5] L. Budiarto, Ayu Adzani Sabila, and Hafizha Cyndriyani Putri, "Infeksi Cacar Monyet (Monkeypox)," *Jurnal Medika Utama*, vol. 4, no. 02 Januari, pp. 3224–3236, Jan. 2023, [Online]. Available: <https://jurnalmedikahutama.com/index.php/JMH/article/view/597>
- [6] I Ketut Suarayasa, Zulkifli, and O. mazmur Kristoper, "Mekanisme Penyebaran Cacar Monyet dan Faktor-Faktor Yang Mempengaruhinya," *SEHATMAS: Jurnal Ilmiah Kesehatan Masyarakat*, vol. 2, no. 1, pp. 28–34, Jan. 2023, doi: 10.55123/sehatmas.v2i1.980.
- [7] B. K. Titanji, B. Tegomoh, S. Nematollahi, M. Konomos, and P. A. Kulkarni, "Monkeypox: A Contemporary Review for Healthcare Professionals," *Open Forum Infect Dis*, vol. 9, 2022, doi: 10.1093/ofid/ofac310.
- [8] S. J. R. da Silva, A. Kohl, L. Pena, and K. Pardee, "Clinical and laboratory diagnosis of monkeypox (mpox): Current status and future directions," *iScience*, vol. 26, no. 6, p. 106759, Jun. 2023, doi: 10.1016/j.isci.2023.106759.
- [9] J. I. Lukito, "Tatalaksana Monkeypox," *Cermin Dunia Kedokteran*, vol. 46, no. 8, pp. 504–509, Aug. 2019, doi: 10.55175/cdk.v46i8.423.
- [10] E. U. H. Qazi, T. Zia, and A. Almorjan, "Deep Learning-Based Digital Image Forgery Detection System," *Applied Sciences*, vol. 12, no. 6, p. 2851, Mar. 2022, doi: 10.3390/app12062851.
- [11] M. Rahimzadeh and A. Attar, "A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2," *Inform Med Unlocked*, vol. 19, p. 100360, Jan. 2020, doi: 10.1016/J.IMU.2020.100360.
- [12] S. N. Ali *et al.*, "Monkeypox Skin Lesion Detection Using Deep Learning Models: A Feasibility Study," Oct. 2022. doi: 10.48550/arXiv.2207.03342.

-
- [13] S. N. Ali *et al.*, “A web-based mpox skin lesion detection system using state-of-the-art deep learning models considering racial diversity,” *Biomed Signal Process Control*, vol. 98, p. 106742, Dec. 2024, doi: 10.1016/J.BSPC.2024.106742.
 - [14] F. Yasmin *et al.*, “PoxNet22: A Fine-Tuned Model for the Classification of Monkeypox Disease Using Transfer Learning,” *IEEE Access*, vol. 11, pp. 24053–24076, 2023, doi: 10.1109/ACCESS.2023.3253868.
 - [15] M. Ahsan, M. R. Uddin, M. Farjana, A. N. Sakib, K. Al Momin, and S. A. Luna, “IMAGE DATA COLLECTION AND IMPLEMENTATION OF DEEP LEARNING-BASED MODEL IN DETECTING MONKEYPOX DISEASE USING MODIFIED VGG16 A PREPRINT,” 2022.
 - [16] V. H. Sahin, I. Oztel, and G. Yolcu Oztel, “Human Monkeypox Classification from Skin Lesion Images with Deep Pre-trained Network using Mobile Application,” *J Med Syst*, vol. 46, no. 11, p. 79, Oct. 2022, doi: 10.1007/s10916-022-01863-7.
 - [17] J. Deng, W. Dong, R. Socher, L.-J. Li, Kai Li, and Li Fei-Fei, “ImageNet: A large-scale hierarchical image database,” in *2009 IEEE Conference on Computer Vision and Pattern Recognition*, IEEE, Jun. 2009, pp. 248–255. doi: 10.1109/CVPR.2009.5206848.
 - [18] L. Studer *et al.*, “A Comprehensive Study of ImageNet Pre-Training for Historical Document Image Analysis,” in *2019 International Conference on Document Analysis and Recognition (ICDAR)*, IEEE, Sep. 2019, pp. 720–725. doi: 10.1109/ICDAR.2019.00120.
 - [19] P. Tschandl, C. Rosendahl, and H. Kittler, “Data Descriptor: The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions Background & Summary,” 2018, doi: 10.1038/sdata.2018.161.
 - [20] Daniel T. Larose and Chantal D. Larose, *Discovering Knowledge in Data: An Introduction to Data Mining*. John Wiley & Sons, 2014. Accessed: Dec. 29, 2024. [Online]. Available: <https://ieeexplore.ieee.org/servlet/opac?bknumber=10066951>
 - [21] K. Jankowsky and U. Schroeders, “Validation and generalizability of machine learning prediction models on attrition in longitudinal studies,” *Int J Behav Dev*, vol. 46, no. 2, pp. 169–176, Mar. 2022, doi: 10.1177/01650254221075034.
 - [22] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” Dec. 2015.
 - [23] A. Sorrenti, G. Bellitto, F. P. Salanitri, M. Pennisi, C. Spampinato, and S. Palazzo, “Selective Freezing for Efficient Continual Learning,” in *2023 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW)*, IEEE, Oct. 2023, pp. 3542–3551. doi: 10.1109/ICCVW60793.2023.00381.
 - [24] A. Gupta, A. Anand, and Y. Hasija, “Recall-based Machine Learning approach for early detection of Cervical Cancer,” in *2021 6th International Conference for Convergence in Technology (I2CT)*, IEEE, Apr. 2021, pp. 1–5. doi: 10.1109/I2CT51068.2021.9418099.
 - [25] F. Zhuang *et al.*, “A Comprehensive Survey on Transfer Learning,” *Proceedings of the IEEE*, vol. 109, no. 1, pp. 43–76, 2021, doi: 10.1109/JPROC.2020.3004555.
 - [26] J. Raitoharju, “Convolutional neural networks,” in *Deep Learning for Robot Perception and Cognition*, Elsevier, 2022, pp. 35–69. doi: 10.1016/B978-0-32-385787-1.00008-7.
 - [27] R. Llugsi, S. El Yacoubi, A. Fontaine, and P. Lupera, “Comparison between Adam, AdaMax and Adam W optimizers to implement a Weather Forecast based on Neural Networks for the Andean city of Quito,” in *2021 IEEE Fifth Ecuador Technical Chapters Meeting (ETCM)*, IEEE, Oct. 2021, pp. 1–6. doi: 10.1109/ETCM53643.2021.9590681.
-