

Analisis Performa Deteksi Cacar Monyet dengan Model Klasifikasi Gambar Menggunakan Teachable Machine dan Keras

Ali Nugroho Septihadi, Ilham Hidayatullah, Fredy Susanto*

Teknik Informatika, Fakultas Teknik Ilmu Komputer, Institut Teknologi dan Bisnis Bina Sarana Global Tangerang, Indonesia

1120120131@global.ac.id, 1120120001@global.ac.id, *fredysusanto@global.ac.id

ABSTRACT – Digital Image Detection of Monkeypox Disease Performance Analysis using Image Classification Model with Teachable Machine and Keras. Advancements in artificial intelligence technology, particularly in the field of machine learning, have opened up significant new opportunities for developing disease detection systems that are faster, more accurate, and more efficient. This study aims to analyze the performance of Teachable Machine and Keras models in classifying monkeypox images using a quantitative approach. A dataset of skin images with indications of monkeypox was collected for the development of image classification models using both tools. The results of the study show that the developed models accurately recognized images that had been seen during the training data for the "Monkey Pox" category. However, when faced with test images that had not been seen before, the models showed limitations in generalizing, indicating overfitting in that category. Conversely, for the "Other" category, the models were able to recognize well both in the training data and the test data, demonstrating better generalization capability in this category. Therefore, for future research, it is recommended to conduct a more in-depth evaluation of the use of Data Augmentation techniques to expand data variation, as well as to explore other platforms or tools that can provide greater control over test data management.

Keywords: Disease Detection; Machine Learning; Model Accuracy; Teachable Machine

ABSTRAK – Kemajuan dalam teknologi kecerdasan buatan, khususnya di bidang pembelajaran mesin (machine learning), telah membuka peluang baru yang signifikan untuk membuat sistem deteksi penyakit yang lebih cepat, akurat, dan efisien. Penelitian ini bertujuan untuk menganalisis performa model Teachable Machine dan Keras dalam mengklasifikasikan gambar cacar monyet dengan menggunakan pendekatan kuantitatif. Dataset gambar kulit dengan indikasi cacar monyet dikumpulkan untuk pengembangan model klasifikasi gambar menggunakan kedua alat tersebut. Hasil penelitian menunjukkan bahwa model yang dikembangkan berhasil mengenali dengan akurat gambar-gambar yang telah dikenal dalam data pelatihan untuk kategori "Monkey Pox". Namun, ketika dihadapkan pada gambar uji yang belum pernah dilihat sebelumnya, model menunjukkan keterbatasan dalam menggeneralisasi, yang mengindikasikan adanya overfitting pada kelas tersebut. Sebaliknya, untuk kelas "Other", model mampu mengenali dengan baik baik pada data pelatihan maupun data uji, menunjukkan kemampuan yang lebih baik dalam menggeneralisasi pada kategori ini. Oleh karena itu, untuk penelitian selanjutnya disarankan melakukan evaluasi yang lebih mendalam terhadap penggunaan teknik Data Augmentation untuk memperluas variasi data, serta eksplorasi terhadap platform atau alat lain yang dapat memberikan kontrol yang lebih besar terhadap manajemen data uji.

Kata Kunci: Akurasi Model; Deteksi Penyakit; Pembelajaran Mesin; Teachable Machine

1. PENDAHULUAN

Kemajuan dalam teknologi kecerdasan buatan, khususnya di bidang pembelajaran mesin (*machine learning*), telah membuka peluang baru yang signifikan untuk membuat sistem deteksi penyakit yang lebih cepat, akurat, dan efisien [1]. Penggunaan model pembelajaran mesin dalam klasifikasi gambar terbukti sangat efektif dalam berbagai aplikasi medis, termasuk deteksi dan diagnosis penyakit melalui analisis citra medis, misalnya Menganalisis gambar kulit pasien untuk mendeteksi tanda-tanda cacar monyet.

Cacar monyet, juga dikenal sebagai cacar monyet, adalah penyakit zoonosis yang disebabkan oleh virus cacar monyet, anggota *Genus Orthopoxvirus*, famili *Poxviridae*. Virus ini berkerabat dekat dengan virus variola penyebab penyakit cacar, dan *Virus Vaccinia* yang digunakan untuk membuat vaksin cacar. Penyakit ini dapat menular dari hewan ke manusia maupun antar manusia sehingga menimbulkan gejala yang mirip dengan cacar namun sering kali lebih ringan [2],[3]. Teknologi tidak selalu tersedia di semua tempat, mengintegrasikannya ke dalam praktik medis sehari-hari dapat menjadi langkah penting dalam mengendalikan

penyebaran cacar air, sekaligus memberikan banyak manfaat dalam mendeteksi penyakit lain.

Model klasifikasi gambar berbasis pembelajaran mesin dapat secara otomatis mengidentifikasi dan memproses pola tertentu dalam gambar kulit, meningkatkan akurasi diagnostik dan mengurangi waktu yang diperlukan untuk menganalisis data, sehingga memungkinkan respons yang lebih cepat terhadap potensi epidemi. Dalam konteks ini, dua alat yang populer dan sering digunakan untuk mengembangkan model pembelajaran mesin adalah *Teachable Machine* dan Keras. *Teachable Machine* adalah platform yang dikembangkan oleh Google yang memungkinkan pengguna membuat model pembelajaran mesin tanpa memerlukan keterampilan pemrograman yang ekstensif [4]. Sementara itu, Keras adalah pustaka jaringan saraf tingkat tinggi yang berjalan di atas *TensorFlow*, yang menyediakan antarmuka yang mudah digunakan untuk membuat dan melatih model pembelajaran mesin.

Tujuan dari penelitian ini adalah untuk menguji seberapa akurat model mesin yang dapat diajarkan dalam mengklasifikasikan gambar cacar monyet. Dikenal karena kemudahan penggunaan dan kemampuannya membangun model tanpa memerlukan pengetahuan pemrograman yang mendalam, *Teachable Machine* diharapkan dapat membuat proses pengembangan model pembelajaran mesin menjadi lebih cepat dan efisien. Selain itu, penelitian ini juga mencakup Keras, perpustakaan jaringan saraf yang fleksibel dan canggih, untuk mengevaluasi dan membandingkan kinerja kedua alat dalam konteks klasifikasi citra medis. Kombinasi teknologi *Teachable Machine* dan Keras diharapkan mampu menciptakan model pembelajaran mesin yang tidak hanya cepat dan akurat, namun juga dapat diandalkan untuk aplikasi lapangan. Lebih lanjut, penelitian ini bertujuan untuk mencapai persentase akurasi yang tinggi dalam pendeteksian gambar cacar monyet, yang nantinya dapat digunakan sebagai alat diagnostik yang efektif dalam memerangi wabah. Mengingat tingginya akurasi hasil penelitian, model ini diharapkan menjadi bagian penting dari strategi kesehatan masyarakat untuk memerangi cacar monyet dan mengendalikan penyebarannya di masa depan. Hasil ini diharapkan dapat berkontribusi pada pengembangan lebih lanjut teknologi deteksi penyakit lainnya dan membawa manfaat besar di berbagai bidang medis.

2. DASAR TEORI

Keras

Library Keras adalah sebuah perangkat lunak sumber terbuka yang dirancang untuk memfasilitasi pembangunan, pelatihan, dan evaluasi model neural networks dengan menggunakan bahasa pemrograman Python [5]. Dengan antarmuka yang mudah dipahami dan intuitif, Keras memungkinkan para pengembang untuk dengan cepat membuat prototipe dan mengimplementasikan berbagai arsitektur jaringan saraf, termasuk *Convolutional Neural Networks (CNNs)*, *Recurrent Neural Networks (RNNs)*, dan model-model *deep learning*

lainnya [6]. Keras juga menawarkan dukungan untuk berbagai tugas dalam pembelajaran mesin dan kecerdasan buatan, termasuk klasifikasi, regresi, pengenalan gambar, pemrosesan bahasa alami, dan sebagainya [7].

Teachable Machine

Di sisi lain, *Teachable Machine*, sebagai platform yang memungkinkan pengguna untuk melatih model *machine learning* tanpa perlu pengetahuan mendalam tentang pemrograman atau kecerdasan buatan, memberikan kontribusi penting dalam pengembangan aplikasi deteksi berbasis *mobile* [8]. Dengan menggunakan teknik *transfer learning*, pengguna dapat membuat model *Machine Learning (ML)* yang dapat membedakan antara berbagai kelas objek atau fenomena dengan cepat dan mudah. Integrasi *Teachable Machine* dengan *TensorFlow Lite* membuka peluang baru dalam pengembangan aplikasi deteksi penyakit berbasis *mobile* yang efektif dan efisien [9].

Literatur

Penelitian sebelumnya mengenai metode deteksi penyakit cacar monyet dengan metode *deep learning* sudah dilakukan dengan judul “*Monkeypox Detection Using CNN with Transfer Learning*” [10]. Penelitian ini bertujuan untuk mengembangkan sebuah sistem deteksi penyakit cacar monyet menggunakan *deep learning*, dengan fokus pada identifikasi lesi kulit sebagai indikator infeksi. Pendekatan *deep learning* didukung oleh *transfer learning* dan optimasi *hyperparameter* untuk meningkatkan keakuratan dan efisiensi. Berbagai arsitektur model CNN, termasuk *MobileNetV3-s*, *EfficientNetV2*, *ResNET50*, *Vgg19*, *DenseNet121*, dan *Xception*, dieksplorasi dan disesuaikan dalam kerangka kerja penelitian ini.

Penelitian ini mengevaluasi kinerja model menggunakan berbagai metrik, termasuk *AUC*, akurasi, *recall*, *loss*, dan *F1-score*. Hasil menunjukkan bahwa model hibrida *MobileNetV3-s* yang dioptimalkan menghasilkan kinerja terbaik, dengan *F1-score* rata-rata mencapai 0,98, *AUC* 0,99, akurasi 0,96, dan *recall* 0,97. Metode ini menunjukkan keunggulan dalam mendeteksi penyakit cacar monyet melalui lesi kulit, dengan kemampuan untuk menghasilkan hasil yang konsisten dan akurat.

Penelitian sebelumnya mengenai klasifikasi penyakit cacar monyet dengan metode *deep learning* sudah dilakukan dengan judul “*Klasifikasi Penyakit Cacar Monyet Menggunakan Metode Convolutional Neural Network*” [11]. Penelitian ini bertujuan membangun model klasifikasi cacar monyet menggunakan CNN arsitektur *ResNet-50* dan fungsi optimasi Adam. Dua dataset digunakan, dengan 3192 gambar untuk pelatihan dan validasi, dan 770 gambar untuk pengujian. Model menghasilkan akurasi validasi terbaik 94,82% dan akurasi uji terbaik 76,10%, menunjukkan potensi dalam membantu diagnosis dini cacar monyet.

Penelitian sebelumnya mengenai deteksi penyakit cacar monyet dengan metode *deep learning* sudah dilakukan dengan judul “*Deteksi Citra Digital Penyakit Cacar Monyet menggunakan Algoritma Convolutional Neural Network dengan Arsitektur MobileNetV2*” [12]. Penelitian ini bertujuan mengembangkan model algoritma deteksi otomatis untuk

penyakit cacar monyet menggunakan CNN dengan arsitektur MobileNetV2 dan penerapan transfer learning. Model dilatih dengan 5 epoch dan dua jenis optimizer, yaitu Adam dan RMSprop. Hasil menunjukkan bahwa Adam *optimizer* dengan *learning rate* 10^{-4} menghasilkan akurasi data uji 94% dan akurasi data latih 92% dengan nilai *loss function* 27%. Dibandingkan dengan RMSprop optimizer, Adam *optimizer* terbukti lebih efektif dalam mengoptimalkan model untuk deteksi cacar monyet, menghasilkan akurasi yang lebih tinggi dan nilai *loss function* yang lebih rendah.

Penelitian sebelumnya mengenai deteksi penyakit cacar monyet dengan metode *deep learning* sudah dilakukan dengan judul “*Deep learning based detection of monkeypox virus using skin lesion images*” [13]. Penelitian ini bertujuan untuk mengembangkan model *deep learning* untuk mendiagnosis cacar monyet dari gambar lesi kulit. Lima model *deep neural network* terlatih, yaitu GoogLeNet, Places365-GoogLeNet, SqueezeNet, AlexNet, dan ResNet-18, diuji dan dibandingkan performanya dalam mendeteksi cacar monyet. Hasil penelitian menunjukkan bahwa model ResNet-18 mencapai akurasi tertinggi sebesar 99,49%, dengan model-model lain yang dimodifikasi melalui *hyperparameter tuning* menghasilkan akurasi validasi di atas 95%. Penerapan teknik *Explainable AI* (LIME dan Grad-CAM) memungkinkan interpretasi visual terhadap prediksi model, sehingga membantu tenaga kesehatan dalam menggunakan model ini. Secara keseluruhan, penelitian ini menunjukkan bahwa model *deep learning*, khususnya ResNet-18 yang dimodifikasi, memiliki potensi yang menjanjikan untuk menjadi alat bantu diagnosis cacar monyet yang akurat dan efisien. Penerapan model ini dapat membantu tenaga kesehatan dalam mendeteksi cacar monyet secara dini dan tepat, sehingga dapat membantu dalam penanganan dan pengendalian penyakit ini.

Penelitian sebelumnya mengenai deteksi penyakit cacar monyet dengan metode *deep learning* sudah dilakukan dengan judul “*Monkeypox Skin Lesion Detection Using Deep Learning Models: A Feasibility Study*” [14]. Penelitian ini bertujuan untuk mengembangkan metode deteksi cacar monyet menggunakan *deep learning*. Sebuah *dataset* gambar lesi kulit cacar monyet, cacar air, dan campak (“*Monkeypox Skin Lesion Dataset*” - MSLD) dibuat untuk melatih dan mengevaluasi model *deep learning*. Model VGG-16, ResNet50, dan InceptionV3 dilatih dan dibandingkan performanya dalam mengklasifikasikan cacar monyet. Hasilnya menunjukkan bahwa ResNet50 mencapai akurasi tertinggi (82,96%), lebih baik daripada VGG-16 (81,48%) dan sistem *ensemble* (79,26%). Sebuah prototipe aplikasi web juga dikembangkan untuk skrining cacar monyet *online*. Meskipun hasil awal pada *dataset* MSLD yang terbatas ini menjanjikan, penelitian lebih lanjut dengan *dataset* yang lebih besar dan beragam secara demografis diperlukan untuk meningkatkan generalisasi model. Pendekatan *deep learning* dengan MSLD memiliki potensi untuk menjadi alat bantu diagnosis cacar monyet yang akurat dan efisien, membantu tenaga kesehatan dalam mendeteksi cacar monyet secara dini dan tepat,

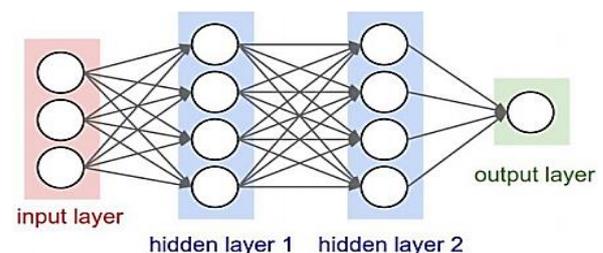
sehingga dapat membantu dalam penanganan dan pengendalian penyakit ini.

Sedangkan penelitian yang membahas mengenai model *Teachable Machine* dengan kasus yang berbeda telah dilakukan dengan judul “*Development of an Image Analysis-Based Prognosis Score Using Google’s Teachable Machine in Melanoma*” [15]. Studi ini menggunakan kecerdasan buatan (AI) untuk mengembangkan risiko kelangsungan hidup pada melanoma berdasarkan analisis gambar. Mereka menggunakan 831 kasus melanoma antara 2012-2015, membaginya menjadi kelompok pelatihan (500 kasus) dan kelompok uji (331 kasus). Dengan menggunakan perangkat lunak *Teachable Machine* dari Google, mereka berhasil mengembangkan skor prognosis untuk kelangsungan hidup secara keseluruhan dengan AUC 0,694. Kelompok prognosis “risiko rendah” (230 kasus) memiliki tingkat kelangsungan hidup 93%, sementara kelompok “risiko tinggi” (101 kasus) memiliki tingkat kelangsungan hidup 77,2%. Studi ini menyoroti potensi AI untuk memberikan estimasi risiko pada melanoma, meskipun belum secara signifikan meningkatkan klasifikasi risiko yang ada.

3. METODOLOGI

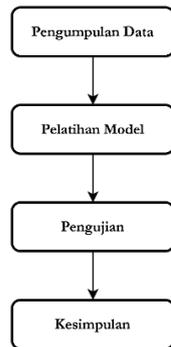
Metode penelitian ini dimulai dengan tahap yang krusial, yaitu pengumpulan *dataset* yang relevan dan representatif sesuai dengan tujuan penelitian. Proses ini melibatkan pencarian sumber data yang terpercaya serta memastikan keberagaman dan kualitas *dataset* yang digunakan. Langkah selanjutnya adalah memanfaatkan platform *Teachable Machine* sebagai alat utama untuk melatih model *machine learning*. *Teachable Machine* menawarkan antarmuka yang ramah pengguna untuk proses pelatihan, memungkinkan peneliti untuk dengan mudah mengunggah *dataset* mereka dan menyesuaikan parameter pelatihan.

Proses pelatihan dilakukan dengan memanfaatkan CNN, sebuah arsitektur *neural network* yang dikenal efektif dalam memproses data gambar dan mengidentifikasi pola yang kompleks [16]. CNN memiliki kemampuan untuk secara otomatis mengekstraksi fitur-fitur penting dari gambar yang diberikan, menjadikannya pilihan yang tepat untuk tugas-tugas pengenalan pola visual seperti yang dilakukan dalam penelitian ini [17]. Selama proses pelatihan, model CNN diberikan informasi dari *dataset* yang telah disiapkan, dan dilakukan iterasi berulang untuk mengoptimalkan bobot dan parameter lainnya guna meningkatkan akurasi prediksi [18].



Gambar 1. Gambar CNN [21]

Setelah proses pelatihan selesai, tahap selanjutnya adalah evaluasi kinerja model yang dihasilkan. Hal ini dilakukan dengan menguji model menggunakan data uji yang belum pernah dilihat sebelumnya. Hasil evaluasi ini memberikan gambaran tentang seberapa baik model dapat menggeneralisasi pola dari data latih ke data uji, dan sejauh mana model dapat diandalkan dalam aplikasi dunia nyata. Dengan demikian, langkah-langkah ini secara keseluruhan memastikan bahwa penelitian ini menghasilkan model yang dapat dipercaya dan relevan dalam konteks pengenalan pola visual.



Gambar 2 Diagram Alur Penelitian

Pengumpulan Data

Dataset untuk penelitian ini diambil dari website Kaggle (<https://www.kaggle.com/datasets/nazmussadat013/monkey-pox-dataset>), sebuah *platform* yang menyediakan berbagai *dataset* untuk keperluan analisis dan penelitian [19]. *Dataset* yang digunakan terdiri dari 900 gambar yang menunjukkan gejala penyakit cacar monyet

dan 900 gambar penyakit dengan gejala yang hampir serupa dengan cacar monyet, namun bukan penyakit cacar monyet. Penggunaan *dataset* ini diharapkan dapat membantu dalam pelatihan model untuk deteksi penyakit cacar monyet dengan akurasi yang tinggi.

Pembagian Data

Dari 900 gambar *monkey pox* dan 900 gambar *other* yang dimasukkan ke dalam *platform* "Teachable Machine" untuk pelatihan model deteksi penyakit. Platform ini secara otomatis membagi data menjadi dua bagian, yaitu 85% untuk "training" dan 15% untuk "testing". Sehingga, dari total 900 gambar yang di latih ada 135 sampel gambar yang dijadikan data pengujian.

Pelatihan Model

Machine learning untuk deteksi penyakit cacar monyet dilatih menggunakan platform *Teachable Machine* yang sangat mudah digunakan dalam pembuatan model klasifikasi *machine learning* tanpa perlu keahlian khusus. [20] Dalam proses pelatihan ini, model dibagi menjadi dua kelas atau kategori: kelas "monkey pox" dan kelas "other". Kelas "monkey pox" berisi gambar-gambar yang menunjukkan gejala penyakit cacar monyet, sedangkan kelas "other" berisi gambar-gambar penyakit dengan gejala yang mirip namun bukan cacar monyet.

Dengan pengaturan *hyperparameter* yang ditetapkan, model dilatih dengan total 120 epoch, menggunakan *batch size* sebesar 32, dan *learning rate* sebesar 0.0001. Proses pelatihan ini bertujuan untuk meningkatkan akurasi dalam mengklasifikasikan gambar-gambar tersebut dengan lebih baik, memungkinkan deteksi penyakit cacar monyet dengan akurasi yang lebih tinggi.



Gambar 3 Contoh Sampel Penyakit Cacar Monyet



Gambar 4 Contoh Sampel Dataset Penyakit Bukan Cacar Monyet

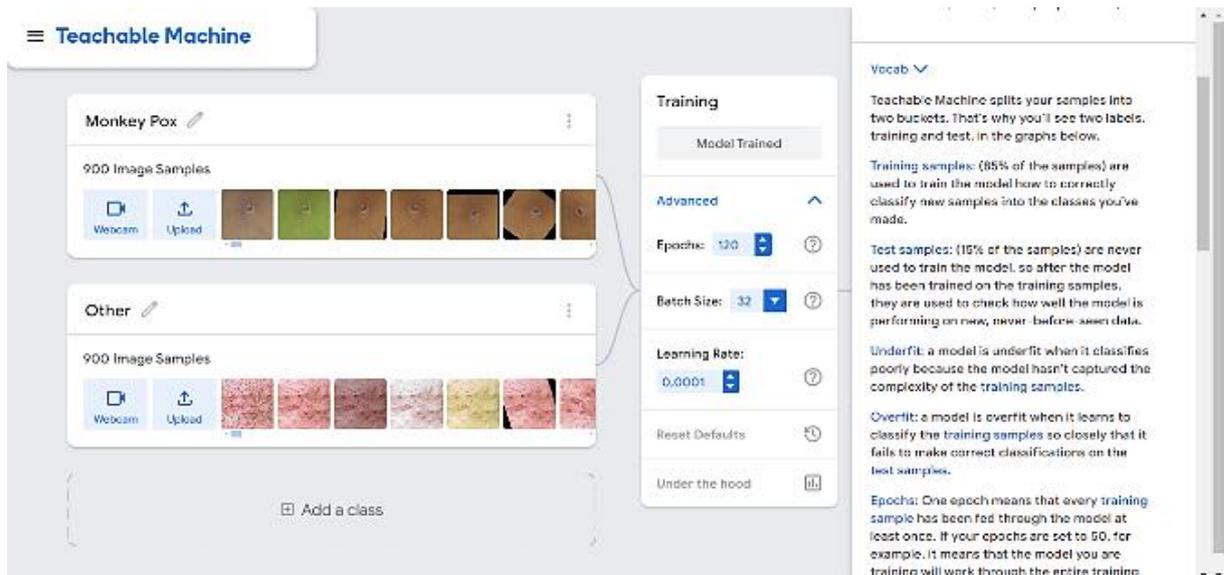
4. HASIL DAN PEMBAHASAN

Pengujian

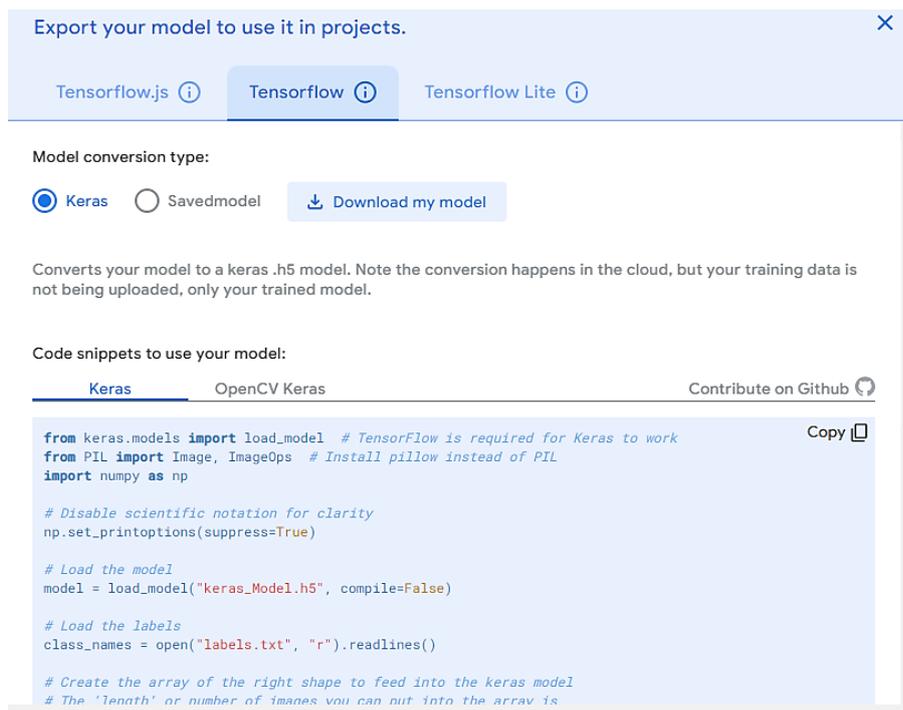
Langkah pengujian dimulai dengan model yang telah dilatih sebelumnya di impor ke dalam format Keras menggunakan alat konversi yang sesuai. Proses konversi ini penting agar model dapat berfungsi secara optimal dalam lingkungan Keras. Selanjutnya, *dataset* yang telah disiapkan diberikan kepada model yang telah dikonversi untuk menguji kinerjanya. Dalam pengujian ini, fokus utama adalah pada kemampuan model untuk menghasilkan *output* yang relevan dan akurat. Setelah

pengujian selesai, akurasi model dievaluasi berdasarkan hasil yang dihasilkan, yang kemudian dapat dihitung sebagai persentase dari *output* yang benar.

Setelah model berhasil *export*, langkah selanjutnya adalah menempatkan model beserta labelnya pada lokasi yang sama. Proses pengujian model dilakukan dengan menggunakan *Google Colab*, sebuah platform yang memungkinkan penggunaan sumber daya komputasi yang kuat secara online. Gambar-gambar uji disimpan dalam folder yang telah disiapkan, yaitu "*test*", dan setiap file diakses melalui path yang telah ditetapkan dalam kode program.



Gambar 5 Pelatihan Model Dengan *Teachable Machine*



Gambar 6 *Export* Model dalam Format Keras

```

from keras.models import load_model # TensorFlow is required for Keras to work
from PIL import Image, ImageOps # Install pillow instead of PIL
import numpy as np

# Disable scientific notation for clarity
np.set_printoptions(suppress=True)

# Load the model
model = load_model("keras_model.h5", compile=False)

# Load the labels
class_names = open("labels.txt", "r").readlines()

# Create the array of the right shape to feed into the Keras model
# The 'length' or number of images you can put into the array is
# determined by the first position in the shape tuple, in this case 1
data = np.ndarray(shape=(1, 224, 224, 3), dtype=np.float32)

# Replace this with the path to your image
image = Image.open("test_data_other/NM01_01_00.jpg").convert("RGB")

# resizing the image to be at least 224x224 and then cropping from the center
size = (224, 224)
image = ImageOps.fit(image, size, Image.Resampling.LANCZOS)

# turn the image into a numpy array
image_array = np.asarray(image)

# Normalize the image
normalized_image_array = (image_array.astype(np.float32) / 127.5) - 1

# Load the image into the array
data[0] = normalized_image_array

# Predicts the model
prediction = model.predict(data)
index = np.argmax(prediction)
class_name = class_names[index]
confidence_score = prediction[0][index]

# Print prediction and confidence score
print("Class:", class_name[2:], end="")
print("Confidence Score:", confidence_score)
    
```

1/1 [=====] - 2s 2s/step
 Class: Monkey Pox
 Confidence Score: 0.99676955

Gambar 7 Pengujian dengan Google Colab

Ketika skrip dijalankan dalam lingkungan Google Colab, hasil prediksi akan ditampilkan secara langsung. Sebagai contoh, mungkin terjadi prediksi bahwa suatu

gambar termasuk dalam kelas "monkey pox", dengan tingkat kepercayaan sebesar 0.99676955. Ini adalah salah satu cara untuk mengevaluasi performa model secara kuantitatif.

Proses pengujian ini diulang sebanyak 10 kali dengan 3 gambar gambar train class "monkey pox" dan 2 gambar test yang tidak dilatih sebelumnya lalu 3 gambar train untuk class "other" dan 2 gambar test yang tidak dilatih sebelumnya untuk memastikan reliabilitas hasil. Dalam setiap iterasi, digunakan 5 gambar yang merupakan contoh cacar monyet dan 5 gambar lainnya yang mewakili kategori lainnya.

Dari hasil pengujian, diperoleh informasi sebagai berikut:

(1) Kelas *Monkey Pox*: Dari 3 gambar yang digunakan untuk pelatihan model, model berhasil mendeteksi dengan baik. Namun, dari 2 gambar uji yang belum pernah digunakan sebelumnya, model gagal mendeteksi kelas "monkey pox".

(2) Kelas *Other*: Model mampu mendeteksi dengan benar baik pada gambar yang digunakan untuk pelatihan maupun pada gambar uji. Yang artinya dapat peneliti simpulkan bahwa model yang dihasilkan dari penelitian ini mengalami *overfitting*. *Overfitting* terjadi ketika model *machine learning* terlalu kompleks sehingga mampu "menghafal" data pelatihan dengan sangat baik, namun gagal dalam menggeneralisasi ke data baru yang belum pernah dilihat sebelumnya. Hal ini dapat terjadi karena model terlalu sensitif terhadap *noise* atau detail yang tidak representatif dalam data pelatihan. Dalam kasus ini, *overfitting* terlihat pada kelas "monkey pox" di mana model gagal mengenali gambar uji baru meskipun berhasil pada data pelatihan.

Table 1 Hasil Pengujian Deteksi Penyakit Cacar Monyet

No	Gambar	Kategori Sebenarnya	Gambar Train/Test	Hasil Deteksi	Akurasi %
1	M01_03_09.jpg	Cacar Monyet	Train	Cacar Monyet	0.99676955
2	M02_02_09.jpg	Cacar Monyet	Train	Cacar Monyet	0.96165013
3	M05_02_11.jpg	Cacar Monyet	Train	Cacar Monyet	0.99649316
4	M19_02.jpg	Cacar Monyet	Test	Bukan Cacar Monyet	0.9995782
5	M48_01.jpg	Cacar Monyet	Test	Bukan Cacar Monyet	0.99999464
6	NM01_01_00.jpg	Bukan Cacar Monyet	Train	Bukan Cacar Monyet	0.99999976
7	NM03_01_00.jpg	Bukan Cacar Monyet	Train	Bukan Cacar Monyet	1.0
8	NM04_01_12.jpg	Bukan Cacar Monyet	Train	Bukan Cacar Monyet	1.0
9	NM12_01.jpg	Bukan Cacar Monyet	Test	Bukan Cacar Monyet	1.0
10	NM79_01.jpg	Bukan Cacar Monyet	Test	Bukan Cacar Monyet	1.0

Untuk mengatasi kendala ini, beberapa langkah perbaikan dapat dipertimbangkan:

Penyetelan *Hyperparameter* dapat dilakukan dengan lebih mendalam, seperti penggunaan regularisasi atau upaya untuk mengurangi kompleksitas model. Hal ini dapat membantu model agar tidak terlalu fokus pada detail dan *noise* dalam data pelatihan yang mungkin tidak representatif secara umum.

Penggunaan teknik Data *Augmentation* juga bisa menjadi solusi yang efektif. Dengan memperluas variasi data melalui augmentasi, model dapat diberikan lebih banyak contoh yang berbeda-beda, sehingga dapat memperkuat kemampuannya dalam mengenali pola

umum tanpa terlalu mengandalkan detail yang spesifik dari data pelatihan.

Evaluasi lebih lanjut terhadap platform seperti *Teachable Machine* menjadi hal yang penting dalam konteks penelitian ini. Salah satu keterbatasan yang dapat diidentifikasi adalah kurangnya fleksibilitas dalam pengaturan pembagian data. *Teachable Machine* memang menyediakan kemudahan dengan melakukan pembagian data secara otomatis, namun pengguna tidak memiliki kontrol penuh terhadap proses ini. Sebagai contoh, pengguna tidak dapat menentukan persentase gambar yang akan dialokasikan untuk data pelatihan (*train*) dan data uji (*test*) secara langsung. Hal ini dapat menjadi

kendala ketika pengguna ingin mengatur ulang atau menyesuaikan pembagian data sesuai dengan kebutuhan spesifik penelitian atau eksperimen yang dilakukan. Sehingga keterbatasan ini dapat mempengaruhi kemampuan model untuk menggeneralisasi dengan baik ke data baru, karena pembagian yang tidak optimal dapat mempengaruhi kualitas pelatihan dan evaluasi model. Dalam penelitian yang mengandalkan pada akurasi dan generalisasi model, kontrol yang lebih besar terhadap pengelolaan data uji dapat membantu memastikan bahwa model dapat diuji dengan cara yang sesuai dan representatif.

Dengan mengimplementasikan langkah-langkah ini, diharapkan dapat meningkatkan kemampuan model untuk mengenali dengan lebih baik kelas yang berbeda, serta mengurangi kemungkinan terjadinya *overfitting* pada data yang baru atau belum pernah dilihat sebelumnya.

5. KESIMPULAN

Penelitian ini difokuskan pada analisis performa deteksi cacar monyet menggunakan model klasifikasi gambar dengan menggunakan *Teachable Machine* dan Keras. Dari hasil pengujian yang telah dilakukan, terdapat beberapa temuan utama yang dapat disimpulkan. Pertama, model yang dikembangkan berhasil mengenali dengan akurat gambar-gambar yang telah dikenal dalam data pelatihan untuk kategori "*Monkey Pox*". Namun, ketika dihadapkan pada gambar uji yang belum pernah dilihat sebelumnya, model menunjukkan keterbatasan dalam menggeneralisasi, yang menunjukkan adanya *overfitting* pada kelas tersebut. Hasil ini menyoroti pentingnya untuk melakukan penyetelan lebih lanjut terhadap *hyperparameter* model, seperti penggunaan regularisasi atau upaya untuk mengurangi kompleksitas model. Kedua, untuk kelas "*Other*", model mampu mengenali dengan baik pada data yang digunakan untuk pelatihan maupun pada data uji, menunjukkan kemampuan yang lebih baik dalam menggeneralisasi pada kategori ini.

Dari segi manfaat dan penerapan penelitian, hasil ini memberikan wawasan yang berharga dalam penggunaan model klasifikasi gambar untuk tujuan deteksi medis. Meskipun demikian, penelitian juga menghadapi beberapa keterbatasan, terutama dalam fleksibilitas platform seperti *Teachable Machine* dalam mengelola data uji dengan cara yang lebih disesuaikan. Hal ini mengindikasikan perlunya platform yang lebih fleksibel dan dapat disesuaikan untuk penelitian yang lebih mendalam dan kompleks di masa depan.

Untuk penelitian selanjutnya, disarankan untuk melakukan evaluasi yang lebih mendalam terhadap penggunaan teknik *Data Augmentation* untuk memperluas variasi data, serta eksplorasi terhadap platform atau alat lain yang dapat memberikan kontrol yang lebih besar terhadap manajemen data uji. Langkah-langkah ini diharapkan dapat meningkatkan performa dan generalisasi model secara keseluruhan dalam aplikasi deteksi kelas yang lebih luas dan lebih kompleks.

DAFTAR PUSTAKA

- [1] F. D. Telaumbanua, P. Hulu, T. Z. Nadeak, R. R. Lumbantong, and A. Dharma, "Penggunaan Machine Learning Di Bidang Kesehatan," *J. Teknol. dan Ilmu Komput. Prima*, vol. 2, no. 2, pp. 391–399, 2020, doi: 10.34012/jutikomp.v2i2.657.
- [2] L. Budiarto, A. A. Sabila, and H. C. Putri, "Infeksi Cacar Monyet (Monkeypox)," *J. Med. Hutama*, vol. 4, no. 02 Januari, pp. 3224–3236, 2023.
- [3] D. Li, Y. Liu, K. Li, and L. Zhang, "Targeting F13 from monkeypox virus and variola virus by tecovirimat: Molecular simulation analysis," *J. Infect.*, vol. 85, no. 4, pp. e99–e101, 2022, doi: 10.1016/j.jinf.2022.07.001.
- [4] N. Malleswari, P. Yogendra Prasad, D. Prasad, M. N. Shetty, and N. Gupta, "Implementation of Machine Learning Based Google Teachable Machine in Early Childhood Education," *Artic. Int. J. Early Child. Spec. Educ.*, vol. 14, no. May, p. 2022, 2022, [Online]. Available: <https://www.researchgate.net/publication/360438764>
- [5] R. Conlin, K. Erickson, J. Abbate, and E. Kolemen, "Keras2c: A library for converting Keras neural networks to real-time compatible C," *Eng. Appl. Artif. Intell.*, vol. 100, 2021, doi: 10.1016/j.engappai.2021.104182.
- [6] J. Hung *et al.*, "Keras R-CNN: Library for cell detection in biological images using deep neural networks," *BMC Bioinformatics*, vol. 21, no. 1, pp. 1–7, 2020, doi: 10.1186/s12859-020-03635-x.
- [7] D. Gupta, "Image segmentation Keras: Implementation of Segnet, FCN, UNet, PSPNet and other models in Keras," *ArXiv*, vol. abs/2307.1, pp. 1–5, 2023, [Online]. Available: <https://api.semanticscholar.org/CorpusID:260155027>
- [8] M. Carney *et al.*, "Teachable Machine: Approachable Web-Based Tool for Exploring Machine Learning Classification," in *Extended Abstracts of the 2020 CHI Conference on Human Factors in Computing Systems*, in CHI EA '20. New York, NY, USA: Association for Computing Machinery, 2020, pp. 1–8. doi: 10.1145/3334480.3382839.
- [9] E. A. U. Malahina, R. P. Hadjon, and F. Y. Bisilisin, "Teachable Machine: Real-Time Attendance of Students Based on Open Source System," *IJICS (International J. Informatics Comput. Sci.)*, vol. 6, no. 3, p. 140, 2022, doi: 10.30865/ijics.v6i3.4928.

- [10] M. Altun, H. Gürüler, O. Özkaraca, F. Khan, J. Khan, and Y. Lee, "Monkeypox Detection Using CNN with Transfer Learning," *Sensors*, vol. 23, no. 4, 2023, doi: 10.3390/s23041783.
- [11] T. O. Saputra and D. Alamsyah, "Klasifikasi Penyakit Cacar Monyet Menggunakan," *Mdp Student Conf.*, pp. 179–184, 2023.
- [12] P. S. Fransisca and N. Matondang, "Deteksi Citra Digital Penyakit Cacar Monyet menggunakan Algoritma Convolutional Neural Network dengan Arsitektur MobileNetV2," *J. Ilmu Komput. dan Agri-Informatika*, vol. 10, no. 2, pp. 200–211, 2023, doi: 10.29244/jika.10.2.200-211.
- [13] T. Nayak *et al.*, "Deep learning based detection of monkeypox virus using skin lesion images," *Med. Nov. Technol. Devices*, vol. 18, no. March, p. 100243, 2023, doi: 10.1016/j.medntd.2023.100243.
- [14] S. N. Ali *et al.*, "Monkeypox Skin Lesion Detection Using Deep Learning Models: A Feasibility Study," pp. 2–5, 2022, [Online]. Available: <http://arxiv.org/abs/2207.03342>
- [15] S. Forchhammer, A. Abu-ghazaleh, G. Metzler, and C. Garbe, "Development of an Image Analysis-Based Prognosis Score Using Google's Teachable Machine in Melanoma," 2022.
- [16] E. Rasywir, R. Sinaga, and Y. Pratama, "Analisis dan Implementasi Diagnosis Penyakit Sawit dengan Metode Convolutional Neural Network (CNN)," *Paradig. - J. Komput. dan Inform.*, vol. 22, no. 2, pp. 117–123, 2020, doi: 10.31294/p.v22i2.8907.
- [17] M. Fasounaki, E. B. Yüce, S. Öncül, and G. Ince, "CNN-based Text-independent Automatic Speaker Identification Using Short Utterances," *Proc. - 6th Int. Conf. Comput. Sci. Eng. UBMK 2021*, vol. 01, pp. 413–418, 2021, doi: 10.1109/UBMK52708.2021.9559031.
- [18] M. A. Hossain and M. S. Alam Sajib, "Classification of Image using Convolutional Neural Network (CNN)," *Glob. J. Comput. Sci. Technol.*, vol. 19, no. May, pp. 13–18, 2019, doi: 10.34257/gjcsdtdvol19is2pg13.
- [19] T. Islam, M. A. Hussain, F. U. H. Chowdhury, and B. M. R. Islam, "A Web-scraped Skin Image Database of Monkeypox, Chickenpox, Smallpox, Cowpox, and Measles," *bioRxiv*, pp. 1–12, 2022, doi: 10.1101/2022.08.01.502199.
- [20] C. Chazar and M. H. Rafsanjani, "Penerapan Teachable Machine Pada Klasifikasi Machine Learning Untuk Identifikasi Bibit Tanaman," *Pros. Semin. Nas. Inov. dan Adopsi Teknol.*, vol. 2, no. 1, pp. 32–40, 2022, doi: 10.35969/inotek.v2i1.207.
- [21] C. Dabakoglu, "Artificial Neural Network with Keras," *Medium*, 2018, [Online]. Available: <https://medium.com/@cdabakoglu/artificial-neural-network-with-keras-d858f82f90c5> (diakses: Juni 2024).