

## Deteksi Dini Cacar Monyet menggunakan Convolutional Neural Network (CNN) dalam Aplikasi Mobile

Rifqi Triginandri<sup>1,\*</sup>, Egia Rosi Subhiyakto<sup>1,2</sup>

<sup>1</sup> Program Studi Teknik Informatika, Universitas Dian Nuswantoro, Indonesia

<sup>2</sup> Research Center for Intelligent Distributed Surveillance and Security (IDSS), Universitas Dian Nuswantoro, Indonesia

\* Correspondence: 111202113267@mhs.dinus.ac.id

**Copyright:** © 2024 by the authors

Received: 1 Oktober 2024 | Revised: 4 Oktober 2024 | Accepted: 29 Oktober 2024 | Published: 19 Desember 2024

### Abstrak

Cacar Monyet adalah infeksi kulit yang menjadi perhatian serius di Indonesia sejak meningkatnya kasus pada 2022. Diagnosis cacar monyet memerlukan keahlian khusus, tes laboratorium, dan observasi klinis. Diagnosis umumnya menggunakan tes PCR sering tidak tersedia di daerah terpencil. Penelitian ini bertujuan mengembangkan aplikasi mobile berbasis deep learning untuk deteksi dini cacar monyet melalui klasifikasi gambar lesi kulit. Metodologi CRISP-DM diterapkan dalam pengembangan aplikasi ini, dimulai dengan pengumpulan dataset dari situs Kaggle yang terdiri dari 8.910 gambar dan dibagi menjadi kelompok training 80%, validation 10%, dan testing 10% dengan teknik augmentasi untuk meningkatkan akurasi model. Model CNN yang dikembangkan diimplementasikan menggunakan Create ML pada platform iOS. Evaluasi model menggunakan beberapa matrik seperti akurasi, *precision*, *recall*, dan *F1 score*, dengan *threshold* yang digunakan adalah probabilitas tertinggi dari prediksi model. Hasil evaluasi model menunjukkan akurasi sebesar 81%, *precision* 80,2%, *recall* 76%, dan *F1 score* 0,78 untuk data uji. Aplikasi yang dihasilkan memungkinkan deteksi cacar monyet secara cepat dan dapat diakses oleh masyarakat luas, sehingga dapat membantu mengurangi keterlambatan diagnosis, terutama di wilayah yang sulit dijangkau. Penelitian ini menunjukkan potensi signifikan dalam mendukung sistem kesehatan di Indonesia melalui penerapan teknologi kecerdasan buatan untuk penyakit menular.

**Kata kunci:** aplikasi kesehatan; cacar monyet; *deep learning*; deteksi dini; klasifikasi gambar

### Abstract

Monkeypox is a skin infection that has become a serious concern in Indonesia since the increase in cases in 2022. Diagnosis of monkeypox requires special expertise, laboratory tests, and clinical observations. Diagnosis generally uses PCR tests which are often not available in remote areas. This study aims to develop a deep learning-based mobile application for early detection of monkeypox through image classification of skin lesions. The CRISP-DM methodology is applied in developing this application, starting with collecting datasets from the Kaggle site consisting of 8,910 images and divided into 80% training groups, 10% validation, and 10% testing with augmentation techniques to improve model accuracy. The developed CNN model was implemented using Create ML on the iOS platform. The model evaluation uses several metrics such as accuracy, precision, recall, and F1 score, with the threshold being the highest probability of the model predicting model evaluation results show an accuracy of 81%, precision of 80.2%, recall of 76%, and F1 score of 0.78 for the test data. The resulting application allows rapid detection of monkeypox and is accessible to the wider community, thereby helping to reduce delays in diagnosis, especially in hard-to-reach areas. This study shows significant potential in supporting the health system in Indonesia through the application of artificial intelligence technology for infectious diseases.



**Keywords:** *health app; monkey pox; deep learning; early detection; image classification*

## PENDAHULUAN

Kasus cacar monyet di Indonesia mengalami peningkatan yang signifikan sejak tahun 2022 (Sari & Hairunisa, 2022). Cacar monyet adalah penyakit *zoonosis* (Khan et al., 2023) yang ditandai dengan lesi kulit yang sulit dibedakan dari infeksi lainnya seperti cacar air (Ozsahin et al., 2023) dan campak (Ariansyah et al., 2023). Berdasarkan data dari laman [infeksiemerging.kemkes.go.id](https://infeksiemerging.kemkes.go.id) tercatat 88 kasus konfirmasi cacar monyet antara tahun 2022 hingga 2024 (Caloh, 2024). Di tingkat global, WHO pada 14 Agustus 2024 kembali menetapkan cacar monyet sebagai *Public Health Emergency of International Concern* (PHEIC) (Parums, 2024), menyusul lonjakan kasus di Afrika dan munculnya varian baru virus Mpox (clade Ib) (Asakura et al., 2024).

Keterbatasan akses terhadap tes laboratorium berbasis PCR untuk mendeteksi cacar monyet di wilayah terpencil menyebabkan keterlambatan diagnosis, sehingga meningkatkan risiko penyebaran penyakit (Altindis et al., 2022). Hal ini memerlukan solusi alternatif yang dapat mendukung proses deteksi dini cacar monyet tanpa harus bergantung sepenuhnya pada fasilitas kesehatan modern, yang tidak selalu tersedia di daerah terpencil.

Menghadapi permasalahan deteksi dini cacar monyet, perlu menerapkan pendekatan *Convolutional Neural Network* (CNN) dalam menganalisis citra medis terbukti efektif di berbagai bidang (Liu et al., 2023), termasuk mendeteksi lesi kulit yang menjadi gejala awal cacar monyet (Salehin et al., 2023). CNN memiliki kemampuan untuk menganalisis citra medis dengan akurasi tinggi (Salehi et al., 2023). Kolla et al. (2022) mengemukakan bahwa CNN dapat digunakan untuk mendeteksi pola kompleks dalam gambar, dan Muñoz-Saavedra et al. (2023) mendukung kemampuan CNN dalam mendeteksi lesi kulit terkait cacar monyet.

Penelitian sebelumnya yang dilakukan oleh Eliwa et al. (2023) dan Altun et al. (2023) menunjukkan efektivitas CNN dalam deteksi lesi kulit terkait cacar monyet. Namun, penelitian sebelumnya berfokus pada pengembangan model tanpa mempertimbangkan aspek implementasi praktisnya dan faktor lain seperti keterbatasan akses internet (Putra et al., 2023), kapasitas komputasi perangkat mobile (Luo et al., 2020), serta aksesibilitas aplikasi oleh tenaga medis di daerah terpencil (Yaacoub et al., 2020). Selain itu, Alrusaini (2023) juga mencatat bahwa meskipun model CNN dapat mencapai akurasi tinggi dalam mendeteksi lesi cacar monyet, penggunaannya dalam aplikasi *mobile* yang mudah diakses masyarakat luas masih terbatas. Penelitian ini mengatasi keterbatasan tersebut dengan membangun aplikasi *mobile* yang dapat diakses tanpa koneksi internet dan bekerja optimal di perangkat *mobile*, sehingga mudah digunakan masyarakat luas dan tenaga medis di daerah dengan infrastruktur terbatas.

Hasil temuan dari beberapa penelitian sebelumnya, terletak pada kurangnya perhatian terhadap integrasi model CNN ke dalam aplikasi *mobile* yang siap digunakan dalam kondisi di lapangan. Sebagian besar penelitian berfokus pada pengembangan dan pengujian model dalam lingkungan terkontrol, tanpa memperhatikan bagaimana model tersebut dapat diimplementasikan secara praktis dalam aplikasi *mobile*. Terutama, belum ada penelitian yang membahas secara mendalam bagaimana model ini dapat bekerja secara *offline* dan diakses oleh masyarakat di wilayah dengan keterbatasan infrastruktur teknologi dan kesehatan. Penelitian ini bertujuan untuk menyempurnakan temuan sebelumnya dengan mengintegrasikan model CNN ke dalam aplikasi *mobile* yang tidak hanya memiliki akurasi tinggi, tetapi juga dapat beroperasi tanpa koneksi internet, mendukung kinerja optimal di perangkat *mobile*, dan mudah diakses oleh pengguna di daerah terpencil.

Penelitian ini bertujuan untuk mengembangkan aplikasi *mobile* berbasis CNN yang dapat mendeteksi cacar monyet melalui gambar lesi kulit secara *offline* dan mudah digunakan oleh masyarakat maupun tenaga medis di wilayah terpencil. Aplikasi ini diharapkan dapat mempercepat proses deteksi dini dan meningkatkan kesadaran masyarakat terhadap bahaya

cacar monyet, serta memperkuat kapasitas layanan kesehatan dalam menangani penyakit ini, terutama di Indonesia.

## METODE

Penelitian ini menggunakan metodologi CRISP-DM untuk mengembangkan model deep learning dan aplikasi dalam klasifikasi cacar monyet. CRISP-DM dipilih karena kerangka ini menawarkan pendekatan terstruktur dan fleksibel, yang dapat disesuaikan di setiap tahap proyek. Metodologi ini terdiri dari enam fase utama: *business understanding*, *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *deployment*.

Pada fase *business understanding*, tujuan utama aplikasi ini adalah untuk memfasilitasi diagnosis cacar monyet menggunakan *deep learning*. Fase ini juga mencakup identifikasi kebutuhan medis dan pengembangan aplikasi yang dapat memudahkan diagnosis awal cacar monyet oleh masyarakat dan tenaga medis. Selain itu, juga dilakukan analisis terhadap tujuan dan dampak yang dihasilkan dengan pembangunan aplikasi ini. Pada tahap *data understanding*, gambar lesi kulit cacar monyet dikumpulkan dari dataset *open-source* yang relevan. Gambar pada dataset kemudian dianalisis untuk memastikan kualitas dan resolusi yang sesuai untuk *deep learning*. Dataset terdiri dari 8.910 gambar lesi kulit dengan resolusi minimal 224x224 piksel, yang diklasifikasikan ke dalam lima kategori berdasarkan kemiripan visual seperti bentuk dan ukuran lesi kulit.

Fase *data preparation* mencakup pemrosesan dan persiapan data sebelum digunakan dalam pelatihan model. Data dipecah menjadi kelompok *training* 80%, *validation* 10%, dan *testing* 10% untuk memastikan evaluasi model dilakukan dengan seimbang. Teknik augmentasi gambar diterapkan untuk meningkatkan variasi data dan akurasi model, memastikan gambar diproses dengan baik untuk pelatihan model *deep learning*. Pada fase *modeling*, Create ML digunakan untuk membangun dan melatih model klasifikasi berdasarkan dataset gambar lesi kulit. Create ML menawarkan antarmuka sederhana yang memudahkan pengembang melatih model *machine learning*. Model ini menggunakan arsitektur CNN yang diatur otomatis oleh Create ML, menyederhanakan proses konfigurasi lapisan konvolusi, pooling, dan fungsi aktivasi, sehingga pengembang dapat fokus pada pelatihan model.

Evaluasi model dilakukan pada fase *evaluation* menggunakan *confusion matrix* serta metrik lain seperti akurasi, *precision*, *recall*, dan *F1 score*. *Confusion matrix* memberikan pemahaman yang mendalam tentang performa model dalam membedakan berbagai kelas, mencakup elemen *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*. Selain itu, akurasi, *precision*, *recall*, dan *F1 score* dihitung untuk memberikan gambaran menyeluruh tentang performa model. Evaluasi dilakukan pada data *validation* dan *testing*, dengan hasil yang menunjukkan performa yang andal dalam klasifikasi cacar monyet.

$$\text{Akurasi} = \frac{\text{Jumlah pengujian sukses}}{\text{Jumlah pengujian}} \times 100 \quad (1)$$


Pada fase *deployment*, model yang telah dilatih diintegrasikan ke dalam aplikasi mobile berbasis iOS. Metode *Rapid Application Development (RAD)* diterapkan untuk mempercepat integrasi dan iterasi pengujian aplikasi. Dalam fase ini, RAD memungkinkan pengembang melakukan pengujian secara terus-menerus selama proses integrasi sehingga mempercepat deteksi bug dan optimalisasi fitur sesuai dengan kebutuhan pengguna. Tahapan RAD meliputi *requirements planning* di mana kebutuhan dikumpulkan dengan cepat, *user design* yang fokus pada pengembangan prototipe interaktif, *construction* yang mencakup pengembangan iteratif serta *cutover* di mana implementasi akhir dan pengujian manual akan dilakukan menggunakan 10 sampel gambar untuk menguji akurasi aplikasi secara langsung yang akan dihitung menggunakan persamaan (1). Aplikasi ini dirancang untuk memberikan solusi praktis bagi

tenaga medis dan masyarakat umum di Indonesia dengan fokus pada peningkatan deteksi dini cacar monyet terutama di daerah yang sulit dijangkau.

## HASIL DAN PEMBAHASAN

### Hasil

Penelitian ini melibatkan pengembangan model dan aplikasi sesuai dengan metodologi CRISP-DM dan RAD yang telah direncanakan. Tahapan awal dimulai dengan identifikasi kebutuhan melalui fase *business understanding*, tujuan utama proyek ini adalah mengembangkan aplikasi mobile yang membantu deteksi dini infeksi cacar monyet, mendorong individu untuk segera memeriksakan diri ke fasilitas kesehatan. Aplikasi ini tidak hanya meningkatkan kesadaran akan gejala awal, tetapi juga mendukung tenaga medis dalam mempercepat diagnosis. Analisis kebutuhan dilakukan dengan mengidentifikasi permasalahan utama yang dihadapi masyarakat, terutama di daerah dengan akses terbatas terhadap tenaga medis. Kebutuhan masyarakat akan alat deteksi cepat dan akurat menjadi sangat mendesak, mengingat keterbatasan sumber daya di beberapa wilayah. Selain itu, aplikasi ini dirancang untuk memberikan informasi tentang lesi kulit berdasarkan probabilitas deteksi, yang berguna bagi masyarakat dalam mengenali gejala secara mandiri sebelum mendapat penanganan medis.



**Gambar 1.** Penamaan dan pengorganisasian dataset

Pada fase kedua, yaitu *data understanding*, dataset gambar lesi kulit diperoleh dari situs Kaggle yang tersedia di <https://www.kaggle.com/datasets/ahmedxc4/skin-ds> awalnya berisi 14 jenis kategori lesi kulit, namun dalam penelitian ini hanya digunakan lima kategori yang relevan berdasarkan kemiripan pada visualnya yaitu *Monkeypox*, *Cowpox*, *Chickenpox*, *Measles*, dan *Healthy* sebagai referensi untuk membantu model mendeteksi perbedaan antara kulit yang sehat. Dari 5 kategori tersebut memiliki total 8.910 gambar. Gambar 1 menunjukkan bagaimana dataset diberi nama dan diatur secara sistematis untuk proses pelatihan model. Dataset dibagi menjadi 7.128 gambar untuk *training*, 890 gambar untuk *validation*, dan 892 gambar untuk *testing*. Kategori *Monkeypox* atau cacar monyet yang dapat mempengaruhi hasil klasifikasi karena ketidakseimbangan data, karena model mungkin lebih cenderung mendeteksi kategori yang lebih sering muncul. Untuk mengatasi potensi bias ini, dilakukan augmentasi data untuk memastikan model dapat mengklasifikasikan semua kategori secara adil.

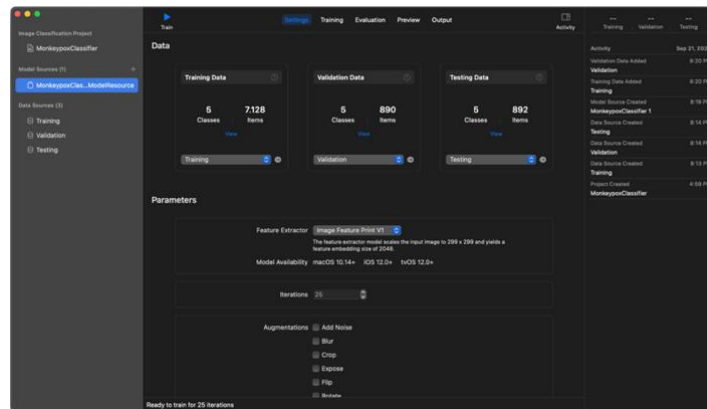
Tahapan selanjutnya, fase *data preparation* dataset disiapkan untuk pelatihan model. Pembagian dataset dilakukan dengan mempertimbangkan distribusi seimbang antara data pelatihan, validasi, dan pengujian. Tujuannya adalah memastikan representasi yang cukup pada setiap fase pelatihan dan evaluasi model, untuk menghindari *overfitting*. Dataset yang lebih besar, terutama pada bagian training, memberikan kesempatan lebih besar bagi model untuk belajar dan meningkatkan akurasi. Format gambar yang digunakan adalah JPEG, yang umum digunakan dalam pelatihan model *machine learning*. Proses augmentasi gambar diterapkan untuk menambah variasi dataset sehingga memperkuat generalisasi model.




**Gambar 2.** Model klasifikasi gambar create ml

Selanjutnya, pada fase *modeling*, model klasifikasi gambar untuk deteksi lesi kulit dikembangkan menggunakan *framework* Create ML. Gambar 2 menunjukkan bagaimana model klasifikasi gambar dihasilkan menggunakan Create ML. Proses pemodelan dimulai dengan menjalankan CreateML melalui Xcode, di mana sebuah proyek baru dibuat dengan memilih tipe model *Image Classification* selanjutnya mengisi informasi yang diperlukan.

Antarmuka Create ML yang mudah digunakan memungkinkan manajemen dataset yang lancar, dengan alur kerja yang jelas untuk melatih model. Data input dibagi menjadi tiga kategori. Pertama, kategori *Training* digunakan untuk melatih model. Kedua, kategori *Validation* digunakan untuk memverifikasi kemajuan model selama pelatihan. Terakhir, kategori *Testing* merupakan kumpulan data yang terpisah dan digunakan untuk mengevaluasi kinerja model setelah pelatihan. Dataset diimpor ke Create ML sesuai dengan kategorinya dan opsi konfigurasi tambahan untuk meningkatkan akurasi model seperti pada gambar 3.



**Gambar 3.** Konfigurasi data input dan proses pelatihan model



**Gambar 4.** Hasil pelatihan model

Pelatihan model dapat dimulai ketika dataset telah dimasukan dan dikonfigurasi. Proses pembelajaran model berlangsung secara iteratif, setiap iterasi model belajar dari karakteristik set data pelatihan dan memverifikasi akurasi dengan set data validasi. Gambar 4 menunjukkan dimana pelatihan telah selesai dan *Create ML* menampilkan perkembangan model dalam bentuk grafik, dimana garis hitam menunjukkan akurasi model pada data pelatihan sebesar 84,7% yang dibulatkan menjadi 85% oleh *Create ML* pada bagian *activity* agar lebih sederhana dan tidak mempengaruhi interpretasi hasil secara keseluruhan, sementara garis abu-abu menggambarkan akurasi pada data validasi sebesar 81%. Grafik ini menggambarkan stabilitas pelatihan, namun terlihat adanya sedikit penurunan akurasi pada data validasi dibandingkan dengan data pelatihan, yang menunjukkan potensi *overfitting*.

Fase evaluasi dari model klasifikasi gambar untuk deteksi lesi kulit cacar monyet dilakukan menggunakan perhitungan berbasis *Confusion Matrix*. Ketika pelatihan selesai *Create ML* secara otomatis menghitung dan menampilkan metrik evaluasi seperti *precision*, *recall*, dan *F1 score* untuk setiap dataset. Gambar 5 kiri menunjukkan hasil evaluasi pada data *training* dengan performa rata-rata *precision* sebesar 83,6%, *recall* sebesar 81,4%, dan *F1 score* sebesar 0,83. Evaluasi ini menunjukkan bahwa model mampu melakukan klasifikasi

yang cukup akurat pada data yang telah dilatihnya. Namun, hasil tinggi tidak menjamin performa serupa pada data baru, karena model bisa mengalami *overfitting*, dimana model terlalu menghafal data training dan kurang mampu menggeneralisasi pada data baru.

Pada Gambar 5 kanan, hasil evaluasi pada data *validation* menunjukkan penurunan performa dengan *precision* rata-rata turun menjadi 79%, *recall* menjadi 76,8%, dan *F1 score* menjadi 0,78. Penurunan ini mengindikasikan adanya potensi *overfitting*, di mana model lebih akurat pada data pelatihan tetapi kurang mampu mengenali pola pada data baru. Penyebab utama penurunan ini mungkin karena kompleksitas model atau kurangnya keragaman dalam dataset pelatihan, sehingga model kesulitan dalam menggeneralisasi. Untuk mengatasi masalah ini peningkatan kualitas dataset dengan menambahkan lebih banyak variasi gambar lesi kulit atau melakukan augmentasi data dapat dilakukan. Serta pengoptimalan model seperti *fine-tuning* pada *hyperparameter* dapat membantu meningkatkan kemampuan generalisasi model.

Training					
Class	Count	Precision	Recall	F1 Score	
Monkeypox	3408	86%	86%	89%	0,87
Measles	660	83%	80%	80%	0,82
Healthy	1368	86%	86%	86%	0,87
Cowpox	792	87%	86%	86%	0,87
Chickenpox	900	76%	64%	64%	0,7

Validation					
Class	Count	Precision	Recall	F1 Score	
Monkeypox	426	84%	84%	86%	0,85
Measles	82	70%	74%	74%	0,72
Healthy	171	80%	80%	86%	0,83
Cowpox	99	84%	74%	74%	0,78
Chickenpox	112	77%	64%	64%	0,7

Gambar 5. Hasil evaluasi data training dan data validation

Testing (From Initial Setup)							
Class	Count	Correct	False Positives	False Negatives	Precision	Recall	F1 Score
Monkeypox	426	372	74	54	83%	87%	0,85
Healthy	171	145	44	26	77%	85%	0,81
Chickenpox	113	82	15	31	85%	73%	0,78
Cowpox	99	76	23	23	77%	77%	0,77
Measles	83	48	13	35	79%	58%	0,67

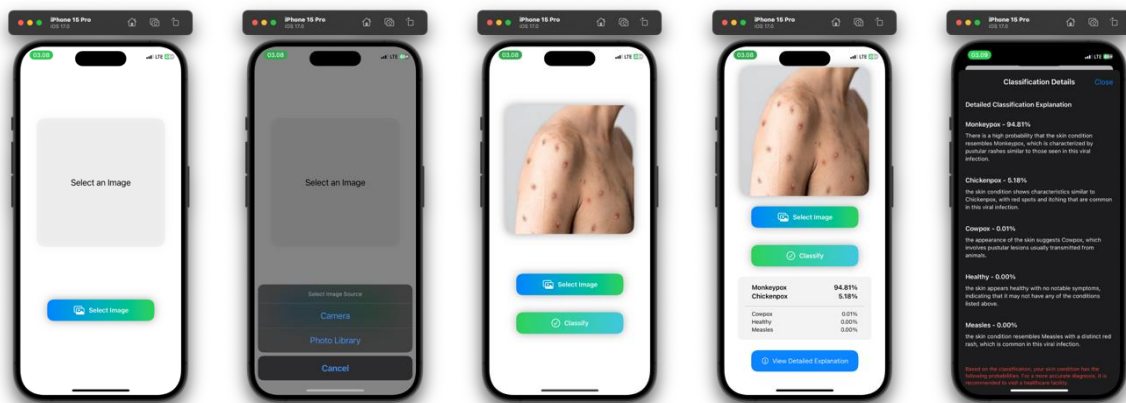
Gambar 6. Hasil evaluasi data testing

Gambar 6 menunjukkan hasil evaluasi model pada data *testing* dengan *precision* 80,2%, *recall* 76%, dan *F1 score* 0,78. *Precision* yang tinggi menandakan model mampu menghasilkan prediksi yang lebih relevan, namun *recall* yang lebih rendah menunjukkan model masih melewatkan beberapa kasus positif. *Test accuracy* tercatat sebesar 81%, dengan 723 prediksi benar dan 169 salah, yang menunjukkan stabilitas dalam menangani data baru. Kebingungan utama terjadi pada kategori *chickenpox* atau cacar air yang sering diklasifikasikan sebagai cacar monyet, kemungkinan karena kemiripan visualnya. Kategori cacar monyet memiliki *precision* dan *recall* terendah, menunjukkan model masih memiliki kesulitan dalam mendeteksi kategori ini secara akurat. Dengan demikian, performa *testing* tetap menunjukkan stabilitas, meskipun perbaikan diperlukan untuk meningkatkan akurasi lebih lanjut. Langkah seperti peningkatan kualitas dataset, augmentasi data, serta penyesuaian *hyperparameter* dapat dilakukan untuk meningkatkan akurasi model secara keseluruhan dan mengurangi risiko *overfitting*, sehingga model dapat bekerja lebih baik pada data yang belum pernah dilihat. Selanjutnya model dapat disimpan ke *file system* dalam format “.mlmodel” yang dapat dilakukan pada tab *output*. Pendekatan sistematis dalam pengembangan model ini bertujuan untuk menghasilkan alat yang akurat untuk deteksi dini lesi kulit, sehingga dapat mendukung diagnosa medis secara efektif.

Fase selanjutnya adalah *development*, metode RAD diterapkan melalui tahapan penting yang diintegrasikan ke dalam proses CRISP-DM. Fase ini dimulai dengan tahap *requirements*

*planning*, di mana kebutuhan utama aplikasi diidentifikasi, seperti kemampuan untuk memprediksi gambar lesi kulit dan integrasi model ke dalam aplikasi mobile menggunakan *framework* CoreML dan Vision. Proses ini memastikan bahwa fitur penting seperti pengambilan gambar dengan kamera atau pengunggahan dari galeri, serta klasifikasi otomatis, sudah tercakup dalam perencanaan.

Pada tahap *user design*, rancangan antarmuka pengguna difinalisasi berdasarkan kebutuhan yang diidentifikasi. Aplikasi ini dirancang dengan langkah-langkah sederhana, seperti yang ditunjukkan pada gambar 7, dimana pengguna dapat mengambil gambar menggunakan kamera atau mengimpor dari galeri foto untuk dianalisis. Setelah gambar dipilih, pengguna menekan tombol *Classify* untuk memproses gambar, dan hasil prediksi beserta persentase kepercayaan akan ditampilkan. Aplikasi ini juga menampilkan detail dari hasil klasifikasi gambar yang telah dilakukan.



**Gambar 7.** Antarmuka aplikasi deteksi cacar monyet

Tahap selanjutnya, *construction* dalam RAD berfokus pada pengembangan aplikasi secara iteratif menggunakan Xcode dan bahasa pemrograman Swift, di mana *framework* CoreML digunakan untuk mengintegrasikan model. Pada fase ini, proses *debugging* dan *testing* dilakukan untuk memastikan aplikasi dapat mengolah gambar dan memberikan hasil prediksi yang akurat. Tim pengembang juga memanfaatkan AVFoundation dan PhotoKit untuk menangani pengambilan dan penyimpanan gambar secara efisien. Pembangunan model yang terintegrasi dilakukan dalam beberapa iterasi untuk meningkatkan keakuratan dan performa.

**Tabel 1.** Hasil pengujian aplikasi

Gambar Uji	Output	Probabilitas	Kesimpulan
Monkeypox1	<i>Monkeypox</i>	84.89 %	Sukses
Monkeypox2	<i>Monkeypox</i>	99.99 %	Sukses
Measles1	<i>Measles</i>	97.53 %	Sukses
Measles2	<i>Measles</i>	89.08 %	Sukses
Healthy1	<i>Healthy</i>	99.99 %	Sukses
Healthy2	<i>Healthy</i>	99.68 %	Sukses
Cowpox1	<i>Cowpox</i>	99.83 %	Sukses
Cowpox2	<i>Cowpox</i>	99.99 %	Sukses
Chickenpox1	<i>Chickenpox</i>	63.50 %	Sukses
Chickenpox2	<i>Chickenpox</i>	52.84 %	Sukses

Selanjutnya tahap *cutover*, aplikasi memasuki fase pengujian akhir. Pengujian dilakukan dengan menggunakan 10 sampel gambar dari berbagai kategori, sebagaimana disajikan dalam

Tabel 1. Pengujian dikatakan sukses jika memperoleh probabilitas tertinggi sesuai dengan kategori gambar yang digunakan yang telah disiapkan dan diberi label. Berdasarkan hasil penghitungan akurasi dari pengujian manual menunjukkan aplikasi mencapai akurasi 100%. Ini menunjukkan bahwa model dapat secara efektif mendeteksi lesi kulit dengan tingkat keyakinan yang sangat tinggi. Namun, terdapat kasus di mana kategori *chickenpox* memiliki probabilitas yang lebih rendah, hanya 63.50% dan 52.84%. Hal ini dapat disebabkan oleh kemiripan visual *chickenpox* dengan kategori lain, yang mungkin membingungkan model dalam melakukan klasifikasi. Ketidakseimbangan jumlah gambar untuk kategori tertentu juga dapat menyebabkan model lebih cenderung mendeteksi kategori yang dominan dalam dataset.

Secara keseluruhan, model deteksi lesi kulit dalam aplikasi mobile ini menunjukkan performa yang sangat baik dengan tingkat akurasi yang tinggi, terutama pada kategori cacar monyet dan beberapa kategori lain. Namun, penurunan akurasi pada kategori *chickenpox* mengindikasikan tantangan dalam membedakan lesi yang memiliki kemiripan visual, serta potensi ketidakseimbangan data. Meski demikian, aplikasi ini memiliki potensi besar untuk membantu masyarakat dan tenaga medis dalam melakukan deteksi dini cacar monyet, khususnya di daerah dengan akses terbatas ke layanan kesehatan.

## Pembahasan

Penelitian ini berhasil mengembangkan aplikasi mobile berbasis *deep learning* untuk mendeteksi cacar monyet melalui klasifikasi gambar lesi kulit, dengan metodologi CRISP-DM diterapkan secara sistematis. Pada fase *business understanding*, fokusnya adalah mengembangkan aplikasi yang dapat membantu masyarakat melakukan deteksi dini infeksi cacar monyet, terutama di wilayah dengan akses tenaga medis terbatas. Fase *data understanding* dan *data preparation* melibatkan pengolahan dataset lesi kulit dengan distribusi data yang seimbang antara *training*, *validation*, dan *testing* untuk mengurangi bias. Pada fase *modeling*, model *deep learning* dikembangkan menggunakan Create ML dan diintegrasikan ke dalam aplikasi iOS, memungkinkan klasifikasi gambar otomatis melalui perangkat *mobile*.

Penurunan performa pada data *validation* dan *testing*, dengan F1 score turun dari 0,83 pada data *training* menjadi 0,78 pada data *validation* dan *testing*, menunjukkan adanya potensi overfitting, di mana model terlalu fokus pada pola di data *training* dan tidak mampu menggeneralisasi dengan baik pada data baru. Untuk mengatasi masalah ini, teknik seperti *regularization*, *dropout*, dan *cross-validation* dapat diterapkan, serta augmentasi data untuk meningkatkan variasi dataset. Kualitas dan variasi dataset juga berperan penting dalam performa model (Susanti et al., 2024), di mana dataset yang digunakan masih mengalami ketidakseimbangan jumlah gambar antar kategori, khususnya cacar monyet yang memiliki lebih banyak gambar, mempengaruhi kemampuan model dalam mendeteksi kategori dengan jumlah data yang lebih sedikit. Penelitian ini juga menunjukkan bahwa model *deep learning* yang dikembangkan menggunakan Create ML mencapai akurasi 81% pada data *testing* dengan rata-rata *F1-score* 0,78. Pengujian manual terhadap aplikasi menunjukkan hasil akurasi yang sangat baik yaitu 100%. Meskipun terdapat kasus di mana kategori *chickenpox* menunjukkan probabilitas deteksi yang rendah. Hal ini disebabkan oleh kemiripan visual dengan kategori lain yang dapat membingungkan model dalam klasifikasi dan ketidakseimbangan jumlah gambar dalam kategori tertentu membuat model cenderung mendeteksi kategori yang dominan.

Temuan sebelumnya yang dilakukan oleh Eliwa et al. (2023) menunjukkan bahwa penggunaan CNN yang dioptimalkan dengan *Grey Wolf Optimizer* (GWO) menghasilkan akurasi mencapai 95,3% dalam klasifikasi lesi kulit cacar monyet. Penelitian ini menekankan pentingnya pengembangan model yang efisien untuk meningkatkan diagnosis penyakit yang sulit dilakukan secara visual. Sementara itu, Altun et al. (2023) juga menggunakan metode CNN dengan pendekatan *transfer learning*, yang menghasilkan akurasi hingga 96% dan *F1-score* rata-rata 0,98, menunjukkan efektivitas tinggi dalam mendeteksi cacar monyet di konteks



pandemi. Perbandingan hasil penelitian ini dengan penelitian sebelumnya menunjukkan adanya kesenjangan dalam performa model. Perbedaan ini kemungkinan besar dipengaruhi oleh faktor seperti kompleksitas dan kualitas dataset, serta metode pengoptimalan yang diterapkan. Meskipun begitu, kelebihan penelitian ini terletak pada integrasi model dalam aplikasi mobile yang menjadikan solusi praktis untuk deteksi cacar monyet. Namun, perbaikan performa model masih diperlukan untuk meningkatkan akurasi, dengan upaya lebih lanjut dalam memperkaya dataset dan menerapkan teknik optimasi tambahan.

Penelitian kami ini berhasil mengembangkan aplikasi *mobile* berbasis *deep learning* yang mampu mendeteksi cacar monyet secara otomatis melalui gambar lesi kulit. Aplikasi ini dirancang untuk berfungsi secara *real-time* dan dapat digunakan oleh masyarakat umum maupun tenaga medis, khususnya di wilayah dengan akses kesehatan terbatas. Berbeda dengan penelitian sebelumnya oleh Eliwa et al. (2023) dan Altun et al. (2023), yang lebih berfokus pada pengembangan model untuk klasifikasi cacar monyet, penelitian ini menonjol dengan inovasi pada penerapan model dalam aplikasi iOS yang siap digunakan di lapangan. Meskipun akurasi model dalam penelitian ini belum sebanding dengan studi sebelumnya oleh Eliwa et al. (2023) dan Altun et al. (2023), keunggulan penelitian ini terletak pada integrasi model dalam bentuk aplikasi *mobile* dan kemampuan aplikasi untuk digunakan secara *offline* serta memberikan deteksi otomatis yang dapat diandalkan dalam kondisi lapangan. Uji klinis dan pengembangan fitur seperti pemantauan lesi berkelanjutan akan lebih meningkatkan akurasi dan kegunaan aplikasi di masa mendatang.

## SIMPULAN

Penelitian ini berhasil mengembangkan aplikasi mobile berbasis CNN yang mampu mendeteksi cacar monyet melalui gambar lesi kulit dengan akurasi yang memadai. Model yang dihasilkan menunjukkan performa yang baik dalam pengklasifikasian lesi kulit, meskipun terdapat tantangan seperti potensi *overfitting* dan ketidakmampuan model untuk sepenuhnya membedakan kategori yang memiliki kemiripan visual. Aplikasi ini dirancang agar mudah digunakan oleh masyarakat di wilayah terpencil dengan kemampuan beroperasi secara *offline*, sehingga dapat membantu deteksi dini cacar monyet. Implikasi dari penelitian ini adalah penyediaan alat bantu diagnostik yang praktis dan mudah diakses untuk mempercepat penanganan kasus cacar monyet, terutama di daerah dengan keterbatasan akses terhadap fasilitas kesehatan. Dengan deteksi dini, masyarakat dapat segera mencari penanganan medis yang tepat, sehingga berpotensi menurunkan penyebaran penyakit di Indonesia.

## REFERENSI

- Alrusaini, O. A. (2023). Deep Learning Models for the Detection of Monkeypox Skin Lesion on Digital Skin Images. (*IJACSA*) *International Journal of Advanced Computer Science and Applications*, 14, 637-644. <https://doi.org/10.14569/ijacsa.2023.0140170>
- Altindis, M., Puca, E., & Shapo, L. (2022). Diagnosis of monkeypox virus—An overview. *Travel medicine and infectious disease*, 50, 102459. <https://doi.org/10.1016/j.tmaid.2022.102459>
- Altun, M., Gürüler, H., Özkaraca, O., Khan, F., Khan, J., & Lee, Y. (2023). Monkeypox Detection Using CNN with Transfer Learning. *Sensors*, 23(4). <https://doi.org/10.3390/s23041783>
- Ariansyah, M. H., Winarno, S., & Sani, R. R. (2023). Monkeypox and measles detection using CNN with VGG-16 Transfer Learning. *Journal of Computing Research and Innovation*, 8(1), 32–44. <https://doi.org/10.24191/jcrinn.v8i1.340>
- Asakura, T. R., Jung, S. M., Jin, S., Hu, G., Endo, A., & Dickens, B. L. (2024). Characterising global risk profiles of Mpox clade Ib importation. *Journal of Travel Medicine*, taae136. <https://doi.org/10.1093/jtm/taae136>

- Eliwa, E. H. I., El Koshiry, A. M., Abd El-Hafeez, T., & Farghaly, H. M. (2023). Utilizing convolutional neural networks to classify monkeypox skin lesions. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-41545-z>
- Caloh, G. B. A. (2024). *Update Mpox Minggu ke 38 dan ke 39 2024 (15 - 28 September 2024)*. Infeksi Emerging Kementerian Kesehatan Republik Indonesia. <https://infeksiemerging.kemkes.go.id/situasi-mpox/update-mpox-minggu-ke-38-dan-ke-39-2024-15-28-september-2024>
- Khan, S. A., Parajuli, S. B., & Rauniyar, V. K. (2023). Neurological manifestations of an emerging zoonosis—Human monkeypox virus: A systematic review. *Medicine*, 102(35), e34664. <https://doi.org/10.1097/MD.00000000000034664>
- Kolla, M., Mishra, R. K., Zahoor Ul Huq, S., Vijayalata, Y., Gopalachari, M. V., & Siddiquee, K. E. A. (2022). CNN-Based Brain Tumor Detection Model Using Local Binary Pattern and Multilayered SVM Classifier. *Computational Intelligence and Neuroscience*, 2022. <https://doi.org/10.1155/2022/9015778>
- Liu, J., Sun, H., & Katto, J. (2023). Learned image compression with mixed transformer-cnn architectures. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 14388-14397). <https://doi.org/10.1109/CVPR52729.2023.01383>
- Luo, C., He, X., Zhan, J., Wang, L., Gao, W., & Dai, J. (2020). Comparison and Benchmarking of AI Models and Frameworks on Mobile Devices. *ArXiv Preprint ArXiv*. <https://doi.org/10.48550/arXiv.2005.05085>
- Muñoz-Saavedra, L., Escobar-Linero, E., Civit-Masot, J., Luna-Perejón, F., Civit, A., & Domínguez-Morales, M. (2023). A Robust Ensemble of Convolutional Neural Networks for the Detection of Monkeypox Disease from Skin Images. *Sensors*, 23(16). <https://doi.org/10.3390/s23167134>
- Parums, D. V. (2024). Reasons for Increasing Global Concerns for the Spread of Mpox. *Medical Science Monitor: International Medical Journal of Experimental and Clinical Research*, 30, e946343-1. <https://doi.org/10.12659/MSM.946343>
- Putra, O. V., Mustaqim, M. Z., & Muriatmoko, D. (2023). Transfer Learning untuk Klasifikasi Penyakit dan Hama Padi Menggunakan MobileNetV2. *Techno.COM*, 22(3), 562–575. <https://doi.org/10.33633/tc.v22i3.8516>
- Salehi, A. W., Khan, S., Gupta, G., Alabduallah, B. I., Almjally, A., Alsolai, H., ... & Mellit, A. (2023). A study of CNN and transfer learning in medical imaging: Advantages, challenges, future scope. *Sustainability*, 15(7), 5930.
- Salehin, I., Islam, M. S., Amin, N., Baten, M. A., Noman, S. M., Saifuzzaman, M., & Yazmyradov, S. (2023). Real-Time Medical Image Classification with ML Framework and Dedicated CNN-LSTM Architecture. *Journal of Sensors*, 2023. <https://doi.org/10.1155/2023/3717035>
- Sari, M., & Hairunisa, N. (2022). A Review of The Monkeypox Outbreak In Indonesia In 2022. *Diponegoro Medical Journal (Jurnal Kedokteran Diponegoro)*, 11(5), 268–274. <https://doi.org/10.14710/dmj.v11i5.35895>
- Susanti, I. D., Winarno, S., & Zeniarja, J. (2024). Yogyakarta Batik Image Classification Based on Convolutional Neural Network. *Advance Sustainable Science, Engineering and Technology*, 6(1). <https://doi.org/10.26877/asset.v6i1.18002>
- Ozsahin, D.U., Mustapha, M. T., Uzun, B., Duwa, B., & Ozsahin, I. (2023). Computer-Aided Detection and Classification of Monkeypox and Chickenpox Lesion in Human Subjects Using Deep Learning Framework. *Diagnostics*, 13(2). <https://doi.org/10.3390/diagnostics1302029>
- Yaacoub, E., Abualsaud, K., Khatat, T., & Chehab, A. (2020). Secure Transmission of IoT mHealth Patient Monitoring Data from Remote Areas Using DTN. *IEEE Network*, 34(5), 226–231. <https://doi.org/10.1109/MNET.011.1900627>