

Classification of Cat Skin Diseases Using MobileNetV2 Architecture with Transfer Learning

Dian Saputra Aji^{1*}, Wahid Miftahul Ashari^{2*}, Dony Ariyus^{3*}

* Teknik Komputer, Fakultas Ilmu Komputer, Universitas Amikom Yogyakarta

dsaputraaji@students.amikom.ac.id¹, wahidashari@amikom.ac.id², dony.a@amikom.ac.id³

Article Info

Article history:

Received 2025-10-09

Revised 2025-10-28

Accepted 2025-11-08

Keyword:

Classification, Convolutional Neural Network, MobileNetV2, Transfer Learning, Cat Skin Diseases.

ABSTRACT

Skin diseases in cats often present similar visual symptoms across different conditions, making early and accurate diagnosis challenging for pet owners and veterinarians. This study develops a classification model for cat skin diseases: Fungal Infection, Flea Infestation, Scabies, and Healthy, using the MobileNetV2 architecture with a transfer learning approach. A total of 1,600 RGB images were collected from public datasets and divided into 1,280 training and 320 validation samples. The dataset underwent preprocessing, normalization, and data augmentation techniques such as rotation, shear, zoom, and flipping to enhance model generalization and reduce overfitting. Several experiments were conducted to analyze the impact of input size and learning rate adjustments on model performance. The optimal configuration was achieved using an input size of 224×224 pixels, a learning rate of 0.001, and augmentation applied to the training data. The resulting model achieved a validation accuracy of 91.8%, with an average precision, recall, and F1-score of 91%, demonstrating balanced performance across all classes. These results indicate that the MobileNetV2 architecture, combined with appropriate hyperparameter tuning and augmentation, provides a reliable and computationally efficient method for automatic identification of cat skin diseases. This approach can support early diagnosis, improve animal welfare, and serve as a foundation for the development of practical veterinary diagnostic applications.



This is an open access article under the [CC-BY-SA](#) license.

I. PENDAHULUAN

Kucing (*Felis catus*) adalah salah satu hewan peliharaan yang banyak disenangi oleh orang-orang dan sudah menjadi bagian penting dalam hubungan antara manusia dan hewan. Menurut American Pet Products Association (APP) tahun 2023–2024, tercatat sekitar 46,5 juta rumah tangga di Amerika Serikat memelihara kucing, dengan populasi kucing peliharaan mencapai lebih dari 85 juta ekor [1]. Sementara itu, menurut Euromonitor (2022), populasi kucing peliharaan di Indonesia diperkirakan mencapai 4,8 juta ekor [2]. Konsekuensi dari status ini adalah meningkatnya tanggung jawab pemilik terhadap pemeliharaan kesehatan dan pemenuhan standar kesejahteraan hewan [3]. Di antara berbagai isu kesehatan yang sering terjadi, dermatosis atau penyakit kulit merupakan salah satu kondisi yang paling sering dilaporkan pada praktik kedokteran hewan. Kondisi ini dapat menurunkan kualitas hidup kucing secara signifikan,

seperti pruritus (rasa gatal), nyeri, dan infeksi sekunder, serta berpotensi bersifat zoonosis, yang artinya dapat menular kepada manusia [4].

Beberapa jenis penyakit kulit yang penyebarannya cukup tinggi pada kucing meliputi dermatofitosis (infeksi jamur), infestasi ektoparasit seperti kutu (*flea infestation*), dan skabies (*scabies*) [5], [6], [7]. Sebuah masalah utama dalam mendiagnosa penyakit-penyakit ini adalah adanya kesamaan gejala pada awal tahap penyakit, misalnya alopecia (kerontokan rambut), eritema (kemerahan kulit), dan pembentukan lesi [8]. Kesamaan gejala antarpenyakit sering menyulitkan proses membedakan satu kasus dengan yang lain. Proses ini penting agar penyebab penyakit dapat diketahui secara tepat sehingga penanganan yang diberikan juga sesuai. Penentuan penyakit kulit pada kucing biasanya dilakukan melalui pemeriksaan klinis oleh dokter hewan. Namun, untuk memastikan hasilnya, sering kali diperlukan pemeriksaan tambahan seperti uji mikroskopis atau kultur

jamur. Prosedur tersebut tidak hanya membutuhkan waktu dan keahlian khusus, tetapi juga dapat menjadi hambatan karena faktor biaya serta keterbatasan akses ke fasilitas kesehatan hewan bagi sebagian pemilik. Keterlambatan dalam mengenali penyakit kulit pada kucing dapat memperburuk kondisi penyakit dan meningkatkan risiko penularan [9]. Oleh karena itu, pengembangan sebuah sistem pendukung keputusan yang mampu memberikan identifikasi awal secara cepat dan akurat menjadi sangat relevan.

Seiring dengan kemajuan teknologi, Kecerdasan Buatan (*Artificial Intelligence*), khususnya pada Visi Komputer (*Computer Vision*), menawarkan solusi yang menjanjikan. Metode Pembelajaran Mendalam (*Deep Learning*), terutama arsitektur Jaringan Saraf Konvolusional (*Convolutional Neural Network/CNN*), telah menunjukkan performa unggul dalam berbagai tugas klasifikasi citra, termasuk dalam bidang medis. CNN mampu secara otomatis mempelajari dan mengekstraksi fitur penting dari citra, sehingga dapat mengenali pola visual yang kompleks untuk membedakan berbagai kondisi penyakit [10].

Penelitian ini menggunakan arsitektur MobileNetV2 sebagai model dasar. Arsitektur ini dikenal efisien secara komputasi, sehingga cocok digunakan pada perangkat dengan sumber daya terbatas, namun tetap mampu memberikan akurasi yang baik [11]. Untuk meningkatkan performa model pada dataset yang spesifik dan terbatas, diterapkan metode *transfer learning*. Metode ini memanfaatkan pengetahuan yang telah diekstraksi oleh model yang sebelumnya dilatih pada dataset berskala besar (ImageNet), lalu mengadaptasinya untuk tugas klasifikasi penyakit kulit kucing.

Penelitian sebelumnya yang dilakukan oleh Pangestu dan Ramadhani (2023) merancang sistem deteksi penyakit kulit pada kucing menggunakan algoritma *Convolutional Neural Network* (CNN) yang diimplementasikan dalam bentuk aplikasi Android. Sistem tersebut mampu mengklasifikasikan empat jenis penyakit kulit, yaitu infeksi jamur, skabies, jerawat kucing, dan tungau telinga, dengan akurasi rata-rata sebesar 78,33% [12]. Hasil ini menunjukkan potensi besar pemanfaatan *deep learning* dalam mendukung diagnosis penyakit kulit pada kucing, meskipun masih terdapat ruang pengembangan untuk meningkatkan akurasi.

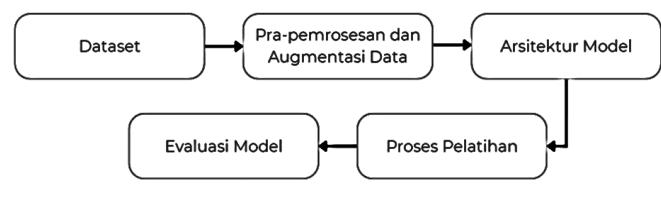
Urgensi penelitian ini didasarkan pada tingginya kasus penyakit kulit pada kucing serta potensi dampaknya terhadap manusia akibat sifatnya yang zoonosis. Di sisi lain, keterbatasan akses terhadap fasilitas diagnostik veteriner membuat banyak pemilik hewan kesulitan mendapatkan penanganan tepat waktu. Oleh karena itu, dibutuhkan inovasi berupa sistem klasifikasi berbasis *deep learning* yang tidak hanya akurat tetapi juga efisien secara komputasi sehingga dapat diaplikasikan pada berbagai perangkat. Upaya ini penting untuk mempercepat identifikasi awal, menekan risiko penularan, serta mendukung upaya peningkatan kesejahteraan hewan.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model

klasifikasi penyakit kulit pada kucing (Dermatofitosis, Infestasi Kutu, dan Skabies) serta membedakannya dari kondisi kulit normal (Sehat) menggunakan arsitektur Jaringan Saraf Konvolusional MobileNetV2 dengan pendekatan *transfer learning*. Hasil dari penelitian ini diharapkan dapat berkontribusi sebagai alat bantu diagnosis awal yang objektif dan efisien bagi pemilik hewan maupun praktisi veteriner.

II. METODE

Metodologi penelitian ini dirancang secara sistematis, dimulai dari pengumpulan dataset citra penyakit kulit pada kucing hingga tahap evaluasi model klasifikasi. Pendekatan ini bertujuan untuk mengoptimalkan proses *training* dan validasi, sekaligus memastikan bahwa arsitektur MobileNetV2 mampu memberikan hasil klasifikasi yang akurat. Alur penelitian ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

A. Dataset

Data yang digunakan dalam penelitian ini merupakan kumpulan citra penyakit kulit pada kucing yang diperoleh dari Kaggle (*Cat Skin Disease V2*) dan Roboflow Universe (*Cat Skin Disease Classification Computer Vision Dataset*). Dataset terdiri dari total 1.600 citra, yang terbagi menjadi 4 kelas dengan jumlah seimbang, masing-masing 400 citra, yaitu: Scabies (400 citra), Jamuran (400 citra), Kutuan (400 citra), dan Sehat (400 citra), <https://www.kaggle.com/datasets/adityavahreza/cat-skin-disease-v2>, <https://universe.roboflow.com/alvian-i1njf/cat-skin-disease-classification-b18ja>. Sampel citra dari masing-masing kelas ditunjukkan pada gambar 2.



Gambar 2. Sampel Citra dari Masing-masing Kelas

B. Preprocessing Data

Tahap pra-pemrosesan data dilakukan untuk memastikan bahwa citra yang digunakan dalam pelatihan model berada pada format yang seragam dan sesuai dengan kebutuhan arsitektur MobileNetV2. Proses ini bertujuan untuk meningkatkan kualitas data sehingga model dapat belajar secara optimal [13]. Tahapan *preprocessing* yang dilakukan meliputi:

- 1) *Split Dataset*: Dataset dibagi ke dalam dua bagian dengan rasio 80% data latih dan 20% data validasi. Pembagian ini bertujuan untuk memastikan model dapat dilatih sekaligus dievaluasi dengan data independen [14].
- 2) *Resizing*: Seluruh citra diubah ukurannya menjadi 224 × 224 piksel agar sesuai dengan dimensi input standar pada arsitektur MobileNetV2.
- 3) Normalisasi: Setiap piksel citra dinormalisasi dengan skala 0–1, yaitu dengan membagi nilai piksel (0–255) menjadi nilai pecahan desimal. Langkah ini membantu mempercepat konvergensi model selama proses pelatihan [15].
- 4) *Data Augmentation*: Untuk meningkatkan variasi data dan mengurangi risiko *overfitting*, dilakukan augmentasi citra pada data latih dengan beberapa transformasi, seperti rotasi, translasi (geser horizontal dan vertikal), *shear* (kemiringan), *zoom*, serta *flipping* horizontal. Proses augmentasi ini menghasilkan data pelatihan yang lebih beragam meskipun jumlah dataset terbatas [16].

C. Transfer Learning

Penelitian ini menggunakan pendekatan *transfer learning*, yaitu memanfaatkan model yang telah dilatih sebelumnya (*pre-trained model*) untuk mempercepat dan meningkatkan kinerja proses pelatihan. Model dasar yang digunakan adalah MobileNetV2 dengan bobot awal dari dataset ImageNet [17].

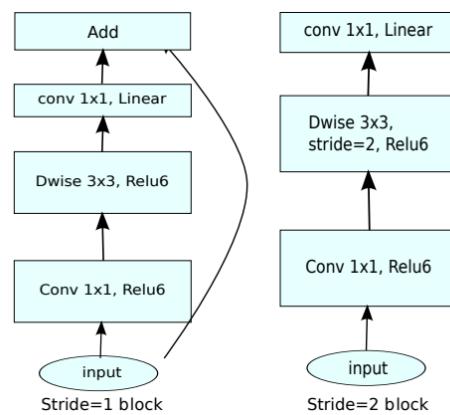
Pada tahap awal, lapisan konvolusi MobileNetV2 dibuat *non-trainable* (*frozen*) sehingga bobot *pre-trained* tetap digunakan sebagai ekstraktor fitur. Selanjutnya ditambahkan lapisan kustom berupa Global Average Pooling 2D, Dropout (0.3), dan Dense Softmax sesuai jumlah kelas. Lapisan kustom inilah yang dioptimalkan menggunakan dataset penyakit kulit pada kucing.

Setelah proses pelatihan awal selesai, dilakukan tahap *fine-tuning* parsial untuk menyesuaikan bobot model terhadap karakteristik spesifik citra penyakit kulit pada kucing. Pada tahap ini, 20 lapisan terakhir MobileNetV2 dibuka (*unfreeze*) agar dapat ikut dilatih, sementara lapisan lainnya tetap dibekukan. Strategi ini memungkinkan model mempertahankan kemampuan ekstraksi fitur umum dari ImageNet, sekaligus menyesuaikan representasi fitur tingkat tinggi terhadap pola visual baru seperti tekstur kulit, warna lesi, dan distribusi luka. Pendekatan ini juga membantu mencapai keseimbangan antara efisiensi komputasi dan peningkatan akurasi, tanpa meningkatkan risiko *overfitting*.

D. Arsitektur MobileNetV2

MobileNetV2 merupakan arsitektur *Convolutional Neural Network* (CNN) yang dirancang untuk mencapai keseimbangan antara akurasi dan efisiensi komputasi [18]. Arsitektur ini banyak digunakan pada perangkat dengan keterbatasan sumber daya karena jumlah parameteranya yang relatif kecil namun tetap memiliki performa kompetitif [19].

Arsitektur MobileNetV2 menggunakan *depthwise separable convolution* untuk mengurangi jumlah parameter dan beban komputasi tanpa menurunkan akurasi secara signifikan [20]. Setiap blok inti terdiri dari *inverted residual block* dengan dua variasi, yaitu blok dengan *stride* 1 yang memiliki *skip connection* dan blok dengan *stride* 2 yang tidak menggunakan *skip connection*. Proses dalam blok ini dimulai dengan memperluas jumlah channel menggunakan konvolusi 1x1, kemudian dilanjutkan dengan *depthwise convolution* 3x3 untuk mengekstraksi fitur, dan diakhiri dengan pengecilan kembali channel melalui konvolusi 1x1 linear. Ciri khas lain dari MobileNetV2 adalah penggunaan *linear bottleneck*, di mana aktivasi non-linear tidak diterapkan pada output *bottleneck* untuk mencegah hilangnya informasi penting. Dengan rancangan ini, MobileNetV2 mampu menjaga efisiensi sekaligus mempertahankan performa yang baik dalam tugas klasifikasi citra [21], [22]. Diagram alir dari arsitektur MobileNetV2 ditunjukkan pada Gambar 3.



Gambar 3. Arsitektur MobileNetV2 [23]

Dalam penelitian ini, MobileNetV2 digunakan sebagai *extractor* fitur utama untuk mengklasifikasikan citra penyakit kulit pada kucing. Dengan memanfaatkan bobot awal dari ImageNet, model dapat menggunakan pengetahuan visual yang sudah dipelajari sebelumnya dan menyesuaikannya dengan dataset khusus penelitian ini.

E. Evaluasi Model

Untuk mengetahui seberapa baik model MobileNetV2 dalam mengklasifikasikan citra penyakit kulit pada kucing, dilakukan evaluasi kinerja menggunakan data validasi. Analisis kuantitatif dilakukan dengan memanfaatkan *library* Scikit-learn dan metrik evaluasi standar. Metrik utama yang digunakan meliputi akurasi, presisi, *recall*, dan *F1-score* untuk menilai performa model pada setiap kelas, serta ditampilkan *confusion matrix* untuk memberikan gambaran visual mengenai distribusi prediksi benar dan salah dari setiap kelas. Akurasi menunjukkan seberapa banyak prediksi model yang benar dibandingkan dengan seluruh data, rumus (1) akurasi adalah:

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

Presisi mengukur ketepatan model dalam memprediksi suatu kelas dengan melihat proporsi prediksi benar dari semua prediksi positif, rumus (2) presisi adalah:

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

Recall menilai seberapa baik model dalam menemukan semua sampel yang benar-benar termasuk dalam suatu kelas, rumus (3) recall adalah:

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

F1-score merupakan harmonisasi antara precision dan recall, yang berguna untuk menyeimbangkan performa ketika terdapat ketidakseimbangan jumlah data antar kelas, rumus (4) F1-score adalah:

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

F. Lingkungan dan Spesifikasi Komputasi

Seluruh eksperimen dalam penelitian ini menggunakan hardware dan software yang spesifik untuk memastikan hasilnya konsisten dan dapat direproduksi. Tabel 1 merangkum spesifikasi sistem yang digunakan selama proses pelatihan model.

TABEL I
SPESIFIKASI LINGKUNGAN KOMPUTASI

Kategori	Spesifikasi
Software	Microsoft Windows 11 Operating System, Python 3.12.6, TensorFlow 2.18.0, Keras 3.4.1, NumPy 1.26.4, Matplotlib 3.9.2, dan Scikit-learn 1.5.2
Hardware	Processor: Intel Core i3 1115G4 (2 Core, 4 Thread, Base Clock 3.00GHz) RAM: 12GB, SSD: 512GB

III. HASIL DAN PEMBAHASAN

A. Pengumpulan Data

Data penelitian diperoleh dari dua sumber utama, yaitu Kaggle dan Roboflow Universe, yang menyediakan dataset citra terkait penyakit kulit pada kucing. Proses pengumpulan data dilakukan dengan mengunduh citra dari kedua platform tersebut sesuai dengan kategori yang dibutuhkan.

Total data yang berhasil dikumpulkan adalah 1.600 citra berwarna (RGB), yang terbagi ke dalam empat kelas secara seimbang, yaitu Skabies, Jamuran, Kutuan, dan Sehat,

masing-masing berjumlah 400 citra. dataset dibagi menjadi dua subset dengan rasio 80% untuk data latih (1.280 citra) dan 20% untuk data validasi (320 citra). Dataset yang sudah terstruktur inilah yang menjadi dasar utama dalam proses pelatihan dan evaluasi model klasifikasi berbasis MobileNetV2. Daftar kelas dan jumlah citra ditunjukkan pada Tabel 2.

TABEL II
DAFTAR KELAS DAN JUMLAH CITRA

No	Nama Kelas	Data Latih	Data Validasi	Total
1	Skabies	320	80	400
2	Jamuran	320	80	400
3	Kutuan	320	80	400
4	Sehat	320	80	400
	Jumlah	1280	320	1600

B. Augmentasi Data

Dalam penelitian ini, augmentasi data dilakukan untuk meningkatkan keberagaman data pelatihan dan mencegah model dari *overfitting*. Teknik augmentasi yang diterapkan adalah sebagai berikut:

- 1) *Rescaling* (Normalisasi): Skala setiap piksel gambar disesuaikan agar berada dalam rentang [0, 1].
- 2) Rotasi Gambar: Memutar citra pada sudut 20 derajat secara acak.
- 3) Pergeseran Horizontal dan Vertikal: Citra digeser vertikal atau horizontal secara acak dalam batas 10% dari ukurannya.
- 4) *Shear Transformation*: Transformasi *shear* sebesar 0.2, yang membuat distorsi pada citra secara acak.
- 5) *Zoom*: Citra diperbesar atau diperkecil secara acak dalam kisaran 20% dari ukuran asli.
- 6) Pembalikan Horizontal: Citra dibalik secara horizontal.
- 7) Pengisian Gambar: Ruang kosong yang muncul pada citra yang disebabkan transformasi seperti rotasi atau pergeseran diisi menggunakan metode *nearest*, yaitu mengambil nilai piksel terdekat.

C. Hasil Pelatihan Model

Proses pelatihan dilakukan dengan membandingkan beberapa konfigurasi, yaitu ukuran citra masukan (224×224, 180×180, dan 150×150 piksel) serta kondisi dengan augmentasi dan tanpa augmentasi. Tujuannya adalah untuk mengetahui pengaruh ukuran citra dan augmentasi terhadap performa model MobileNetV2.

Pelatihan dilakukan selama 25 epoch dengan batch size 32 dan *learning rate* 0,0001. Nilai akurasi dan loss dicatat pada data latih maupun data validasi. Untuk memudahkan analisis, hasil eksperimen disajikan dalam dua tabel terpisah, yaitu Tabel 3 untuk model dengan augmentasi data dan Tabel 4 untuk model tanpa augmentasi data.

TABEL III
HASIL PELATIHAN MODEL DENGAN AUGMENTASI DATA

Ukuran Input	Akurasi Latih (%)	Akurasi Validasi (%)	Loss Latih	Loss Validasi
224 × 224	84.9	88.4	0.41	0.33
180 × 180	84.2	87.2	0.40	0.37
150 × 150	81.3	86.5	0.54	0.40

TABEL IV
HASIL PELATIHAN MODEL TANPA AUGMENTASI DATA

Ukuran Input	Akurasi Latih (%)	Akurasi Validasi (%)	Loss Latih	Loss Validasi
224 × 224	87.1	88.4	0.35	0.36
180 × 180	86.5	89.1	0.40	0.34
150 × 150	84.3	86.3	0.40	0.38

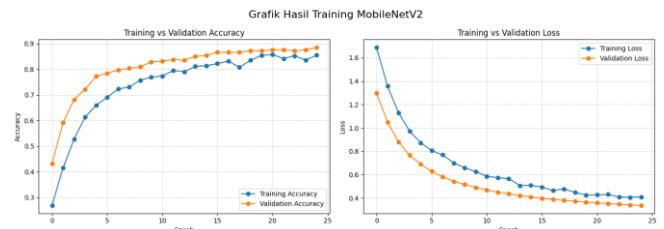
Hasil eksperimen menunjukkan bahwa baik model dengan augmentasi maupun tanpa augmentasi sama-sama mampu menghasilkan akurasi validasi yang tinggi pada keempat kelas penyakit kulit kucing. Namun, terdapat perbedaan pola yang menarik.

Model dengan augmentasi data menghasilkan akurasi latih yang sedikit lebih rendah (sekitar 84–81%), tetapi akurasi validasi relatif stabil (86,5–88,4%), yang menandakan kemampuan generalisasi lebih baik. Augmentasi memberikan variasi data tambahan seperti rotasi, pergeseran, *shear*, *zoom*, dan *flipping* sehingga model tidak sekadar menghafal data latih, melainkan belajar pola yang lebih umum.

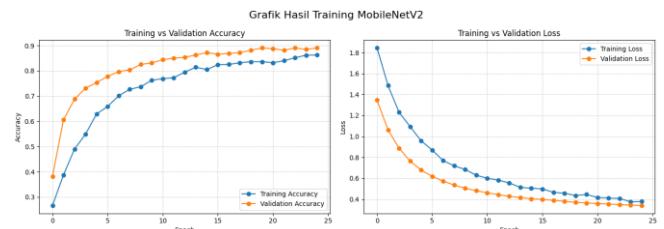
Sementara itu, model tanpa augmentasi data memperlihatkan akurasi latih lebih tinggi (84–87%) dan pada beberapa konfigurasi (misalnya input 180 × 180 piksel) bahkan memperoleh akurasi validasi tertinggi (89,1%). Namun, pola ini juga mengindikasikan potensi *overfitting* karena model belajar pada data yang lebih homogen tanpa variasi tambahan, ditunjukkan oleh perbedaan *loss* validasi yang sedikit lebih tinggi pada beberapa konfigurasi.

Secara keseluruhan, augmentasi data tetap direkomendasikan karena mampu menjaga generalisasi model terutama pada dataset terbatas, sedangkan ukuran input 224 × 224 piksel dengan augmentasi dapat dianggap sebagai konfigurasi terbaik untuk klasifikasi penyakit kulit kucing menggunakan MobileNetV2.

Visualisasi hasil pelatihan model ditampilkan pada Gambar 4 dan Gambar 5. Gambar 4 menunjukkan grafik akurasi dan *loss* per epoch untuk model MobileNetV2 dengan konfigurasi 224 × 224 piksel menggunakan augmentasi data, sedangkan Gambar 5 menunjukkan grafik akurasi dan *loss* per epoch untuk model MobileNetV2 dengan konfigurasi 180 × 180 piksel tanpa augmentasi data. Kedua grafik ini memperlihatkan perkembangan akurasi dan penurunan *loss* pada data latih maupun validasi selama 25 epoch. Konfigurasi ini merupakan hasil terbaik pada kondisi dengan augmentasi data (224 × 224 piksel) dan tanpa augmentasi data (180 × 180 piksel).



Gambar 4. Grafik akurasi dan loss per epoch untuk model MobileNetV2 dengan konfigurasi 224 × 224 piksel menggunakan augmentasi data



Gambar 5. Grafik akurasi dan loss per epoch untuk model MobileNetV2 dengan konfigurasi 180 × 180 piksel tanpa augmentasi data

D. Pengaruh Perubahan Learning Rate

Pada tahap ini dilakukan pengujian perubahan *learning rate* untuk melihat dampaknya terhadap proses pelatihan model. Nilai *learning rate* yang semula 0,0001 dinaikkan menjadi 0,001 pada dua konfigurasi terbaik sebelumnya, yaitu 224 × 224 piksel dengan augmentasi data dan 180 × 180 piksel tanpa augmentasi data. Tujuan pengujian ini adalah untuk mengetahui apakah peningkatan *learning rate* dapat mempercepat konvergensi model serta meningkatkan performa pada data validasi [24]. Hasil pelatihan model dengan *learning rate* 0,001 ditunjukkan pada tabel 5.

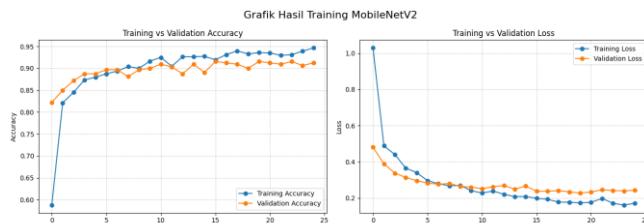
TABEL V
HASIL PELATIHAN MODEL DENGAN LEARNING RATE 0,001

Ukuran Input	Augmentasi Data	Akurasi Latih (%)	Akurasi Validasi (%)	Loss Latih	Loss Validasi
224 × 224	Ya	95.1	91.8	0.14	0.23
180 × 180	Tidak	98.3	90.6	0.07	0.31

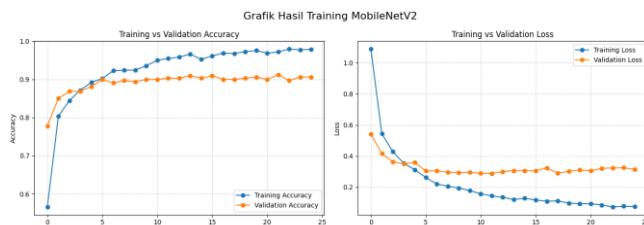
Hasil pelatihan menunjukkan bahwa model dengan ukuran input 224 × 224 piksel dan augmentasi data mencapai akurasi latih 95,17% dengan *loss* 0,1457 pada epoch ke-25, sedangkan akurasi validasi mencapai 91,87% dengan *loss* 0,2395. Tren ini menunjukkan *learning rate* yang lebih besar membantu model belajar lebih cepat, terlihat dari kenaikan akurasi yang signifikan pada beberapa epoch awal, meskipun *loss* validasi cenderung sedikit berfluktuasi di epoch akhir.

Sementara itu, model dengan ukuran input 180 × 180 piksel tanpa augmentasi data mencapai akurasi latih 98,30% dengan *loss* 0,0777 pada epoch ke-25, sedangkan akurasi validasi sebesar 90,62% dengan *loss* 0,3141. Model ini menunjukkan kemampuan belajar sangat cepat di data latih tetapi *loss* validasi yang relatif lebih tinggi dibandingkan dengan kondisi augmentasi, yang mengindikasikan adanya potensi *overfitting*.

Untuk memberikan gambaran visual atas performa kedua konfigurasi terbaik tersebut, Gambar 6 dan Gambar 7 menampilkan grafik akurasi dan *loss* per epoch. Gambar 6 memperlihatkan tren model MobileNetV2 berukuran 224×224 piksel dengan augmentasi data (*learning rate* 0,001), sedangkan Gambar 7 menunjukkan tren model MobileNetV2 berukuran 180×180 piksel tanpa augmentasi data (*learning rate* 0,001). Kedua grafik ini digunakan untuk melihat perkembangan akurasi dan loss pada data latih dan validasi selama proses pelatihan.



Gambar 6. Grafik akurasi dan loss per epoch untuk model MobileNetV2 berukuran 224×224 piksel dengan augmentasi data (*learning rate* 0,001)



Gambar 7. Grafik akurasi dan loss per epoch untuk model MobileNetV2 berukuran 180×180 piksel tanpa augmentasi data (*learning rate* 0,001)

Secara keseluruhan, hasil percobaan menunjukkan bahwa konfigurasi model MobileNetV2 224×224 piksel dengan augmentasi data dan *learning rate* 0,001 merupakan kombinasi yang paling stabil dan memiliki akurasi validasi yang tinggi. Meskipun konfigurasi 180×180 piksel tanpa augmentasi mencapai akurasi latih tertinggi, model ini menunjukkan potensi *overfitting*. Hal ini menegaskan pentingnya augmentasi data dan pemilihan *learning rate* yang tepat untuk menjaga performa model pada data validasi.

Berdasarkan Tabel 5 dan Gambar 6, nilai *training accuracy* dan *validation accuracy* pada konfigurasi terbaik yaitu model MobileNetV2 berukuran 224×224 piksel dengan augmentasi data (*learning rate* 0,001) menunjukkan perbedaan yang kecil, yaitu sekitar 3,3%, dengan tren penurunan *loss* yang stabil pada kedua dataset. Hal ini mengindikasikan bahwa model tidak mengalami *overfitting* secara signifikan dan mampu melakukan generalisasi dengan baik terhadap data validasi.

E. Perbandingan Performa Model Transfer Learning dan CNN Baseline

Untuk mengukur efektivitas pendekatan *transfer learning*, dilakukan pelatihan model CNN baseline tanpa menggunakan bobot *pre-trained*. Arsitektur CNN ini terdiri dari tiga blok konvolusi, masing-masing diikuti oleh lapisan Batch

Normalization dan MaxPooling2D untuk menstabilkan distribusi aktivasi dan mengurangi dimensi fitur. Setelah itu, ditambahkan lapisan Dropout sebesar 0,3 guna mencegah *overfitting*. Hasil keluaran kemudian diratakan melalui lapisan Flatten dan diteruskan ke lapisan Dense dengan 256 neuron (ReLU) serta lapisan Dropout sebesar 0,4 sebelum menuju lapisan keluaran softmax.

Pelatihan dilakukan selama 25 epoch dengan konfigurasi yang serupa dengan model MobileNetV2 pada hasil terbaik, yaitu ukuran input 224×224 piksel, batch size 32, serta menggunakan augmentasi data yang sama, meliputi rotasi acak, pergeseran posisi, zoom, *shear*, dan flip horizontal.

Perbedaan utama terletak pada nilai *learning rate*, di mana model CNN baseline dilatih menggunakan *learning rate* 0,0001. Nilai ini dipilih karena pada percobaan awal dengan *learning rate* 0,001, model menunjukkan ketidakstabilan selama pelatihan (*training loss* berfluktuasi besar dan akurasi validasi sulit meningkat). Dengan penyesuaian *learning rate* menjadi 0,0001, proses pelatihan menjadi lebih stabil dan konvergen meskipun dengan laju pembelajaran yang lebih lambat. Tabel 6 menunjukkan hasil perbandingan antara model MobileNetV2 dengan *transfer learning* dan CNN baseline tanpa *transfer learning* berdasarkan hasil akurasi dan *validation loss*.

TABEL VI
PERBANDINGAN MODEL MOBILENETV2 DENGAN CNN BASELINE

Model	Akurasi Latih (%)	Akurasi Validasi (%)	Loss Latih	Loss Validasi	Waktu Latih
MobileNetV2 (dengan transfer learning)	95.1	91.8	0.14	0.23	85 detik
CNN Baseline (tanpa transfer learning)	76.9	80.0	1.99	1.89	247 detik

Berdasarkan hasil tersebut, MobileNetV2 memperoleh akurasi validasi yang jauh lebih tinggi, dengan proses pelatihan yang lebih stabil dan loss validasi yang lebih rendah dibandingkan model CNN baseline. Perbedaan ini menegaskan bahwa penggunaan *pre-trained weights* pada arsitektur *transfer learning* mampu meningkatkan kemampuan generalisasi model serta mempercepat konvergensi selama proses pelatihan.

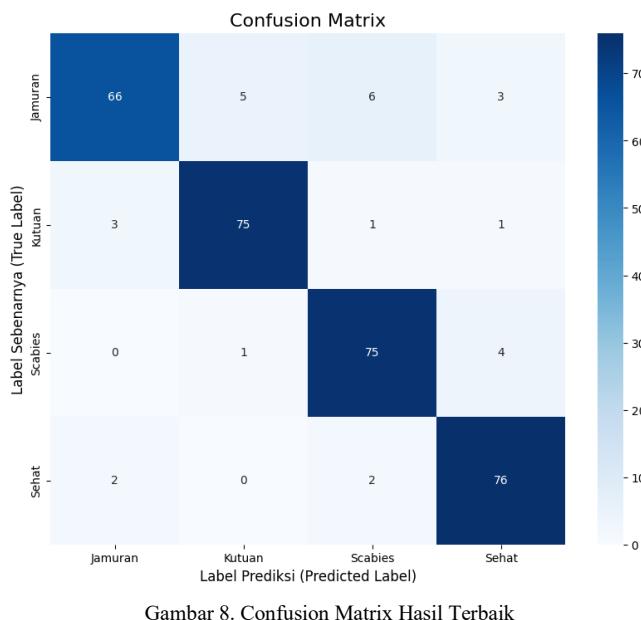
F. Evaluasi Model Terbaik

Sebagai bagian dari proses evaluasi, Tabel 7 menyajikan ringkasan hasil akurasi dan metrik evaluasi utama, meliputi precision, recall, dan nilai rata-rata keseluruhan. Evaluasi ini dilakukan pada konfigurasi terbaik, yaitu model MobileNetV2 dengan ukuran input 224×224 piksel, menggunakan augmentasi data dan *learning rate* sebesar 0,001.

TABEL VII
HASIL EVALUASI MODEL BERDASARKAN AKURASI, PRESISI, DAN RECALL

Nilai	Nama Penyakit	Presentase
Presisi	Jamuran	93%
	Kutuan	93%
	Scabies	89%
	Sehat	90%
Recall	Jamuran	82%
	Kutuan	94%
	Scabies	94%
	Sehat	95%
F1-Score	Jamuran	87%
	Kutuan	93%
	Scabies	91%
	Sehat	93%
Rata-rata Precision		91,25%
Rata-rata Recall		91,25%
Rata-rata F1-Score		91%
Akurasi		91,8%

Berdasarkan Tabel 7, model MobileNetV2 dengan konfigurasi terbaik (224×224 piksel) menggunakan augmentasi data dan *learning rate* 0,001 berhasil mencapai akurasi validasi sebesar 91,8%. Nilai *precision*, *recall*, dan rata-rata keseluruhan menunjukkan hasil yang relatif seimbang di keempat kelas penyakit kulit kucing. *Precision* tertinggi terdapat pada kelas Jamuran dan Kutuan (93%), sedangkan *recall* tertinggi pada kelas Sehat (95%). Rata-rata *precision* dan *recall* sama-sama sebesar 91,25%, yang menunjukkan kemampuan model untuk mendeteksi setiap kelas secara konsisten tanpa bias yang signifikan. Hasil ini mengindikasikan bahwa model tidak hanya memiliki akurasi yang baik, tetapi juga keseimbangan performa antar kelas yang memadai, sehingga dapat diandalkan untuk klasifikasi penyakit kulit pada kucing.



Gambar 8. Confusion Matrix Hasil Terbaik

Selain itu, untuk memberikan gambaran yang lebih luas mengenai performa model dalam mengklasifikasikan setiap

kelas penyakit kulit kucing, Gambar 8 menampilkan visualisasi *confusion matrix*. *Confusion matrix* ini menggambarkan distribusi prediksi model terhadap label sebenarnya, sehingga dapat memperlihatkan pola kesalahan klasifikasi dan tingkat ketepatan prediksi pada masing-masing kelas.

Berdasarkan hasil tersebut, model menunjukkan performa yang sangat baik pada seluruh kelas. Kelas Kutuan dan Sehat memperoleh hasil paling tinggi dengan 75 dan 76 prediksi benar dari total 80 citra uji, menunjukkan tingkat akurasi lebih dari 93% pada kedua kelas tersebut. Kelas Scabies juga diklasifikasikan dengan cukup akurat dengan 75 prediksi benar dan hanya beberapa kesalahan minor pada kelas Sehat.

Sementara itu, kelas Jamuran memiliki jumlah kesalahan tertinggi, dengan 66 prediksi benar dari 80 citra. Sebagian besar kesalahan terjadi ketika gambar Jamuran diprediksi sebagai Kutuan atau Scabies, yang kemungkinan disebabkan oleh kemiripan tekstur antar kelas tersebut.

Secara keseluruhan, *confusion matrix* menunjukkan bahwa model MobileNetV2 mampu membedakan empat kelas penyakit kulit kucing dengan tingkat akurasi yang tinggi dan kesalahan klasifikasi yang relatif kecil.

IV. KESIMPULAN

Penelitian ini berhasil mengimplementasikan arsitektur MobileNetV2 untuk klasifikasi penyakit kulit pada kucing dengan empat kelas (Jamuran, Kutuan, Scabies, dan Sehat) menggunakan dataset sebanyak 1.600 citra. Proses pelatihan model melibatkan tahap pra-pemrosesan data, augmentasi data, serta pengujian berbagai ukuran input citra dan *learning rate*.

Hasil eksperimen menunjukkan bahwa model MobileNetV2 dengan ukuran input 224×224 piksel menggunakan augmentasi data dan *learning rate* 0,001 memberikan performa terbaik dengan akurasi validasi sebesar 91,8%, serta nilai *precision* dan *recall* rata-rata 91,25%. Augmentasi data terbukti meningkatkan kemampuan generalisasi model dengan menjaga kestabilan akurasi dan *loss* pada data validasi, sementara variasi *learning rate* dapat mempercepat konvergensi model meskipun berpotensi meningkatkan risiko *overfitting* pada kondisi tertentu.

Secara keseluruhan, penelitian ini menunjukkan bahwa penggunaan arsitektur MobileNetV2 dengan strategi augmentasi data dan pemilihan *hyperparameter* yang tepat dapat menjadi pendekatan efektif dalam mendeteksi penyakit kulit pada kucing. Hasil ini diharapkan dapat dimanfaatkan sebagai dasar pengembangan sistem deteksi otomatis yang mampu membantu pemilik kucing maupun praktisi veteriner dalam melakukan identifikasi dini penyakit kulit, sehingga kesehatan dan kesejahteraan kucing dapat lebih terjaga di masa mendatang.

DAFTAR PUSTAKA

- [1] T. Wall, "Graph: Cats and dogs lead US pet ownership growth 2023-2025." Accessed: Sep. 30, 2025. [Online]. Available: <https://www.petfoodindustry.com/pet-ownership-statistics/article/15747936/chart-cats-and-dogs-lead-us-pet-ownership-growth-20232025>
- [2] E. Sutriyanto, "Mayoritas Pemilik Datangi Klinik Saat Hewan Kesayangan Sakit dan Perlu Pengobatan." Accessed: Sep. 30, 2025. [Online]. Available: <https://www.tribunnews.com/nasional/2023/12/16/mayoritas-pemilik-datangi-klinik-saat-hewan-kesayangan-sakit-dan-perlu-pengobatan>
- [3] L. R. Finka, "Conspecific and Human Sociality in the Domestic Cat: Consideration of Proximate Mechanisms, Human Selection and Implications for Cat Welfare," *Animals*, vol. 12, no. 3, p. 298, Jan. 2022, doi: 10.3390/ani12030298.
- [4] H. H. N. Alautaish, H. A. Naji, Z. A. H. Saud, and B. G. Ghali, "Clinical study of common bacterial, fungal and parasitic skin diseases in cats," *Adv. Life Sci.*, vol. 11, no. 3, pp. 580–584, 2024, doi: 10.62940/als.v11i3.1873.
- [5] N. Yuliansyah, R. Ferdinand, R. S. Zamzami, R. Daud, and A. Hamzah, "Prevalence of dermatophytosis in cats at Alfa Anima Clinic Banda Aceh," *Int. J. Trop. Vet. Biomed. Res.*, vol. 9, no. 1, pp. 56–59, 2024, [Online]. Available: www.jurnal.usk.ac.id/IJTVBR
- [6] N. Azrizal-Wahid, M. Sofian-Azirun, and V. L. Low, "Risk factors associated with flea infestation on cats," *Trop. Biomed.*, vol. 36, no. 4, pp. 810–821, 2019.
- [7] N. Qudsiyati, A. Khirqah, A. Muntolip, D. Priyowidodo, S. Indarjulianto, and R. W. Nurcahyo, "Cat Scabies Prevalence at Animal Health Center Pemalang," *J. Sain Vet.*, vol. 41, no. 3, p. 354, 2023, doi: 10.22146/jsv.79996.
- [8] L. A. Nadira, S. Kayati Widystuti, and I. G. Soma, "Dermatophytosis Caused By Trichophyton Spp. In A Local Kitten," *Vet. Sci. Med. J.*, vol. 3, no. 3, pp. 271–280, Oct. 2023, doi: 10.24843/vsmj.2023.v5.i10.p06.
- [9] D. Prasetyo, I. A. Amri, S. Murwani, and D. Qosimah, "Peneguhan diagnosa scabies metode sitologi kulit pada kucing domestik di Kota Malang," *ARSHI Vet. Lett.*, vol. 3, no. 2, pp. 27–28, May 2019, doi: 10.29244/avl.3.2.27-28.
- [10] Imam Fathurrahman, Mahpuz, Muhammad Djamiluddin, Lalu Kerta Wijaya, and Ida Wahidah, "Pengembangan Model Convolutional Neural Network (CNN) untuk Klasifikasi Penyakit Kulit Berbasis Citra Digital," *Infotek J. Inform. dan Teknol.*, vol. 8, no. 1, pp. 298–308, Jan. 2025, doi: 10.29408/jit.v8i1.28655.
- [11] A. R. Hermanto, A. Aziz, and S. Sudianto, "Perbandingan Arsitektur MobileNetV2 dan RestNet50 untuk Klasifikasi Jenis Buah Kurma Comparison of MobileNetV2 and RestNet50 Architectures for Date Fruit Classification by Type," *J. Sist. dan Teknol. Inf.*, vol. 12, no. 4, pp. 630–637, 2024, doi: 10.26418/justin.v12i4.80358.
- [12] I. Y. Pangestu and S. R. Ramadhani, "Perancangan Sistem Deteksi Penyakit Kulit Pada Kucing Menggunakan Deep Learning Berbasis Android," *Teknika*, vol. 12, no. 3, pp. 173–182, Oct. 2023, doi: 10.34148/teknika.v12i3.673.
- [13] M. Najmi, "Hybrid Mobilenetv2 Dan Extreme Gradient Boosting Untuk Klasifikasi Kerusakan Bangunan," *J. Inform. dan Tek. Elektro Terap.*, vol. 13, no. 3, pp. 402–412, 2025, doi: 10.23960/jitet.v13i3.6858.
- [14] V. Oktaviani, N. Rosmawarni, and M. P. Muslim, "Perbandingan Kinerja Random Forest Dan Smote Random Forest Dalam Mendekripsi Dan Mengukur Tingkat Stres Pada Mahasiswa Tingkat Akhir," *Inform. J. Ilmu Komput.*, vol. 20, no. 1, pp. 43–49, 2024, doi: 10.52958/iftk.v20i1.9158.
- [15] J. Simangunsong, N. D. Simanjuntak, and A. A. Matondang, "Penerapan Transfer Learning untuk Klasifikasi Citra Bunga Berbasis Convolutional Neural Network," *J. Minfo Polgan*, vol. 14, no. 1, pp. 1062–1067, 2025, doi: 10.33395/jmp.v14i1.14980.
- [16] Dede Husen, "Evaluasi Teknik Augmentasi Data Untuk Klasifikasi Tumor Otak Menggunakan Cnn Pada Citra Mri," *Tek. Teknol. Inf. dan Multimed.*, vol. 5, no. 2, pp. 219–228, 2024, doi: 10.46764/teknimedia.v5i2.220.
- [17] N. Wangsa Kencana, R. Umar, and Murinto, "Implementasi Transfer Learning Untuk Klasifikasi Jenis Ras Ayam Menggunakan Arsitektur MobileNetV2," *J. Inform. Polinema*, vol. 11, pp. 147–154, 2025.
- [18] R. Hikmianto and E. Utami, "Sistemasi: Jurnal Sistem Informasi Klasifikasi Algoritma Jaringan Syaraf Tiruan Konvolusi untuk Deteksi Hama pada Kangkung Classification using Convolutional Neural Network Algorithms for Pest Detection in Water Spinach," *J. Sist. Inf.*, vol. 14, no. 1, pp. 342–353, 2025, [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [19] F. Zaelani and Y. Miftahuddin, "Perbandingan Metode EfficientNetB3 dan MobileNetV2 Untuk Identifikasi Jenis Buah-buahan Menggunakan Fitur Daun," *J. Ilm. Teknol. Infomasi Terap.*, vol. 9, no. 1, pp. 1–11, 2022, doi: 10.33197/jitter.vol9.iss1.2022.911.
- [20] F. A. Prayogi, F. H. Arvianto, D. R. Pratama, and S. Sugiyanto, "Mushroom Classification Using Convolutional Neural Network MobileNetV2 Architecture for Overfitting Mitigation and Enhanced Model Generalization," *J. Appl. Informatics Comput.*, vol. 9, no. 4, pp. 1770–1777, Aug. 2025, doi: 10.30871/jaic.v9i4.10183.
- [21] D. Dhimas, P. Putra, G. Kurnia Anaga, and W. T. Fitriyana, "Implementasi Algoritma Convolutional Neural Network Arsitektur Mobilenetv2 Untuk Klasifikasi Ekspresi Wajah Pada Dataset FER," *Pros. Semin. Nas. Teknol. Dan Sains*, vol. 3, no. 1, pp. 291–297, 2024.
- [22] M. B. Kurniawan and E. Utami, "Performance Comparison of ResNet50, VGG16, and MobileNetV2 for Brain Tumor Classification on MRI Images," *Sistemasi*, vol. 14, no. 2, p. 767, 2025, doi: 10.32520/stmsi.v14i2.5054.
- [23] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 4510–4520, 2018, doi: 10.1109/CVPR.2018.00474.
- [24] P. D. Wardani, "Klasifikasi Tipe Kematangan Pisang Menggunakan Metode Ensemble Convolutional Neural Network (CNN)," *J. Pengemb. Teknol. Inf. Dan Ilmu Komput.*, vol. 8, no. 9, pp. 1–10, 2017, [Online]. Available: <https://j-ptik.uk.ac.id/index.php/j-ptik/article/view/14157>