

Perbandingan Model *EfficientNetV2B0* dan *ResNet50* untuk Klasifikasi Citra Penyakit Mulut dan Kuku pada Sapi

^{1*}Farhan Kumara Abdiel, ²Ratih Kumalasari Niswatin, ³Danar Putra Pamungkas

^{1,2,3}Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ¹farhankumara18@gmail.com, ²ratih.k@unpkediri.ac.id, ³danar@unpkediri.ac.id

Penulis Korespondens : Farhan Kumara Abdiel

Abstrak—Penyakit Mulut dan Kuku (PMK) merupakan penyakit menular pada hewan ternak yang berdampak besar terhadap perekonomian peternak. Deteksi dini berbasis citra digital menggunakan deep learning menjadi pendekatan yang menjanjikan untuk mendukung identifikasi PMK secara cepat dan efisien. Penelitian ini membandingkan dua arsitektur *Convolutional Neural Network* (CNN), yaitu *EfficientNetV2B0* dan *ResNet50*, dalam mengklasifikasikan citra sapi ke dalam empat kelas: Kuku_PMK, Kuku_Sehat, Mulut_PMK, dan Mulut_Sehat. Dataset berjumlah 406 citra asli yang kemudian diperbesar menjadi 2.400 citra melalui augmentasi offline, dengan pembagian 80:20 untuk data latih dan validasi. Kedua model dilatih menggunakan transfer learning dua fase dengan optimizer Adam dan teknik fine-tuning. Hasil evaluasi menunjukkan bahwa *ResNet50* mencapai akurasi 92,50% dan *F1-score* makro 0,93, sedangkan *EfficientNetV2B0* menghasilkan akurasi 91,25% dengan *F1-score* makro 0,92. Meskipun *ResNet50* unggul secara akurasi, *EfficientNetV2B0* lebih efisien dari sisi jumlah parameter, menjadikannya kandidat potensial untuk implementasi pada perangkat dengan sumber daya terbatas.

Kata Kunci—Klasifikasi Citra, CNN, *EfficientNetV2B0*, Penyakit Mulut dan Kuku, *ResNet50*

Abstract—Foot-and-Mouth Disease (FMD) is a highly contagious livestock disease with significant economic impact on cattle farmers. Digital image-based early detection using deep learning has emerged as a promising approach for rapid and efficient FMD identification. This study compares two Convolutional Neural Network (CNN) architectures, namely *EfficientNetV2B0* and *ResNet50*, in classifying cattle images into four classes: Kuku_PMK, Kuku_Sehat, Mulut_PMK, and Mulut_Sehat. The dataset consists of 326 original images expanded to 2,400 images through offline augmentation, with an 80:20 split for training and validation. Both models were trained using two-phase transfer learning with the Adam optimizer and fine-tuning technique. Evaluation results show that *ResNet50* achieves 92.50% accuracy with a macro *F1-score* of 0.93, while *EfficientNetV2B0* yields 91.25% accuracy with a macro *F1-score* of 0.92. Although *ResNet50* outperforms in accuracy, *EfficientNetV2B0* is more efficient in terms of parameter count, making it a promising candidate for deployment on resource-constrained devices.

Keywords—Foot-and-Mouth Disease, *EfficientNetV2B0*, *ResNet50*, Transfer Learning, Image Classification

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Penyakit Mulut dan Kuku (PMK) adalah penyakit infeksius akut yang disebabkan oleh virus Aphthovirus dari famili Picornaviridae dan menyerang hewan berkuku belah, terutama sapi, kambing, domba, dan babi. Penyakit ini kembali mewabah di Indonesia pada tahun 2022 setelah bebas selama puluhan tahun, mengakibatkan kerugian ekonomi yang sangat besar akibat penurunan produktivitas ternak, biaya pengobatan, dan pembatasan perdagangan hewan [1]. Gejala klinis PMK meliputi terbentuknya vesikel dan lesi pada area mulut (lidah, gusi, dan bibir) serta kaki (celah antar-kuku dan mahkota kuku), disertai demam tinggi dan penurunan drastis produksi susu [2].

Proses diagnosis konvensional PMK memerlukan pengamatan klinis oleh dokter hewan berpengalaman yang dikonfirmasi melalui uji laboratorium seperti ELISA dan RT-PCR. Pendekatan ini membutuhkan waktu dan biaya yang signifikan, sehingga kurang efisien untuk penanganan massal di lapangan, terutama di daerah terpencil [3]. Oleh karena itu, diperlukan sistem deteksi otomatis yang cepat, akurat, dan mudah diakses oleh peternak maupun petugas kesehatan hewan.

Perkembangan deep learning, khususnya Convolutional Neural Network (CNN), telah membuka peluang baru dalam deteksi penyakit hewan berbasis citra. Berbagai penelitian telah menunjukkan keunggulan CNN dalam klasifikasi penyakit kulit sapi, identifikasi laminitis, dan analisis kondisi kesehatan ternak secara umum [4]. Teknik transfer learning yang memanfaatkan bobot pra-latih dari dataset besar seperti ImageNet memungkinkan adaptasi model pada dataset khusus dengan ukuran lebih kecil sekalipun [5].

Penelitian ini bertujuan membandingkan performa dua arsitektur CNN populer, yaitu EfficientNetV2B0 dan ResNet50, dalam mengklasifikasikan citra sapi ke dalam empat kelas berbasis kondisi PMK pada kuku dan mulut. Pemilihan kedua model didasarkan pada karakteristik yang saling kontras: EfficientNetV2B0 dikenal efisien secara parameter namun modern dalam arsitektur, sedangkan ResNet50 merupakan model klasik dengan kedalaman yang sudah terbukti robust untuk berbagai tugas klasifikasi citra. Hasil perbandingan ini diharapkan memberikan rekomendasi model yang paling sesuai untuk implementasi sistem deteksi PMK berbasis citra di lapangan [6].

II. METODE

Penelitian ini menggunakan pendekatan eksperimental dengan membandingkan dua model deep learning berbasis transfer learning. Seluruh eksperimen dilakukan pada platform Kaggle dengan akselerasi GPU NVIDIA Tesla T4 menggunakan framework TensorFlow 2.19.0.

A. Dataset

Dataset yang digunakan merupakan koleksi citra klinis PMK pada sapi yang mencakup empat kategori: Kuku_PMK, Kuku_Sihat, Mulut_PMK, dan Mulut_Sihat. Total dataset asli berjumlah 406 citra dengan distribusi: Kuku_PMK (86 citra), Kuku_Sihat (86 citra), Mulut_PMK (117 citra), dan Mulut_Sihat (117 citra). Dataset dikumpulkan secara mandiri melalui penelusuran pada platform Kaggle dan Roboflow, kemudian dipilih dan dilabeli sesuai kategori kelas yang telah ditentukan. Berikut adalah contoh datasetnya:

Tabel 1. Dataset Sapi

No.	Data Citra PMK	Kelas(Bagian)
1.		Mulut PMK
2.		Mulut Sehat
3.		Kuku PMK
4.		Kuku Sehat

B. Preprocessing dan Augmentasi Data

Dataset dibagi terlebih dahulu dengan rasio 80:20 untuk data latih dan data validasi sebelum proses augmentasi dilakukan. Pembagian ini menghasilkan 69 citra latih dan 17 citra validasi per kelas untuk Kuku_PMK dan Kuku_Sihat, serta 94 citra latih dan 23 citra validasi per kelas untuk Mulut_PMK dan Mulut_Sihat, sehingga total data validasi berjumlah 80 citra. Skema ini memastikan tidak ada kebocoran data (data leakage) antara set latih dan validasi [7].

Augmentasi offline diterapkan hanya pada data latih dengan target 600 citra per kelas, menghasilkan total 2.400 citra latih. Teknik augmentasi yang digunakan meliputi rotasi ($\pm 30^\circ$), pergeseran lebar dan tinggi (20%), zoom (25%), horizontal flip, penyesuaian kecerahan (70%-130%), shear (15%), dan mode pengisian reflect. Selain augmentasi offline, augmentasi online ringan (rotasi $\pm 15^\circ$, shift 10%, flip horizontal, zoom 10%) juga diterapkan saat pelatihan untuk

meningkatkan generalisasi model. Ukuran citra diseragamkan menjadi 224×224 piksel untuk kedua model.

C. Arsitektur Model

Kedua model dibangun menggunakan pendekatan transfer learning dengan bobot pra-latih ImageNet. Head klasifikasi kustom yang identik ditambahkan di atas masing-masing backbone: Global Average Pooling (GAP) dan Global Max Pooling (GMP) yang dikoncatenas, diikuti Batch Normalization, Dense(512) + ReLU + L2, Batch Normalization, Dropout(0,4), Dense(256) + ReLU + L2, Batch Normalization, Dropout(0,3), dan Dense(4) + Softmax. Perbandingan spesifikasi teknis kedua model ditampilkan pada Tabel 1.

Tabel 2. Perbandingan Spesifikasi Model

No.	Kata	TF(D1)	TF(D2)
1.	Total Parameter	7.376.212 (28,14 MB)	25.837.188 (98,56 MB)
2.	Param. Trainable Ph.1	1.450.244	2.239.748
3.	Param. Trainable Ph.2	6.556.356	24.281.348
4.	Ukuran Input	224×224×3	224×224×3
5.	Unfreeze dari Layer	Layer ke-100	Layer ke-80 (Conv4 + Conv5)

D. Prosedur Pelatihan

Pelatihan dilakukan dalam dua fase. Fase 1 (feature extraction) melatih hanya head klasifikasi dengan backbone dibekukan selama maksimal 30 epoch, optimizer Adam ($lr=1 \times 10^{-3}$), dan label smoothing 0,1. Fase 2 (fine-tuning) membuka sebagian lapisan backbone dan melatih ulang dengan $lr=5 \times 10^{-5}$ selama maksimal 40 epoch. Strategi regularisasi mencakup EarlyStopping (patience 10-12), ReduceLROnPlateau (faktor 0,3, patience 4-5), dan ModelCheckpoint berdasarkan val_accuracy. Bobot kelas dihitung otomatis untuk menangani ketidakseimbangan distribusi data [8].

III. HASIL DAN PEMBAHASAN

A. Hasil Pelatihan

EfficientNetV2B0 mencapai val_accuracy terbaik sebesar 91,25% pada akhir Fase 1 (epoch 14) dan mempertahankan nilai yang sama pada Fase 2. ResNet50 mencapai val_accuracy 93,75% pada Fase 1 (epoch 4) dan 92,50% pada Fase 2, dengan nilai akhir 92,50% yang digunakan sebagai performa final. Kedua model menunjukkan konvergensi yang baik tanpa indikasi overfitting yang signifikan, sebagaimana tercermin dari kurva akurasi pelatihan dan validasi yang stabil.

Tabel 3. Hasil Evaluasi Model *EfficientNetV2B0*

Kelas	Precision	Recall	F1-Score	Support
Kuku PMK	0,94	0,88	0,91	17
Kuku Sehat	1,00	0,94	0,97	17
Mulut PMK	0,90	0,83	0,86	23
Mulut Sehat	0,85	1,00	0,92	23
Macro Avg	0,92	0,91	0,92	80
Accurasy			0,9125	80

Tabel 4. Hasil Evaluasi Model *ResNet50*

Kelas	Precision	Recall	F1-Score	Support
Kuku PMK	0,94	0,88	0,91	17
Kuku Sehat	1,00	0,94	0,97	17
Mulut PMK	0,90	0,83	0,86	23
Mulut Sehat	0,85	1,00	0,92	23
Macro Avg	0,92	0,91	0,92	80
Accurasy			0,9125	80

B. Analisis Perbandingan Antar Model

Berdasarkan Tabel 3 dan Tabel 4, *ResNet50* mengungguli *EfficientNetV2B0* pada metrik akurasi (92,50% vs 91,25%) dan *F1-score* makro (0,93 vs 0,92). Perbedaan yang paling signifikan terlihat pada kelas Mulut_PMK, di mana recall *ResNet50* mencapai 0,96 sementara *EfficientNetV2B0* hanya 0,83. Tingginya recall untuk Mulut_PMK pada *ResNet50* menunjukkan kemampuan model tersebut dalam mendeteksi lebih banyak kasus positif PMK pada area mulut, yang sangat penting secara klinis karena kegagalan mendeteksi PMK (false negative) berdampak lebih buruk daripada deteksi berlebih (false positive) [10].

Di sisi lain, *EfficientNetV2B0* menunjukkan performa lebih baik pada kelas Mulut_Sehat dengan recall sempurna (1,00), artinya tidak ada kasus sapi sehat yang salah dikategorikan sebagai Mulut_PMK. Hal ini mengindikasikan bahwa *EfficientNetV2B0* lebih konservatif dalam mengeluarkan prediksi positif PMK pada area mulut, yang berpotensi mengurangi pemborosan sumber daya pengobatan. Kedua model menunjukkan performa identik pada kelas Kuku_PMK ($F1=0,91$) dan Kuku_Sehat ($F1=0,97$), mengindikasikan bahwa kedua arsitektur sama-sama efektif dalam membedakan kondisi kuku secara visual.

Tabel 5. Perbandingan Ringkasan Performa Kedua Model

Kata	<i>EfficientNetV2B0</i>	<i>ResNet50</i>
Akurasi Validasi	91,25%	92,50%
Validasi Loss	0,6882	0,7381
F1-Score Macro	0,92	0,93
Precision Macro	0,92	0,93
Recall Macro	0,91	0,92
Total Parameter	7,37 juta	25,84 juta
Ukuran Model	28,24 MB	98,56 MB

Dari sisi efisiensi komputasional (Tabel 5), *EfficientNetV2B0* memiliki keunggulan yang substansial: total parameternya hanya 7,37 juta (28,14 MB) dibandingkan *ResNet50* yang

mencapai 25,84 juta (98,56 MB), atau sekitar 3,5 kali lebih besar. Perbedaan ini menjadikan EfficientNetV2B0 lebih sesuai untuk deployment pada perangkat edge atau smartphone dengan kapasitas memori dan komputasi terbatas. Selain itu, meskipun val loss ResNet50 (0,7381) lebih tinggi dibandingkan EfficientNetV2B0 (0,6882), akurasi akhir ResNet50 tetap lebih baik, mengindikasikan bahwa kalibrasi probabilitas kedua model berbeda meskipun keputusan klasifikasi ResNet50 lebih akurat secara keseluruhan.

Temuan ini sejalan dengan karakteristik teoritis masing-masing arsitektur. ResNet50 dengan 50 lapisan konvolusi dan mekanisme residual connection yang dalam mampu mempelajari representasi fitur yang lebih kaya dan hierarkis, sehingga lebih handal untuk dataset dengan variasi intra-kelas yang tinggi seperti citra klinis PMK [6]. Sebaliknya, EfficientNetV2B0 yang dirancang dengan prinsip compound scaling dan menggunakan Fused-MBConv block mampu mencapai akurasi tinggi dengan parameter jauh lebih sedikit, menjadikannya pilihan lebih praktis jika pertimbangan efisiensi menjadi prioritas [5] [10].

IV. KESIMPULAN

Penelitian ini berhasil membandingkan dua model deep learning, EfficientNetV2B0 dan ResNet50, dalam tugas klasifikasi citra Penyakit Mulut dan Kuku (PMK) pada sapi menggunakan dataset empat kelas berbasis lokasi gejala. ResNet50 terbukti unggul secara akurasi dengan nilai 92,50% dan F1-score makro 0,93, dibandingkan EfficientNetV2B0 yang mencapai akurasi 91,25% dan F1-score makro 0,92. Perbedaan yang paling menonjol terdapat pada kemampuan deteksi kelas Mulut_PMK, di mana recall ResNet50 (0,96) secara signifikan melampaui EfficientNetV2B0 (0,83).

Meskipun demikian, EfficientNetV2B0 menawarkan keunggulan efisiensi yang signifikan dengan ukuran model hanya 28,14 MB ($3,5\times$ lebih kecil dari ResNet50), menjadikannya lebih potensial untuk implementasi pada sistem deteksi berbasis perangkat mobile di lapangan. Untuk penelitian selanjutnya, disarankan untuk memperluas dataset dengan citra dari berbagai kondisi lapangan yang lebih beragam, mengeksplorasi arsitektur yang lebih ringan seperti MobileNetV3 atau EfficientNetV2B1, serta mengintegrasikan teknik interpretabilitas seperti Grad-CAM untuk meningkatkan kepercayaan pengguna terhadap sistem.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Ibu Dosen Ratih Kumalasari Niswatin dan Bapak Dosen Danar Putra Pamungkas atas dukungan dan bimbingan dalam pelaksanaan penelitian ini.

DAFTAR PUSTAKA

- [1] R. Prasetya, E. Sudarsono, D. Peternakan, K. Hewan, and K. Lamongan, "Kajian Epidemiologi Kejadian Diduga Penyakit Mulut dan Kuku di Kabupaten Lamongan Epidemiological Study of Suspected Occurrence of Foot and Mouth Disease in Lamongan Regency." doi: <https://doi.org/10.20473/jbm.v11i1.37197>.
- [2] S. Alexandersen, Z. Zhang, A. I. Donaldson, and A. J. M. Garland, "The Pathogenesis and Diagnosis of Foot-and-Mouth Disease," *J. Comp. Pathol.*, vol. 129, no. 1, pp. 1–36, Jul. 2003, doi: 10.1016/S0021-9975(03)00041-0.

- [3] M. J. Grubman and B. Baxt, "Foot-and-Mouth Disease," Apr. 2004. doi: 10.1128/CMR.17.2.465-493.2004.
- [4] I. Dittrich, M. Gertz, B. Maassen-Francke, K. H. Krudewig, W. Junge, and J. Krieter, "Combining multivariate cumulative sum control charts with principal component analysis and partial least squares model to detect sickness behaviour in dairy cattle," *Comput. Electron. Agric.*, vol. 186, p. 106209, Jul. 2021, doi: 10.1016/J.COMPAG.2021.106209.
- [5] M. Tan and Q. V Le, "EfficientNetV2: Smaller Models and Faster Training," Jul. 01, 2021, *PMLR*. Accessed: Dec. 10, 2025. [Online]. Available: <https://proceedings.mlr.press/v139/tan21a.html>
- [6] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," Dec. 2015, doi: <https://doi.org/10.48550/arXiv.1512.03385>.
- [7] C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," *J. Big Data*, vol. 6, no. 1, Dec. 2019, doi: 10.1186/s40537-019-0197-0.
- [8] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," Jan. 2017, doi: 10.48550/arXiv.1412.6980.
- [9] A. Fatur Rahman, D. Anggreani, and R. Yuslana Bakt, "Model Deep Learning Berbasis Convolutional Neural Network Untuk Identifikasi Stroke Iskemik Pada Citra CT Scan," *Jurnal Pustaka AI (Pusat Akses Kajian Teknologi Artificial Intelligence)*, vol. 5, no. 2, pp. 290–297, Aug. 2025, doi: 10.55382/jurnalpustakaai.v5i2.1150.
- [10] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Commun. ACM*, vol. 60, no. 6, pp. 84–90, Jun. 2017, doi: 10.1145/3065386.