

Analisis Perbandingan VGG-16 dan ResNet50 untuk Klasifikasi *Multilabel* Gambar Kerbau Toraja: Pendekatan *Deep Learning*

¹Tri Anita Resky Ramadhani, ²Abdul Rachman Manga', ³Purnawansyah

^{1,2,3}Universitas Muslim Indonesia, Jl. Urip Sumohardjo KM.05, Makassar, Indonesia
e-mail: trianitareskyramadhani@gmail.com

Abstrak

Penelitian ini bertujuan untuk membandingkan performa dua model *Convolutional Neural Networks* (CNN), yaitu VGG-16 dan ResNet50, dalam tugas klasifikasi *multilabel* gambar kerbau. *Dataset* yang digunakan terdiri dari 2009 gambar kerbau Toraja yang dilabeli dengan lima kategori: manusia, motor, truk, hewan liar, dan kerbau. Model-model CNN dilatih menggunakan 30 *epoch* dan dievaluasi dengan menggunakan metrik *loss*, akurasi, presisi, *recall*, dan *f1-score*. Hasil eksperimen menunjukkan bahwa VGG-16 secara konsisten mengungguli ResNet50 dengan mencapai akurasi tertinggi 0.95 pada set pelatihan dan 0.94 pada set validasi, serta *f1-score* 0.94 pada set pelatihan dan 0.92 pada set validasi. Temuan ini mengindikasikan bahwa arsitektur CNN yang lebih dalam dan terstruktur, seperti VGG-16, memberikan hasil yang lebih baik dalam mengklasifikasikan gambar-gambar kerbau dengan variasi label yang kompleks.

Kata kunci: *Deep Learning*; CNN; VGG; ResNet; klasifikasi *multilabel*; gambar kerbau toraja

Abstract

This study aims to compare the performance of two Convolutional Neural Networks (CNN) models, namely VGG-16 and ResNet50, in the task of multilabel classification of buffalo images. The Dataset used consists of 2009 buffalo images labeled with five categories: human, motorcycle, truck, wild animal, and buffalo. The CNN models were trained using 30 epochs and evaluated using loss, accuracy, Precision, recall, and f1-score metrics. The experimental results show that VGG-16 consistently outperforms ResNet50 by achieving the highest accuracy of 0.95 in the training set and 0.94 in the validation set, and f1-score of 0.94 in the training set and 0.92 in the validation set. These findings indicate that a deeper and more structured CNN architecture, such as VGG-16, provides better results in classifying buffalo images with complex label variations.

Keywords: *Deep Learning*; CNN; VGG; ResNet; *multilabel classification*; toraja buffalo image

Diterima : Juli 2024

Disetujui : November 2024

Dipublikasi : Desember 2024

©2024 Tri Anita Resky Ramadhani, Abdul Rachman Manga', Purnawansyah
Under the license CC BY-SA 4.0

Pendahuluan

Klasifikasi gambar telah menjadi salah satu bidang yang penting dalam pengolahan citra dan pembelajaran mesin (Simarmata et al., 2024). Dalam beberapa dekade terakhir, perkembangan teknologi *Convolutional Neural Networks* (CNN) telah mengubah cara kita menganalisis dan memahami gambar digital (Technology, n.d.), (Sun, 2020). CNN telah menunjukkan keefektifannya dalam berbagai aplikasi, mulai dari pengenalan wajah hingga diagnostik medis (Deepak, 2019), (Polsinelli, 2020). Dalam konteks penelitian ini, fokusnya adalah pada klasifikasi *multilabel* gambar kerbau, khususnya kerbau Toraja yang memiliki nilai budaya dan ekonomi yang tinggi di Indonesia, terutama di wilayah Sulawesi Selatan. Kerbau Toraja seringkali diidentifikasi

dengan berbagai objek lain dalam lingkungan mereka, seperti manusia, kendaraan, dan hewan liar, yang membuat tugas klasifikasi ini menjadi lebih kompleks.

Masalah utama yang ingin dipecahkan dalam penelitian ini adalah bagaimana mengembangkan model klasifikasi *multilabel* yang efektif untuk gambar kerbau. Klasifikasi *multilabel* merupakan tantangan yang signifikan karena satu gambar dapat berisi lebih dari satu label, yang berbeda dengan klasifikasi gambar tradisional yang biasanya hanya memiliki satu label per gambar (Han, 2022),(Sharif, 2022). Selain itu, gambar kerbau dalam *Dataset* ini seringkali memiliki latar belakang yang rumit dan keberadaan objek lain seperti manusia, motor, truk, dan hewan liar. Kompleksitas ini membutuhkan pendekatan yang kuat dan canggih untuk memastikan akurasi klasifikasi yang tinggi.

Tujuan utama dari penelitian ini adalah untuk menerapkan dan membandingkan dua model CNN yang populer, yaitu VGG-16 dan ResNet50, dalam tugas klasifikasi *multilabel* gambar kerbau. Penelitian ini bertujuan untuk menentukan model mana yang lebih efektif dalam mengidentifikasi dan mengklasifikasikan label-label yang ada dalam gambar, yaitu manusia, motor, truk, hewan liar, dan kerbau. Selain itu, penelitian ini juga bertujuan untuk mengukur performa model-model tersebut berdasarkan metrik-metrik evaluasi seperti *loss*, akurasi, presisi, *recall*, dan *f-measure*. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam bidang klasifikasi gambar *multilabel*.

Penelitian ini difokuskan pada beberapa pertanyaan penelitian utama: Bagaimana performa model VGG-16 dibandingkan dengan ResNet50 dalam tugas klasifikasi *multilabel* gambar kerbau? Apakah model yang lebih dalam seperti ResNet50 dengan *residual connections* dapat memberikan akurasi yang lebih tinggi dibandingkan dengan VGG-16? Selain itu, bagaimana metrik-metrik evaluasi seperti presisi, *recall*, dan *f-measure* menunjukkan kemampuan kedua model dalam menangani kompleksitas *Dataset* ini? Hipotesis yang diajukan adalah bahwa model ResNet50, karena arsitekturnya yang lebih kompleks, akan menunjukkan performa yang lebih baik dalam hal akurasi dan *recall* dibandingkan dengan VGG-16.

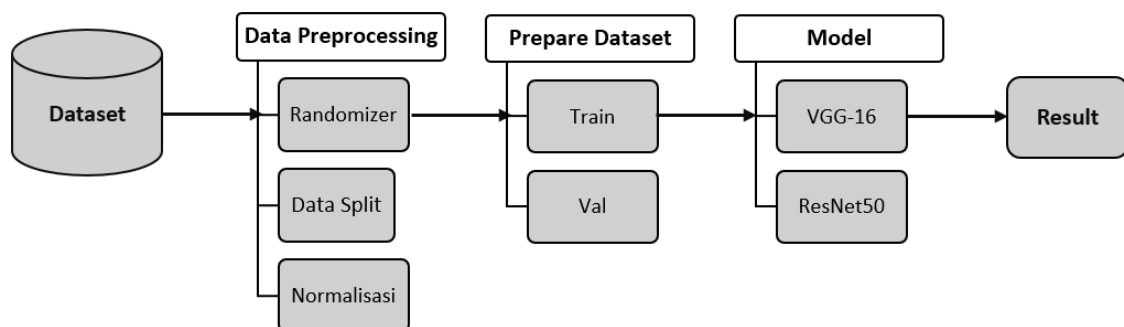
Ruang lingkup penelitian ini mencakup pengumpulan *Dataset* gambar kerbau dengan label *multilabel* yang mencakup manusia, motor, truk, hewan liar, dan kerbau, serta penerapan dua model CNN, VGG-16 dan ResNet50, pada *Dataset* tersebut. Penelitian ini dibatasi pada penggunaan *Dataset* yang terdiri dari 2009 gambar, yang telah dilabeli secara manual. Selain itu, model dilatih selama 30 *epoch* untuk menjaga konsistensi dalam perbandingan performa. Keterbatasan penelitian ini termasuk ukuran *Dataset* yang relatif kecil dan potensi bias dalam pelabelan data. Penelitian ini juga

terbatas pada dua model CNN dan tidak mengeksplorasi model-model lain atau teknik *augmentasi* data yang lebih canggih.

Penelitian ini memberikan beberapa kontribusi penting dalam bidang klasifikasi gambar *multilabel*. Pertama, penelitian ini memberikan evaluasi komprehensif dari dua model CNN, VGG-16 dan ResNet50, dalam tugas klasifikasi *multilabel* pada gambar kerbau. Kedua, hasil penelitian ini dapat digunakan sebagai dasar untuk pengembangan sistem pengawasan dan manajemen peternakan yang lebih cerdas dan efisien, khususnya dalam konteks budaya Toraja. Ketiga, penelitian ini menyediakan *Dataset* berlabel yang dapat digunakan untuk penelitian lanjutan dalam bidang pengolahan citra dan pembelajaran mesin. Akhirnya, penelitian ini berkontribusi pada literatur ilmiah dengan menyediakan analisis mendalam tentang performa model CNN dalam tugas klasifikasi gambar yang kompleks.

Metode

Penelitian ini menggunakan desain *eksperimental* dengan pendekatan kuantitatif untuk mengevaluasi performa dua model *Convolutional Neural Networks* (CNN), yaitu VGG-16 dan ResNet50, dalam tugas klasifikasi *multilabel* gambar kerbau. Desain penelitian ini mencakup pengumpulan *Dataset*, pelabelan data, pelatihan model, dan evaluasi performa model menggunakan metrik-metrik tertentu seperti yang terlihat pada Gambar 1. Setiap langkah dalam penelitian ini dirancang untuk memastikan hasil yang dapat diandalkan dan valid, dengan fokus pada penerapan metode pembelajaran mendalam yang efisien dan akurat.



Gambar 1. Tahapan Penelitian

Pengumpulan *Dataset*

Dataset yang digunakan dalam penelitian ini terdiri dari 2009 gambar kerbau yang diambil dari berbagai sumber dan kondisi lingkungan. Setiap gambar dilabeli dengan lima kategori: manusia, motor, truk, hewan liar, dan kerbau seperti yang terlihat pada Gambar 2. Label-label ini mencerminkan objek-objek yang sering muncul bersama kerbau dalam gambar. Gambar-gambar ini dipilih secara acak namun representatif untuk

memastikan variasi yang cukup dalam *Dataset*. Data ini kemudian dibagi menjadi set pelatihan (80%) dan set validasi (20%) untuk melatih dan menguji model-model CNN.



Gambar 2. *Dataset* Kerbau Toraja

Data Preprocessing

Randomisasi

Randomisasi dilakukan pada data untuk memastikan bahwa pembagian antara data *training* dan validasi tidak mengandung bias yang tidak diinginkan (Berrahal, 2021). Dengan menerapkan metode *randomisasi*, setiap pengamatan atau sampel memiliki peluang yang sama untuk dimasukkan ke dalam setiap subset data. *Praktik* ini sangat penting untuk mencegah *overfitting* atau *underfitting* pada model (Sengupta, 2020). Dengan memastikan bahwa *randomisasi* diterapkan secara konsisten, kita dapat menjamin bahwa karakteristik dan variasi dari setiap subset data mencerminkan secara adil keseluruhan *Dataset*. Dengan kata lain, hal ini membantu model untuk tidak terlalu terfokus pada pola-pola khusus yang mungkin muncul dalam urutan tertentu dari *Dataset*, sehingga memungkinkannya untuk belajar fitur-fitur yang lebih umum dan relevan.

Data Split

Pemisahan data untuk pelatihan dan validasi adalah aspek penting dalam mengevaluasi kinerja model (He, 2020). Pembagian data yang tidak optimal dapat menyebabkan model menghafal data, yang berpotensi menghasilkan generalisasi yang kurang baik. Dalam penelitian ini, data dipisahkan menggunakan proporsi di mana 80% digunakan untuk pelatihan dan 20% untuk validasi, dimana jumlah keseluruhan *Dataset* sebanyak 2009 sampel, yang dibagi menjadi 1608 sampel untuk data pelatihan dan 401 sampel untuk data validasi.

Normalisasi

Dalam proses *pra*-pemrosesan data, kami menerapkan metode normalisasi citra menggunakan pendekatan min-max, yang bertujuan untuk mengubah rentang nilai dalam *Dataset* menjadi 0 hingga 1. Dalam konteks gambar, ini dilakukan dengan mengatur ulang nilai piksel pada gambar agar nilai terendah menjadi 0 dan nilai tertinggi menjadi 1. Persamaan normalisasi min-max dapat dirumuskan sebagai berikut (1):


$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Dalam persamaan ini dijelaskan proses normalisasi Min-Max dengan menghitung perbedaan antara nilai asli x dan nilai minimum x_{min} , kemudian hasilnya dibagi dengan rentang nilai $x_{max} - x_{min}$. Dampak dari persamaan ini adalah menghasilkan nilai baru x_{norm} yang selalu berada dalam rentang 0 hingga 1.

Deep Learning

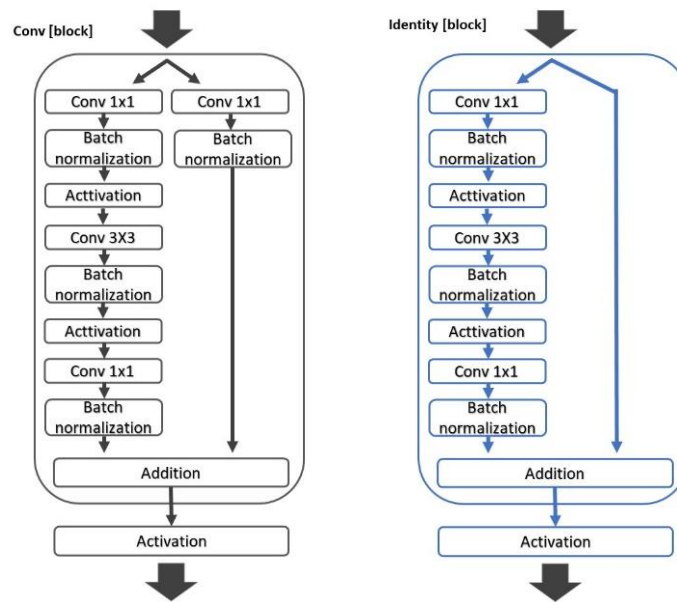
Setelah data dikumpulkan dan *pra*-pemroses, langkah selanjutnya adalah pelatihan dan evaluasi model. Proses ini melibatkan beberapa langkah penting berikut.

Model VGG-16 ini terdiri dari 16 lapisan (*convolutional*, *pooling*, dan *fully connected layers*). Arsitektur ini dilatih menggunakan *optimizer Adam* dengan *learning rate* 0.001 (Song, 2021),(Kaur, 2019),(Younis, 2022). Fungsi *loss* yang digunakan adalah *binary cross-entropy* karena ini adalah tugas klasifikasi *multilabel* (Abdel-Khalek, 2023). Arsitektur dari model VGG-16 dapat dilihat pada Gambar 3.



Gambar 3. Arsitektur VGG-16

Model ResNet50 ini terdiri dari 50 lapisan dengan *residual connections* yang membantu mengatasi masalah *vanishing gradients* (Wu, 2019),(Reddy, 2019). Model ini juga dilatih menggunakan *optimizer Adam* dan fungsi *loss binary cross-entropy*. Arsitektur dari model ResNet50 dapat dilihat pada Gambar 4.



Gambar 4. Arsitektur ResNet50

Formula *binary cross-entropy loss* dapat dilihat pada persamaan (2):

$$Loss = -\frac{1}{N} \sum_{i=1}^N (y_i \log(p_i) + (1 - y_i) \log(1 - p_i)) \quad (2)$$

Dimana y_i adalah label sebenarnya dengan p_i adalah probabilitas prediksi model.

Evaluation Metrics

Pada evaluasi performa model, metrik-metrik utama yang digunakan meliputi *loss*, akurasi, presisi, *recall*, dan *F-measure*. *Loss* digunakan untuk mengukur seberapa baik model memprediksi label yang benar (Lin, 2019), sementara akurasi mengindikasikan persentase prediksi yang tepat dari model (Kim, 2019). Presisi mengukur ketepatan prediksi terhadap kelas positif (Liu, 2019), sementara *recall* mengevaluasi kemampuan model dalam menangkap semua instance kelas positif (Jamil et al., 2023). *F-measure* digunakan untuk menggabungkan presisi dan *recall* menjadi satu metrik kinerja tunggal (Dickel et al., 2019). Proses pelatihan dilakukan selama 30 *epoch* untuk memastikan konvergensi model dan mengurangi kemungkinan *overfitting*, dengan memantau metrik evaluasi pada set pengujian setiap *epoch* untuk mengevaluasi peningkatan kinerja secara bertahap. Formula dari beberapa *metrics* dapat dilihat pada persamaan (3).

$$Accuracy = \frac{True\ Positives(TP) + True\ Negatives(TN)}{TP + TN + FP + FN}$$

$$Precision = \frac{True\ Positives(TP)}{True\ Positives(TP) + False\ Positives(FP)} \quad (3)$$

$$Recall = \frac{True\ Positives(TP)}{True\ Positives(TP) + False\ Negatives(FN)}$$

$$F - measure = 2 \frac{Presisi \times Recall}{Presisi + Recall}$$

Hasil dan Pembahasan

Hasil

Penelitian ini menggunakan dua model *Convolutional Neural Networks* (CNN), yaitu VGG-16 dan ResNet50, untuk klasifikasi *multilabel* gambar kerbau. Model-model ini dilatih menggunakan *Dataset* yang terdiri dari 2009 gambar kerbau yang telah dilabeli dengan lima kategori: manusia, motor, truk, hewan liar, dan kerbau. Proses pelatihan model dilakukan selama 30 *epoch* dan performanya dievaluasi menggunakan metrik-metrik seperti *loss*, akurasi, presisi, *recall*, dan *f1-score*. Pada Tabel 1 merangkum hasil performa kedua model:

Tabel 1. Hasil Perbandingan Performa

Model	Loss		Acc		Precision		Recall		F1-score	
	Train	Val	Train	Val	Train	Val	Train	Val	Train	Val
Resnet50	0.18	0.25	0.80	0.79	0.93	0.88	0.93	0.93	0.93	0.91
Vgg-16	0.12	0.17	0.95	0.94	0.94	0.89	0.93	0.94	0.94	0.92

Tabel 1 menunjukkan bahwa analisis performa model VGG-16 dan ResNet50 pada tugas klasifikasi gambar, VGG-16 terbukti unggul dalam hal akurasi. Hal ini ditunjukkan oleh akurasi validasi VGG-16 yang mencapai 0.94, jauh lebih tinggi dibandingkan dengan ResNet50 yang hanya 0.79. Selain itu, VGG-16 juga memiliki *F1-score* validasi yang lebih tinggi sebesar 0.94 dan nilai *loss* validasi yang lebih rendah yaitu 0.17.

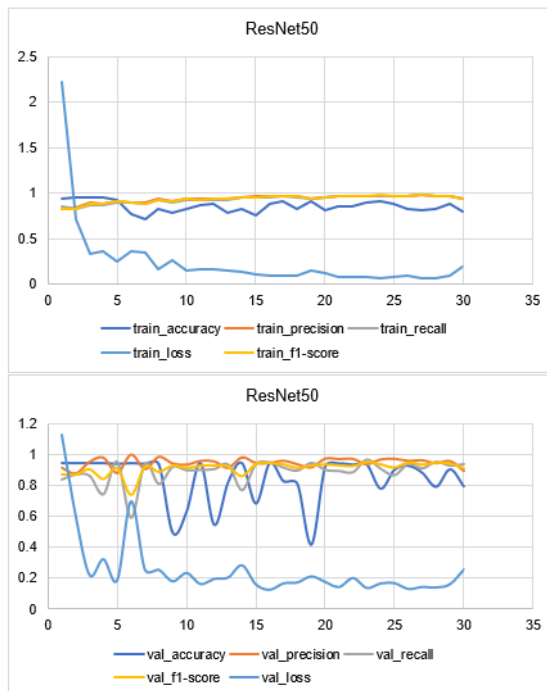
Keunggulan VGG-16 berasal dari beberapa faktor. Pertama, kedalaman jaringan VGG-16 yang terdiri dari 16 lapisan konvolusi relatif lebih sederhana dibandingkan dengan ResNet50 yang memiliki 50 lapisan. Struktur yang lebih sederhana ini membantu meningkatkan akurasi dan mengurangi risiko *overfitting*. Kedua, penggunaan filter konvolusi 3x3 yang konsisten di semua lapisan VGG-16, berbeda dengan ResNet50 yang menggunakan filter dengan berbagai ukuran, berkontribusi pada stabilitas dan efisiensi komputasi yang lebih baik. Ketiga, strategi *pooling* yang digunakan oleh VGG-16 juga lebih konsisten, yaitu menggunakan *pooling* maksimum 2x2 setelah setiap dua lapisan konvolusi, sementara ResNet50 menggunakan kombinasi *pooling* maksimum 1x1 dan 2x2. Konsistensi penggunaan *pooling* maksimum 2x2 pada VGG-16 membantu mengurangi dimensi data dan meningkatkan efisiensi.

Namun, penting untuk diingat bahwa performa model dapat bervariasi tergantung pada *Dataset* dan tugas yang spesifik. Faktor lain seperti jumlah parameter, kecepatan

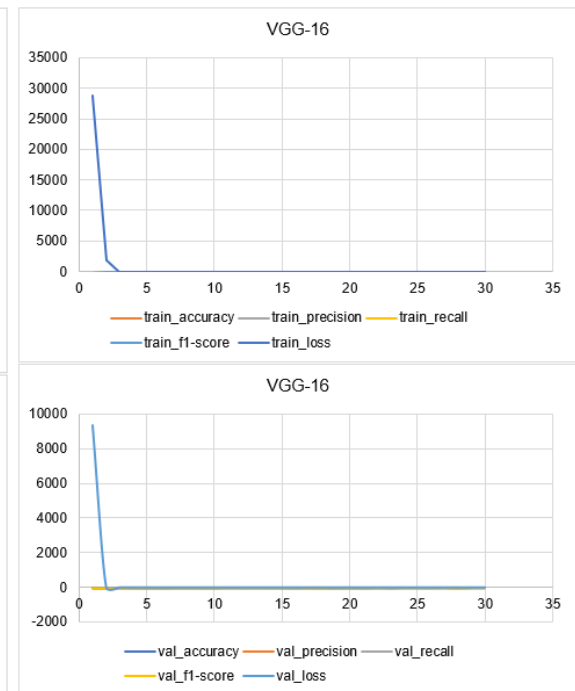
pelatihan, dan konsumsi daya juga perlu dipertimbangkan saat memilih model yang tepat.

Secara keseluruhan, VGG-16 merupakan pilihan yang lebih baik untuk tugas klasifikasi gambar yang membutuhkan akurasi tinggi. Sementara itu, ResNet50 mungkin lebih unggul dalam hal kecepatan pelatihan atau konsumsi daya..

Pembahasan



Gambar 5. Hasil Visualisasi ResNet50



Gambar 6. Hasil Visualisasi VGG-16

Gambar 5 menunjukkan bahwa model ResNet50 belajar untuk mengklasifikasikan data pelatihan dengan benar, tetapi mungkin *overfitting* pada data pelatihan. Hal ini berarti bahwa model tidak berkinerja baik pada data baru yang tidak dilihat selama pelatihan. Metrik validasi menunjukkan bahwa model awalnya belajar untuk menggeneralisasi dengan baik, tetapi kemudian mulai *overfitting*.

Gambar 6 menunjukkan performa pelatihan yang baik dengan peningkatan akurasi dan presisi pelatihan. Namun, potensi *overfitting* terlihat pada tren performa validasi, di mana model VGG-16 mengalami penurunan kemampuan untuk mengidentifikasi contoh positif secara akurat pada data baru.

Hasil penelitian ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa VGG-16 seringkali memberikan performa yang baik dalam tugas klasifikasi gambar (Bi, 2021). Penelitian ini juga memperkuat teori bahwa arsitektur yang lebih dalam dan terstruktur dapat menangani kompleksitas gambar dengan lebih baik dibandingkan arsitektur yang menggunakan *residual connections* seperti ResNet50

(Yildiz, 2021). Hasil penelitian ini memiliki implikasi *praktis* yang signifikan, khususnya dalam pengembangan sistem pengawasan dan manajemen peternakan yang lebih cerdas. Dengan menggunakan model VGG-16, sistem dapat lebih akurat dalam mengidentifikasi dan mengklasifikasikan berbagai objek dalam lingkungan peternakan, yang dapat membantu dalam pengelolaan sumber daya dan pemantauan kesehatan ternak.

Salah satu keterbatasan utama dari penelitian ini adalah ukuran *Dataset* yang relatif kecil, yaitu 2009 gambar. Ukuran *Dataset* yang lebih besar dapat memberikan hasil yang lebih akurat dan robust. Selain itu, penelitian ini hanya membandingkan dua model CNN, sementara masih banyak model lain yang mungkin memberikan performa yang lebih baik.

Penelitian selanjutnya disarankan untuk mengeksplorasi penggunaan *Dataset* yang lebih besar dan lebih bervariasi untuk meningkatkan generalisasi model. Selain itu, pengujian model-model CNN lainnya, seperti EfficientNet atau DenseNet, dapat memberikan wawasan tambahan tentang model mana yang paling efektif untuk tugas klasifikasi *multilabel* gambar kerbau. Eksplorasi teknik *augmentasi* data yang lebih canggih juga dapat membantu meningkatkan performa model.

Kesimpulan

Penelitian ini mengevaluasi performa dua model *Convolutional Neural Networks* (CNN), VGG-16 dan ResNet50, dalam tugas klasifikasi *multilabel* gambar kerbau Toraja. Hasil penelitian menunjukkan bahwa model VGG-16 secara konsisten menunjukkan performa yang lebih baik dibandingkan dengan ResNet50 dalam semua metrik evaluasi yang digunakan, termasuk *loss*, akurasi, presisi, *recall*, dan *f1-score*. VGG-16 mencapai akurasi sebesar 0.95 pada set pelatihan dan 0.94 pada set validasi, dengan *f1-score* sebesar 0.94 pada set pelatihan dan 0.92 pada set validasi, menunjukkan keunggulan yang konsisten dibandingkan ResNet50. Temuan ini menjawab hipotesis bahwa model CNN yang lebih dalam dan terstruktur lebih efektif dalam tugas klasifikasi *multilabel* gambar kerbau, dengan kontribusi untuk pemahaman lebih lanjut dalam penerapan teknologi *Deep Learning* dalam sistem pengawasan dan manajemen peternakan. Rekomendasi untuk penelitian selanjutnya mencakup penggunaan *Dataset* yang lebih besar dan bervariasi, eksplorasi model CNN lainnya seperti EfficientNet atau DenseNet, serta penerapan teknik *augmentasi* data yang lebih canggih untuk meningkatkan performa dan generalisasi model dalam konteks klasifikasi gambar kerbau.

Daftar Pustaka

- Abdel-Khalek, S. (2023). Quantum neural network-based *multilabel* image classification in high-resolution unmanned aerial vehicle imagery. *Soft Computing*, 27(18), 13027–13038. doi: 10.1007/s00500-021-06460-3
- Berrahal, M. (2021). Augmented *binary* multi-labeled CNN for *practical* facial attribute classification. *Indonesian Journal of Electrical Engineering and Computer Science*, 23(2), 973–979. doi: 10.11591/ijeecs.v23.i2.pp973-979
- Bi, Z. (2021). Improved VGG model-based efficient traffic sign recognition for safe driving in 5G scenarios. *International Journal of Machine Learning and Cybernetics*, 12(11), 3069–3080. doi: 10.1007/s13042-020-01185-5
- Deepak, S. (2019). Brain tumor classification using deep CNN features via transfer learning. *Computers in Biology and Medicine*, 111. doi: 10.1016/j.compbiomed.2019.103345
- Dickel, H., Podolskiy, V., & Gerndt, M. (2019). Evaluation of autoscaling *metrics* for (stateful) IoT gateways. *2019 IEEE 12th Conference ...*
- Han, S. (2022). The *multilabel* fault diagnosis model of bearing based on integrated *convolutional* neural network and gated recurrent unit. *International Journal of Intelligent Computing and Cybernetics*, 15(3), 401–413. doi: 10.1108/IJICC-08-2021-0153
- He, K. (2020). Mask R-CNN. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(2), 386–397. doi: 10.1109/TPAMI.2018.2844175
- Jamil, M., Warsito, B., Wibowo, A., & Kiswanto, K. (2023). Diabetes Mellitus Early Detection Simulation using The K-Nearest Neighbors Algorithm with Cloud-Based Runtime (COLAB). *ILKOM Jurnal Ilmiah*, 15(2), 215–221. Retrieved from <https://jurnal.fikom.umi.ac.id/index.php/ILKOM/article/view/1510>
- Kaur, T. (2019). Automated brain image classification based on VGG-16 and transfer learning. In Proceedings - 2019 International Conference on Information Technology, ICIT 2019 (pp. 94–98). doi: 10.1109/ICIT48102.2019.00023
- Kim, H. G. (2019). Improvement diagnostic *accuracy* of sinusitis recognition in paranasal sinus X-ray using multiple *Deep Learning* models. *Quantitative Imaging in Medicine and Surgery*, 9(6), 942–951. doi: 10.21037/qims.2019.05.15
- Lin, Z. (2019). A unified matrix-based *convolutional* neural network for fine-grained image classification of wheat leaf diseases. *IEEE Access*, 7, 11570–11590. doi: 10.1109/ACCESS.2019.2891739
- Liu, Z. (2019). The applications of radiomics in *Precision* diagnosis and treatment of oncology: Opportunities and challenges. In Theranostics (Vol. 9, Issue 5, pp.

- 1303–1322). doi: 10.7150/thno.30309
- Polsinelli, M. (2020). A light CNN for detecting COVID-19 from CT scans of the chest. *Pattern Recognition Letters*, 140, 95–100. doi: 10.1016/j.patrec.2020.10.001
- Reddy, A. S. B. (2019). Transfer learning with RESNET-50 for malaria cell-image classification. In Proceedings of the 2019 IEEE International Conference on Communication and Signal Processing, ICCSP 2019 (pp. 945–949). doi: 10.1109/ICCSP.2019.8697909
- Sengupta, S. (2020). A review of *Deep Learning* with special emphasis on architectures, applications and recent trends. *Knowledge-Based Systems*, 194. doi: 10.1016/j.knosys.2020.105596
- Sharif, O. (2022). M-BAD: A *Multilabel Dataset* for Detecting Aggressive Texts and Their Targets. In CONSTRAINT 2022 - 2nd Workshop on Combating Online Hostile Posts in Regional Languages during Emergency Situation, Proceedings of the Workshop (pp. 75–85). Retrieved from https://api.elsevier.com/content/abstract/scopus_id/85137428853
- Simarmata, A. M., Putra, A. Z., & Husein, A. M. (2024). Penerapan Metode Computer Vision Dalam Klasifikasi Buah Jeruk Menggunakan Teknik Image Pre-Processing. *Jurnal Data Science Indonesia*, 3(2), 110–116.
- Song, Z. (2021). Attention-based multi-label neural networks for integrated prediction and interpretation of twelve widely occurring RNA modifications. *Nature Communications*, 12(1). doi: 10.1038/s41467-021-24313-3
- Sun, Y. (2020). Automatically Designing CNN Architectures Using the Genetic Algorithm for Image Classification. *IEEE Transactions on Cybernetics*, 50(9), 3840–3854. doi: 10.1109/TCYB.2020.2983860
- Technology, E. (n.d.). *Strengthening Student's Competencies as the Z Generation and Future Change Agents: Learning from Extension Science and Communication of Innovation Course (KPM121C)*.
- Wu, Z. (2019). Wider or Deeper: Revisiting the ResNet Model for Visual Recognition. *Pattern Recognition*, 90, 119–133. doi: 10.1016/j.patcog.2019.01.006
- Yildiz, C. (2021). An improved residual-based *convolutional* neural network for very short-term wind power forecasting. *Energy Conversion and Management*, 228. doi: 10.1016/j.enconman.2020.113731
- Younis, A. (2022). Brain Tumor Analysis Using *Deep Learning* and VGG-16 Ensembling Learning Approaches. *Applied Sciences (Switzerland)*, 12(14). doi: 10.3390/app12147282