JURNAL NASIONAL ILMU KOMPUTER

Jurnal Nasional Ilmu Komputer
e-ISSN: 2746-1343
Vol. 5, No. 3, Agustus 2024

Optimisasi Hyperparameter pada Model Klasifikasi Jenis Bunga dengan arsitektur MobileNetV3-Small

Lailatuz Zahro[1], Hadi Syaputra[2]*, Serly Oktarina[3], M. Taufik Roseno[4], Edi Supratman[5]

[1234]Program Studi Ilmu Komputer, Universitas Sumatera Selatan
[5]Program Studi Sistem Informasi, Universitas Bina Daram
Penulis Korespondensi : hadisyaputra@uss.ac.id
lailatuz002@students.uss.ac.id, hadisyaputra@uss.ac.id, serlyoktarina@uss.ac.id, mtroseno@gmail.com, edi_supratman@binadarma.ac.id

Informasi Artikel:

Received: 18 Juni 2024, Accepted: 24 Juli 2024, Published: 01 Agustus 2024

Abstract

This study aims to classify various types of flowers using the deep learning method with the Convolutional Neural Networks MobileNetV3-Small architecture. The research stages include data collection and sharing, model training using the MobileNetV3-Small architecture, and testing with evaluation using the Confusion Matrix. Eight models with hyperparameter variations were tested to find the model with the highest accuracy. Model five achieved the highest validation accuracy of 99.25%. The evaluation showed that model five achieved the highest accuracy of 92%. These results indicate that increasing the amount of data and parameter settings can significantly improve model accuracy, indicating that the model can achieve near-perfect performance with more training data and optimal parameter settings. This study uses open-access data from Kaggle covering five types of flowers: daisy, dandelion, rose, sunflower, and tulip.

Keywords: MobileNetV3-Small, *Deep Learning*, *Confusion Matrix*, *Hyperparamter*, *Convolutional Neural Networks*, Bunga.

1. Pendahuluan

Pengolahan Citra Digital merupakan bidang yang mempelajari berbagai teknik untuk mengolah citra, baik foto maupun video, secara digital dengan bantuan komputer [1]. Salah satu aplikasi dalam bidang ini adalah ekstraksi fitur citra untuk mengklasifikasikan jenis gambar [2]. Beragam pendekatan dalam *Machine Learning* (ML) telah diterapkan untuk klasifikasi citra, termasuk metode Naïve Bayes [3], K-Nearest Neighbor [4], dan Random Forest [5]. Dengan kemajuan teknologi, metode Deep Learning (DL), yang merupakan cabang dari ML, mulai banyak digunakan. Beberapa algoritma DL yang umum digunakan meliputi *Convolutional Neural Networks* (CNN) dengan arsitektur seperti AlexNet [6], VGG19 [7], SqueezeNet [8], dan MobileNetV3-Small [9].

Penerapan DL telah meluas ke berbagai bidang, seperti pertanian [10], pengenalan citra wajah [11], kedokteran [12], industri [13], serta media sosial [14]. Salah satu contohnya adalah penggunaan model DL dalam pertanian untuk mengklasifikasikan spesies tanaman, termasuk

Published by: Training & Research Institute JERAMBA ILMU SUKSES

bunga. Bunga memiliki variasi warna dan bentuk yang sangat beragam, sehingga klasifikasi digital menggunakan DL dapat mengatasi masalah identifikasi manual yang memakan waktu. Penelitian oleh Jaya Sumpena (2023) telah dilakukan dengan menggunakan arsitektur DenseNet dan NasNetLarge untuk klasifikasi bunga dengan *dataset* dari Kaggle, yang terdiri dari 4317 citra bunga dari lima kelas (daisy, dandelion, rose, sunflower, tulip). Hasil penelitian menunjukkan akurasi 89% untuk DenseNet dan 86% untuk NasNetLarge [15].

Namun Arsitektur DenseNet dan NasNetLarge memiliki beberapa kelemahan apabila terkait dengan sumber daya komputasi terbatas. DenseNet, meskipun efisien dalam hal penggunaan parameter dan mampu mengurangi masalah *vanishing gradient* dengan koneksi langsung antar layer, cenderung memerlukan lebih banyak memori dan daya komputasi karena kepadatan koneksi tersebut [16]. Hal ini dapat menjadi masalah saat diterapkan pada perangkat dengan sumber daya terbatas. Sementara itu, NasNetLarge, yang merupakan hasil dari pencarian arsitektur *neural network* otomatis, memiliki performa yang sangat baik namun juga sangat kompleks dan berat, sehingga memerlukan lebih banyak daya komputasi dan waktu untuk pelatihan serta inferensi [17]. Sebaliknya, MobileNetV3-Small dirancang khusus untuk efisiensi dan kecepatan pada perangkat dengan sumber daya terbatas, seperti ponsel pintar dan perangkat *edge* [18]. MobileNetV3-Small menggunakan teknik seperti *inverted residuals* dan *linear bottlenecks*, yang membuatnya lebih ringan dan cepat dibandingkan DenseNet dan NasNetLarge, tanpa mengorbankan terlalu banyak akurasi. Oleh karena itu, dalam konteks aplikasi *real-time* dan perangkat dengan keterbatasan sumber daya, MobileNetV3-Small lebih unggul dibandingkan DenseNet dan NasNetLarge.

Berdasarkan keunggulan yang ditunjukkan oleh MobileNetV3-Small maka penelitian ini bertujuan untuk mengeksplorasi penggunaan MobileNetV3-Small dengan *dataset* bunga dari Kaggle yang terdiri dari lima kelas. Selanjutnya untuk melihat kinerja arsitektur MobileNetV3-Small akan dilakukan evaluasi dengan menggunakan *Confusion Matrix* untuk mengukur akurasi klasifikasi.

2. Tinjauan Literatur

Penelitian yang dilakukan oleh Giraddi et al., 2020 [19], menggunakan metode VGG16 dengan *dataset* yang terdiri dari 5 kelas bunga, menunjukkan akurasi validasi 97,67% dan akurasi pengujian 95,00%. Sementara itu, penelitian oleh Han et al., 2020 [20], menggunakan metode InceptionV3 pada *dataset* serupa, menghasilkan akurasi 88,3% dan akurasi pelatihan tanpa model sebesar 60,2%. Selanjutnya, Sumpena, 2023 [15], melakukan klasifikasi bunga menggunakan metode Densenet dan NasLargeNet, dengan hasil akurasi masing-masing 89% dan 86%. Dengan kasus yang berbeda dengan keunggulan berdasarkan sumber daya komputasi terbatas, penelitian yang dilakukan oleh Moon and Lee, 2022 [21], menerapkan arsitektur MobileNetV3-Small dengan objek klasifikasi permukaan kulit mendapatkan nilai akurasi terbaik yaitu 94%. Selanjutnya penelitian dari Budiarto and Utaminingrum, 2023 [9], menggunakan metode MobilenetV3-Small dengan objek klasifikasi permukaan jalan dan lubang dari *Region of Interest* pada layar secara *realtime* dengan rata-rata akurasi 88.076%.

3. Metode Penelitian

Metode penelitian yang di lakukan meliputi pengumpulan data citra bunga, *splitting* data, *hyperparameter tuning*, pelatihan model klasifikasi dengan MobilenetV3, dan evaluasi model dengan melihat hasil klasifikasi menggunakan *confusion matrix*.

3.1 Tahapan Penelitian

Published by: Training & Research Institute JERAMBA ILMU SUKSES

Penelitian ini dilakukan dengan menggunakan data sekunder. Tahapan yang dilakukan sebagai berikut:

- Pengumpulan data: Proses pengumpulan data dilakukan dengan cara mengambil data bunga dari Kaggle, dengan jumlah 5 jenis bunga yaitu 4317 citra bunga, terdiri dari 764 citra bunga daisy, 1052 citra bunga dandelion, 784 citra bunga rose, 733 citra bunga sunflower, dan 984 citra bunga tulip.
- *Splitting* data: Data dibagi menjadi data *train* (70%), data *val* (15%), dan data *test* (15%).
- *Hyperparameter*: Mengatur nilai *hyperparameter* seperti *optimizer*, *batch size*, *learning rate*, *epoch*.
- Pelatihan model: Pelatihan model dilakukan dengan menggunakan arsitektur CNN MobilenetV3-Small.
- Evaluasi menggunakan *Confusion Matrix* untuk mengukur nilai akurasinya.

3.2 Arsitektur Penelitian

Arsitektur yang digunakan dalam penelitian ini adalah arsitektur MobilenetV3-Small Fitur Utama MobileNetV3-Small yaitu *Inverted Residual Blocks*: Seperti pada MobileNetV2, arsitektur ini menggunakan blok residual terbalik yang memperluas dimensi saluran sebelum menguranginya kembali, memungkinkan lebih banyak informasi yang diproses dengan efisiensi yang lebih tinggi. *Squeeze-and-Excitation* (SE) *Block* menambahkan modul perhatian yang secara adaptif merekalibrasi fitur saluran, meningkatkan representasi fitur penting. *Hard-Swish Activation*: Fungsi aktivasi baru ini lebih efisien dan mendukung komputasi yang lebih cepat dibandingkan dengan *Swish activation. Efficient*. Pada tahap akhir, arsitektur ini mengurangi jumlah operasi dan parameter tanpa mengorbankan performa. Berikut ini adalah diagram blok dari arsitektur MobileNetV3:

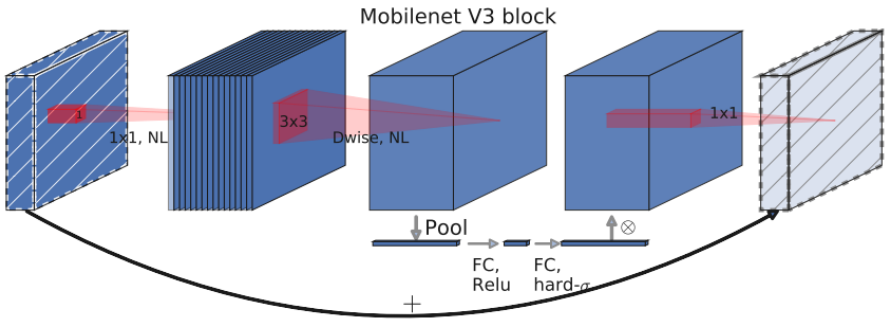

Figure 1. MobileNetV3 Block
Source : Searching for MobileNetV3 [22]

3.3 Dataset

Data yang digunakan dalam penelitian ini diambil dari Kaggle [23], dengan 5 jenis bunga yaitu 4317 citra bunga terdiri dari 764 citra bunga daisy, 1052 citra bunga dandelion, 784 citra bunga rose, 733 citra bunga sunflower, dan 984 citra bunga tulip.

Published by:
Training & Research Institute JERAMBA ILMU SUKSES



Daisy Dandelion Sunflower



Rose Tulip

Figure 2. Jenis Citra Bunga

3.4 Splitting Data

Pada spliting data dibagi menjadi 3 yaitu data *train*, data *val*, dan data *test*. *Dataset* yang digunakan untuk melatih, memvalidasi, dan menguji model klasifikasi bunga. Jumlah total gambar untuk setiap kelas yaitu : Daisy memiliki 534 citra untuk pelatihan, 114 citra untuk validasi, dan 116 citra untuk pengujian. Dandelion memiliki 736 citra untuk pelatihan, 157 citra untuk validasi, dan 159 citra untuk pengujian. Rose memiliki 548 citra untuk pelatihan, 117 citra untuk validasi, dan 119 citra untuk pengujian. Sunflower memiliki 513 citra untuk pelatihan, 109 citra untuk validasi, dan 111 citra untuk pengujian. Terakhir, tulip memiliki 688 citra untuk pelatihan, 147 citra untuk validasi, dan 149 citra untuk pengujian.

Table 1. Pembagian *Dataset*

		Proses	
Kelas	*Train (70%)*	Val (15%)	Test (15%)
Daisy	534	114	116
Dandelion	736	157	159
Rose	548	117	119
Sunflower	513	109	111
Tulip	688	147	149

3.5 Hyperparameter

Pada penelitian ini, beberapa *hyperparameter* utama yang digunakan dalam model pelatihan adalah sebagai berikut. *Optimizer* yang dipilih adalah ADAM, yang dikenal karena kemampuannya untuk menyesuaikan *learning rate* selama pelatihan dan mempercepat konvergensi. *Batch size* yang digunakan adalah 32, yang menyeimbangkan antara efisiensi komputasi dan stabilitas pelatihan. *Learning rate* diatur dengan tiga variasi, yaitu 0.01, 0.001, dan 0.0001, untuk menemukan nilai optimal yang memastikan pelatihan model berjalan dengan baik tanpa terjebak dalam local minima atau divergensi. Jumlah *epoch* yang dicoba juga bervariasi, yaitu 10, 50, dan 100, untuk menentukan berapa banyak iterasi yang dibutuhkan agar model dapat belajar dari data secara efektif. Ukuran citra input yang digunakan adalah 224 x 224 piksel, yang merupakan ukuran umum untuk banyak arsitektur CNN, termasuk MobileNetV3-Small, untuk menjaga keseimbangan antara detail informasi citra dan efisiensi

Published by:
Training & Research Institute JERAMBA ILMU SUKSES

komputasi dapat dilihat dari Table 2.

Table 2. Hyperparamater

Hyperparameter	Konfigurasi
Optimizer	ADAM
Batch Size	32
Learning Rate	[0.01, 0.001, 0.0001]
Epoch	[10, 50, 100]
Input Image Size	224 x 224

4. Hasil dan Pembahasan

4.1 Pelatihan Model

Pelatihan model menggunakan arsitektur mobilenetv3-small, arsitektur ini akan disesuaikan dengan optimasi parameter untuk mencapai model yang paling optimal. Berikut adalah struktur dan sejumlah model yang digunakan dalam penelitian ini (Table 3).

Table 3. Model

Model	Optimizer	Data Train	Data Validasi	Data Test	Learning Rate	Epoch
Satu	ADAM	3019	644	654	0.01	50
Dua	ADAM	3019	644	654	0.01	100
Tiga	ADAM	3019	644	654	0.001	10
Empat	ADAM	3019	644	654	0.001	50
Lima	ADAM	3019	644	654	0.001	100
Enam	ADAM	3019	644	654	0.0001	10
Tujuh	ADAM	3019	644	654	0.0001	50
Delapan	ADAM	3019	644	654	0.0001	100

Penelitian ini menguji delapan model berbeda menggunakan metode ADAM *optimizer* untuk mengklasifikasikan jenis bunga. Data pelatihan, validasi, dan uji yang digunakan masing-masing memiliki ukuran yang telah ditentukan. Variasi *learning rate* dari 0.01 hingga 0.0001 serta jumlah *epochs* antara 10 hingga 100 dieksplorasi untuk setiap model. Optimalisasi hyperparameter seperti memilih *learning rate* yang tepat dan menentukan jumlah *epochs* yang mencukupi terbukti krusial dalam mencapai kinerja terbaik dalam tugas klasifikasi ini.

4.2 Hasil Pelatihan Model

Berdasarkan hasil pelatihan, performa berbagai model dapat dievaluasi dari segi akurasi dan loss pada data pelatihan dan validasi. Model "Lima" menonjol sebagai yang terbaik dengan akurasi pelatihan mencapai 99.25% dan loss sebesar 2.33%. Akurasi validasinya juga tinggi, yaitu 91.56%, dengan loss sebesar 32.77%. Model "Delapan" juga menunjukkan performa yang sangat baik dengan akurasi pelatihan 98.70%, loss 4.48%, akurasi validasi 91.73%, dan loss validasi 29.21%. Di sisi lain, model "Dua" memiliki akurasi pelatihan yang lebih rendah (80.34%) namun akurasi validasinya tinggi (95.44%), meskipun dengan loss validasi yang cukup besar (503.51%). Model "Empat" dan "Tujuh" juga menunjukkan performa yang solid dengan akurasi pelatihan masing-masing 98.61% dan 97.90%, serta akurasi validasi 90.15% dan 91.50%, dengan loss validasi yang lebih rendah yaitu 34.62% dan 27.37%. Model "Satu" memiliki akurasi pelatihan yang baik (93.05%) namun akurasi validasinya lebih rendah (77.55%) dengan loss validasi yang sangat tinggi (362.06%). Model "Tiga" dan "Enam"

Published by:
Training & Research Institute JERAMBA ILMU SUKSES

menunjukkan performa yang cukup baik dengan akurasi pelatihan 93.79% dan 91.42%, serta akurasi validasi 85.06% dan 90.11%, dengan loss validasi yang cukup rendah yaitu 56.03% dan 30.54%. Dari data tersebut, dapat disimpulkan bahwa model "Lima" adalah yang paling unggul, diikuti oleh model "Delapan", karena keduanya memiliki kombinasi akurasi dan loss yang sangat baik pada data pelatihan dan validasi. Meskipun beberapa model lain menunjukkan akurasi yang tinggi pada pelatihan, mereka tidak selalu menunjukkan performa yang sama baiknya pada validasi, yang mengindikasikan potensi overfitting. Dapat dilihat pada hasil pelatihan model

Table 3. Hasil pelatihan Model

Model	Accuracy	Loss	Validation accuracy	Validation loss
Satu	93.05%	20.33%	77.55%	362.06%
Dua	80.34%	13.34%	95.44%	503.51%
Tiga	93.79%	18.22%	85.06%	56.03%
Empat	98.61%	4.20%	90.15%	34.62%
Lima	99.25%	2.33%	91.56%	32.77%
Enam	91.42%	27.02%	90.11%	30.54%
Tujuh	97.90%	6.96%	91.50%	27.37%
Delapan	98.70%	4.48%	91.73%	29.21%

Dari hasil train model dapat dilihat pada Figure 3 diambil dari model "Lima" dengan nilai akurasi tertinggi.

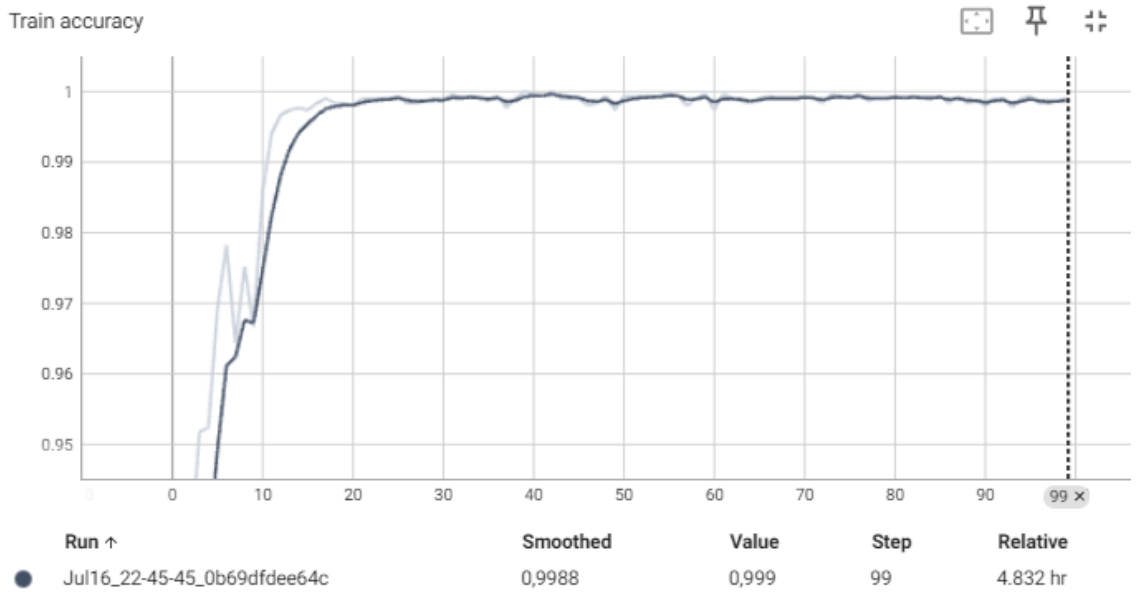

Figure 3. *Grafik Akurasi* pada Model "Lima"

Grafik di atas menunjukkan akurasi pelatihan dari sebuah model selama proses pelatihan. Pada awal pelatihan, akurasi mengalami fluktuasi, tetapi dengan cepat meningkat tajam dalam 20 langkah pertama, mencapai akurasi hampir 1 atau 100%. Setelah itu, akurasi stabil dan tetap mendekati 1 sepanjang sisa langkah pelatihan hingga langkah ke-99. Pada akhir pelatihan,

Published by:
Training & Research Institute JERAMBA ILMU SUKSES

akurasi smoothed tercatat sebesar 0.9988, dengan nilai akurasi terakhir 0.999. Waktu relatif yang dihabiskan untuk pelatihan adalah sekitar 4.832 jam. Grafik ini menunjukkan bahwa model tersebut mencapai tingkat akurasi yang sangat tinggi dengan cepat dan mempertahankannya sepanjang pelatihan, mengindikasikan bahwa model berhasil belajar pola dari data pelatihan dengan baik.

4.3 Evaluasi

Setelah dilakukan uji model yang telah dirancang, akan didapatkan hasil akurasi yang menunjukkan kinerja masing-masing model yang diuji, hasil ini mengetahui model mana yang berhasil mencapai tingkat akurasi terbaik dan model mana yang menunjukkan tingkat akurasi terendah dalam pengujian. Untuk memberikan gambaran yang lebih jelas dan terperinci, berikut tabel hasil akurasi dari uji model tersebut dengan menggunakan confusion matrix. Dengan adanya tabel ini, kita dapat diketahui hasil akurasi masing-masing model.

Table 4. Hasil Uji Model dengan data test

Model	Accuracy
Satu	17%
Dua	82%
Tiga	87%
Empat	91%
Lima	92%
Enam	90%
Tujuh	90%
Delapan	89%

Dari hasil evaluasi yang diberikan, terlihat perbedaan yang signifikan dalam akurasi berbagai model. Model "Satu" menunjukkan performa yang paling rendah dengan akurasi hanya 17%. Sebaliknya, model "Dua" mencatat peningkatan yang cukup besar dengan akurasi 82%. Model "Tiga" lebih baik lagi dengan akurasi 87%. Model "Empat", "Enam", dan "Tujuh" memiliki performa yang sangat mirip, masing-masing dengan akurasi 91%, 90%, dan 90%. Model "Lima" sedikit lebih unggul dengan akurasi 92%, sementara model "Delapan" memiliki akurasi 89%. Dari data tersebut, dapat disimpulkan bahwa model "Lima" menunjukkan performa terbaik, diikuti oleh model "Empat", sedangkan model "Satu" perlu banyak perbaikan untuk mencapai tingkat akurasi yang lebih kompetitif.

	precision	recall	f1-score	support
daisy	0.93	0.88	0.90	116
dandelion	0.95	0.92	0.94	159
rose	0.90	0.90	0.90	119
sunflower	0.94	0.92	0.93	111
tulip	0.87	0.95	0.91	149
accuracy			0.92	654
macro avg	0.92	0.91	0.92	654
weighted avg	0.92	0.92	0.92	654

Figure 4. *Precision*, *Recall*, *F1-Score* dan *Support* pada Model "Lima"

Figure 4, Hasil evaluasi kinerja model untuk klasifikasi lima jenis bunga ditunjukkan pada

Published by:
Training & Research Institute JERAMBA ILMU SUKSES

tabel dengan metrik *precision*, *recall*, *f1-score*, dan *support*. Model ini mencapai *precision* tertinggi pada kelas "dandelion" dengan nilai 0.95 dan *recall* tertinggi pada kelas "*tulip*" dengan nilai 0.95. *F1-score*, yang merupakan harmonisasi dari *precision* dan *recall*, menunjukkan performa yang konsisten di berbagai kelas, dengan nilai tertinggi untuk "dandelion" sebesar 0.94 dan "sunflower" sebesar 0.93. Kelas "daisy" memiliki *precision* 0.93, *recall* 0.88, dan *f1-score* 0.90, sedangkan "rose" menunjukkan nilai *precision* dan *recall* yang sama sebesar 0.90 dengan *f1-score* 0.90. Secara keseluruhan, model mencapai akurasi 0.92 dengan nilai rata-rata (*macro average*) *precision* 0.92, *recall* 0.91, dan *f1-score* 0.92. Nilai *weighted average*, yang mempertimbangkan jumlah *instance* di setiap kelas, juga menunjukkan nilai yang sama, yaitu 0.92. Ini menunjukkan bahwa model memiliki kinerja yang sangat baik dan konsisten dalam mengklasifikasikan jenis-jenis bunga yang diuji.

5. Kesimpulan

Penelitian ini menggunakan *deep learning* untuk mengklasifikasikan jenis-jenis bunga. Penggunaan arsitektur Mobilenetv3-Small dengan delapan konfigurasi model yang berbeda menunjukkan bahwa Model "Lima" mencapai akurasi tertinggi, yakni 92%. Hasil pengujian menunjukkan bahwa pilihan *learning rate* yang tidak terlalu rendah atau tinggi serta jumlah *epochs* yang lebih besar cenderung meningkatkan akurasi. Hal ini menekankan pentingnya penyesuaian *learning rate* yang tepat dan proses pelatihan yang lebih lama untuk mencapai performa model yang optimal.

Penelitian ini tidak menerapkan *preprocecing* yang mendalam seperti *cropping*, *resize* maupun *augmentation* data, maka untuk meningkatkan performa model disarankan untuk melakukan *preprocecing*, menggunakan *learning rate* yang rendah, jumlah *epoch* yang tinggi untuk mencapai performa yang lebih baik.

Referensi

[1] S. Ratna, "PENGOLAHAN CITRA DIGITAL DAN HISTOGRAM DENGAN PHYTON DAN TEXT EDITOR PHYCHARM," *Technol. J. Ilm.*, vol. 11, no. 3, p. 181, Jul. 2020, doi: 10.31602/tji.v11i3.3294.

[2] T. A. Bowo, H. Syaputra, and M. Akbar, "Penerapan Algoritma Convolutional Neural Network Untuk Klasifikasi Motif Citra Batik Solo," *J. Softw. Eng. Ampera*, vol. 1, no. 2, Art. no. 2, May 2020, doi: 10.51519/journalsea.v1i2.47.

[3] J. P. Hidayatullah, "Klasifikasi Bunga Menggunakan Naïve Bayes Berdasarkan Fitur Warna Dan Texture," . *Volume*, vol. 4, 2021.

[4] L. Farokhah, "Implementasi K-Nearest Neighbor untuk Klasifikasi Bunga Dengan Ekstraksi Fitur Warna RGB," *J. Teknol. Inf. Dan Ilmu Komput.*, vol. 7, no. 6, Art. no. 6, Dec. 2020, doi: 10.25126/jtiik.2020722608.

[5] Y. Pachipala, H. C. Maddipati, P. S. Udimudi, V. Thota, V. N. Sree, and L. R. Burra, "Iris Flower Classification by using Random Forest in AWS," in *2022 6th International Conference on Intelligent Computing and Control Systems (ICICCS)*, May 2022, pp. 1772–1777. doi: 10.1109/ICICCS53718.2022.9788415.

[6] I. A. Dly, J. Jasril, S. Sanjaya, L. Handayani, and F. Yanto, "Klasifikasi Citra Daging Sapi dan Babi Menggunakan CNN Alexnet dan Augmentasi Data," *J. Inf. Syst. Res. JOSH*, vol. 4, no. 4, pp. 1176–1185, Jul. 2023, doi: 10.47065/josh.v4i4.3702.

[7] L. A. Susanto, A. Nilogiri, and L. Handayani, "Klasifikasi Citra Lesi Kulit Serupa Virus

Published by: Training & Research Institute JERAMBA ILMU SUKSES

Monkeypox Menggunakan VGG-19 Convolutional Neural Network," *JUSTINDO J. Sist. Dan Teknol. Inf. Indones.*, vol. 8, no. 1, Art. no. 1, Feb. 2023, doi: 10.32528/justindo.v8i1.168.

[8] F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer, "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size." arXiv, Nov. 04, 2016. Accessed: Jul. 14, 2024. [Online]. Available: http://arxiv.org/abs/1602.07360

[9] M. R. W. Budiarto and F. Utaminingrum, "Sistem Klasifikasi Permukaan Jalan dan Penghindaran Jalan Berlubang pada Kursi Roda Pintar dengan Metode MobileNetV3-Small," *J. Pengemb. Teknol. Inf. Dan Ilmu Komput.*, vol. 7, no. 5, Art. no. 5, Aug. 2023, Accessed: Jul. 14, 2024. [Online]. Available: https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/12693

[10] A. Akram, K. Fayakun, and H. Ramza, "Klasifikasi Hama Serangga pada Pertanian Menggunakan Metode Convolutional Neural Network," *Build. Inform. Technol. Sci. BITS*, vol. 5, no. 2, Art. no. 2, Sep. 2023, doi: 10.47065/bits.v5i2.4063.

[11] T. Susim and C. Darujati, "Pengolahan Citra untuk Pengenalan Wajah (Face Recognition) Menggunakan OpenCV," *J. Syntax Admiration*, vol. 2, no. 3, pp. 534–545, Mar. 2021, doi: 10.46799/jsa.v2i3.202.

[12] F. N. Cahya, N. Hardi, D. Riana, and S. Hadiyanti, "Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN)," *SISTEMASI*, vol. 10, no. 3, p. 618, Sep. 2021, doi: 10.32520/stmsi.v10i3.1248.

[13] R. Kurniawan, A. T. Martadinata, and S. D. Cahyo, "Klasifikasi Tingkat Kematangan Buah Sawit Berbasis Deep Learning dengan Menggunakan Arsitektur Yolov5," *J. Inf. Syst. Res. JOSH*, vol. 5, no. 1, Art. no. 1, Oct. 2023, doi: 10.47065/josh.v5i1.4408.

[14] A. Kholik, "KLASIFIKASI MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) PADA TANGKAPAN LAYAR HALAMAN INSTAGRAM," *J. Data Min. Dan Sist. Inf.*, vol. 2, no. 2, Art. no. 2, Aug. 2021, doi: 10.33365/jdmsi.v2i2.1345.

[15] J. Sumpena, "A Comparative study of Transfer Learning CNN for Flower Type Classification," *J. Appl. Intell. Syst.*, vol. 8, no. 3, pp. 389–399, Nov. 2023, doi: 10.33633/jais.v8i3.9380.

[16] C. Yu, X. He, H. Ma, X. Qi, J. Lu, and Y. Zhao, "S-DenseNet: A DenseNet Compression Model Based on Convolution Grouping Strategy Using Skyline Method," *IEEE Access*, vol. 7, pp. 183604–183613, 2019, doi: 10.1109/ACCESS.2019.2960315.

[17] S. Alfarhood, A. Alrayeh, M. Safran, M. Alfarhood, and D. Che, "Image-Based Arabian Camel Breed Classification Using Transfer Learning on CNNs," *Appl. Sci.*, vol. 13, no. 14, Art. no. 14, Jan. 2023, doi: 10.3390/app13148192.

[18] N. Kanwal *et al.*, "Equipping Computational Pathology Systems with Artifact Processing Pipelines: A Showcase for Computation and Performance Trade-offs." medRxiv, p. 2024.03.11.24304119, Mar. 13, 2024. doi: 10.1101/2024.03.11.24304119.

[19] S. Giraddi, S. Seeri, P. S. Hiremath, and J. G.N, "Flower Classification using Deep Learning models," *2020 Int. Conf. Smart Technol. Comput. Electr. Electron. ICSTCEE*, pp. 130–133, Oct. 2020, doi: 10.1109/ICSTCEE49637.2020.9277041.

Published by:

Training & Research Institute JERAMBA ILMU SUKSES

[20] K. Han, J. He, Y. Wang, Y. Xiong, and C. Zhang, "An Image Classification Approach based on Deep Learning and Transfer Learning," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 768, no. 7, p. 072055, Mar. 2020, doi: 10.1088/1757-899X/768/7/072055.

[21] C.-I. Moon and O. Lee, "Skin Microstructure Segmentation and Aging Classification Using CNN-Based Models," *IEEE Access*, vol. 10, pp. 4948–4956, 2022, doi: 10.1109/ACCESS.2021.3140031.

[22] A. Howard *et al.*, "Searching for MobileNetV3." arXiv, Nov. 20, 2019. Accessed: Jul. 15, 2024. [Online]. Available: http://arxiv.org/abs/1905.02244

[23] "Flowers Recognition." Accessed: Jul. 14, 2024. [Online]. Available: https://www.kaggle.com/datasets/alxmamaev/flowers-recognition

Copyrights

Copyright for this article is retained by the author(s), with first publication rights granted to the journal.

This is an open-access article distributed under the terms and conditions of the Creative Commons Attribution license (http://creativecommons.org/licenses/by/4.0/)

Published by:

Training & Research Institute JERAMBA ILMU SUKSES