

COMPARISON OF CNN AND EFFICIENTNET-B0 MODELS IN CORN LEAF DISEASE CLASSIFICATION USING CLASS WEIGHTING

PERBANDINGAN MODEL CNN DAN EFFICIENTNET-B0 DALAM KLASIFIKASI PENYAKIT DAUN JAGUNG MENGUNAKAN *CLASS WEIGHTING*

Aliyah Nadhratunnaim¹, Naufal Azizan Rafiansyah^{2‡}, Farah Annisa Mahmud^{3‡}, Fazila Alya Dilta Hareer^{4‡}, Tengku Muhammad Hafizh Fadhlah^{5‡}, and Cici Suhaeni^{6‡}

^{1,2,3,4,5,6} Department of Statistics and Data Science, IPB University, Indonesia

[‡]corresponding author: naufalazizan@apps.ipb.ac.id

Copyright © 2026 Aliyah Nadhratunnaim, Naufal Azizan Rafiansyah, Farah Annisa Mahmud, Fazila Alya Dilta Hareer, Tengku Muhammad Hafizh Fadhlah, and Cici Suhaeni. This is an open-access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Abstract

Corn leaf diseases can significantly reduce agricultural productivity and impact food security, necessitating an effective automated detection system. This study implements the Convolutional Neural Network (CNN) algorithm to classify four leaf conditions: healthy, blight, common rust, and gray leaf spot. The dataset comprises 4188 preprocessed images. The evaluated models consist of a transfer learning-based EfficientNet-B0 architecture and a standard CNN model built from scratch. A balanced class weight method was applied during training to handle imbalanced data, specifically aiming to enhance the model's sensitivity for the minority gray leaf spot class. The results show that EfficientNet-B0 achieved a macro average F1-score of 96.23% while the standard CNN model reached a macro average F1-score of 89.54%. EfficientNet-B0 consistently outperformed the standard CNN across all classes. However, both models exhibited a small number of misclassifications due to similar visual characteristics and limited minority class data. Overall, EfficientNet-B0 showed better classification performance and generalization, while the CNN model remained competitive with lower computational complexity.

Keywords: Class Weighting, Convolutional Neural Network, Corn Disease Classification, EfficientNet-B0, Transfer Learning.

Abstrak

Penyakit daun jagung dapat menurunkan produktivitas pertanian dan berdampak pada ketahanan pangan, sehingga diperlukan sistem deteksi otomatis yang efektif. Penelitian ini mengimplementasikan algoritma *Convolutional Neural Network* (CNN) untuk mengklasifikasikan empat kondisi daun jagung: *healthy*, *blight*, *common rust*, dan *gray leaf spot*. Dataset yang digunakan mencakup 4188 citra hasil prapemrosesan. Model yang dievaluasi terdiri dari arsitektur EfficientNet-B0 berbasis *transfer learning* dan model CNN standar yang dibangun dari awal (*from scratch*). Metode *balanced class weight* diterapkan selama pelatihan untuk mengatasi ketidakseimbangan data, khususnya guna meningkatkan sensitivitas model pada kelas *gray leaf spot* selaku kelas minoritas. Hasilnya EfficientNet-B0 mencatat nilai F1-score di *macro average* sebesar 96,23%, sementara CNN standar mencapai nilai F1-score di *macro average* sebesar 89,54%. EfficientNet-B0 menunjukkan performa yang lebih baik pada semua kelas. Namun, kedua model masih mengalami sedikit misklasifikasi pada beberapa kelas yang disebabkan oleh kemiripan karakteristik visual serta keterbatasan data minoritas. Secara keseluruhan, EfficientNet-B0 memiliki performa dan generalisasi yang lebih baik, sedangkan CNN tetap kompetitif dengan kompleksitas yang lebih rendah.

Kata Kunci: *Convolutional Neural Network*, EfficientNet-B0, Klasifikasi Penyakit Jagung, Pembobotan Kelas, *Transfer Learning*.

1. Pendahuluan

Jagung merupakan komoditas strategis bagi ketahanan pangan dan industri pakan ternak di Indonesia. Data Badan Pusat Statistik (BPS) (2024) menunjukkan bahwa produksi jagung nasional mencapai lebih dari 14 juta ton per tahun, bahkan meningkat menjadi 15,14 juta ton pada tahun 2024 atau naik 2,47% dibandingkan tahun sebelumnya. Namun, produktivitas jagung masih menghadapi ancaman berbagai penyakit daun, seperti *blight*, *gray leaf spot*, dan *common rust*, yang dapat mengganggu fotosintesis serta menurunkan hasil panen.

Perkembangan teknologi kecerdasan buatan, khususnya *Convolutional Neural Network* (CNN), memberikan solusi otomatis untuk mengidentifikasi penyakit daun melalui ekstraksi fitur citra secara efektif (Alzubaidi *et al.*, 2021). Salah satu arsitektur yang banyak digunakan adalah EfficientNet-B0 yang menerapkan *compound scaling* untuk menyeimbangkan kedalaman, lebar, dan resolusi citra sehingga lebih efisien secara komputasi serta mampu menghasilkan akurasi yang tinggi (Albahli & Masood, 2022). Selain itu, penerapan *transfer learning* dapat mempercepat proses pelatihan model, sedangkan *class weighting* membantu mengatasi

ketidakseimbangan data dengan meningkatkan sensitivitas terhadap kelas minoritas.


Beberapa penelitian terdahulu telah membandingkan performa model CNN dan *transfer learning*, seperti yang dilakukan oleh Utami *et al.* (2025) pada klasifikasi penyakit daun tanaman padi, di mana model EfficientNet-B0 menghasilkan performa yang lebih baik dibandingkan model CNN *baseline*. Selain itu, penelitian yang dilakukan oleh Yasin & Fatima (2023) pada deteksi penyakit pada daun tanaman tomat dan kentang, serta penelitian yang dilakukan oleh Kaur & Sharma (2025) pada deteksi penyakit pada daun tanaman kentang juga menunjukkan bahwa model EfficientNet-B0 mampu memberikan akurasi yang lebih tinggi dibandingkan model CNN konvensional atau *custom CNN* pada klasifikasi penyakit tanaman berbasis citra digital.

Penelitian ini bertujuan mengimplementasikan EfficientNet-B0 dengan *transfer learning* dan *class weighting* untuk klasifikasi penyakit daun jagung. Selain itu, dilakukan perbandingan kinerja antara CNN dan EfficientNet-B0 untuk mengevaluasi efektivitas masing-masing model dalam menangani data yang tidak seimbang serta menghasilkan klasifikasi yang akurat dan efisien. Evaluasi terhadap model ini diharapkan dapat menjadi rujukan teknologi identifikasi penyakit tanaman yang presisi dan aplikatif bagi petani.

2. Metodologi

2.1 Bahan dan Data

Data yang digunakan dalam penelitian ini berasal dari *Corn or Maize Leaf Disease Dataset* yang tersedia secara publik melalui platform Kaggle. Dataset terdiri atas 4188 citra daun jagung (*maize*) dengan empat kategori, yaitu *common rust*, *gray leaf spot*, *blight*, dan *healthy*. Keempat kelas tersebut merepresentasikan kondisi daun jagung sehat serta beberapa jenis penyakit yang umum menyerang tanaman jagung. Contoh gugus data citra ditampilkan pada Gambar 1.



Gambar 1: Contoh dataset (a) *common rust* (b) *gray leaf spot* (c) *blight* (d) *healthy*.

2.2 Metode Penelitian

Prosedur analisis pada penelitian ini dilakukan menggunakan *software* Python melalui platform Kaggle dengan tahapan analisis sebagai berikut:

1. Data dibagi menjadi tiga subset, yaitu *train* (70%), *validation* (15%), dan *test* (15%). Data *train* digunakan untuk melatih model, data *validation* untuk evaluasi dan penyesuaian parameter, sedangkan data *test* untuk menilai kinerja akhir pada data yang belum pernah digunakan (Kabiru et al., 2025).
2. Melakukan prapemrosesan citra dengan mengubah ukuran seluruh gambar menjadi 224×224 piksel, serta menerapkan normalisasi menggunakan *mean* dan *standard deviation* standar ImageNet.
3. Menerapkan augmentasi data pada citra *train* untuk meningkatkan kemampuan generalisasi model. Teknik yang digunakan meliputi *random rotation*, *random horizontal flip*, dan *color jitter* untuk menghasilkan variasi data tanpa mengubah label kelas. Proses ini membantu model mempelajari berbagai variasi bentuk dan posisi objek, sekaligus mengurangi risiko *overfitting* selama pelatihan (Sapitri et al., 2023).
4. Mengatasi ketidakseimbangan data dengan mengubah label *one-hot encoding* menjadi label tunggal, kemudian menghitung *class weighting* menggunakan pendekatan *balanced class weight*:

$$w_i = \frac{N}{K \times n_i} \quad (1)$$

dengan N adalah jumlah total sampel, K adalah jumlah kelas, dan n_i adalah jumlah sampel pada kelas ke- i . Pendekatan ini memberikan bobot lebih besar pada kelas minoritas sehingga mengurangi bias model terhadap kelas mayoritas (Bakirarar & Elhan, 2023).

5. Merancang arsitektur CNN untuk klasifikasi citra karena mampu mengekstraksi fitur visual secara otomatis melalui proses konvolusi. Arsitektur model terdiri atas *feature extraction layer* dan *classification layer*. *Feature extraction layer* disusun menggunakan empat *convolution block* yang masing-masing terdiri atas *convolution layer*, *Batch Normalization*, aktivasi ReLU, *Max Pooling*, dan *Dropout* 0,25. Jumlah filter ditingkatkan secara bertahap dari 32, 64, 128, hingga 256 dengan kernel 3×3 dan *padding* 1 untuk mempelajari fitur dari sederhana hingga kompleks. Fungsi aktivasi ReLU digunakan untuk memberikan non-linearitas pada model.

$$f(x)_{RELU} = \max(0, x) \quad (2)$$

Selanjutnya, *Max Pooling* 2×2 digunakan untuk mereduksi dimensi fitur dan meningkatkan efisiensi komputasi, sedangkan *Dropout* diterapkan untuk mengurangi *overfitting* (Alzubaidi *et al.*, 2021). Pada *classification layer*, digunakan *Adaptive Global Average Pooling* sebelum *fully connected layer* berukuran 256 neuron dengan aktivasi ReLU dan *Dropout* 0,5 untuk menghasilkan *output* klasifikasi (Habib & Qureshi, 2022; Sathiyapriya & Shanti, 2022).

6. Menerapkan pendekatan *transfer learning* menggunakan arsitektur EfficientNet-B0 dengan *pretrained weights* dari ImageNet untuk mempercepat konvergensi dan meningkatkan kemampuan ekstraksi fitur citra. EfficientNet-B0 menggunakan pendekatan *compound scaling* yang menyeimbangkan kedalaman, lebar jaringan, dan resolusi input secara efisien. Arsitektur ini tersusun atas beberapa *MBConv block* dengan *depthwise convolution* dan *squeeze-and-excitation* untuk meningkatkan efisiensi komputasi dan representasi fitur (Albahli & Masood, 2022). Seluruh parameter model dilatih kembali (*full fine-tuning*) agar model dapat menyesuaikan representasi fitur dengan karakteristik dataset penelitian (Yosinski *et al.*, 2014). Selanjutnya, feature map diproses menggunakan *Global Average Pooling* dan *Dropout* 0,3 untuk mengurangi *overfitting* (Burhanuddin *et al.*, 2025), kemudian diteruskan ke *fully connected layer* dengan aktivasi Softmax untuk menghasilkan prediksi empat kategori penyakit daun jagung.
7. Menentukan konfigurasi pelatihan model meliputi *batch size* 32, maksimum 30 *epoch*, dan *random seed* 42 untuk menjaga stabilitas pelatihan serta meningkatkan *reproducibility* penelitian. Proses pelatihan dijalankan pada dua GPU NVIDIA Tesla T4 menggunakan PyTorch 2.10.0+cu128.
8. Melatih model menggunakan *Adam optimizer* dengan *learning rate* 0,001 karena mampu mengoptimasi parameter secara adaptif dan efisien pada model *deep learning*. Untuk meningkatkan stabilitas pelatihan, diterapkan *ReduceLROnPlateau* dengan *patience* 3 dan *factor* 0,5 untuk menurunkan *learning rate* saat *validation loss* tidak membaik. Selain itu, digunakan *early stopping* dengan *patience* 10 dan *min_delta* 0,001 untuk mengurangi risiko *overfitting*, serta *model checkpointing* untuk menyimpan bobot model dengan akurasi *validation* terbaik (Burhanuddin *et al.*, 2025).
9. Mengevaluasi model dengan *accuracy*, *precision*, *recall*, *F1-score*, *confusion matrix*, serta *training curve* dan *validation curve*. Metode

utama yang digunakan adalah *F1-score macro average* karena menyeimbangkan *precision* dan *recall* pada setiap kelas. Rumus evaluasi yang digunakan adalah sebagai berikut:

$$F1 - score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (3)$$

$$Precision = \frac{TP}{TP + FP} \quad (4)$$

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

dengan TP (*True Positive*) adalah jumlah data positif yang diprediksi benar, FP (*False Positive*) adalah data negatif yang diprediksi positif, dan FN (*False Negative*) adalah data positif yang diprediksi negatif (Burhanuddin et al., 2025).

3. Hasil dan Pembahasan

3.1 Pembagian Data dan Proses Data

Dataset dibagi menjadi data training (70%), validation (15%), dan testing (15%) dengan distribusi setiap kelas disajikan pada Tabel 1. Selanjutnya, seluruh citra diubah menjadi ukuran 224×224 piksel, dikonversi ke dalam bentuk tensor, dan dinormalisasi menggunakan mean serta standard deviation standar ImageNet.

Tabel 1: Pembagian data setiap kelas.


<i>Class</i>	<i>Train</i>	<i>Validation</i>	<i>Test</i>
<i>Blight</i>	802	172	172
<i>Common Rust</i>	914	196	196
<i>Gray Leaf Spot</i>	402	86	86
<i>Healthy</i>	813	174	175

3.2 Augmentasi Data

Teknik augmentasi yang digunakan meliputi *random rotation* hingga 15° , *random horizontal flip* dengan probabilitas 50%, serta penyesuaian kecerahan dan kontras sebesar 0,2 (*Color jitter*). Augmentasi hanya diterapkan pada data *train*, sedangkan data *validation* dan *test* menggunakan citra asli agar evaluasi model tetap objektif dan hasil pengujian lebih representatif (Ameen et al., 2023).

3.3 Class Weighting


Distribusi data menunjukkan kondisi *class imbalance*, dengan kelas *gray leaf spot* memiliki jumlah sampel paling sedikit seperti terlihat pada Gambar 2. Hasil perhitungan *class weighting* menunjukkan bahwa kelas *gray leaf spot* memiliki bobot tertinggi sebesar 1,8228, sedangkan *blight*, *common rust*, dan *healthy* masing-masing sebesar 0,9137, 0,8017, dan 0,9013. Oleh karena itu, diterapkan metode *balanced class weight* untuk mengurangi bias model terhadap kelas mayoritas (Kaope & Pristyanto, 2023).



Gambar 2: Distribusi data setiap kelas.

3.4 CNN


Berdasarkan grafik *training curve* pada Gambar 3, model CNN menunjukkan proses pembelajaran yang cukup baik selama pelatihan. Angka *training loss* dan *validation loss* mengalami penurunan secara bertahap seiring bertambahnya *epoch*, yang menunjukkan bahwa model semakin mampu mempelajari pola pada dataset. Nilai *training loss* menurun dari angka 0,7636 ke 0,3262, sementara nilai *validation loss* juga menunjukkan tren penurunan hingga mencapai nilai sekitar 0,2395. Hal tersebut sejalan dengan grafik akurasi yang terus meningkat secara konsisten. Terlihat bahwa nilai *training accuracy* meningkat dari angka 0,6974 hingga mencapai 0,8772, sementara *validation accuracy* juga menunjukkan performa yang cukup stabil dengan hasil akurasi terbaik mencapai angka 0,9236. Hal ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data *validation*.



Gambar 3: Grafik *training* dan *validation curve* model CNN (a) Loss (b) Accuracy.

3.5 EfficientNet-B0

Berdasarkan grafik *training curve* pada Gambar 4, model EfficientNet-B0 menunjukkan proses pelatihan yang stabil dan konsisten. Grafik *training loss* dan *validation loss* mengalami penurunan yang cukup signifikan pada awal *training*, kemudian menurun secara bertahap hingga mencapai kondisi yang relatif stabil pada *epoch* akhir. Nilai *training loss* menurun dari angka 0,3352 menjadi 0,0130, sedangkan *validation loss* menurun hingga 0,1942. Hal tersebut sejalan dengan grafik akurasi yang terus meningkat secara konsisten. Nilai *training accuracy* meningkat secara konsisten dari angka 0,8867 hingga mencapai 0,9952 pada akhir *training*. Selain itu, *validation accuracy* juga menunjukkan performa yang stabil dengan nilai akurasi terbaik mencapai angka 0,9777. Kondisi ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data *validation*.



Gambar 4: Grafik *training* dan *validation curve* model EfficientNet-B0 (a) Loss (b) Accuracy.

3.6 Perbandingan Kinerja Model

Berdasarkan hasil pengujian pada data *test*, model EfficientNet-B0 memperoleh *macro average F1-score* sebesar 96,23%, lebih tinggi


dibandingkan model CNN yang memperoleh *macro average F1-score* sebesar 89,54%. Hasil tersebut menunjukkan bahwa pendekatan *transfer learning* pada EfficientNet-B0 mampu memberikan performa klasifikasi yang lebih baik secara keseluruhan dibandingkan model CNN yang dibangun dari awal (*trained from scratch*).

Tabel 2: *Classification report* model CNN dan EfficientNet-B0 pada data test.

	Model	Precision	Recall	F1-score	Support
Blight	CNN	0,9139	0,8023	0,8545	172
	EfficientNet-B0	0,9474	0,9419	0,9446	
Common Rust	CNN	0,9534	0,9388	0,9460	196
	EfficientNet-B0	0,9796	0,9796	0,9796	
Gray Leaf Spot	CNN	0,7064	0,8953	0,7897	86
	EfficientNet-B0	0,9195	0,9302	0,9249	
Healthy	CNN	0,9886	0,9943	0,9915	175
	EfficientNet-B0	1,0000	1,0000	1,0000	
Accuracy	CNN			0,9110	629
	EfficientNet-B0			0,9682	
Macro avg.	CNN	0,8906	0,9077	0,8954	629
	EfficientNet-B0	0,9616	0,9629	0,9623	
Weighted avg.	CNN	0,9186	0,9110	0,9123	629
	EfficientNet-B0	0,9682	0,9682	0,9682	

Berdasarkan *classification report* yang tersaji pada Tabel 2, kedua model menunjukkan performa yang sangat baik pada kelas *healthy* dan *common rust*. Model EfficientNet-B0 memperoleh nilai *F1-score* tertinggi pada kelas *healthy* sebesar 1,000, yang menunjukkan bahwa seluruh data pada kelas tersebut berhasil diklasifikasikan dengan benar. Sementara itu, model CNN juga menunjukkan performa yang sangat baik pada kelas *healthy* dengan *F1-score* sebesar 0,9915. Pada kelas *common rust*, model EfficientNet-B0 juga menunjukkan performa lebih baik dengan *F1-score* sebesar 0,9796 dibandingkan model CNN sebesar 0,9460. Hal ini menunjukkan bahwa kemampuan ekstraksi fitur pada model EfficientNet-B0 lebih efektif dalam mengenali pola visual pada kelas tersebut. Pada kelas *gray leaf spot*, model CNN memperoleh *F1-score* sebesar 0,7897,

sedangkan model EfficientNet-B0 memperoleh *F1-score* sebesar 0,9249. Hasil tersebut menunjukkan bahwa EfficientNet-B0 mampu mengenali karakteristik visual pada kelas *gray leaf spot* dengan lebih baik dibandingkan model CNN.



Gambar 5: *Confusion matrix* (a) Model CNN (b) Model EfficientNet-B0.

Hasil serupa juga dapat dilihat melalui *confusion matrix* pada Gambar 5 yang menunjukkan bahwa sebagian besar data pada masing-masing kelas berhasil diklasifikasikan dengan benar oleh kedua model. Pada model CNN, kelas *healthy* memiliki tingkat klasifikasi benar sebesar 99%, sedangkan kelas *common rust* mencapai 94%. Selain itu, kelas *gray leaf spot* pada model CNN berhasil diklasifikasikan dengan benar sebesar 90%, meskipun masih terdapat sekitar 8% data yang salah diprediksi sebagai *blight*. Sementara itu, model EfficientNet-B0 menunjukkan performa yang lebih baik pada hampir seluruh kelas. Kelas *healthy* berhasil diklasifikasikan secara sempurna dengan tingkat klasifikasi mencapai 100%, sedangkan kelas *common rust* mencapai 98%. Pada kelas *gray leaf spot*, model EfficientNet-B0 juga menunjukkan peningkatan performa dengan tingkat klasifikasi benar sebesar 93%, meskipun masih terdapat sekitar 7% data yang salah diprediksi sebagai *blight*. Selain itu, kelas *blight* pada EfficientNet-B0 memiliki tingkat klasifikasi benar sebesar 94%, lebih tinggi dibandingkan model CNN yang sebesar 80%. Kesalahan klasifikasi tersebut kemungkinan disebabkan oleh kemiripan karakteristik visual antara kelas *gray leaf spot* dan *blight*, seperti pola bercak dan perubahan warna daun yang memiliki bentuk serupa sehingga model mengalami kesulitan dalam membedakan fitur antar kelas secara konsisten. Selain itu, jumlah data pada kelas *gray leaf spot* yang lebih sedikit dibandingkan kelas lainnya juga dapat memengaruhi kemampuan model dalam mempelajari karakteristik

kelas tersebut secara optimal. Kondisi *class imbalance* tersebut menyebabkan model memiliki representasi fitur yang lebih terbatas pada kelas minoritas sehingga meningkatkan kemungkinan terjadinya kesalahan klasifikasi.

Secara keseluruhan, EfficientNet-B0 menunjukkan performa klasifikasi yang lebih baik dibandingkan CNN. Namun, model CNN tetap menghasilkan performa yang kompetitif dengan kompleksitas yang lebih rendah. CNN memiliki total parameter sebanyak 650.404, sedangkan EfficientNet-B0 memiliki 4.012.672 parameter. Perbedaan tersebut menunjukkan bahwa EfficientNet-B0 memiliki kompleksitas yang lebih tinggi, sementara model CNN lebih ringan dari sisi komputasi dan berpotensi membutuhkan sumber daya pelatihan yang lebih rendah. Dengan demikian, EfficientNet-B0 lebih unggul dari sisi performa, sedangkan model CNN menawarkan efisiensi komputasi dengan hasil klasifikasi yang tetap baik. Hasil penelitian ini sejalan dengan beberapa penelitian terdahulu, antara lain penelitian oleh Utami *et al.* (2025), Yasin dan Fatima (2023), serta Kaur dan Sharma (2025) yang menunjukkan bahwa model EfficientNet-B0 memiliki performa lebih baik dibandingkan model CNN pada klasifikasi penyakit daun tanaman.

4. Simpulan dan Saran

Penelitian ini berhasil mengimplementasikan model klasifikasi penyakit daun jagung menggunakan pendekatan CNN dan *transfer learning* berbasis EfficientNet-B0 dengan penerapan *class weighting* untuk mengatasi ketidakseimbangan data. Hasil pengujian menunjukkan bahwa model EfficientNet-B0 memberikan performa yang lebih baik dengan *macro average F1-score* sebesar 96,23% dibandingkan model CNN. Model tersebut juga menunjukkan kemampuan generalisasi yang baik berdasarkan kestabilan nilai *validation loss* dan *validation accuracy* selama proses pelatihan. Secara keseluruhan, pendekatan *transfer learning* menggunakan model EfficientNet-B0 terbukti efektif dalam klasifikasi penyakit daun jagung dengan performa yang baik. Penelitian selanjutnya dapat dilakukan dengan menambahkan jumlah data pada kelas minoritas, menerapkan augmentasi data yang lebih beragam, serta mengeksplorasi arsitektur *deep learning* lain untuk meningkatkan performa model secara lebih optimal.

Daftar Pustaka

- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaria, J., Fadhel, M. A., Al-Amidie, M. & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1): 1-74. <https://doi.org/10.1186/s40537-021-00444-8>
- Albahli, S. & Masood, M. (2022). Efficient attention-based CNN network (EANet) for multi-class maize crop disease classification. *Frontiers in Plant Science*, 13: 1003152. <https://doi.org/10.3389/fpls.2022.1003152>
- Ameen, Y. A., Badary, D. M., Abonnoor, A. E. I., Hussain, K. F. & Sewisy, A. A. (2023). Which data subset should be augmented for deep learning? A simulation study using urothelial cell carcinoma histopathology images. *BMC Bioinformatics*, 24(1): 75.
- Badan Pusat Statistik. (2024). *Luas Panen dan Produksi Jagung di Indonesia 2023*. Direktorat Statistik Tanaman Pangan, Hortikultura, dan Perkebunan. 1: 1-67.
- Bakirarar, B. & Elhan, A. H. (2023). Class weighting technique to deal with imbalanced class problem in machine learning: Methodological research. *Turkiye Klinikleri Journal of Biostatistics*, 15(1): 19–29. <https://doi.org/10.5336/biostatic.2022-93961>
- Burhanuddin, M. I., Syaifullah, A., Jaya, S. A. P. & Somoal, M. G. (2025). Analisis komparatif model MobilenetV1 dan EfficientnetB0 dalam klasifikasi citra empat musim menggunakan transfer learning. *JEKIN (Jurnal Teknik Informatika)*, 5(2): 510–521.
- Habib, G. & Qureshi, S. (2022). GAPCNNwithHyPar: Global Average Pooling convolutional neural network with novel NNLU activation function and HYBRID parallelism. *Frontiers in Computational Neuroscience*: 16.
- Kabiru, H., Buhari, S. A. & Idris, A. K. (2025). Artificial neural networks for detection of diabetes mellitus by selecting significant risk factors using backward stepwise feature selection method. *Advanced Journal of Science, Technology and Engineering*, 5(1): 115–128.
- Kaope, C. & Pristyanto, Y. (2023). The effect of class imbalance handling on datasets toward classification algorithm performance. *Matrik: Jurnal Manajemen, Teknik Informatika, dan Rekayasa Komputer*, 22(2): 227–238.
- Kaur, S. & Sharma, S. (2025). A comparative study of plant disease classification using a hybrid EfficientNetB0-based deep learning model. *Journal of Emerging Technologies and Innovative Research (JETIR)*, 12(1): c435–c442. <http://www.jetir.org/papers/JETIR2501252.pdf>

- Sapitri, W., Kunang, Y. N., Yadi, I. Z. & Mahmud, M. (2023). The impact of data augmentation techniques on the recognition of script images in deep learning models. *JOIN (Jurnal Online Informatika)*, 8(2): 169–176. <https://doi.org/10.15575/join.v8i2.1073>
- Sathiyapriya, G. & Shanthi, S. A. (2022). Image classification using convolutional neural network. In *2022 First International Conference on Electrical, Electronics, Information and Communication Technologies (ICEEICT)*. IEEE.
- Utami, T. W., Novita, M. & Latifa, K. (2025) Implementation and comparative analysis of CNN and transfer learning models (EfficientNetB0, MobileNetV2, and ResNet50) for rice leaf disease detection based on digital images. *Journal of Applied Informatics and Computing (JAIC)*, 9(6), 3862–3870. <https://doi.org/10.30871/jaic.v9i6.11616>
- Yasin, A. & Fatima, R. (2023). On the image-based detection of tomato and corn leaves diseases: an in-depth comparative experiments. *arXiv preprint arXiv:2312.08659*.
- Yosinski, J., Clune, J., Bengio, Y. & Lipson, H. (2014). How transferable are features in deep neural networks? *Advances in Neural Information Processing Systems (NeurIPS)*, 27.