

AUGMENTASI DATA PADA IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK ARSITEKTUR EFFICIENTNET-B3 UNTUK KLASIFIKASI PENYAKIT DAUN PADI

Desy Putri Ayuni¹, Jasril², Muhammad Irsyad³, Febi Yanto⁴, Suwanto Sanjaya⁵

¹²³⁴⁵ Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Islam Negeri
Sultan Syarif Kasim Riau

Jl. HR. Soebrantas No 155 Km. 15, Simpang Baru, Kota Pekanbaru, Riau 28293

e-mail: ¹11950121681@students.uin-suska.ac.id, ²jasril@uin-suska.ac.id, ³irsyadtech@uin-suska.ac.id, ⁴febiyanto@uin-suska.ac.id, ⁵suwantosanjaya@uin-suska.ac.id

Abstrak

Padi adalah salah satu jenis biji-bijian dengan urutan ketiga sebagai bahan pokok makanan setelah gandum dan jagung. Jenis penyakit yang menyerang daun tanaman terdiri atas blast, brownspot, leaf smut. Pada penelitian ini metode Convolutional Neural Network dengan Arsitektur Efficientnet-B3 digunakan untuk mengklasifikasikan penyakit daun pada tanaman padi. Tujuan penelitian ini membandingkan tingkat akurasi menggunakan CNN arsitektur EfficientNet-B3 serta hyperparameter untuk mengklasifikasi citra penyakit daun pada tanaman padi menggunakan augmentasi data dan tanpa augmentasi data. Augmentasi data yang digunakan brightness, rotation, dan vertical_flip. Selain itu dilakukan juga pengujian menggunakan optimizer yang berbeda yaitu optimizer RMSprop dan optimizer SGD (Stochastic Gradient Descent). Pengujian dilakukan dengan tiga model perbandingan data yaitu 90:10, 80:20 dan 70:30. Hasil pengujian memperlihatkan akurasi tertinggi menggunakan data asli pada rasio 70:30 yaitu sebesar 92.39% dengan optimizer RMSprop. Sedangkan untuk akurasi tertinggi menggunakan data augmentasi terdapat pada rasio 90:10 yaitu sebesar 98.91% dengan optimizer RMSprop.

Kata Kunci: Augmentasi Data, Convolutional Neural Network, deep learning, Efficientnet-B3, penyakit daun padi.

Abstract

Rice is a type of grain with the third order as a staple food after wheat and corn. Types of diseases that attack plant leaves consist of blast, brownspot, leaf smut. In this study the Convolutional Neural Network method with Efficientnet-B3 Architecture was used to classify foliar diseases in rice plants. The purpose of this study is to compare the accuracy of using data without augmentation (original) and data that has been augmented. The data augmentation used is brightness, rotation, and vertical_flip. In addition, testing was also carried out using a different optimizer, namely the RMSprop optimizer and the SGD (Stochastic Gradient Descent) optimizer. Tests were carried out with three data comparison models, namely 90:10, 80:20 and 70:30. The test results show the highest accuracy using the original data at a ratio of 70:30, which is 92.39% with the RMSprop optimizer. Meanwhile, the highest accuracy using augmentation data is at a ratio of 90:10, which is 98.91% with the RMSprop optimizer.

Keywords: Data Augmentation, Convolutional Neural Networks, deep learning, Efficientnet-B3, rice leaf disease.

1. PENDAHULUAN

Padi adalah jenis biji-bijian dengan urutan ketiga sebagai bahan pokok makanan setelah gandum dan jagung yang diperlukan untuk memenuhi kebutuhan sehari-hari[1]. Indonesia sebagai penghasil beras terbesar di dunia dengan jumlah produksi 54,65% juta ton pada tahun 2020 dari data *Food and Agriculture* (FAO). Pada tahun 2020 luas panen padi menurun menurut badan pusat statistik dibandingkan pada tahun 2019 sebesar 0.19%. Salah satu faktor yang mempengaruhi kualitas produksi tanaman padi merupakan kualitas dari pupuk yang terdiri atas Fosfor (P), Kalium (K), dan Nitrogen (N)[2]. Menurut FAO penyebab utama dalam penurunan hasil panen padi adalah terdapat 20-40% hama dan penyakit pada padi. Padi sering diserang oleh organisme pengganggu tanaman (OTPT) dan juga menyebabkan gagal panen[3]. Pengetahuan yang minim dan keterlambatan diagnose jenis penyakit pada tanaman padi menyebabkan gejala yang semakin parah yang kemudian menimbulkan terjadinya gagal panen.

Gangguan pada daun padi merupakan penyakit pada tanaman padi yang mempengaruhi hasil produksi beras. Pada tanaman padi beragam jenis penyakitnya [4]. Penyakit yang menyerang tanaman padi biasa terdapat pada bagian daun[5]. Daun padi mengalami penyakit berbagai gejala, serta perubahan warna bahkan pada daun yang permukaannya terdapat becak. Penyakit daun yang paling sering menyerang tanaman padi yaitu *Blast*, *brown spot*, *leaf smut*, dan penyakit lainnya[6].

Dari beberapa penelitian yang membedakan penyakit pada daun tanaman padi dengan memanfaatkan pengolahan citra yaitu dengan menggunakan metode machine learning. Pada tahun 2020 Lei feng dan kawan-kawan melakukan penelitian pada daun padi dengan melakukan fitur ekstraksi yang menggunakan model *support vector machine* (SVM) dan *logistic regression* (LR)[7]. Pada tahun 2022 Guosheng beserta kawannya melakukan penelitian pada daun tanaman padi dengan menghitung standar deviasi menggunakan SVM yang menghasilkan akurasi rata-rata 80%[8].

Penelitian menggunakan metode *deep learning* menghasilkan akurasi yang lebih akurat dan lebih stabil dalam Penggunaan metode *Machine learning* masih belum mencapai akurasi yang tinggi. Pada tahun 2020 Nuli Giarsyani dan kawan-kawan melakukan penelitian komparasi algoritma *Machine learning* dan *deep learning*. Hasil penelitian dari komparasi tersebut menunjukkan bahwa algoritma *long short-term memori* dan *gated recurrent units* menghasilkan akurasi lebih baik sebesar 0.999 dibandingkan metode *Machine learning* dengan akurasi sebesar 0.98[9]. Pada tahun 2019 Mohammad Farid Naufal telah melakukan perbandingan pada metode *machine learning* dengan metode *deep learning*. Hasil penelitian tersebut menunjukkan bahwa algoritma CNN memiliki performa terbaik dengan *accuracy* 94.20%, *recall* 94.20% dan *f1-score* 94.20%[10]. Tahun 2021 kelvin beserta kawan-kawan melakukan penelitian Analisa perbandingan algoritma CNN dan multi-layer perceptron neural. Dari penelitian tersebut algoritma CNN menghasilkan akurasi lebih baik sebesar 0.98% dibandingkan algoritma MLP sebesar 0.43%[11]. Hal tersebut membuktikan bahwa metode *deep learning* memiliki akurasi performa terbaik dibandingkan menggunakan metode *Machine learning*.

Pada CNN terdapat berbagai model arsitektur yang terdiri atas *EfficientNet*, *VGGNet*, *AlexNet*, *ResNet*, *LesNet*, dan arsitektur lainnya. Arsitektur CNN biasanya terdiri atas *Convolution layer*, *pooling layer*, dan *fully connected layer*. Tahun 2022 Abwabul Jihan dan B.herawan Hayadi melakukan penelitian menggunakan *deep learning* dapat menghasilkan akurasi cukup baik dan sesuai untuk mengklasifikasi penyakit pada daun padi dengan hasil sebesar 91.7%[12]. Tahun 2021 telah dilakukan penelitian menggunakan arsitektur *Efficientnet-B3* terkait klasifikasi tanaman padi oleh Endang Anggiratih dan kawan-kawan. Menghasilkan akurasi training sebesar 99% menggunakan pembelajaran transfer dalam pelatihan model[13]. Penelitian menggunakan augmentasi brightness dilakukan oleh Savira dan kawan-kawan pada tahun 2022 menggunakan CNN arsitektur *efficientnet-b0* dan *RMSprop* yang menghasilkan nilai *f1-score* sebesar 91%[14]. Pada tahun 2022 M.fahriyal beserta kawan-kawannya melakukan penelitian yang membandingkan *EfficientNetB3* dengan *MobileNetV2*. Hasil penelitian tersebut menunjukkan bahwa *EfficientNetB3* menghasilkan akurasi sebesar 99,7% dibandingkan *MobileNetv2* sekitar 99,6%[15]. Dari beberapa penelitian tersebut menunjukkan


arsitektur EfficientNetB3 menghasilkan tingkat akurasi lebih baik. Penelitian ini menggunakan arsitektur EfficientNetB3 untuk melakukan model klasifikasi.

Pada penelitian yang dilakukan oleh M.fahriyal beserta kawan-kawannya pada tahun 2022. Penelitian tersebut menghasilkan tingkat akurasi lebih baik dengan menggunakan augmentasi data pada arsitektur EfficientNetB3[15]. Pada tahun 2022 Nadia dan kawan-kawan telah melakukan penelitian menggunakan arsitektur efficientnet dan augmentasi brightness rotation serta optimizer Adam dan RMSProp yang dapat menghasilkan akurasi tertinggi 98% [16]. Berdasarkan dari penelitian tersebut arsitektur yang digunakan yaitu *EfficientNet-B3* dengan augmentasi data menggunakan *brightness*, *vertical-flip* dan *rotation*. Selain itu, juga melakukan kombinasi *hyperparameter* dengan *learning rate*, *dense*, *batch size*, Optimizer SGD (*Stochastic Gradient Descent*) dan RMSProp untuk klasifikasi citra penyakit daun pada tanaman padi.

Semua algoritma memiliki metode pengoptimalan yang sama tapi tidak ada algoritma yang terbaik dalam menyelesaikan permasalahan. Tahun 2019 Jia Wu beserta kawannya melakukan penelitian terkait menggunakan *hyperparameter optimization* yang dapat meningkatkan hasil akurasi pada penelitian [17]. *Hyperparameter* diperlukan pada penelitian ini sebagai pengoptimalan kinerja algoritma[18]. Penelitian ini bertujuan untuk membandingkan tingkat akurasi menggunakan CNN arsitektur EfficientNet-B3 serta *hyperparameter* untuk mengklasifikasi citra penyakit daun pada tanaman padi menggunakan augmentasi data dan tanpa augmentasi data.

2. METODE PENELITIAN

Pada penelitian ini terdapat dua proses klasifikasi yaitu proses klasifikasi menggunakan augmentasi data dan proses klasifikasi citra asli. Proses klasifikasi yang digunakan untuk citra asli tidak menggunakan tahap proses augmentasi data. Tahapan penelitian untuk klasifikasi penyakit daun pada padi dapat dilihat pada gambar 1 sebagai berikut.



Gambar 1. Tahapan Penelitian

2.1 Pengumpulan Data

Pengumpulan data penulis mengumpulkan citra penyakit daun pada tanaman padi. Data sekunder digunakan untuk penelitian ini. Data sekunder didapatkan dari *website* penyedia data-data yaitu *kagge*[19][20] dan *UCI Machine Learning*[21]. Data yang dikumpulkan adalah data gambar penyakit daun tanaman padi. Data tersebut terbagi atas 4 kelas, yaitu citra padi sehat, padi dengan penyakit *Brown Spot*, *Leaf Smut*, dan *Blast*.

2.2 Preprocessing

Pada tahap *preprocessing* dilakukan setelah terkumpulnya data. Tujuan tahap ini menghasilkan data yang lebih baik. *Preprocessing* yang digunakan yaitu *Cropping* dan *Resize*.

- a. *Cropping* bertujuan menghilangkan bagian yang tidak diinginkan pada citra dan hanya fokus pada pola citra[22]. *cropping* diproses menggunakan kodingan *python* untuk melakukan *cropping* pada citra.



Gambar 2. Proses Cropping Daun Padi

- b. *Resize* bertujuan untuk menyamakan ukuran citra dengan cara diperkecil menjadi 224×224 piksel. Selain itu, *resize* berfungsi untuk memudahkan proses perhitungan [22]. Tahap *Resize* menggunakan kodingan *python* [23].


Berikut sampel dari data citra pada penelitian ini.

Tabel 1. Jenis-jenis Dataset

Jenis data	Jumlah data
Sehat	110
<i>Blast</i>	110
<i>brown spot</i>	110
<i>leaf smut</i>	110




Gambar 3. Dataset sehat



Gambar 4. Dataset *Blast*



Gambar 5. Dataset *Brown spot*



Gambar 6. Dataset Leaf Smut


2.3 Augmentasi Data

Augmentasi data adalah cara untuk memperbanyak jumlah citra. Pada citra asli tahapan augmentasi tidak dilakukan. Adapun jenis-jenis augmentasi data yang diterapkan pada penelitian ini adalah *Brightness*, *Rotation*, dan *vertical flip*.

- Brightness* bertujuan untuk mencerahkan kualitas dari label citra[24]. *Brightness* diproses dengan menggunakan kodingan *python* untuk melakukan *Brightness* pada citra.
- Rotation* bertujuan untuk memutar gambar secara acak dari 0 hingga 360 derajat searah jarum jam[25]. Proses *Rotation* diproses dengan menggunakan dengan kodingan *python* untuk melakukan *Rotation* pada citra.
- Vertical_flip* bertujuan membalikan gambar secara *vertical* dan diproses menggunakan dengan kodingan *python* untuk melakukan *vertical flip* pada citra.

2.4 Deep Learning

Setelah kualitas citra ditingkatkan dengan augmentasi, data dibagi menjadi data *test*, *valid* dan *train*. Data dibagi menjadi tiga rasio yaitu rasio 90:10, rasio 80:20 dan rasio 70:30. Penelitian ini menerapkan *deep learning* dengan *Convolution Neural Network*[26]. *EfficientNet* adalah arsitektur CNN yang dilakukan menggunakan metode penskalaan yang sederhana dan efisien. Penelitian ini juga menerapkan model klasifikasi yang dibangun menggunakan arsitektur *EfficientNet-B3*[27] dan menggunakan *parameter* dengan *learning rate*, *dense*, *batch size*, *Optimizer SGD* dan *RMSProp*. Berikut adalah arsitektur *EfficientNet-B3* dari penelitian ini.



Gambar 7. Arsitektur EfficientNet-B3

2.5 Evaluasi

Evaluasi adalah tahap untuk mendapatkan performa dari hasil model. Mendapatkan performa tersebut menggunakan *confusion matrix* yang merupakan metode dari evaluasi untuk mengevaluasi metode klasifikasi. Matriks berukuran $N \times N$. N merupakan jumlah kelas target. Pada penelitian ini matriks yang digunakan adalah *accuracy*, *precision*, *recall*, dan *f1-score* dengan rumus 1, 2, 3, dan 4.

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

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

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

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

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pengujian

Hasil dari implementasi penelitian menggunakan arsitektur EfficientNet-B3 dengan *tools google colab*, bahasa pemrograman *Python* serta *library keras* dan *Tensorflow*. Pada penelitian dilakukan eksperimen yang terdiri dari atas eksperimen dataset daun padi tanpa augmentasi data dan eksperimen dataset daun padi menggunakan augmentasi data yaitu *Brightness*, *Vertical_flip* dan *Rotation*.


Tabel 2. Hasil pengujian data Asli dan data menggunakan Augmentasi

Jenis Gambar	Split Data	Dense	Batch Size	Learning Rate	Optimezer	Valic Acc	Epoch
Original	70:30:00	256	64	0.1	SDG	85.87%	1
		256	64	0.1	RMSprop	90.21%	19
		256	64	0.01	RMSprop	88.04%	37
		256	64	0.001	RMSprop	90.21%	3
		256	64	0.0001	RMSprop	88.04%	12
	80:20:00	256	128	0.1	RMSprop	86.95%	25
		64	64	0.1	RMSprop	92.39%	44
		256	64	0.1	SDG	85.00%	9
		256	64	0.1	RMSprop	86.66%	9
		256	64	0.01	RMSprop	86.66%	4
		256	64	0.001	RMSprop	85.00%	6

Jenis Gambar	Split Data	Dense	Batch Size	Learning Rate	Optimezer	Valic Acc	Epoch
		256	64	0.0001	RMSprop	85.00%	2
		256	128	0.1	RMSprop	86.66%	35
		64	64	0.1	RMSprop	86.66%	5
		256	64	0.1	SDG	89.28%	3
		256	64	0.1	RMSprop	89.28%	17
		256	64	0.01	RMSprop	89.28%	37
	90:10:00	256	64	0.001	RMSprop	89.28%	8
		256	64	0.0001	RMSprop	85.71%	11
		256	128	0.01	RMSprop	85.71%	19
		64	64	0.01	RMSprop	85.71%	15
	70:30:00	256	64	0.1	SDG	93.11%	49
		256	64	0.1	RMSprop	92.27%	48
		256	64	0.01	SGD	90.94%	17
		256	64	0.001	SGD	88.76%	32
		256	64	0.0001	SGD	77.17%	49
		256	128	0.1	SGD	92.39%	26
		64	64	0.1	SGD	93.11%	39
Augmentasi		256	64	0.1	SDG	95.69%	6
		256	64	0.1	RMSprop	95.16%	12
		256	64	0.01	SGD	94.62%	24
	80:20:00	256	64	0.001	SGD	92.47%	39
		256	64	0.0001	SGD	86.55%	32
		256	128	0.1	SGD	94.62%	17
		64	64	0.1	SGD	94.62%	21
	90:10:00	256	64	0.1	SDG	95.65%	26


Jenis Gambar	Split Data	Dense	Batch Size	Learning Rate	Optimezer	Valic Acc	Epoch
		256	64	0.1	RMSprop	98.91%	11
		256	64	0.01	RMSprop	95.65%	33
		256	64	0.001	RMSprop	95.65%	9
		256	64	0.0001	RMSprop	94.56%	11
		256	128	0.1	RMSprop	97.82%	36
		64	64	0.1	RMSprop	98.91%	27

Berdasarkan tabel 2 dapat dilihat bahwa hasil akurasi tertinggi menggunakan data asli pada rasio 70:30 dengan menggunakan parameter berupa *learning rate* 0.1, *dense* 64, *batch size* 64 dan *optimizier* RMSProp menghasilkan *accuracy* 92.39% pada epoch 44. Sedangkan untuk akurasi tertinggi pada data menggunakan augmentasi terdapat pada rasio 90:10 dengan menggunakan parameter berupa *learning rate* 0.1, *dense* 64, *batch size* 64 dan *optimizier* RMSprop menghasilkan *accuracy* 98.91% pada epoch 27.



Gambar 8. Grafik hasil model *accuracy* dan *loss* pengujian citra tanpa menggunakan augmentasi data

Pada gambar 8 adalah grafik hasil model *accuracy* dan *loss* pengujian dari data asli terdapat pada rasio 70:30. *Optimizer* yang digunakan RMSprop, 64 *dense*, 0.1 *learning rate*, 64 *batch size*. Grafik model pada gambar 8 menunjukkan nilai pada *val_loss* dan *val_accuracy* naik turun yaitu 0.1594 dan 0.8370 yang menyebabkan pelatihnya tidak stabil dan menyebabkan kerugian validasi.



Gambar 9. Grafik hasil model *accuracy* dan *loss* pengujian citra menggunakan augmentasi data

Pada gambar 9 adalah grafik hasil model accuracy dan loss pengujian dari data augmentasi terdapat pada rasio 90:10. *Optimizer* RMSprop 64 *dense*, 0.1 *learning rate*, 64 *batch size*. Grafik model pada gambar 9 menunjukkan nilai grafik val_loss dan val_accuracy menurun val_loss sebesar 0.7234 dan val_accuracy sebesar 0.9348 yang menyebabkan kerugian validasi.

3.2 Pembahasan

Pada penelitian sebelumnya telah dilakukan penelitian tentang klasifikasi penyakit padi menggunakan arsitektur efficientNet-B3. Penelitian ini dilakukan pada tahun 2021 oleh ending dan kawan-kawan yang menghasilkan akurasi tertinggi sebesar 99%[13]. Penelitian lain yang menggunakan arsitektur efficientNet-B3 dan agmentasi data dilakukan pada tahun 2022 oleh M.fahriyal beserta kawan-kawannya yang melakukan penelitian tentang makanan di Taiwan menghasilkan akurasi yang lebih tinggi sebesar 99,7%[15]. Pada tahun 2022 telah dilakukan penelitian menggunakan arsitektur efficientNet dan augmentasi serta menggunakan *optimizer* Adam dan RMSprop yg menghasilkan akurasi tinggi sebesar 98%[16]. Berdasarkan dari penelitian yang telah dilakukan maka pada penelitian ini akan dilakukan perbandingan tingkat akurasi menggunakan CNN arsitektur EfficientNet-B3 serta *hyperparameter* untuk mengklasifikasi citra penyakit daun pada tanaman padi menggunakan augmentasi data dan tanpa augmentasi data.

4. KESIMPULAN

Dari penelitian ini diperoleh bahwa implementasi citra daun tanaman padi menggunakan CNN arsitektur EffisientNet-B3 dengan parameter yaitu *learning rate*, *dense*, *batch size*, *SGD Optimizer*, *RMSProp Optimizer*. hasil akurasi tertinggi menggunakan data asli pada rasio 70:30 dengan menggunakan parameter berupa *learning rate* 0.1, *dense* 64, *batch size* 64 dan *optimizier* RMSProp menghasilkan *accuracy* 92.39% pada epoch 44. Sedangkan untuk akurasi tertinggi pada data menggunakan augmentasi terdapat pada rasio 90:10 dengan menggunakan parameter berupa *learning rate* 0.1, *dense* 64, *batch size* 64 dan *optimizier* RMSprop menghasilkan *accuracy* 98.91% pada epoch 27.

Daftar Pustaka

- [1] F. Habib Hawari, F. Fadillah, M. Rifqi Alviandi, and T. Arifin, "Klasifikasi Penyakit Padi Menggunakan Algoritma Cnn (Convolutional Neural Network)," *Jurnal Responsif*, vol. 4, no. 2, pp. 184–189, 2022, [Online]. Available: <https://ejurnal.ars.ac.id/index.php/jti>
- [2] I. M. , R. , P. K. C. Utami. MZ, "Klasifikasi Gejala Defisiensi Nutrisi Pada Tanaman Padi Menggunakan CNN Dengan Arsitektur Googlenet," 2022.
- [3] K. K. Rekayasa, M. Khoiruddin, A. Junaidi, and W. A. Saputra, "Terbit online pada laman web jurnal: <http://journal.ittelkom-pwt.ac.id/index.php/dinda> Journal of Dinda Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network," *Data Institut Teknologi Telkom Purwokerto*, vol. 2, no. 1, pp. 37–45, 2022, [Online]. Available: <https://www.kaggle.com/tedisetiady/leaf-rice-disease->
- [4] S. Agustiani, Y. Tajul Arifin, A. Junaidi, S. Khotimatul Wildah, and A. Mustopa, "Klasifikasi Penyakit Daun Padi menggunakan Random Forest dan Color Histogram 1,*)." [Online]. Available: <https://www.kaggle.com/vbookshelf/rice-leaf->
- [5] Ulfah Nur Oktaviana, Ricky Hendrawan, Alfian Dwi Khoirul Annas, and Galih Wasis Wicaksono, "Klasifikasi Penyakit Padi berdasarkan Citra Daun Menggunakan Model Terlatih Resnet101," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 6, pp. 1216–1222, Dec. 2021, doi: 10.29207/resti.v5i6.3607.
- [6] A. Faizin, A. T. Arsanto, M. Lutfi, and A. R. Musa, "Deep Pre-Trained Model Menggunakan Arsitektur Densenet Untuk Identifikasi Penyakit Daun Padi," 2022.

- [7] L. Feng *et al.*, “Investigation on Data Fusion of Multisource Spectral Data for Rice Leaf Diseases Identification Using Machine Learning Methods,” *Front Plant Sci*, vol. 11, Nov. 2020, doi: 10.3389/fpls.2020.577063.
- [8] G. Zhang, T. Xu, Y. Tian, S. Feng, D. Zhao, and Z. Guo, “Classification of rice leaf blast severity using hyperspectral imaging,” *Sci Rep*, vol. 12, no. 1, Dec. 2022, doi: 10.1038/s41598-022-22074-7.
- [9] N. H. A. F. R. R. Giarsyani, “Komparasi Algoritma Machine Learning Dan Deep Learning Untuk Named Entity Recognition : Studi Kasus Data Kebencanaan,” *Jurnal Informatika & Rekayasa Elektronika*, vol. 3, 2020.
- [10] M. F. Naufal, “Analisis Perbandingan Algoritma Svm, Knn, Dan Cnn Untuk Klasifikasi Citra Cuaca,” doi: 10.25126/jtiik.202184553.
- [11] K. L. Kohsasih *et al.*, “Analisis Perbandingan Algoritma Convolutional Neural Network Dan Algoritma Multi-Layer Perceptron Neural Dalam Klasifikasi Citra Sampah,” 2021. [Online]. Available: <http://ejournal.stmik-time.ac.id>
- [12] A. Jinan and B. H. Hayadi, “Klasifikasi Penyakit Tanaman Padi Menggunakan Metode Convolutional Neural Network Melalui Citra Daun (Multilayer Perceptron),” 2022.
- [13] E. Anggiratih, S. Siswanti, S. K. Octaviani, and A. Sari, “Klasifikasi Penyakit Tanaman Padi Menggunakan Model Deep Learning Efficientnet B3 dengan Transfer Learning,” *Jurnal Ilmiah SINUS*, vol. 19, no. 1, p. 75, Jan. 2021, doi: 10.30646/sinus.v19i1.526.
- [14] S. A. dan A. M. W. F. Sabrina, “Klasifikasi Penyakit pada Tanaman Kopi Robusta Berdasarkan Citra Daun Menggunakan Convolutional Neural Network.”
- [15] M. Fahriyal Aldi, N. Damanik, M. Eka Zuwanda, A. Manajemen, K. Kunci, and M. Taiwan, “Klasifikasi 101 Jenis Makanan Taiwan Dengan Convolutional Neural Network,” vol. 2, no. 2, 2022.
- [16] N. Azahro Choirunisa, T. Karlita, and R. Asmara, “Deteksi Ras Kucing Menggunakan Compound Model Scaling Convolutional Neural Network,” *Technomedia Journal*, vol. 6, no. 2, pp. 236–251, Nov. 2021, doi: 10.33050/tmj.v6i2.1704.
- [17] J. Wu, X. Y. Chen, H. Zhang, L. D. Xiong, H. Lei, and S. H. Deng, “Hyperparameter optimization for machine learning models based on Bayesian optimization,” *Journal of Electronic Science and Technology*, vol. 17, no. 1, pp. 26–40, Mar. 2019, doi: 10.11989/JEST.1674-862X.80904120.
- [18] T. Yu and H. Zhu, “Hyper-Parameter Optimization: A Review of Algorithms and Applications,” Mar. 2020, [Online]. Available: <http://arxiv.org/abs/2003.05689>
- [19] Shayan Riyaz, “Rice Leafs,” *kagge*, 2020. <https://www.kaggle.com/datasets/shayanriyaz/riceleafs> (accessed Feb. 14, 2023).
- [20] Vbookshelf, “Rice Leaf Diseases Dataset,” *kagge*, 2020. <https://www.kaggle.com/datasets/vbookshelf/rice-leaf-diseases> (accessed Feb. 14, 2023).
- [21] Jitesh P. Shah, Harshadkumar B. Prajapati, and Vipul K. Dabhi, “Rice Leaf Diseases Data Set,” 2017. <https://archive.ics.uci.edu/ml/datasets/rice+leaf+diseases> (accessed Feb. 14, 2023).
- [22] D. Efendi, S. Sanjaya, F. Syafria, and E. Budianita, “Penerapan Algoritma Convolutional Neural Network Arsitektur ResNet-50 untuk Klasifikasi Citra Daging Sapi dan Babi,” *Jurnal Riset Komputer*, vol. 9, no. 3, pp. 2407–389, 2022, doi: 10.30865/jurikom.v9i3.4176.
- [23] G. Y. Alhafis, J. Jasril, S. Sanjaya, F. Syafria, and E. Budianita, “Klasifikasi Citra Daging Sapi dan Daging Babi Menggunakan Ekstraksi Ciri dan Convolutional Neural Network,” *JURIKOM (Jurnal Riset Komputer)*, vol. 9, no. 3, p. 653, Jun. 2022, doi: 10.30865/jurikom.v9i3.4175.

- [24] I. Kandel, M. Castelli, and L. Manzoni, "Brightness as an Augmentation Technique for Image Classification," *Emerging Science Journal*, vol. 6, no. 4, pp. 881–892, Aug. 2022, doi: 10.28991/ESJ-2022-06-04-015.
- [25] D. Oleh, "IMAGE RECOGNITION ALFABET BAHASA ISYARAT INDONESIA (BISINDO) MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK TUGAS AKHIR."
- [26] S. A. V. P. Anam Alidrus, *Deteksi Penyakit Pada Daun Tanaman Padi Menggunakan Metode Convolutional Neural Network*. 2021.
- [27] mingxing, v. le, quoc Tan, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," Sep. 11, 2020.



ZONasi: Jurnal Sistem Informasi

is licensed under a [Creative Commons Attribution International \(CC BY-SA 4.0\)](https://creativecommons.org/licenses/by-sa/4.0/)