

Klasifikasi Serangga Hama Tanaman Padi Menggunakan Metode *Convolutional Neural Network (CNN)*

¹*Bryan Rizqi Prakosa, ²Made Ayu Dusea Widya Dara, ³Umi Mahdiyah

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

Email: *bryanrp1950@gmail.com, 2madedara@unpkediri.ac.id, 3umimahdiyah@gmail.com

Penulis Korespondensi : Bryan Rizqi Prakosa

Abstrak—Indonesia merupakan negara agraris dengan sekitar 40% penduduknya bermata pencaharian sebagai petani, dan padi menjadi komoditas pertanian utama. Namun, produksi padi sering kali terganggu oleh serangan hama seperti wereng dan kumbang air padi. Kurangnya pengetahuan petani dalam mengenali jenis-jenis hama secara visual menjadi tantangan tersendiri dalam penanggulangan hama. Penelitian ini bertujuan untuk melakukan klasifikasi serangga hama pada tanaman padi menggunakan algoritma Convolutional Neural Network (CNN). Dataset citra hama yang digunakan terdiri dari 2,305 gambar yang diperoleh dari situs Kaggle, dan dilakukan proses augmentasi. Model CNN dibangun dan dilatih dengan berbagai konfigurasi parameter seperti epoch, jenis optimizer, dan fungsi aktivasi. Hasil penelitian menunjukkan bahwa model mampu mengklasifikasikan wereng dan kumbang air padi dengan akurasi sebesar 96% pada data testing. Confusion matrix juga memperlihatkan tingkat kesalahan klasifikasi yang sangat rendah. Dengan demikian, CNN terbukti efektif dan andal dalam mengenali serta mengklasifikasikan serangga hama tanaman padi berdasarkan citra.

Kata Kunci—Augmentasi, Convolutional Neural Network (CNN), Kaggle, Klasifikasi hama, Pengolahan citra digital, Tanaman padi

Abstract—Indonesia is an agricultural country with around 40% of its population working as farmers, and rice is the main agricultural commodity. However, rice production is often disrupted by pests such as rice planthoppers and rice water beetles. Farmers limited ability to visually identify pests presents challenges in pest control. This study aims to classify rice plant pests using the Convolutional Neural Network (CNN) algorithm. A dataset of 2,305 pest images from Kaggle was used, and data augmentation was applied. The CNN model was trained with various parameters, including epochs, optimizers, and activation functions. The results showed the model achieved 96% accuracy in classifying rice planthoppers and rice water beetles on the test data. The confusion matrix also indicated a very low classification error. These results demonstrate that CNN is effective and reliable in automatically identifying insect pests on rice plants through image-based classification.

Keywords—Augmentation, Convolutional Neural Network (CNN), Kaggle, Pest classification, Digital image processing, Rice plants

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



I. PENDAHULUAN

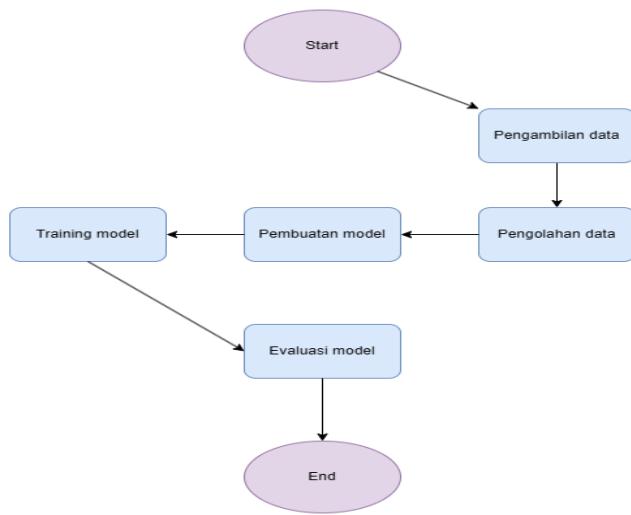
Indonesia adalah negara agraris, yang 40% mata pencaharian mayoritas penduduknya bertani. Indonesia merupakan negara agraris karena sebagian besar atau mayoritas penduduknya bekerja di sektor pertanian [1]. Padi merupakan sektor pertanian yang besar di Indonesia, menurut BPS pada tahun 2024 Indonesia memproduksi 53.142.726,65 ton padi dengan luas panen 10.046.135,36 hektar. Namun, di sisi lain serangga hama pada tanaman padi dapat mengurangi produksi padi. Pada tanaman padi terdapat banyak hama yang menyerang, sehingga apabila tidak dilakukan pengendalian dan penanggulangan yang tepat dapat mengakibatkan penurunan produksi padi [2]. Serangga hama berukuran relatif kecil yang terkadang sulit dilihat dan masih banyak para petani yang belum memahami jenis-jenis hama yang dapat menyerang padi, pengetahuan tentang hama padi dan penanggulangannya hanya didapat dari pengalaman saja [1].

Dengan masalah yang dipaparkan di atas, sangat menarik untuk membuat penelitian klasifikasi serangga hama tanaman padi dengan teknologi pengolahan citra. Pada artikel yang ditulis oleh Ramadhani, Rima Dias menyatakan terdapat beberapa algoritma untuk klasifikasi citra seperti K-means, Support Vector Machine (SVM), dan Convolutional Neural Network (CNN). Namun, dari ketiga algoritma tersebut CNN yang paling banyak digunakan untuk klasifikasi citra [3]. Convolutional Neural Network adalah salah satu metode machine learning dari pengembangan Multi Layer Perceptron (MLP) yang didesain untuk mengolah data dua dimensi [5]. Berdasarkan artikel yang ditulis oleh Ramadhani, Rima Dias, maka pada penelitian ini digunakan algoritma Convolutional Neural Network (CNN) untuk melakukan klasifikasi serangga hama pada tanaman padi. Berdasarkan yang sudah telah dijelaskan di atas, tujuan dari penelitian ini adalah untuk melakukan penelitian klasifikasi serangga hama pada tanaman padi (wereng dan kumbang air padi) menggunakan algoritma *Convolutional Neural Network (CNN)*. Penelitian sebelumnya yang dilakukan oleh Sukanya S. dkk dengan judul “Pest Detection System for Rice Crop Using Pest-Net Model” yang menggunakan metode CNN memiliki hasil yang cukup baik. Dalam penelitian ini, digunakan kumpulan data yang terdiri dari 2554 gambar. Fokus penelitian ini adalah pada pengembangan model eksperimen yang disebut Pest-Net. Sebagai perbandingan, penelitian ini juga melatih model menggunakan Alex-Net untuk klasifikasi kumpulan data yang sama. Di akhir penelitian, ditemukan bahwa model Pest-Net menunjukkan akurasi yang lebih tinggi, yaitu 88. 6%, dibandingkan dengan Alex-Net yang hanya mencapai 80. 2% [7].

II. METODE

Metode penelitian yang digunakan dalam penelitian ini yaitu Penelitian Eksperimen (Experimental Research) yang bertujuan untuk mengevaluasi performa algoritma CNN dalam mengenali dan mengklasifikasikan citra berdasarkan metrik evaluasi tertentu. Secara umum, CNN memiliki struktur yang terdiri dari input, ekstraksi fitur, klasifikasi, dan output. Proses ekstraksi fitur pada CNN terdiri dari beberapa lapisan atau layer, yaitu lapisan konvolusi (convolutional layer), fungsi aktivasi (menggunakan ReLU), dan lapisan pooling. Sedangkan pada proses klasifikasi, lapisan yang digunakan terdiri dari fully-connected layer dan fungsi aktivasi (menggunakan Softmax) [6]. Kelas serangga hama pada tanaman padi yang

dimasukkan yaitu wereng dan kumbang air padi. Dataset citra didapatkan dari situs kaggle dengan total jumlah 2305 citra. Proses penelitian dapat dilihat sebagai gambar berikut ini.



Gambar 1. Diagram metode penelitian

Proses dimulai dari pengambilan data berupa gambar serangga hama pada tanaman padi, lalu dilanjutkan dengan pengolahan data seperti normalisasi piksel dan augmentasi. Setelah data siap, dilakukan pembuatan dan pelatihan model menggunakan algoritma CNN. Model yang telah dilatih kemudian dievaluasi untuk mengukur performanya dalam mengenali jenis-jenis serangga hama pada tanaman padi. Proses tersebut akan dilakukan sebanyak eksperimen yang akan dilakukan. Pada eksperimen ini, dilakukan dengan mengganti nilai epoch training, optimizer, dan fungsi aktivasi.

A. Pengambilan data

Dataset citra yang digunakan dalam penelitian ini diperoleh dari situs Kaggle. Halaman dataset berada pada <https://www.kaggle.com/datasets/bryanrizqiprakosa/dataset-artikel-29mei>. Total jumlah citra yang tersedia dalam dataset ini adalah sebanyak 2305 citra. Dataset tersebut diklasifikasikan ke dalam dua kelas, yaitu wereng dan kumbang air padi. Distribusi jumlah citra pada masing-masing kelas relatif seimbang, dengan rincian kelas wereng 1110 citra dan kelas kumbang air padi 1194 citra. Sampel data citra dapat dilihat pada tabel di bawah ini.

Tabel 1. Sampel data citra

Kelas	Gambar
Wereng	

Kumbang air padi



B. Pengolahan Data

Pada tahap ini, dataset citra serangga hama pada tanaman padi dikumpulkan. Selanjutnya, dataset dibagi menjadi tiga bagian, yaitu data pelatihan (training), data validasi, dan data pengujian (testing). Selain itu, dilakukan augmentasi data seperti rotasi, vertical flip, horizontal flip, dan zooming. Proses augmentasi data bertujuan untuk meningkatkan jumlah sampel data latih dan menciptakan variasi dalam data, sehingga model dapat lebih baik dalam menggeneralisasi dan mengatasi overfitting [8]. Sampel data citra hasil pengolahan data dapat dilihat pada tabel di bawah ini.

Tabel 2. Sampel data citra hasil pengolahan data

Augmentasi	Kelas	Sampel
Vertical flip	Wereng	
Horizontal flip	Kumbang air padi	
Zoom citra	Wereng	

Rotasi citra Kumbang air padi



C. Pembuatan Model

Setelah data siap, tahap selanjutnya adalah pembuatan model CNN. Model dapat terdiri dari beberapa lapisan konvolusi, pooling, dan fully connected layer. Pemilihan arsitektur yang tepat sangat penting untuk memastikan model mampu membedakan antar kelas secara akurat. Tabel di bawah merupakan arsitektur CNN yang digunakan.

Tabel 3. Arsitektur CNN yang digunakan

No	Layer	Tipe	Output
1.	Input (224 x 224 x 3)	Input layer	224 x 224 x 3
2.	Conv 1 (3x3), 32	Convolutional layer	222 x 222 x 32
3.	Max Pooling 1 (2x2)	Pooling layer	111 x 111 x 32
4.	Conv 2 (3x3), 64	Convolutional layer	109 x 109 x 64
5.	Max Pooling 2 (2x2)	Pooling layer	54 x 54 x 64
6.	Conv 3 (3x3), 128	Convolutional layer	52 x 52 x 128
7.	Max Pooling 3 (2x2)	Pooling layer	26 x 26 x 128
8.	Conv 4 (3x3), 512	Convolutional layer	24 x 24 x 256
9.	Max Pooling 4 (2x2)	Pooling layer	12 x 12 x 256
10.	Conv 5 (3x3), 512	Convolutional layer	10 x 10 x 384
11.	Max Pooling 5 (2x2)	Pooling layer	5 x 5 x 384
12.	Flatten	Flatten layer	9600
13.	Dense	Fully connected layer	384
14.	Dropout	Dropout layer	384
15.	Dense	Fully connected layer	384
16.	Dropout	Dropout layer	384
17.	Dense (softmax)	Classifier	2

D. Pelatihan Model

Model akan CNN dilatih untuk mengenali pola dari citra serangga dan mengklasifikasikannya ke dalam kategori yang sesuai. Selama pelatihan, model akan melakukan optimasi terhadap bobot-bobot jaringan menggunakan algoritma seperti Adam, serta fungsi loss seperti categorical cross-entropy. Proses pelatihan juga dilengkapi dengan teknik validasi untuk memantau performa model. Pada pelatihan model, akan dilakukan beberapa eksperimen dengan mengubah parameter epoch, fungsi aktivasi, dan algoritma optimasi (*optimizer*).

E. Evaluasi

Evaluasi model akan dilakukan dengan menggunakan metrik - metrik tertentu. Pengujian model CNN melibatkan menjalankan model pada data uji yang belum pernah dilihat sebelumnya untuk mengukur kinerjanya [10]. Evaluasi dilakukan dengan berbagai metrik seperti akurasi, presisi, recall, dan F1-score. Selain itu, digunakan pula metode evaluasi tambahan seperti confusion matrix.

1. Confusion matrix

Confusion matrix atau matrix kebingungan merupakan alat pengukuran yang digunakan dalam machine learning. Matrix kebingungan merepresentasikan hasil kelas prediksi, sementara kolom merepresentasikan hasil kelas sebenarnya, sehingga dapat menghitung semua kemungkinan kasus dalam masalah klasifikasi [4]. Contoh confusion matrix pada hasil klasifikasi serangan hama pada tanaman padi seperti dibawah berikut.

Tabel 4. Contoh confusion matrix

		Hasil Prediksi	
		Wereng	Kumbang air padi
Kelas Asli	Wereng	25	3
	Kumbang air padi	2	15

Tabel di atas merupakan contoh confusion matrix. Pada kolom merupakan hasil prediksi dan pada baris merupakan kelas asli. Contoh di atas berjumlah 45.

- TP (True Positive) yaitu ketika model memprediksi positif dan data tersebut memang memiliki label positif, pada contoh confusion matrix tersebut nilainya adalah 25
- FP (False Positive) yaitu ketika model memprediksi positif namun data tersebut memiliki label negatif, pada contoh confusion matrix tersebut nilainya adalah 3
- TN (True Negative) yaitu ketika model memprediksi negatif dan data tersebut memang memiliki label negatif, pada contoh confusion matrix tersebut nilainya adalah 15
- FN (False Negative) yaitu ketika model memprediksi positif namun data tersebut memiliki label positif, pada contoh confusion matrix tersebut nilainya adalah 2

2. Akurasi

Akurasi merupakan pembagian dari prediksi model yang dianggap benar dengan jumlah total yang diprediksi [9]. Ini adalah metrik evaluasi yang paling sederhana dan sering digunakan.

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN}$$

$$\text{Akurasi} = \frac{25 + 15}{25 + 15 + 3 + 2} = 0,8$$

3. Presisi

Presisi mengukur seberapa akurat prediksi positif model — dari semua yang diprediksi sebagai positif, berapa banyak yang benar-benar positif.

$$\text{Presisi} = \frac{TP}{TP + FP}$$

$$\text{Presisi} = \frac{25}{25 + 3} = 0,89$$

4. Recall

Recall mengukur kemampuan model dalam menemukan semua contoh positif yang sebenarnya.

$$\text{Recall} = \frac{TP}{TP+FN}$$

$$\text{Recall} = \frac{25}{25+2} = 0,92$$

5. F1-Score

F1-score adalah rata-rata harmonis antara presisi dan recall. Digunakan untuk mendapatkan keseimbangan antara keduanya, terutama saat data tidak seimbang.

$$\text{Recall} = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}}$$

$$\text{Recall} = 2 \times \frac{0,89 \times 0,92}{0,89 + 0,92} = 2 \times \frac{0,81}{1,81} = 0,89$$

III. HASIL DAN PEMBAHASAN

Pada eksperimen ini akan dilakukan penggantian parameter di algoritma CNN seperti epoch, optimizer, dan fungsi aktivasi. Sebelum klasifikasi, jumlah citra pada awalnya berjumlah 2305 lalu dilakukan split dataset dengan rincian berikut.

Tabel 5. Split dataset citra

Dataset	Presentase	Jumlah Citra
Training set	70 %	1612
Validation set	15 %	460
Testing set	15 %	232

Setelah dilakukan split dataset, proses selanjutnya yaitu augmentasi citra dengan metode augmentasi vertical flip, horizontal flip, zoom citra, dan rotasi citra. Mula – mula dilakukan eksperimen epoch dengan jumlah 15, 30, dan 60. Eksperimen awal ini dilakukan dengan optimizer Adam dan fungsi aktivasi Relu sebagai parameter yang umum digunakan.

Tabel 6. Klasifikasi eksperimen epoch

Epoch	Optimizer	Aktivasi	Akurasi	Loss
15	Adam	Relu	84%	0, 33
30	Adam	Relu	87%	0, 28
60	Adam	Relu	96%	0, 1

Setelah eksperimen pertama dilakukan, antara jumlah epoch yang didefinisikan pada Tabel 6 terdapat epoch dengan jumlah 60 dengan nilai akurasi dan nilai loss terbaik. Di eksperimen selanjutnya dilakukan eksperimen fungsi aktivasi, fungsi aktivasi yang akan dilakukan antara lain yaitu Relu, Sigmoid, Elu, Linear, Softplus, Tanh, dan Softsign.

Tabel 7. Klasifikasi eksperimen fungsi aktivasi

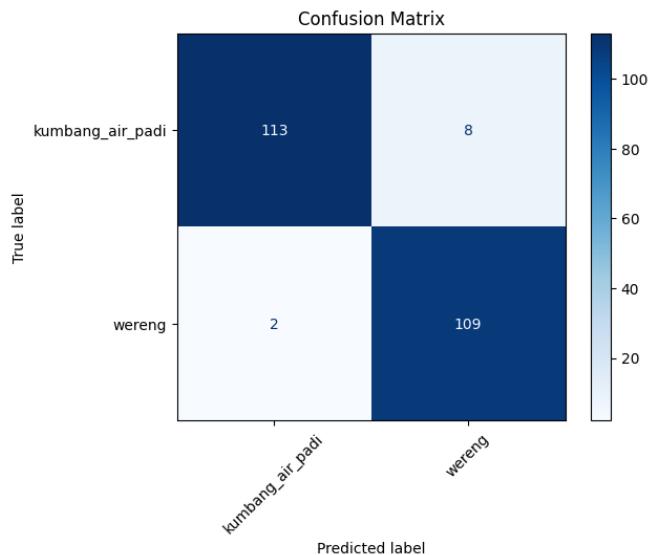
Epoch	Optimizer	Aktivasi	Akurasi	Loss
60	Adam	Relu	96%	0, 1
60	Adam	Sigmoid	52%	0, 69
60	Adam	Elu	96%	0, 06
60	Adam	Linear	91%	0, 19
60	Adam	Softplus	52%	0, 69
60	Adam	Tanh	52%	0, 71
60	Adam	Softsign	53%	0, 72

Setelah eksperimen fungsi aktivasi berhasil dilakukan, terdapat fungsi aktivasi Elu dengan nilai akurasi dan nilai loss terbaik. Pada eksperimen selanjutnya akan dilakukan eksperimen optimizer. Optimizer yang akan dilakukan eksperimen antara lain, Adam, Nadam, RMSProp, SGD, dan Adagrad.

Tabel 8. Klasifikasi eksperimen optimizer

Epoch	Optimizer	Aktivasi	Akurasi	Loss
60	Adam	Elu	96%	0, 1
60	Nadam	Elu	47%	0, 69
60	RMSProp	Elu	93%	0, 14
60	SGD	Elu	81%	0, 4
60	Adagrad	Elu	77%	0, 5

Setelah eksperimen epoch, fungsi aktivasi, dan optimizer, parameter terbaik ialah dengan 60 epoch, optimizer Adam, dan fungsi aktivasi Elu. Hasil klasifikasi yang lebih rinci dari parameter tersebut dapat dilihat pada confusion matrix di bawah ini.



Gambar 2. Confusion matrix hasil klasifikasi

Berdasarkan matriks tersebut, dari total 121 data aktual Kumbang air padi, sebanyak 113 data berhasil diklasifikasikan dengan benar, sedangkan 8 data lainnya salah diklasifikasikan sebagai Wereng. Sementara itu, dari 111 data aktual Wereng, sebanyak 109 berhasil dikenali dengan benar, dan hanya 2 data yang salah diklasifikasikan Kumbang air padi. Hasil ini menunjukkan bahwa model memiliki tingkat kesalahan klasifikasi yang sangat rendah, dengan jumlah prediksi yang benar jauh lebih banyak dibandingkan kesalahan. Kesalahan paling banyak terjadi ketika model keliru mengklasifikasikan Kumbang air padi sebagai Wereng, namun jumlahnya masih tergolong kecil (hanya 8 dari 121). Sebaliknya, model hanya melakukan 2 kesalahan dalam mengklasifikasikan Wereng. Secara keseluruhan, confusion matrix ini membuktikan bahwa model memiliki akurasi tinggi dan mampu membedakan dua jenis hama secara efektif.

Tabel 9. Rincian hasil klasifikasi

	Precision	Recall	F1-Score	Akurasi
Kumbang air padi	0.98	0.93	0.96	
Wereng	0.93	0.98	0.96	
Macro avg	0.96	0.96	0.96	
Weighted avg	0.96	0.96	0.96	0.96

Berdasarkan hasil evaluasi pada Tabel di atas, model klasifikasi menunjukkan kinerja yang sangat baik dalam mengklasifikasikan dua jenis hama. Untuk kelas Kumbang air padi, model memiliki nilai precision sebesar 0,98, yang berarti hampir seluruh prediksi terhadap kelas ini benar. Sementara itu, recall-nya sebesar 0,93 menunjukkan bahwa sebagian besar data aktual Kumbang air padi berhasil dikenali dengan tepat oleh model. Nilai F1-Score yang mencapai 0,96 mencerminkan keseimbangan antara precision dan recall, menunjukkan bahwa model mampu menjaga kinerja baik tanpa mengorbankan salah satu aspek. Hal yang sama juga terlihat pada kelas Wereng, dengan precision sebesar 0,93 dan recall sebesar 0,98. Meskipun precision sedikit lebih rendah dibandingkan dengan Kumbang air padi, recall yang tinggi menunjukkan bahwa model sangat sensitif dalam mendeteksi keberadaan Wereng. F1-Score yang juga mencapai 0,96 memperkuat bahwa model memiliki kinerja seimbang untuk kedua kelas.

Nilai *macro average* dan *weighted average* untuk semua metrik, masing-masing sebesar 0,96, menunjukkan konsistensi kinerja model baik secara rata-rata antar kelas maupun berdasarkan distribusi jumlah sampel di tiap kelas. Akurasi keseluruhan model mencapai 0,96 atau 96%, yang berarti bahwa 96% dari seluruh prediksi yang dilakukan oleh model adalah benar. Hasil ini menunjukkan bahwa model klasifikasi yang dikembangkan sangat andal dan dapat digunakan untuk mendeteksi jenis hama dengan tingkat keakuratan yang tinggi.

IV. KESIMPULAN

Model yang dilatih memiliki performa yang sangat baik dalam mengklasifikasikan serangga hama pada tanaman padi, yaitu Kumbang air padi dan Wereng. Nilai precision, recall, dan F1-score yang tinggi dan seimbang untuk kedua kelas, masing-masing sebesar 0,96, menunjukkan bahwa model mampu mengenali dan membedakan kedua jenis hama dengan akurasi yang tinggi. Akurasi keseluruhan sebesar 96% semakin memperkuat keandalan model dalam melakukan klasifikasi yang tepat. Selain itu, hasil confusion matrix menunjukkan bahwa model hanya membuat sedikit kesalahan klasifikasi, dengan 113 dari 121 data kumbang air padi dan 109 dari 111 data wereng berhasil dikenali secara akurat. Jumlah kesalahan yang sangat

minim ini menunjukkan bahwa model tidak hanya akurat tetapi juga stabil dan konsisten dalam kinerjanya. Berdasarkan hasil eksperimen yang telah dilakukan, dapat disimpulkan bahwa metode Convolutional Neural Network (CNN) mampu melakukan klasifikasi serangga hama pada tanaman padi dengan akurasi yang baik. Hal ini menunjukkan bahwa CNN memiliki kemampuan yang andal dalam mengenali pola visual dari citra serangga hama pada tanaman padi.

DAFTAR PUSTAKA

- [1] Ayun, Qurotu, Shidiq Kurniawan, and Wahyu Adhi Saputro. "Perkembangan konversi lahan pertanian di bagian negara agraris." *Vigor: Jurnal Ilmu Pertanian Tropika Dan Subtropika* 5.2 (2020): 38-44.
- [2] Nagara, Erliza Septia, and Rini Nurhayati. "Sistem Pendukung Keputusan Penentuan Hama Padi Menggunakan PHP." *Jurnal TAM (Technology Acceptance Model)* 4 (2021): 1-12, doi: <https://doi.org/10.56327/jurnaltam.v4i0.31>.
- [3] Ramadhani, Rima Dias, et al. "Optimasi Akurasi Metode Convolutional Neural Network untuk Identifikasi Jenis Sampah." *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)* 5.2 (2021): 312-318, doi: <https://doi.org/10.29207/resti.v5i2.2754>.
- [4] Ridhovan, Andreanov, and Aries Suharso. "Penerapan metode residual network (resnet) dalam klasifikasi penyakit pada daun gandum." *JIPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)* 7.1 (2022): 58-65, doi: <https://doi.org/10.29100/jipi.v7i1.2410>.
- [5] Christiawan, Gracia Yoel, et al. "Penerapan Metode Convolutional Neural Network (CNN) Dalam Mengklasifikasikan Penyakit Daun Tanaman Padi." *J-INTECH (Journal of Information and Technology)* 11.2 (2023): 294-306, doi: <https://doi.org/10.32664/jintech.v11i2.1006>.
- [6] Darojat, M. D., Y. A. Sari, dan R. C. Wihandika. "Convolutional Neural Network Untuk Klasifikasi Citra Makanan Khas Indonesia". *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, vol. 5, no. 11, Oktober 2021, hlm. 4764-9, <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/10096>.
- [7] Gaikwad, Sukanya S., and Mallikarjun Hangarge. "Pest Detection System for Rice Crop Using Pest-Net Model." *First International Conference on Advances in Computer Vision and Artificial Intelligence Technologies (ACVAIT 2022)*. Atlantis Press, 2023, doi: https://doi.org/10.2991/978-94-6463-196-8_45.
- [8] Akram, Ar'rafi & Fayakun, Kun & Ramza, Harry. (2023). Klasifikasi Hama Serangga pada Pertanian Menggunakan Metode Convolutional Neural Network. *Building of Informatics, Technology and Science (BITS)*. 5, doi: 10.47065/bits.v5i2.4063.
- [9] Azmi, Khairul, Sarjon Defit, and Sumijan Sumijan. "Implementasi convolutional neural network (CNN) untuk klasifikasi batik tanah liat sumatera barat." *Jurnal Unitek* 16.1 (2023): 28-40, doi: <https://doi.org/10.52072/unitek.v16i1.504>.
- [10] Maulana, Sandy Andika, et al. "Penerapan Metode CNN (Convolutional Neural Network) Dalam Mengklasifikasi Jenis Ubur-Ubur." *Jurnal Penelitian Rumpun Ilmu Teknik* 2.4 (2023): 122-130, doi: <https://doi.org/10.55606/juprit.v2i4.3084>.