

KLASIFIKASI HAMA SERANGGA PADA PERTANIAN MENGUNAKAN ARSITEKTUR INCEPTION-RESNET-V2

Diterima Redaksi: 16 Desember 2024; Revisi Akhir: 24 Februari 2025; Diterbitkan Online: 30 Mei 2025

Dimas Saputra¹⁾, Archamul Fajar Pratama²⁾, Muhammad Dawam Fakhri³⁾, Muhammad Ahsanur Rafi⁴⁾, Fetty Tri Anggraeny⁵⁾

^{1, 2, 3, 4, 5)} Informatika, Universitas Pembangunan Nasional “Veteran” Jawa Timur

Jalan Raya Rungkut Madya No. 1 Surabaya, Indonesia

e-mail: 21081010151@student.upnjatim.ac.id¹⁾, 21081010178@student.upnjatim.ac.id²⁾,
21081010256@student.upnjatim.ac.id³⁾, 21081010305@student.upnjatim.ac.id⁴⁾,
fettyanggraeny.if@upnjatim.ac.id⁵⁾

Abstrak: Pengenalan objek dalam gambar merupakan tantangan utama dalam pemrosesan citra digital dengan aplikasi yang luas, termasuk di sektor pertanian. Penelitian ini bertujuan untuk mengembangkan model Convolutional Neural Network (CNN) berbasis arsitektur Inception-ResNet-V2 untuk klasifikasi hama serangga dalam pertanian. Dataset yang digunakan dalam penelitian ini terdiri dari 1.591 gambar dari 13 kelas hama serangga yang berbeda, yang dikumpulkan dari sumber publik Kaggle dengan judul "Dangerous Farm Insects Dataset". Untuk meningkatkan kualitas dan variasi data, dilakukan beberapa tahapan preprocessing seperti resizing, normalisasi, dan augmentasi gambar. Augmentasi yang dilakukan meliputi rotasi, pergeseran, zooming, flipping horizontal, dan shearing. Proses pelatihan model dilakukan selama 10 epoch, menghasilkan akurasi sebesar 89,52% dengan loss sebesar 0,4024. Hasil penelitian menunjukkan bahwa model CNN yang dikembangkan mampu mendeteksi dan mengklasifikasikan hama serangga dengan tingkat akurasi yang tinggi pada beberapa kelas. Namun, terdapat variasi performa antar kelas, di mana beberapa kelas seperti Africanized Honey Bees dan Cabbage Loopers menunjukkan performa yang sangat baik dengan F1-Score masing-masing 0,90 dan 0,95, sementara kelas lain seperti Corn Earworms dan Thrips memiliki performa yang lebih rendah dengan F1-Score 0,69 dan 0,67. Secara keseluruhan, model ini memiliki total precision sebesar 0,8734, recall 0,8346, dan F1-Score 0,8327. Hasil penelitian ini menunjukkan bahwa model CNN berbasis Inception-ResNet-V2 dapat menjadi solusi efektif untuk klasifikasi hama serangga dalam pertanian, meskipun masih terdapat ruang untuk peningkatan, terutama dalam mengatasi variasi performa antar kelas. Penelitian ini diharapkan dapat menjadi dasar pengembangan sistem berbasis aplikasi yang membantu petani dalam mengidentifikasi hama serangga secara lebih efisien, mendukung pengambilan keputusan dalam pengendalian hama, dan meningkatkan hasil pertanian. Ke depan, penelitian ini dapat dikembangkan dengan mengeksplorasi teknik augmentasi yang lebih canggih dan integrasi dengan teknologi Internet of Things (IoT) untuk deteksi hama secara real-time di lapangan.

Kata Kunci—CNN, Inception-Resnet-V2, Hama Serangga, Deep Learning

Abstract: Object recognition in images is a major challenge in digital image processing, with wide-ranging applications, including in the agricultural sector. This study aims to develop a Convolutional Neural Network (CNN) model based on the Inception-ResNet-V2 architecture for the classification of agricultural insect pests. The dataset used in this research consists of 1,591 images from 13 different classes of insect pests, collected from the publicly available "Dangerous Farm Insects Dataset" on Kaggle. To enhance data quality and variability, several preprocessing steps were applied, including resizing, normalization, and image augmentation. Augmentation techniques included rotation, shifting, zooming, horizontal flipping, and shearing. The model training process was conducted over 10 epochs, achieving an accuracy of 89.52% with a loss of 0.4024. The results indicate that the developed CNN model is capable of detecting and classifying insect pests with high accuracy across several classes. However, there was variation in performance between classes, with some classes such as Africanized Honey Bees and Cabbage Loopers showing excellent performance with F1-Scores of 0.90 and 0.95, respectively, while other classes like Corn Earworms and Thrips had lower performance with F1-Scores of 0.69 and 0.67. Overall, the model achieved a total precision of 0.8734, recall of 0.8346, and F1-Score of 0.8327. The findings of this study demonstrate that the Inception-ResNet-V2-based CNN model can serve as an effective solution for classifying agricultural insect pests, although there is still room for improvement, particularly in addressing performance variations across classes. This research is expected to serve as a foundation for the development of an application-based system that helps farmers identify insect pests more efficiently, supports decision-making in pest control, and improves agricultural yields. Future work could explore more advanced augmentation techniques and integration with Internet of Things (IoT) technology for real-time pest detection in the field.

Keywords— *CNN, Inception-Resnet-V2, Insect Pest, Deep Learning*

I. PENDAHULUAN

Pengenalan objek dalam gambar adalah salah satu isu penting dalam bidang pemrosesan citra digital, yang memang mempunyai banyak aplikasi pada berbagai sektor termasuk pertanian, layanan kesehatan, dan keamanan. Pendekatan yang terbukti efektif dalam menyelesaikan masalah pengenalan gambar adalah penggunaan Convolution Neural Network (CNN). CNN merupakan salah satu teknik yang digunakan dalam pembelajaran mendalam yang telah menunjukkan performa yang cukup baik dalam klasifikasi gambar dan deteksi objek, terutama terkait dengan kemampuan untuk mengenali pola kompleks secara visual.

Dalam hal pertanian, terutama terkait dengan kebutuhan untuk mendeteksi hama serangga yang mungkin mengancam hasil panen, pengenalan citra untuk hama tersebut sangat penting. Hama serangga dapat menyebabkan kerusakan serius pada tanaman yang, pada gilirannya, akan mengurangi nilai dan kuantitas produksi pertanian. Mereka dapat memiliki dampak ekonomi dan ekologi yang signifikan. Mereka dapat menjadi gangguan konstan atau menyebabkan wabah berkala, yang menyebabkan kerugian ekonomi yang signifikan [1]. Oleh karena itu, riset dan pengembangan sistem otomatis untuk pengenalan hama berdasarkan klasifikasi ultra-cepatnya sangat penting untuk membantu petani menerapkan langkah-langkah pengendalian hama yang lebih efektif.

Beberapa studi sebelumnya telah melaporkan bahwa CNN dapat diterapkan di berbagai bidang klasifikasi gambar, seperti deteksi hama tanaman, klasifikasi ekspresi wajah, dan bahkan pengenalan kendaraan. Misalnya, sebuah studi melaporkan bahwa model CNN yang mengandung beberapa lapisan konvolusi serta augmentasi gambar mencapai akurasi hingga 83,02 dan mampu mengklasifikasikan hama tanaman padi [1]. Di sisi lain, penelitian lain menunjukkan bahwa CNN mampu mengenali ekspresi wajah dengan tingkat akurasi 66% [2]. Sementara itu, penelitian di bidang pengenalan kendaraan prioritas memberikan bukti serupa, yaitu bahwa CNN mampu memberikan akurasi tertinggi hingga 69,23% dalam beberapa skenario uji [3].

Dalam penelitian ini, minat utama penyelidikan adalah penggunaan CNN untuk klasifikasi hama serangga dalam pertanian. Dataset yang digunakan dalam studi ini adalah “Dangerous Farm Insects Dataset” yang berisi gambar dari berbagai spesies hama serangga yang ditemukan dalam pertanian. Data yang dikumpulkan akan diproses dengan teknik pra-proses dan augmentasi gambar untuk meningkatkan kualitas dataset sebelum melatih model. Struktur model jaringan saraf konvolusi yang digunakan dalam penelitian ini adalah model CNN dengan arsitektur Inception-ResNet-V2, salah satu arsitektur CNN yang paling kuat dalam ekstraksi fitur gambar [3].

Penelitian ini memiliki tujuan untuk mengembangkan dan mengevaluasi model CNN untuk memungkinkan klasifikasi otomatis hama serangga dengan akurasi tinggi. Di antara tujuan lainnya, penelitian ini bermaksud untuk menyelidiki penggunaan teknik pra-proses dan augmentasi data untuk meningkatkan kinerja model dan mengevaluasi kinerja model dengan metrik seperti akurasi, presisi, recall, dan F1-Score.

Diharapkan penelitian ini dapat menghasilkan sistem deteksi hama serangga yang cepat dan akurat yang membantu petani dalam klasifikasi hama, sehingga memungkinkan pengambilan keputusan yang lebih baik saat mengendalikan hama dan meningkatkan hasil pertanian.

II. TINJAUAN PUSTAKA

A. Hama Serangga Pertanian

Hama serangga adalah organisme yang menyebabkan kerusakan pada tanaman, produk yang disimpan, atau sumber daya lain yang penting bagi manusia. Mereka dapat memiliki dampak ekonomi dan ekologi yang signifikan. Mereka dapat menjadi gangguan konstan atau menyebabkan wabah berkala, yang menyebabkan kerugian ekonomi yang signifikan [4].

Hama serangga dapat dikelompokkan berdasarkan jenis tanaman yang diserang dan cara mereka beradaptasi. Hama khusus atau oligofag menyerang tanaman dalam lingkup sempit, seringkali spesifik pada spesies atau kelompok tumbuhan tertentu. Hama produk tersimpan, seperti kumbang, berevolusi dari serangga yang awalnya menyerang tanaman di lapangan dan kini beradaptasi untuk menyerang biji-

bijian yang disimpan serta produk lainnya, berkembang biak dalam kondisi yang mendukung. Sementara itu, hama daun menyerang bagian daun tanaman, sering menjadi vektor virus atau patogen lain dengan dampak pada berbagai jenis tanaman, kadang spesifik pada bagian tertentu [4].

B. Penelitian Terdahulu

Dari hasil penelitian Susi Yuliany dan kawan-kawan (2020) yang berjudul “Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN)” diketahui bahwa Model arsitektur CNN yg dibangun terdiri dari tiga lapisan konvolusi, dua lapisan fully connected, dan ada penambahan dropout. Pada model pelatihan yang dibagi data training dan validasi dengan rasio 90:10% diperoleh 3 model dengan nilai validasi masing-masing 83,02%; 78,30% dan 81,13%. Terdapat lima model CNN yang diujikan, dimana model terakhir menghasilkan nilai akurasi tertinggi sebesar 77,33% sedangkan nilai akurasi training dilaporkan mencapai 78,30% pada data yang dibagi 90:10% [1].

Dari penelitian yang sudah dilakukan oleh Derry Alamsyah, dkk pada tahun 2020, berjudul “Implementasi Jaringan Syaraf Tiruan Konvolusional (CNN) Untuk Klasifikasi Ekspresi Citra Wajah Pada Dataset FER-2013”, model CNN mampu mengenali emosi seseorang dari citra wajah dan dilaporkan akurat 66% apabila dioptimalkan dengan Adamax. Hasil pengukuran UPT Recall menunjukkan nilai happy: 68% dan sad: 64%. Kenyataan di lapangan menunjukkan penggunaan SGD optimizer belum cukup untuk membuat jaringan CNN mampu mengenali emosi dari citra wajah [2].

Mellynia Sanjaya menjelaskan chi-square dan accuracy measures on classify rempah menggunakan algoritma CNN mencapai hasil terbaik untuk chi-square yang telah dicapai adalah 86% dan rata-rata tingkat akurasi adalah 60%. Pada penelitian ini, base data terdiri dari gambar berjumlah 1800 gambar yang diambil dari 12 spesies jenis rempah [5].

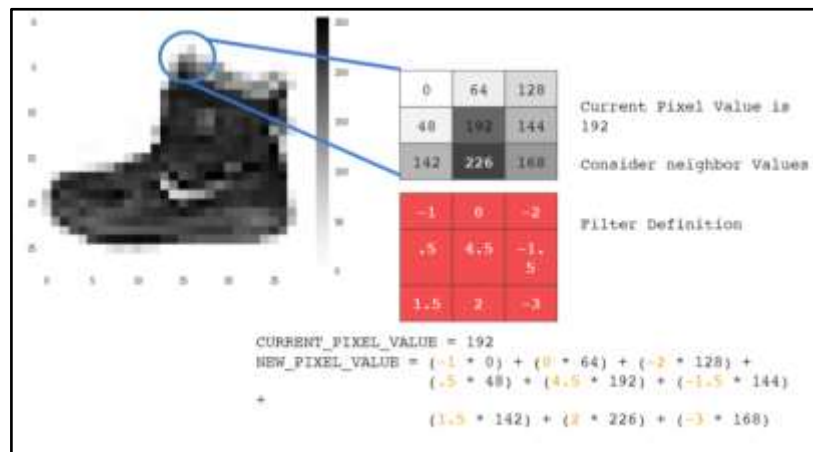
Penelitian yang berjudul “Analisis dan Implementasi Algoritma Convolutional Neural Network untuk Memprioritaskan Klasifikasi Kendaraan” yang dilakukan oleh Rijal Abdul Hakim memperoleh hasil validasi dengan akurasi terbesar pada skenario 2 yaitu 66,15% dan hasil akurasi tertinggi yang diperoleh dari matriks kebingungan mencapai 69,231% dalam kondisi perbandingan antara data pelatihan, data validasi, dan data pelatihan dengan rasio 60:20:20. Data video berasal dari rekaman kamera pengawas. Data dibagi menjadi tiga dataset dengan lima skenario berbeda menggunakan metode holdout [6].

Seperti yang dijelaskan dalam penelitian oleh Samuel lebih spesifiknya gambar uav dari perkebunan rempah dilaporkan pada pelatihan 3 kamera yang berbeda menangkap 1800 gambar dan diproses oleh model CNN dengan arsitektur csrnet dan pada akhir mencapai skor F-1 84% untuk evaluasi di perkebunan sawit Malaysia, rata-rata skor F-1 mencapai 71%. Keterbatasan temuan penelitian disebabkan oleh variasi dalam kualitas foto UAV, hambatan cuaca, dan perbedaan waktu yang dapat menyebabkan perbedaan dalam gambar yang diambil oleh kamera UAV [7].

Dari sejumlah studi tersebut, dapat dirangkum bahwa CNN memiliki potensi besar dalam klasifikasi gambar di berbagai domain, dengan akurasi yang bervariasi tergantung pada arsitektur model, teknik optimasi, dan kualitas data. Penelitian menunjukkan akurasi maksimum 83,02% untuk klasifikasi hama, 66% untuk ekspresi wajah, dan 84% untuk klasifikasi rempah oleh UAV. Namun, tantangan seperti variabilitas data, kualitas gambar, dan teknik optimasi memang memengaruhi hasil yang diperoleh. Dengan demikian, meskipun cukup fleksibel, keberhasilan CNN sebagian besar bergantung pada desain model dan sifat data.

C. Convolutional Neural Network (CNN)


Convolutional Neural Network (CNN) merupakan salah satu algoritma pembelajaran mendetail yang sering digunakan untuk menangani masalah pengenalan gambar [8]. Proses kerja CNN dimulai dengan memasukkan citra ke dalam jaringan. Pada lapisan konvolusi, citra dilewatkan melalui filter atau kernel untuk mengekstrak fitur-fitur penting [9]. CNN efektif dalam mengidentifikasi pola visual seperti tepi, tekstur, dan objek dalam gambar, sehingga banyak digunakan dalam tugas-tugas seperti klasifikasi gambar, pengenalan objek, pengenalan wajah, dan pemrosesan video. CNN terdiri dari beberapa komponen utama seperti convolution layer dan pooling layer.



Gambar 1. Proses Konvolusi

Pada gambar 1 terdapat visualisasi konvolusi, di mana nilai piksel warna pada data asli akan dikalikan dengan nilai kernel sesuai dengan ukuran yang ada pada kernelnya. Melalui tahapan konvolusi pada output dari lapisan sebelumnya, lapisan konvolusi merupakan tahapan utama yang menjadi dasar pokok metode CNN [10]. Layer Konvolusi menerapkan filter kernel untuk mengekstraksi objek atau ciri dari gambar yang dimasukkan. Isi kernel adalah bobot, yang dapat mendeteksi karakter objek. Pada gambar 1, terlihat gambar sepatu dengan sampel warnanya ditandai dengan kotak berwarna hitam ke putih yang kemudian dilakukan operasi dot dengan nilai value filter konvolusi dengan kotak warna merah.

Tahapan selanjutnya yang dilakukan yaitu konvolusi agar dapat dihasilkan informasi yang penting atau dibutuhkan dari citra yang dimasukkan atau dilakukan konvolusi [11]. Hasil dari konvolusi tersebut akan menghasilkan bobot nilai dengan isi nilai sesuai dengan kernel konvolusi yang digunakan kemudian bisa dilakukan pelatihan pada CNN [10].

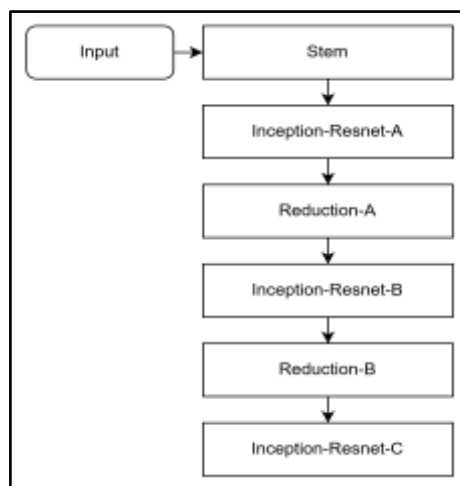


Gambar 2. Proses Layer Pooling

Pada gambar 2 terdapat visualisasi dari proses *Pooling*. *Pooling Layer* membantu mereduksi dimensi data melalui teknik seperti *max pooling*, yang memilih nilai maksimum dari area tertentu untuk mengurangi kompleksitas data tanpa kehilangan fitur penting [12]. Berbagai teknik *pooling*, seperti *average pooling* dan *global average pooling*, juga digunakan, dengan masing-masing memiliki cara untuk merangkum data dalam area tertentu [13]. Untuk mencegah *overfitting*, *Dropout* digunakan dengan mengabaikan neuron secara acak selama pelatihan, sehingga mempercepat proses pembelajaran [14]. Selain itu, *Flattening* mengubah data multidimensi menjadi vektor 1-dimensi, mempersiapkan data untuk diproses di lapisan *fully connected*. Inception adalah arsitektur yang menggabungkan beberapa ukuran kernel dalam satu layer untuk menangkap informasi dari berbagai skala spasial dalam satu waktu, sehingga memungkinkan model untuk mengenali fitur lebih efisien [15]. Dengan kombinasi ini, CNN mampu menganalisis data visual secara efisien dan telah diterapkan secara luas dalam berbagai aplikasi berbasis gambar.

D. Inception-ResNet-V2

Inception-ResNet-v2 adalah arsitektur jaringan saraf konvolusional (Convolutional Neural Network, CNN) yang dirancang untuk mengenali objek dengan akurasi tinggi dan mampu menangani data tidak terstruktur seperti gambar [16]. Arsitektur ini menggabungkan modul Inception dan koneksi residual untuk meningkatkan efisiensi dan efektivitas dalam mengekstraksi fitur visual [17]. Modul Inception memungkinkan ekstraksi fitur multiskala melalui cabang-cabang konvolusi paralel dengan berbagai ukuran filter, sehingga model dapat menangkap informasi dari berbagai bidang reseptif dan meningkatkan kemampuan adaptasi terhadap pola visual yang beragam [17]. Selain itu, modul ini dirancang untuk mengurangi jumlah parameter model, sehingga mengurangi kompleksitas tanpa mengorbankan representasi fitur [18]. Koneksi residual digunakan untuk mengatasi masalah gradien yang hilang (vanishing gradient) yang sering terjadi pada pelatihan jaringan dalam, sehingga model dapat mempertahankan informasi penting dari lapisan sebelumnya dan meningkatkan konvergensi selama pelatihan [17]. Dengan menggabungkan berbagai ukuran kernel konvolusi, model ini mampu mengekstrak fitur dari berbagai skala, termasuk detail kecil seperti retakan pada gambar [18]. Pendekatan ini juga mengadopsi teknik Network-in-Network (NIN) yang mengoptimalkan struktur jaringan untuk mengurangi jumlah kernel konvolusi tanpa kehilangan performa, sehingga lebih hemat sumber daya [18]. Selain itu, modul fusi informasi konteks multiskala memungkinkan penggabungan peta fitur dari berbagai lapisan, memudahkan deteksi objek kecil atau detail halus dalam gambar [18]. Inception-ResNet-v2 dirancang untuk menjadi model yang efisien dan andal dalam berbagai tugas pengenalan objek, termasuk aplikasi khusus seperti deteksi retakan pada gambar [16], [18]. Layer detail yang terdapat pada arsitektur Inception-ResNet-V2 sesuai dengan yang terdapat pada gambar 3.



Gambar 3. Arsitektur Inception-ResNet-V2

E. Confusion Matrix

Confusion matrix adalah alat visualisasi uji yang digunakan pada pembelajaran mesin untuk menilai kinerja model klasifikasi dengan menyederhanakan visualisasi hasil prediksi dengan hasil sebenarnya. Tabel ini berbentuk persegi, dengan baris mewakili kelas aktual dan kolom mewakili kelas yang diprediksi. Jumlah baris dan kolom sesuai dengan jumlah kelas dalam masalah klasifikasi [19].

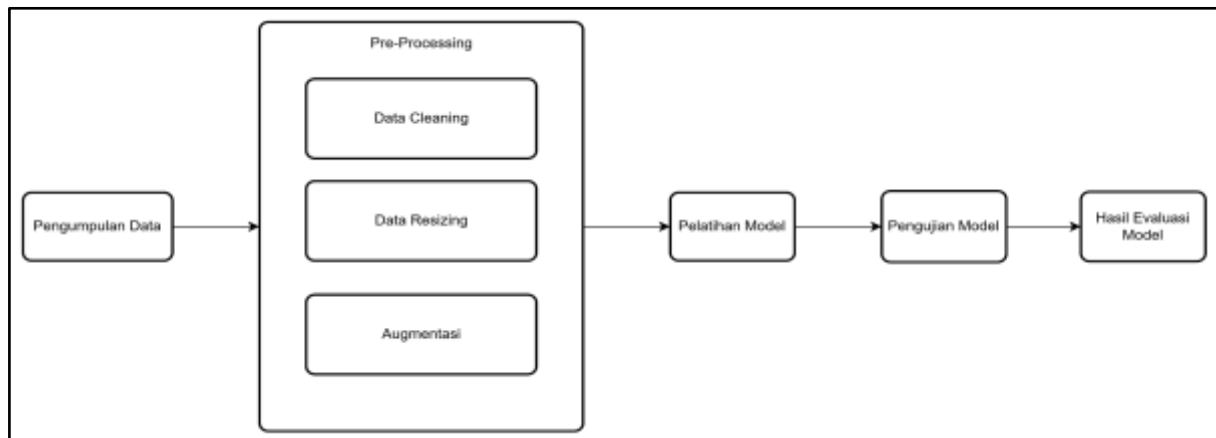
		Predicted			
		A	B	C	
Actual	A	c_{11} 32	c_{12} 10	c_{13} 8	← Row A
	B	c_{21} 9	c_{22} 38	c_{23} 4	← Row B
	C	c_{31} 12	c_{32} 9	c_{33} 28	← Row C
		Column A	Column B	Column C	
		A	B	C	

Gambar 4. Confusion Matrix Multi-class

Confusion matrix tiga kelas adalah tabel 3x3 seperti yang ditunjukkan pada gambar 4 digunakan untuk mengevaluasi kinerja model klasifikasi yang membagi data ke dalam tiga kelas. Baris menunjukkan kelas aktual (A, B, C) dan kolom menunjukkan kelas yang diprediksi (A,B,C), memberikan gambaran tentang seberapa baik model memprediksi setiap kelas.

III. METODE PENELITIAN

A. Tahapan Penelitian



Gambar 5. Diagram Pengolahan Data

Diagram pada gambar 5 menggambarkan alur proses pengolahan data untuk penelitian ini, dimulai dari Pengumpulan Data sebagai langkah awal untuk mengumpulkan data mentah dari kaggle dengan judul dataset “*Dangerous Insects Datasets*” [20]. Data tersebut kemudian masuk ke tahap Pre-Processing, yang mencakup tiga sub-proses penting: Data Cleaning untuk membersihkan data dari format gambar yang tidak sesuai contohnya terdapat data berformat video atau GIF, Data Resizing untuk menstandarkan ukuran data, dan Augmentasi untuk meningkatkan variasi data. Selanjutnya, data yang telah diproses digunakan dalam Pelatihan Model, di mana algoritma pembelajaran mesin atau metode lain dilatih untuk mengenali pola dalam data. Model yang digunakan pada penelitian ini yaitu model CNN menggunakan arsitektur Inception-ResNet-V2. Model yang dilatih kemudian diuji pada tahap Pengujian Model untuk mengevaluasi performanya menggunakan data uji yang belum pernah dilihat sebelumnya. Akhirnya, proses diakhiri dengan Hasil Evaluasi Model, di mana metrik kinerja seperti akurasi atau error rate digunakan untuk menilai efektivitas model dalam mengenali pola.

B. Pengumpulan Data

Pada langkah ini, dataset berupa gambar hama serangga pada pertanian dikumpulkan dari situs publik Kaggle dengan nama “*Dangerous Farm Insects Dataset*” untuk data utama yang dilakukan pengujian pada penelitian ini. Dataset tersebut dapat diakses melalui halaman <https://www.kaggle.com/datasets/tarundalal/dangerous-insects-dataset> [18]. Dataset ini mencakup data mentah yang berjumlah 1591 yang terdiri dari 13 kelas jenis serangga berbeda yang akan digunakan dalam proses pengenalan citra. Berikut merupakan sampel dataset yang akan dilatih nantinya:



a) Fruit Flies



b) Colorado Potato Beetles



c) Western Corn Rootworm



d) *Brown Marmorated Stink Bug*



e) *Thrips*



f) *Aphids*

Gambar 6. Sampel Gambar Dataset Hama Serangga Pertanian

Pada gambar 6 merupakan contoh sampel gambar dataset yang akan digunakan pada penelitian ini. Beberapa kelas atau jenis hama serangga pada gambar tersebut yaitu Fruit Flies (*Drosophila spp.*), Colorado Potato Beetles (*Leptinotarsa decemlineata*), Western Corn Rootworm (*Diabrotica virgifera virgifera*), Brown Marmorated Stink Bug (*Halyomorpha halys*), Thrips (*Thysanoptera*), dan Aphids (*Aphidoidea*)

C. Pra-proses

Pra-proses merupakan proses yang dilalui sebelum melaksanakan pelatihan atau pengujian model. Praproses dataset kemudian melalui proses pembagian data pelatihan, pengujian, dan validasi. Untuk memulai tahapannya, dataset awal yang terdiri dari 1591 gambar dipilih kemudian diubah menjadi 1356 gambar. Pada dataset training terdapat 1090 gambar yang terdiri dari 13 kelas dengan masing-masing kelas berisi sekitar 80 gambar. Sedangkan pada dataset testing memiliki 133 gambar yang terdiri dari 13 kelas dengan masing-masing 10 gambar dan tambahan 3 gambar pada 3 kelas berbeda.

Pada dataset validasi memiliki jumlah dataset gambar dan kelas yang sama dengan dataset training yang berjumlah 133 gambar dan 13 kelas. Pengkategorian ini dilakukan untuk mencegah terjadinya gambar pada jenis hama yang sama namun terdapat pada kelas yang berbeda yang dikhawatirkan dapat membingungkan model nantinya. Pra-proses dilakukan untuk memperjelas kualitas gambar, mengurangi derau, dan menyesuaikan fitur gambar untuk memenuhi persyaratan analisis atau pengolahan gambar berikutnya. Semua gambar dalam dataset pelatihan, pengujian, atau klasifikasi penelitian ini diresize, yaitu proses mengubah ukuran gambar menjadi 224 x 224 pixel. Ini adalah pra-proses yang dilakukan dalam penelitian ini. Untuk meningkatkan efisiensi komputasi, gambar diubah formatnya menjadi format Red-Green-Blue lalu dinormalisasi dengan mengubah nilai piksel ke rentang 0 hingga 1 melalui pembagian dengan 255.

Setelah itu dilakukan beberapa metode augmentasi yaitu *Rescaling*, *zooming*, *rotation*, *shifting* (*width and height*), *shearing*, *horizontal flipping*, dan *fill mode*. Diharapkan dengan beberapa augmentasi tersebut dapat menjadikan data lebih beragam dan bervariasi. Berikut merupakan contoh augmentasi



a) *Rotasi*



b) *Shifting*

Gambar 7. Hasil Augmentasi Serangga Aphids

Pada gambar 7, terdapat contoh augmentasi pada data serangga *Aphids* di mana pada gambar (a) dilakukan rotasi dari gambar aslinya dan gambar (b) dilakukan *shift* atau pergeseran dari gambar aslinya.

D. Pelatihan Model

Penelitian ini menggunakan arsitektur pre-trained inception-resnet-v2 kemudian dilanjutkan dengan konvolusi. Dapat dilihat pada gambar 8 yang merupakan detail layer yang digunakan pada model penelitian ini.

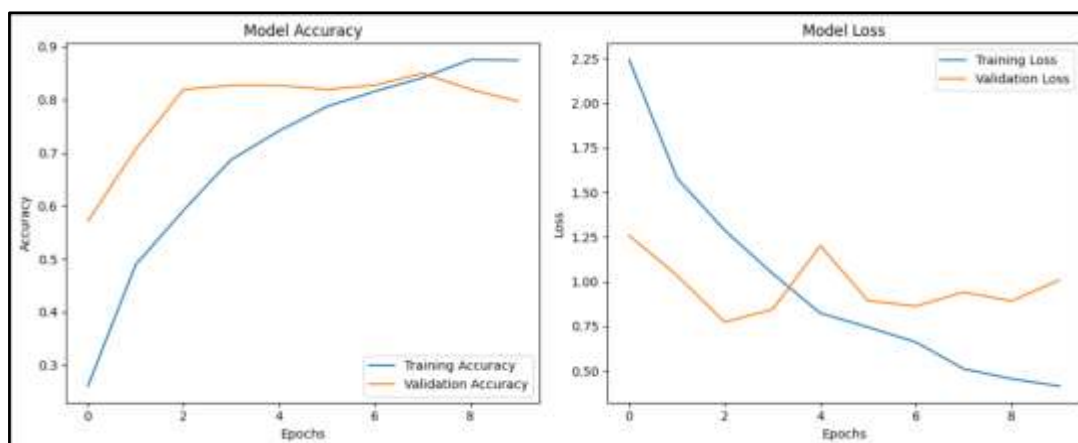
Model: "sequential"		
Layer (type)	Output Shape	Param #
inception_resnet_v2 (Functional)	(None, 5, 5, 1536)	54,336,736
conv2d_203 (Conv2D)	(None, 3, 3, 32)	442,400
max_pooling2d_4 (MaxPooling2D)	(None, 1, 1, 32)	0
dropout (Dropout)	(None, 1, 1, 32)	0
flatten (Flatten)	(None, 32)	0
dense (Dense)	(None, 13)	429
Total params: 54,779,565 (208.97 MB)		
Trainable params: 54,719,021 (208.74 MB)		
Non-trainable params: 60,544 (236.50 KB)		

Gambar 8. Layer Model

Model CNN ini dimulai dengan Inception-ResNet-v2, sebuah arsitektur pretrained dari TensorFlow dengan bobot ImageNet, yang digunakan sebagai ekstraktor fitur. Model ini bekerja pada input gambar berukuran 224 x 224 x 3 dan menghasilkan fitur tingkat tinggi yang diolah lebih lanjut. Setelah fitur diekstraksi, hasilnya melewati layer Conv2D dengan 32 filter dan kernel (3, 3) untuk menangkap fitur lokal, diikuti oleh MaxPooling2D untuk mereduksi dimensi spasial. Kemudian, layer Dropout dengan tingkat 0,3 diterapkan untuk mencegah overfitting, sebelum hasil diratakan menggunakan Flatten. Terakhir, layer Dense dengan 13 neuron dan aktivasi softmax digunakan untuk memprediksi probabilitas pada 13 kelas target.


IV. HASIL DAN PEMBAHASAN

Evaluasi model pada penelitian ini akan diukur dengan nilai akurasi dan loss pada training dan validation. Selain itu juga dilakukan visualisasi prediksi menggunakan *confusion matrix* dan beberapa matriks evaluasi seperti *precision*, *recall*, dan *f1-score*.



Gambar 9. Hasil Akurasi dan Loss

Pada gambar 9 terlihat akurasi dan loss pada tiap epoch pelatihannya. Setelah dilakukan pelatihan sebanyak 5 epoch didapatkan akurasi pelatihan sebesar 73,81% dengan loss 0,8420 serta akurasi validasi sebesar 82,71% dengan loss 1,2005. Kemudian setelah dilakukan proses pelatihan sebanyak 10 epoch didapatkan akurasi pelatihan sebesar 89,52% dengan loss 0,4024 serta akurasi validasi sebesar 79,70% dengan loss validasi 1,0086.



Gambar 10. Confusion Matrix Hasil Uji Model

Terlihat confusion matrix dari hasil prediksi pada data uji pada Gambar 10, menghasilkan prediksi yang benar sebanyak 111 data dan prediksi meleset sebanyak 22 data. Pada gambar tersebut juga terlihat gambar serangga pada kelas Thrips yang memiliki prediksi meleset paling banyak di antara kelas hama serangga yang lainnya.

Tabel 1. Hasil Classification Report Hama Serangga

No.	Hama Serangga	Precision	Recall	F1 Score
1.	Africanized Honey Bees (Killer Bees)	1,00	0,82	0,90
2.	Aphids	0,90	0,82	0,86
3.	Armyworms	0,89	0,73	0,80
4.	Brown Marmorated Stink Bugs	0,77	1,00	0,87
5.	Cabbage Loopers	1,00	0,90	0,95
6.	Citrus Canker	0,83	1,00	0,91
7.	Colorado Potato Beetles	0,77	1,00	0,87
8.	Corn Earworms	0,56	0,90	0,69
9.	Fruit Flies	1,00	0,60	0,75
10.	Spider Mites	0,71	1,00	0,83
11.	Thrips	1,00	0,50	0,67
12.	Tomato Hornworms	0,90	0,90	0,90
13.	Western Corn Rootworms	1,00	0,70	0,82

Berdasarkan Tabel 1, hasil *classification report* untuk identifikasi hama serangga menunjukkan variasi performa model dalam mengklasifikasikan setiap kelas. Kelas Africanized Honey Bees dan Cabbage Loopers memiliki performa yang sangat baik dengan F1-Score tertinggi, masing-masing 0,90 dan 0,95, memperlihatkan nilai setara yang baik antara precision dan recall. Hal serupa terjadi pada kelas Tomato Hornworms yang mencatat F1-Score 0,90, menunjukkan model mampu mengenali kelas tersebut dengan akurat. Sebaliknya, kelas seperti Corn Earworms dan Thrips menunjukkan performa lebih rendah dengan F1-Score masing-masing 0,69 dan 0,67, yang disebabkan oleh rendahnya precision atau recall. Misalnya, pada kelas Thrips, recall hanya 0,50, yang berarti sebagian besar sampel dari kelas ini tidak berhasil dikenali dengan baik.

Kelas lain seperti Fruit Flies dan Western Corn Rootworms juga mencatat F1-Score yang relatif lebih rendah, yaitu 0,75 dan 0,82, meskipun memiliki precision yang tinggi. Hal ini menunjukkan model lebih baik dalam memprediksi positif tetapi kurang mampu menangkap seluruh sampel dari kelas tersebut (low recall). Sebaliknya, kelas seperti Brown Marmorated Stink Bugs, Citrus Canker, dan Spider Mites memiliki recall sempurna (1,00) tetapi precision lebih rendah, yang mengindikasikan

beberapa prediksi positif mungkin salah. Secara keseluruhan, hasil ini menunjukkan bahwa performa model cukup bervariasi antar kelas, dengan beberapa kelas memperlihatkan nilai setara yang baik antara precision dan recall, sementara kelas lain menunjukkan kelemahan dalam mengenali sampel positif atau menjaga akurasi prediksi.

Dari hasil uji model diperoleh beberapa nilai *precision*, *recall* dan *f1-score* pada tiap kelasnya sehingga juga dapat diperoleh total *precision* yaitu 0,8734, *recall* yaitu 0,8346, dan *f1-score* yaitu 0,8327.

V. KESIMPULAN DAN SARAN

Berdasarkan hasil evaluasi model yang dilakukan, diperoleh bahwa model klasifikasi hama serangga menunjukkan peningkatan performa selama proses pelatihan. Setelah pelatihan sebanyak 10 epoch, model berhasil mencapai akurasi pelatihan sebesar 89,52% dengan loss 0,4024, sedangkan akurasi validasi sebesar 79,70% dengan loss 1,0086. Namun demikian, terdapat perbedaan kinerja yang signifikan antara data pelatihan dan data validasi, yang mengindikasikan adanya potensi overfitting pada model.

Model dapat meningkatkan akurasi dengan baik selama pelatihan, tetapi fluktuasi pada akurasi dan loss validasi menunjukkan bahwa hyperparameter tuning atau penambahan data training mungkin diperlukan untuk meningkatkan generalisasi lebih lanjut. Salah satu langkah yang dapat diambil untuk meningkatkan generalisasi model adalah dengan menggunakan dataset yang lebih beragam, seperti dataset hama serangga lokal yang lebih banyak, yang mencakup variasi lebih luas dari spesies hama yang ada di pertanian lokal. Sebagai contoh, identifikasi Ulat Daun Kubis (*Plutella xylostella*) atau Wereng Coklat (*Brown Planthopper*) dapat dilakukan dengan efisien menggunakan sistem ini. Selanjutnya, hasil penelitian ini dapat dikembangkan menjadi sistem berbasis aplikasi untuk membantu petani atau ahli agronomi dalam mengidentifikasi hama serangga dengan cepat dan akurat. Dengan antarmuka pengguna yang intuitif dan pengembangan berkelanjutan, sistem ini memiliki potensi besar untuk memberikan dampak positif di bidang pertanian, khususnya dalam pengendalian hama.

DAFTAR PUSTAKA

- [1] S. Yuliany, Aradea, and Andi Nur Rachman, 'Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN)', *J. Buana Inform.*, vol. 13, no. 1, pp. 54–65, 2022, doi: 10.24002/jbi.v13i1.5022.
- [2] D. Alamsyah and D. Pratama, 'Implementasi Convolutional Neural Networks (CNN) untuk Klasifikasi Ekspresi Citra Wajah pada FER-2013 Dataset', *J. Teknol. Inf.*, vol. 4, no. 2, pp. 350–355, 2020, doi: 10.36294/jurti.v4i2.1714.
- [3] Q. Wang, Y. Zhang, H. Ge, Y. Jiang, and Y. Qin, 'Identification of Rice Freshness Using Terahertz Imaging and Deep Learning', *Photonics*, vol. 10, no. 5, 2023, doi: 10.3390/photonics10050547.
- [4] B. Freeman, *Ecological and Economic Entomology: A Global Synthesis*. Wallingford, UK: CABI, 2019. [Online]. Available: http://scioteca.caf.com/bitstream/handle/123456789/1091/RED2017-Eng-8ene.pdf?sequence=12&isAllowed=y%0Ahttp://dx.doi.org/10.1016/j.regsciurbeco.2008.06.005%0Ahttps://www.researchgate.net/publication/305320484_SISTEM_PEMBETUNGAN_TERPU_SAT_STRATEGI_MELESTARI
- [5] M. Sanjaya and E. Nurraharjo, 'Deteksi Jenis Rempah-Rempah Menggunakan Metode Convolutional Neural Network Secara Real Time', *J. Sains Komput. Inform.*, vol. 7, no. 1, pp. 22–31, 2023, doi: 10.30645/j-sakti.v7i1.567.
- [6] R. Abdulhakim, C. Carudin, and B. A. Dermawan, 'View of Analisis dan Penerapan Algoritma Convolutional Neural Network untuk Klasifikasi Kendaraan Prioritas.pdf', *J. Sains dan Inform.*, vol. 7, no. 2, pp. 135–144, 2021, doi: 10.34128/jsi.v7i2.335.
- [7] S. Samuel, K. R. Prilianti, H. Setiawan, P. Mimboro, and P. Korespondensi, 'Metode Deteksi Pokok Pohon Secara Automatis pada Citra Perkebunan Sawit Menggunakan Model

- Convolutional Neural Network (CNN) pada Perangkat Lunak Sistem Informasi Geografis’, *J. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 7, pp. 1689–1698, 2022, doi: 10.25126/jtiik.202296772.
- [8] R. Anantama, H. Suyono, and M. Aswin, ‘Application of Cost-Sensitive Convolutional Neural Network for Pneumonia Detection’, *J. Ilm. KURSOR*, vol. 11, no. 3, pp. 101–108, 2022, doi: 10.21107/kursor.v11i3.264.
- [9] A. H. Bik, F. T. Anggraeny, and E. Y. Puspaningrum, ‘Klasifikasi Penyakit Ginjal Menggunakan Algoritma Hibrida CNN-ELM’, *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 3, pp. 3836–3844, 2024, doi: 10.36040/jati.v8i3.9807.
- [10] R. A. Saputra, D. R. R. Putra, and M. A. Asyrofi, ‘Implementasi Convolutional Neural Network (Cnn) Untuk Mendeteksi Penggunaan Masker Pada Gambar’, *JITET (Jurnal Inform. dan Tek. Elektro Ter.)*, vol. 11, no. 3, pp. 710–714, 2023, doi: 10.23960/jitet.v11i3.3286.
- [11] F. N. Cahya, N. Hardi, D. Riana, and S. Hardianti, ‘Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN)’, *Sist. J. Sist. Inf.*, vol. 10, no. 3, pp. 618–626, 2021, doi: 10.59407/jrsit.v1i3.529.
- [12] D. Husen, K. Kusri, and K. Kusnawi, ‘Deteksi Hama Pada Daun Apel Menggunakan Algoritma Convolutional Neural Network’, *J. MEDIA Inform. BUDIDARMA*, vol. 6, no. 4, pp. 2103–2110, 2022, doi: 10.30865/mib.v6i4.4667.
- [13] M. M. Taye, ‘Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions’, *Computation*, vol. 11, no. 3, pp. 1–23, 2023, doi: 10.3390/computation11030052.
- [14] R. Magdalena, S. Saidah, N. K. C. Pratiwi, and A. T. Putra, ‘Klasifikasi Tutupan Lahan Melalui Citra Satelit SPOT-6 dengan Metode Convolutional Neural Network (CNN)’, *JEPIN (Jurnal Edukasi dan Penelit. Inform.)*, vol. 7, no. 3, pp. 335–339, 2021, doi: 10.26418/jp.v7i3.48195.
- [15] M. A. A. Fawwaz, K. N. Ramadhani, and F. Sthevani, ‘Klasifikasi Ras pada Kucing Menggunakan Algoritma Convolutional Neural Network (CNN)’, in *e-Proceeding of Engineering*, 2020, pp. 715–730.
- [16] G. A. Rakhmat and A. M. Yudiantira, ‘Implementation and Optimization Of Inception Resnet-v2 with Data Balancing (Case Study Of Lung Disease Classification)’, in *E3S Web of Conferences*, 2024, pp. 1–9. doi: 10.1051/e3sconf/202448402010.
- [17] A. Sanampudi and S. Srinivasan, ‘Local search enhanced optimal Inception-ResNet-v2 for classification of long-term lung diseases in post-COVID-19 patients’, *Autom. (Journal Control. Meas. Electron. Comput. Commun.)*, vol. 65, no. 2, pp. 473–482, 2024, doi: 10.1080/00051144.2023.2295142.
- [18] J. Wang, X. He, S. Faming, G. Lu, H. Cong, and Q. Jiang, ‘A Real-Time Bridge Crack Detection Method Based on an Improved Inception-Resnet-v2 Structure’, *IEEE Access*, vol. 9, pp. 93209–93223, 2021, doi: 10.1109/ACCESS.2021.3093210.
- [19] M. Fahmy Amin, ‘Confusion Matrix in Three-class Classification Problems: A Step-by-Step Tutorial’, *J. Eng. Res.*, vol. 7, no. 1, pp. 1–11, 2023, doi: 10.21608/erjeng.2023.296718.
- [20] J. Tarun R., ‘Dangerous Farm Insects Dataset’, Kaggle. [Online]. Available: <https://www.kaggle.com/datasets/tarundala/dangerous-insects-dataset>