

Deteksi Residu Insektisida Profenofos pada Cabai Merah (*Capsium annum L.*) melalui Augmentasi Citra dan CNN (*Convolutional Neural Network*)

Profenofos Insecticide Residue Detection on Red Chili (*Capsicum annum L.*) through Image Augmentation and CNN (*Convolutional Neural Network*)

Zulfa Hana Maulida¹⁾, I Putu Gede Budisanjaya¹⁾, I Made Supartha Utama¹⁾, Chatchawan Chaicana^{2*)}, Wahyu Nurkholis Hadi Syahputra²⁾

¹⁾*Program Studi Teknik Pertanian dan Biosistem, Fakultas Teknologi Pertanian, Universitas Udayana, Badung, Bali, Indonesia.*

²⁾*Program Studi Teknik Mesin, Fakultas Teknik, Universitas Chiang Mai, Muang, Chiang Mai, Thailand.*

*Email: chatchawan.c@cmu.ac.th

Abstrak

Penggunaan insektisida dalam pertanian meningkat pesat namun juga menghadapi tantangan terkait dampak negatifnya terhadap kesehatan manusia dan lingkungan. Salah satu insektisida yang umum digunakan adalah profenofos. Profenofos sering digunakan petani untuk mengendalikan hama pada tanaman cabai merah di Indonesia. Oleh karena itu, deteksi residu insektisida profenofos pada cabai penting untuk memastikan keamanan konsumsi cabai. Penelitian ini bertujuan untuk mengembangkan metode baru dalam mendeteksi residu insektisida profenofos pada cabai merah (*Capsicum Annum L.*) melalui augmentasi citra dan CNN (*Convolutional Neural Network*). Dalam penelitian ini, dilakukan penyiapan larutan insektisida, pengambilan citra cabai, pengujian dengan GC (*Gas Chromatography*) Agilent 6890N, pra-pemrosesan citra, dan implementasi pemodelan CNN. Dilakukan penyemprotan pada 15 cabai dengan konsentrasi 0 dan 10 mg/l, diikuti pengambilan citra menggunakan *smartphone* sehingga terdapat 30 citra. Selanjutnya, setiap citra diaugmentasi sebanyak 50 kali, menghasilkan total 1530 citra. Proses ini melibatkan rotasi, pergeseran, *zoom*, serta horizontal dan *vertical flipping*. Model CNN yang terdiri dari *convolution layer* dan *fully connected* dilatih dengan *optimizer Adam*, *loss function categorical crossentropy*, *learning rate* 0,0001, dan dilakukan pelatihan sebanyak 20 *epoch*. Hasil analisis menunjukkan bahwa model mencapai akurasi sebesar 85% dengan nilai *precision*, *recall*, dan *F1-score* masing-masing adalah 0,86; 0,85; dan 0,84. Berdasarkan hasil tersebut, dapat disimpulkan bahwa metode augmentasi citra dan CNN telah berhasil mendeteksi residu insektisida profenofos pada cabai merah dengan konsentrasi 0 dan 10 mg/l.

Kata kunci: *Augmentasi Citra, CNN, Insektisida Profenofos.*

Abstract

The use of insecticide in agriculture is rapidly increasing but also faces challenges related to their negative impacts on human health and the environment. One commonly used insecticide is profenofos. Farmers frequently use Profenofos to control pests on red chili plants in Indonesia. Therefore, detecting profenofos insecticide residue on chili is crucial to ensure the safety of chili consumption. This study aims to develop a new method for detecting profenofos insecticide residues on red chilies (*Capsicum Annum L.*) through image augmentation and CNN (*Convolutional Neural Network*). In this study, insecticide solution preparation, chili image acquisition, testing with GC (*Gas Chromatography*) Agilent 6890, image preprocessing, and CNN model implementation were conducted. Insecticide solution spraying was conducted on 15 chilies with concentrations of 0 and 10 mg/l, followed by smartphone image acquisition, resulting in 30 images. Subsequently, each image was augmented 50 times, resulting in 1530 images. This process involves rotation, shifting, zoom, and horizontal and vertical flipping. The CNN model, consisting of convolution layers and fully connected layers, was trained with the Adam optimizer, categorical cross-entropy loss function, the learning rate of 0,0001, and trained for 20 epochs. The analysis results indicate that the model achieved an accuracy of 85% with precision, recall, and F1-score values of 0,86, 0,85, and 0,84, respectively. Based on these results, it can be concluded that the image augmentation and CNN method successfully detected profenofos insecticide residues on red chilies at concentrations of 0 and 10 mg/l.

Keyword: *Image Augmentation, CNN, Profenofos Insecticide.*

PENDAHULUAN

Pestisida berperan penting dalam mengendalikan gulma, hama, dan jamur. Sepertiga produksi pertanian bergantung pada penerapan pestisida (Lyu et al., 2021). Penggunaan pestisida mengalami peningkatan sebesar 36 persen selama periode 2000-2019, mencapai sekitar 4.200.000 ton pada tahun 2019. Kontribusi tertinggi berasal dari benua Asia, yaitu berkisar 52–53 persen (FAO, 2020). Kurangnya pengetahuan petani dan penyalahgunaan pestisida memiliki efek samping negatif baik dalam jangka panjang maupun pendek terhadap kesehatan manusia, keanekaragaman hayati, dan dapat membunuh makhluk yang bukan sasarannya (Suwimantara et al., 2022). Pestisida dapat ditemukan pada lapisan permukaan buah atau sayur yang sering tidak terlihat namun berpotensi mengandung residu yang dapat masuk ke dalam tubuh manusia ketika dikonsumsi (Manggala et al., 2023).

Pestisida yang penggunaannya cukup besar dan mendominasi perdagangan adalah insektisida, herbisida, dan fungisida. Profenofos adalah salah satu jenis insektisida organofosfat yang banyak digunakan di Indonesia, termasuk di Bali (Ardiwinata et al., 2018; Putra et al., 2021). Profenofos memiliki peran yang signifikan dalam mengendalikan berbagai hama terutama hama lalat buah (*Bactrocera spp*) yang sering menyerang tanaman cabai (Hendra et al., 2021). Penggunaan insektisida profenofos setiap tahunnya meningkat seiring dengan peningkatan permintaan cabai (BPS, 2023). Oleh karena itu, deteksi residu insektisida profenofos pada cabai menjadi krusial untuk memastikan keamanan konsumsi cabai.

Penelitian terdahulu menggunakan metode *Gas Chromatography* (GC) (Hassan et al., 2019) dan *High-Performance Liquid Chromatography* (HPLC) (Ashraf et al., 2022) untuk mendeteksi residu insektisida. Analisis laboratorium terhadap residu insektisida menunjukkan hasil dengan sensitivitas dan akurasi yang sangat baik. Namun, metode tersebut memiliki keterbatasan. Alat yang digunakan mahal dan membutuhkan waktu lama untuk menganalisis. Perkembangan dalam otomatisasi seperti penggunaan sensor dan metode lain yang terintegrasi dengan *machine learning* dapat mengurangi waktu yang dibutuhkan dan mengurangi biaya dalam mendeteksi residu insektisida (Banerjee & Hübschmann, 2022).

Salah satu model *machine learning* yang sering digunakan dan yang terbaik dalam klasifikasi

citra adalah *Convolutional Neural Network* (CNN) (Elngar et al., 2021). Dalam bidang pertanian, CNN telah digunakan untuk berbagai aplikasi, termasuk deteksi penyakit tanaman dan klasifikasi Tingkat kesegaran buah. Penelitian menunjukkan bahwa CNN dapat mencapai akurasi hingga 94,5% dalam klasifikasi citra daun untuk deteksi penyakit (Deepalakshmi et al., 2021) dan hingga 97,82% dalam klasifikasi tingkat kesegaran buah (Palakodati et al., 2020).

Keberhasilan CNN dalam mengenali pola-pola pada citra sangat tergantung pada kualitas dan keberagaman dataset yang digunakan selama tahap pelatihan. Dengan menerapkan teknik augmentasi citra, seperti rotasi, pergeseran, *zoom*, *flipping*, dan distorsi lainnya, dataset pelatihan dapat diperluas dengan lebih baik. Hal ini membantu model CNN untuk memperoleh pemahaman yang lebih komprehensif terhadap pola-pola yang mungkin terjadi dalam berbagai situasi, sehingga meningkatkan kemampuan model untuk melakukan klasifikasi dengan lebih akurat (Sanjaya & Ayub, 2020).

Oleh karena itu, penelitian ini bertujuan untuk memperoleh tingkat akurasi dan menghasilkan metode baru dalam mendeteksi residu insektisida profenofos pada cabai merah (*Capsium annum L.*) melalui augmentasi citra dan CNN.

METODE PENELITIAN

Tempat dan Waktu Penelitian

Penelitian ini dilaksanakan di Laboratorium Sistem dan Manajemen Keteknikan Pertanian dan Biosistem, Fakultas Teknologi Pertanian, Universitas Udayana, Kampus Sudirman dan di Pusat Penelitian Pasca Panen, Fakultas Pertanian, Universitas Chiang Mai, Thailand. Pelaksanaan penelitian ini dilakukan pada bulan Agustus 2023 sampai dengan bulan April 2024.

Bahan dan Alat

Bahan yang digunakan pada penelitian ini adalah insektisida profenofos, aquades, *acetonitrile*, cabai merah, adaptor AC-DC 12V, *visible lighting* 400-700 nm, mikrokontroler Wemos D1 R1, sensor intensitas cahaya OPT3000, *lighting box*, QuEChERS, dan data citra cabai. Alat yang dibutuhkan dibagi menjadi dua kategori yaitu, perangkat lunak dan perangkat keras. Perangkat lunak yang digunakan terdiri dari Arduino IDE, *Google Colab* (12 GB RAM), *Google Drive*, *Os*, *TensorFlow*, *Matplotlib*, *Numpy*, dan *Seaborn*. Perangkat keras yang digunakan meliputi

smartphone Samsung tipe A10S (13 MP), Laptop ASUS Intel(R) Celeron(R) N4500, LCD 16x2, potensiometer 10K Ohm, labu ukur 25 ml, *chopper* Philips HR1393/00, timbangan digital, *vortexer*, *centrifuge*, dan *Gas Chromatography Agilent* 6890N.

Pelaksanaan Penelitian

Penelitian ini melibatkan satu faktor eksperimental, yaitu konsentrasi insektisida profenofos yang terdiri dari dua taraf perlakuan: 0 mg/l (*without_insecticide*) dan 10 mg/l (*with_insecticide*). Dua konsentrasi tersebut disemprotkan ke cabai masing-masing sebanyak 2 ml dan dilakukan pengulangan sebanyak 15 kali pada setiap taraf perlakuan. Pelaksanaan penelitian mencakup persiapan larutan insektisida, pengambilan data citra cabai, pengujian dengan GC, pra-pemrosesan citra, implementasi pemodelan CNN, dan analisis data.

Persiapan Larutan Insektisida

Pesiapan larutan insektisida profenofos dimulai dengan melakukan pengenceran larutan dengan aquades dari konsentrasi awal 10.000 mg/l menjadi 10 mg/l. Perhitungan konsentrasi larutan insektisida dilakukan dengan mengacu pada persamaan berikut (Taarelun et al., 2021):

$$M_1 \times V_1 = M_2 \times V_2 \quad (1)$$

Dimana M_1 adalah konsentrasi awal larutan (mg/l), V_1 adalah volume awal larutan (l), M_2 adalah konsentrasi yang diinginkan dari larutan yang diencerkan (mg/l), dan V_2 adalah volume akhir dari larutan yang diencerkan (l). Berdasarkan rumus perhitungan di atas maka diperoleh:

$$10.000 \text{ mg/l} \times V_1 = 10 \text{ mg/l} \times 25 \text{ ml}$$
$$V_1 = 0,025 \text{ ml}$$

Dari hasil perhitungan 0,025 ml, jumlah aquades yang sesuai ditambahkan hingga memenuhi labu ukur yang berukuran 25 ml. Kemudian diambil sebanyak 2 ml untuk disemprotkan ke cabai. Proses pengambilan larutan dan penyemprotan diulang pada setiap cabai sebanyak 15 kali.

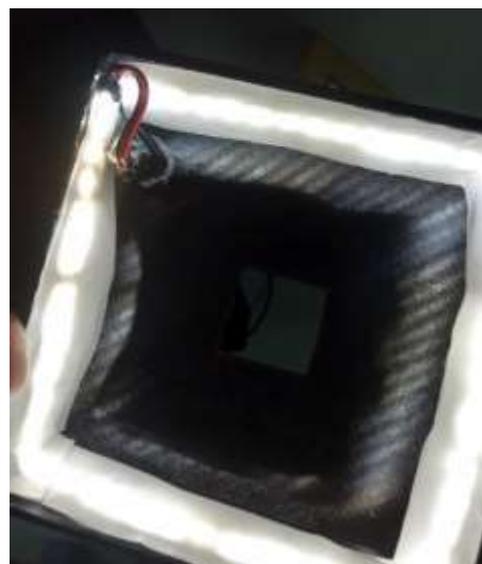
Pengambilan Data Citra Cabai

Lighting box dibuat dengan dimensi 13,5 cm x 13,5 cm x 16,5 cm dan berwarna hitam untuk meminimalkan pengaruh cahaya menyimpang serta menonjolkan sampel terhadap warna latar (Dijk & Croon, 2019). Perangkat ini menggunakan strip LED yang dipasang di bagian bawah penutup dan dihubungkan ke *power supply* melalui adaptor AC-DC 12V. LED menghasilkan cahaya tampak (*visible light*) dengan panjang gelombang 400-700 nm. Sensor intensitas cahaya OPT3000 ditempatkan di dalam *lighting box* dan terhubung dengan mikrokontroler Wemos D1 R1 serta LCD,

yang diprogram melalui Arduino IDE. Intensitas cahaya dalam *lighting box* di atur dengan potensiometer agar tetap dalam rentang 250-350 lux. Pengambilan citra dilakukan dengan *smartphone*. Proses pengamiran citra cabai dapat dilihat pada Gambar 1 dan 2.



Gambar 1. Pengambilan data citra



Gambar 2. Tampak bawah penutup *lighting box*

Pengujian dengan GC

Pengujian dilakukan untuk menjustifikasi keberadaan residu insektisida profenofos pada cabai. Tahap ini dilakukan setelah proses pengambilan citra. Cabai dihancurkan menggunakan *chopper* sebanyak 15 buah per perlakuan, kemudian 15 g sampel dimasukkan ke dalam tabung *centrifuge* berukuran 50 ml. Ditambahkan 15 ml *acetone* dan dihomogenisasi dengan *vortex* selama 1 menit, lalu disentrifugasi selama 15 menit pada 4500 rpm dan suhu 4°C.

QuEChERS *extraction salts* dan *ceramic*

homogenizer ditambahkan, diaduk kembali dengan *vortex* selama 1 menit. Ekstrak 1 ml dipindahkan ke tabung *centrifuge* berukuran 1,5 ml yang berisi *QuEChERS dispersive absorbent*, ditambahkan *acetonitrile* hingga mencapai 1,5 ml. Selanjutnya, dimasukan *ceramic homogenizer* dan kembali di *vortex* selama 1 menit. Tahap berikutnya, tabung *centrifuge* 1,5 ml dimasukan kedalam *centrifuge* mikro selama 5 menit pada kecepatan 4500 rpm dan pada suhu 4°C. Setelah di *centrifuge*, ekstrak akan dipindahkan untuk membuat *aliquot* sebanyak 1 ml sebagai porsi ukur sampel untuk dianalisa pada GC *Agilent 6890N*.

Aliquot 1 ml dari ekstrak yang sudah dipersiapkan kemudian diinjeksikan ke dalam GC, yang dilengkapi dengan kolom kapiler berukuran 30 m × 0,53 mm × 0,88 μm. Analisis sampel menggunakan injektor HP 7683 *Automatic Liquid Sampler* dan melibatkan beberapa langkah. Pertama, suhu oven diatur pada 100°C selama 1 menit, kemudian dinaikkan dengan laju 10°C per menit hingga mencapai 280°C, dan ditahan selama 41 menit. Injektor digunakan dalam mode *splitless* pada suhu 250°C. Dilanjutkan dengan menggunakan detector *Flame Ionization Detector (FID)* yang dioperasikan pada suhu 300°C. Gas pembawa yang digunakan adalah helium (99,999%) pada aliran konstan 3,8 mL per menit dan nitrogen (99,999%) digunakan sebagai gas pengganti dengan laju aliran 60,0 mL per menit.

Pra-pemrosesan Citra

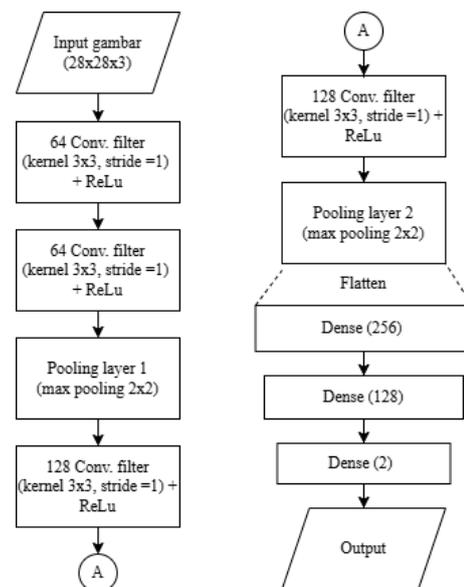
Terdapat beberapa teknik yang dilakukan dalam pra-pemrosesan citra, yaitu augmentasi, normalisasi dan *resizing*. Augmentasi bertujuan untuk meningkatkan keberagaman dataset citra sehingga dapat meningkatkan kinerja model dengan mengatur berbagai transformasi pada citra, seperti rotasi, pergeseran, *zoom*, serta horizontal dan *vertical flipping* (Shorten & Khoshgoftaar, 2019). Normalisasi adalah proses penyesuaian rentang nilai piksel dalam gambar ke rentang yang lebih kecil, yaitu antara 0 dan 1. Ini membantu memastikan bahwa magnitudo setiap piksel serupa dan mencegah nilai piksel yang berlebihan (Son et al., 2022; Lee et al., 2022). *Resizing* adalah penyesuaian ukuran gambar ke dimensi tetap sebelum dimasukkan ke dalam model, tanpa mengubah proporsi aslinya. Citra cabai *resize* menjadi 28x28 karena ukuran kecil membuat model lebih efisien secara komputasi (Ibrahim et al., 2022).

Pengembangan Model CNN

Langkah-langkah dalam pengembangan model

CNN dimulai dengan pembuatan arsitektur. CNN memiliki struktur yang mencakup input, ekstraksi fitur, klasifikasi, dan output. Dalam ekstraksi fitur pada CNN, terdapat beberapa lapisan seperti *convolution layer*, fungsi aktivasi (dengan ReLU), dan lapisan *pooling* (dengan *max pooling*). Sedangkan pada tahap klasifikasi, lapisan yang digunakan meliputi *fully connected layer* dan fungsi aktivasi (dengan *sigmoid*).

Proses dimulai dengan konvolusi, yang melibatkan operasi pergeseran filter (kernel) di seluruh gambar. *Stride* dan *padding* digunakan untuk mengontrol ukuran hasil *feature map*. Kemudian, lapisan *pooling* digunakan untuk mengurangi ukuran *feature map* dan mengambil nilai maksimum di dalam wilayah tertentu. Terakhir lapisan *fully connected* digunakan untuk menghubungkan semua hasil ekstraksi fitur ke dalam satu vektor dan melakukan klasifikasi (Alzubaidi et al., 2021). Arsitektur CNN dapat dilihat pada Gambar 3.



Gambar 3. Arsitektur CNN.

Selanjutnya dilakukan proses pelatihan model menggunakan data latih dan validasi yang melibatkan penyesuaian parameter internal model dengan metode *backpropagation* dan *optimizer Adaptive Moment Estimation (Adam)* (Willemink et al., 2020). Sebelum menjalankan model, dilakukan inisialisasi parameter seperti *learning rate*, *batch size*, dan *epoch*. Setelah parameter yang dibutuhkan sudah diinisialisasi kemudian algoritma diimplementasikan untuk melakukan *feature learning* dan klasifikasi citra. Output klasifikasi menghasilkan 2 kelas, yaitu kelas 0 dengan label *with_insecticide* dan kelas 1 dengan label *without_insecticide*. Selanjutnya dilakukan pengujian menggunakan citra baru untuk

mengevaluasi kinerja model. Data pengujian digunakan untuk mengevaluasi kinerja model secara keseluruhan, memastikan bahwa model dapat melakukan klasifikasi dengan akurat pada data yang belum pernah dilihat sebelumnya (Akram et al., 2023).

Analisis Data

Analisis data dilakukan menggunakan *confusion matrix* dan *classification report* dari *library sklearn.metrics*. *Confusion matrix* digunakan untuk mengorganisasi hasil prediksi model, memberikan gambaran tentang seberapa baik model mengklasifikasikan citra cabai dengan benar, dan jenis kesalahan yang dibuat oleh model (Gong, 2021). *Classification report* memberikan informasi lebih rinci tentang performa model, termasuk *accuracy*, *precision*, *recall*, dan *F1-score* (Fachrel et al., 2023).

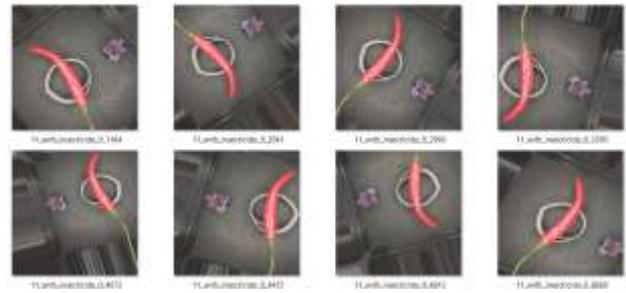
HASIL DAN PEMBAHASAN

Hasil Pengujian dengan GC

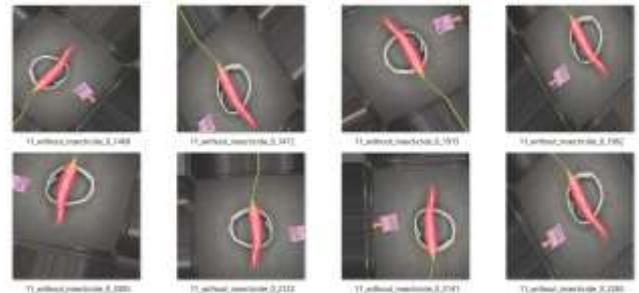
Hasil pengujian sampel cabai dengan konsentrasi 0 mg/l menunjukkan bahwa tidak terdeteksi adanya residu insektisida dalam sampel tersebut. Hal ini sesuai dengan harapan karena pada taraf perlakuan dengan konsentrasi 0 mg/l, tidak ada insektisida profenofos yang ditambahkan ke larutan, hanya menggunakan aquades. Sedangkan pada sampel cabai dengan konsentrasi 10 mg/l, ditemukan adanya residu insektisida profenofos sebesar 65,68165 ppb.

Hasil Pra-pemrosesan Citra

Implementasi augmentasi citra dilakukan dengan menghasilkan 50 citra baru untuk setiap ulangan pada konsentrasi 0 dan 10 mg/l. Dengan 15 ulangan untuk setiap konsentrasi, totalnya terdapat 765 citra untuk masing-masing konsentrasi, sehingga secara keseluruhan terdapat 1530 citra. Contoh citra hasil augmentasi dapat dilihat pada Gambar 4 dan Gambar 5. Gambar-gambar ini menampilkan beberapa contoh variasi citra yang diperoleh setelah penerapan augmentasi, mencakup berbagai transformasi seperti rotasi, pergeseran, *zoom*, serta horizontal dan *vertical flipping*.



Gambar 4. Contoh hasil augmentasi citra *with_insecticide*.



Gambar 5. Contoh hasil augmentasi citra *without_insecticide*.

Setelah mendapatkan hasil augmentasi, data citra kemudian dibagi menjadi tiga bagian, yaitu data pelatihan (*train*), validasi, dan pengujian (*test*) dengan rasio 40:30:30. Sebelum masuk ke dalam implementasi pemodelan, dilakukan normalisasi dan *resizing* pada data citra yang sudah di augmentasi.

Implementasi Pemodelan CNN

Tahap implementasi model CNN melibatkan pembuatan arsitektur, pelatihan, penyimpanan, dan pengujian model untuk mencapai tujuan klasifikasi citra yang ditetapkan. Model CNN dibuat menggunakan *convolution layer* untuk mengekstraksi fitur dari citra dan *fully connected layer* untuk proses klasifikasi. Pada *fully connected layer*, digunakan tiga tumpukan *dense layer*. Jumlah neuron pada setiap tumpukan mengalami penurunan sebanyak setengah dari tumpukan sebelumnya. Hal ini bertujuan untuk mengurangi risiko *overfitting* yang mungkin terjadi akibat peningkatan nilai filter pada *convolution layer* (Shahid & Singh, 2020). Proses komputasi pada *dense layer* diakhiri pada *output layer* menggunakan fungsi aktivasi *sigmoid* untuk mengklasifikasikan dua kelas atau kelompok data, yaitu *with_insecticide* dan *without_insecticide*. Kode arsitektur model dapat dilihat pada Gambar 6.

```

1 # Import library
2 import os
3 import tensorflow as tf
4 from tensorflow.keras.models import Sequential
5 from tensorflow.keras.layers import Conv2D, MaxPooling2D, Flatten,
6
7 # Fungsi untuk membuat model
8 def create_sequential_model(input_shape=(28, 28, 3)):
9     model = Sequential([
10         Conv2D(64, (3, 3), padding='same', activation='relu', input_shape=input_shape),
11         Conv2D(64, (3, 3), padding='same', activation='relu'),
12         MaxPooling2D((2, 2)),
13         Conv2D(128, (3, 3), padding='same', activation='relu'),
14         Conv2D(128, (3, 3), padding='same', activation='relu'),
15         MaxPooling2D((2, 2)),
16         Flatten(),
17         Dense(256, activation='relu'),
18         Dense(128, activation='relu'),
19         Dense(2, activation='sigmoid')
20     ])
21     return model
22
23 # Buat model
24 model = create_sequential_model()
25 model.summary()

```

Gambar 6. Kode pembuatan arsitektur CNN.

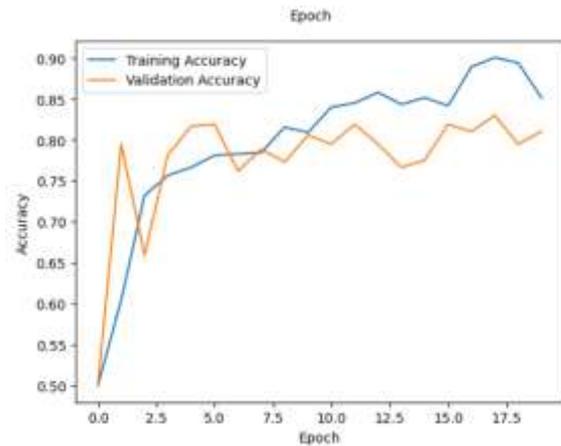
Model *summary* yang memberikan ringkasan tentang arsitektur dan parameter dari model yang telah dibuat dapat dilihat pada Gambar 7.

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 28, 28, 64)	1792
conv2d_1 (Conv2D)	(None, 28, 28, 64)	36928
max_pooling2d (MaxPooling2D)	(None, 14, 14, 64)	0
conv2d_2 (Conv2D)	(None, 14, 14, 128)	73856
conv2d_3 (Conv2D)	(None, 14, 14, 128)	147584
max_pooling2d_1 (MaxPooling2D)	(None, 7, 7, 128)	0
Flatten (Flatten)	(None, 6272)	0
dense (Dense)	(None, 256)	1605888
dense_1 (Dense)	(None, 128)	32896
dense_2 (Dense)	(None, 2)	256

Total params: 1899202 (7.24 MB)
Trainable params: 1899202 (7.24 MB)
Non-trainable params: 0 (0.00 Byte)

Gambar 7. Model *summary*

Pada tahap pelatihan model, dilakukan kompilasi model menggunakan *optimizer* Adam dengan *learning rate* 0,0001 serta *loss function* *categorical_crossentropy*. Setelah itu, model dilatih sebanyak 20 *epoch* dengan *batch size* 16 menggunakan generator data latih dan validasi. Selama pelatihan, model melakukan penyesuaian parameter berdasarkan gradien dari *loss function* menggunakan metode *backpropagation*. Visualisasi performa model selama pelatihan dapat dilihat pada Gambar 8.



Gambar 8. Visualisasi pelatihan model.

Setelah menjalani 20 *epoch*, model berhasil mencapai tingkat akurasi pelatihan sebesar 0,85 dengan *loss* sebesar 0,28 yang dapat dilihat pada Gambar 9. Hasil tersebut menunjukkan bahwa model mampu mengklasifikasikan sebagian besar data dengan benar, dengan tingkat akurasi yang tinggi. Selain itu, nilai *loss* yang relatif rendah menandakan bahwa model telah berhasil meminimalkan kesalahan prediksi selama proses pelatihan (Pratama et al., 2023).

Train Loss: 0.2816693186759949
Train Accuracy: 0.851307213306427

Gambar 9. Hasil *train accuracy* dan *train loss*

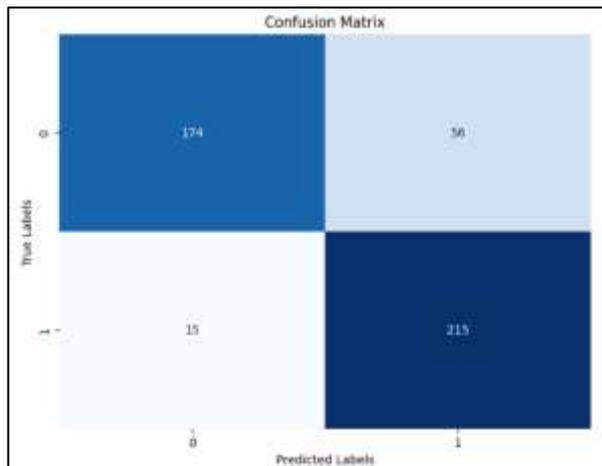
Selanjutnya, citra uji yang dipilih secara acak akan menjalani tahap pra-pemrosesan citra untuk mengubahnya menjadi format yang dapat diterima oleh model. Setelah itu, model akan melakukan prediksi label kelas untuk citra tersebut. Hasil prediksi akan ditampilkan dalam bentuk probabilitas untuk setiap kelas, serta kelas yang diprediksi oleh model. Dengan nilai probabilitas yang mendekati satu, model dapat mengidentifikasi jenis label yang sesuai dengan citra masukan (Yang et al., 2021). Hasil pengujian model dapat dilihat pada Gambar 10.

1/1 [-----] - 0s 96ms/step
Prediction: [0.94168466 0.05116002]
Class: 0
Class Name: with_insecticide

Gambar 10. Hasil pengujian model.

Hasil Analisis Data

Confusion matrix memberikan gambaran yang komprehensif tentang kinerja keseluruhan model dalam mengklasifikasikan sampel pada dataset uji (Amin & Mahmoud, 2022). Hasil evaluasi model dapat dilihat pada Gambar 11.



Gambar 11. Hasil *confusion matrix*.

Confusion matrix memberikan gambaran tentang hasil klasifikasi citra ke dalam dua kelas, yaitu 0 (*with_insecticide*) dan 1 (*without_insecticide*). Dari total 460 citra yang diuji, terdapat hasil klasifikasi sebagai berikut:

1. *True Positive* (TP): 215 gambar diklasifikasikan dengan benar sebagai *without_insecticide*.
2. *False Positive* (FP): 56 gambar diklasifikasikan secara keliru sebagai *with_insecticide*, tetapi sebenarnya *without_insecticide*.
3. *True Negative* (TN): 174 gambar diklasifikasikan dengan benar sebagai *with_insecticide*.
4. *False Negative* (FN): 15 gambar diklasifikasikan secara keliru sebagai *without_insecticide*, tetapi sebenarnya *with_insecticide*.

Berdasarkan hasil dari *confusion matrix*, algoritma dilanjutkan dengan pembuatan *classification report* yang memberikan informasi lebih rinci mengenai kinerja model dalam melakukan klasifikasi.

	precision	recall	f1-score	support
0	0.92	0.76	0.83	230
1	0.79	0.93	0.86	230
accuracy			0.85	460
macro avg	0.86	0.85	0.84	460
weighted avg	0.86	0.85	0.84	460

Gambar 12. *Classification report* model CNN

Classification report menunjukkan evaluasi model berdasarkan sejumlah metrik, seperti *precision*, *recall*, dan *F1-score* untuk setiap kelas, serta akurasi keseluruhan. Dari hasil *classification report* pada Gambar 12, terlihat bahwa model memiliki tingkat akurasi sebesar 0,85 atau 85%. Didapatkan hasil 0,86 untuk *precision*, 0,85 untuk *recall*, dan 0,84 untuk *F1-score*.

KESIMPULAN

Penerapan augmentasi citra dan CNN dalam mendeteksi residu insektisida profenofos pada cabai merah telah terbukti berhasil. Metode augmentasi citra dan CNN telah dievaluasi menggunakan *confusion matrix* dan hasilnya ditampilkan melalui *classification report*. Model mencapai tingkat akurasi sebesar 85%, dengan nilai *precision* sebesar 0,86; *recall* sebesar 0,85; dan *F1-score* sebesar 0,84. Ini menunjukkan bahwa model mampu dengan baik dalam mendeteksi residu insektisida profenofos pada cabai merah (*Capsium annum L.*) dengan mengklasifikasikan sebagian besar citra ke dalam kelas yang sesuai.

Saran

Perlu dilakukan penelitian lebih lanjut untuk memperbanyak dataset dan memperluas cakupan augmentasi citra yang digunakan dalam model agar dapat meningkatkan akurasi model. Selain itu, Perlu melakukan optimasi algoritma CNN melalui eksperimen dengan berbagai arsitektur jaringan dan penyesuaian *hyperparameter* juga diperlukan agar dapat meningkatkan akurasi model.

DAFTAR PUSTAKA

- Akram, A., Fayakun, K., & Ramza, H. (2023). Klasifikasi Hama Serangga pada Pertanian Menggunakan Metode Convolutional Neural Network. *Building of Informatics, Technology and Science (BITS)*, 5(2). <https://doi.org/10.47065/bits.v5i2.4063>
- 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), 53. <https://doi.org/10.1186/s40537-021-00444-8>
- Amin, F., & Mahmoud, M. (2022). Confusion matrix in binary classification problems: a step-by-step tutorial. *Journal of Engineering Research*, 6(5), 0. <http://dx.doi.org/10.21608/erjeng.2022.274526>
- Ardiwinata, A. N., Ginoga, L. N., Sulaeman, E., & Harsanti, E. S. (2018). Pesticide residue monitoring on agriculture in Indonesia.

- Jurnal Sumberdaya Lahan*, 12(2), 133–144.
- Ashraf, H. N., Walayat, N., Saleem, M. H., Niaz, N., Hafeez, A., Atiq, M. N., Chattha, M. S., El-Sheikh, M. A., & Ali, S. (2022). Determination of pesticide residues from grapes procured from different markets using through high performance liquid chromatography (HPLC). *Pakistan Journal of Botany*, 54(2), 737–741. [http://dx.doi.org/10.30848/PJB2022-2\(19\)](http://dx.doi.org/10.30848/PJB2022-2(19))
- Badan Pusat Statistik. (2023). Produksi Tanaman Sayuran 2022.
- Banerjee, K., & Hübschmann, H.-J. (2022). Automation in Pesticide Residue Analysis in Foods: A Step toward Smarter Laboratories and Green Chemistry. *ACS Agricultural Science & Technology*, 2(3), 426–429. <https://doi.org/10.1021/acsagscitech.2c00126>
- Deepalakshmi, P., Lavanya, K., & Srinivasu, P. N. (2021). Plant leaf disease detection using CNN algorithm. *International Journal of Information System Modeling and Design (IJISMD)*, 12(1), 1–21. <https://doi.org/10.4018/IJISMD.2021010101>
- Dijk, T. van, & Croon, G. de. (2019). How do neural networks see depth in single images? *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2183–2191.
- Eingar, A. A., Arafa, M., Fathy, A., Moustafa, B., Mahmoud, O., Shaban, M., & Fawzy, N. (2021). Image classification based on CNN: a survey. *Journal of Cybersecurity and Information Management*, 6(1), 18–50. <https://doi.org/10.54216/JCIM.060102>
- Fachrel, J., Pravitasari, A. A., Yulita, I. N., Ardhisasmita, M. N., & Indrayatna, F. (2023). Enhancing an Imbalanced Lung Disease X-ray Image Classification with the CNN-LSTM Model. *Applied Sciences*, 13(14), 8227. <https://doi.org/10.3390/app13148227>
- Food and Agriculture Organization of the United Nations. (2020). *World Food and Agriculture-Statistical Yearbook 2020*. Food and Agriculture Organization of the United Nations.
- Gong, M. (2021). A novel performance measure for machine learning classification. *International Journal of Managing Information Technology (IJMIT)* Vol, 13. <https://doi.org/10.5121/ijmit.2021.13101>
- Hassan, H., Elsayed, E., El-Raouf, A. E.-R. A., & Salman, S. N. (2019). Method validation and evaluation of household processing on reduction of pesticide residues in tomato. *Journal of Consumer Protection and Food Safety*, 14(1), 31–39. <https://doi.org/10.1007/s00003-018-1197-2>
- Hendra, Sarbino, & Syahputra, E. (2021). Pengaruh Frekuensi Penyemprotan Insektisida Profenofos untuk Mengendalikan Lalat Buah Bactrocera Spp pada Tanaman Cabai. *Jurnal Sains Pertanian Equator*, 10(1), 1–12. <http://dx.doi.org/10.26418/jspe.v10i1.43865>
- Ibrahim, M. S., Hamid, S. A., Muhammad, Z., Leh, N. A. M., Abdullah, S., Bakar, S. J. A., Osman, M. K., & Fadhlullah, S. Y. (2022). CNN Comparative Study for Apple Quality Classification. *2022 IEEE 12th International Conference on Control System, Computing and Engineering (ICCSCE)*, 53–58. <https://doi.org/10.1109/ICCSCE54767.2022.9935652>
- Lee, J., Ko, K., & Chung, H. (2022). Application of colorimetric sensor in monitoring dissolved CO₂ in natural waters. *Journal of Environmental Management*, 312, 114893. <https://doi.org/https://doi.org/10.1016/j.jenvman.2022.114893>
- Lyu, X., Peng, W., Yu, W., Xin, Z., Niu, S., & Qu, Y. (2021). Sustainable intensification to coordinate agricultural efficiency and environmental protection: A systematic review based on metrological visualization. *Journal of Land Use Science*, 16(3), 313–338. <https://doi.org/10.1080/1747423X.2021.1922524>
- Manggala, B., Chaichana, C., Syahputra, W. N. H., & Wongwilai, W. (2023). Pesticide residues detection in agricultural products: A review. *Natural and Life Sciences Communications*, 22(3), e2023049. <https://doi.org/10.12982/NLSC.2023.049>
- Palakodati, S. S. S., Chirra, V. R. R., Yakobu, D., & Bulla, S. (2020). Fresh and Rotten Fruits Classification Using CNN and Transfer Learning. *Rev. d'Intelligence Artif.*, 34(5), 617–622. <https://doi.org/10.18280/ria.340512>
- Pratama, D., Wijaya, S., Santosa, S. A., & Tamba, S. P. (2023). Penerapan Neural Network LSTM dalam Memprediksi Sentimen Pengguna Twitter terhadap Bitcoin. *Jurnal Tekinkom (Teknik Informasi Dan Komputer)*, 6(2), 349–354. <https://doi.org/10.37600/tekinkom.v6i2.921>
- Putra, I. W. W. P., Setiyo, Y., Gunam, I. B. W., & Anggreni, A. A. M. D. (2021). Isolation

-
- and identification of profenofos pesticide degrading bacterium from soil sample of Bedugul, Indonesia. *IOP Conference Series: Earth and Environmental Science*, 724(1). <https://doi.org/10.1088/1755-1315/724/1/012037>
- Sanjaya, J., & Ayub, M. (2020). Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan Random Crop, Rotate, dan Mixup. *Jurnal Teknik Informatika Dan Sistem Informasi*, 6(2). <https://doi.org/10.28932/jutisi.v6i2.2688>
- Shahid, A. H., & Singh, M. P. (2020). A deep learning approach for prediction of Parkinson's disease progression. *Biomedical Engineering Letters*, 10(2), 227–239. <https://doi.org/10.1007/s13534-020-00156-7>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 1–48. <https://doi.org/10.1186/s40537-019-0197-0>
- Son, T. T., Lee, C., Le-Minh, H., Aslam, N., & Dat, V. C. (2022). An enhancement for image-based malware classification using machine learning with low dimension normalized input images. *Journal of Information Security and Applications*, 69, 103308. <https://doi.org/https://doi.org/10.1016/j.jisa.2022.103308>
- Suwimantara, I. M. G., Sucipta, I. N., & Tika, I. W. (2022). Hubungan antara Penggunaan Alat Pelindung Diri (APD) dengan Keluhan Petani akibat Pestisida (Studi Kasus di Subak Sri Gumana, Desa Rejasa, Kabupaten Tabanan). *JURNAL BETA (BIOSISTEM DAN TEKNIK PERTANIAN)*, 10(1), 186–190. <https://doi.org/10.24843/JBETA.2022.v10.i01.p19>
- Taareluan, J. A., Ngangi, J., Roring, V. I. Y., & Ogi, N. L. (2021). Toksisitas Ekstrak Daun Jarak (*Ricinus communis* Linnaeus) Sebagai Biopestisida Terhadap Mortalitas Hama Larva Bawang Daun (*Spodoptera exigua* Hubner). *NUKLEUS BIOSAINS*, 2(1), 1–9. <https://ejurnal.unima.ac.id/index.php/nukleus-biosains/article/view/2441>
- Yang, H., Ni, J., Gao, J., Han, Z., & Luan, T. (2021). A novel method for peanut variety identification and classification by Improved VGG16. *Scientific Reports*, 11(1), 15756.