

## Sistem Deteksi Hama dan Penyakit Tanaman Mangga (*Mangifera indica L.*) Berbasis Deep Learning Menggunakan Model Pra Latih YOLOv5

Harmiansyah\*, Ella Trilia Oviana, Remi Alpaizon, Devi Putri Khalifah, dan Paska Dwirotama

Program Studi Teknik Biosistem, Fakultas Teknologi Industri, Institut Teknologi Sumatera

Jl. Terusan Ryacudu, Lampung Selatan, 35365

\*Alamat korespondensi: harmibm@gmail.com

INFO ARTIKEL	ABSTRACT/ABSTRAK
Diterima: 07-04-2024	
Direvisi: 28-04-2024	<b>Mango Plant Pest and Disease Detection System (<i>Mangifera indica L.</i>) Based on Deep Learning Using YOLOv5 Pre-Trained Model</b>
Dipublikasi: 30-04-2024	
Keywords: Detection, Disease, Mango, Pest, Prediction	Mango ( <i>Mangifera indica L.</i> ) is an important agricultural commodity in Indonesia which has experienced a decline in productivity in recent years due to pest and disease attacks. Limited knowledge about identifying and handling this problem by farmers is one of the contributing factors. Therefore, this research tries to overcome this problem by implementing a deep learning-based pest and disease detection system. This research was carried out in the mango orchard of the Sumatra Institute of Technology, South Lampung, in the period October to December 2023. Data collection was carried out using a cell phone camera and involved 1000 images which fell into four classifications: healthy leaves, leaves with mealybugs, leaves damaged by caterpillars, and leaf blight. The data annotation process was carried out using the Roboflow platform, and the dataset was divided into three parts: 70% training, 20% validation, and 10% testing. The training results showed a low average loss value close to zero, which indicates the effectiveness of the system. This research carried out 2 training sessions using epoch hyperparameters, namely 200 and 300. Based on the training parameters, the total loss value at epoch 200 was 0.0324, while at epoch 300 the value was 0.0342. validation parameters showed that the mAP value at the 0.5 threshold reached 0.9546 and for the mAP value at the 0.5-0.95 threshold it has a value of 0.7269. In addition, at epoch 300 the mAP value at the 0.5-0.95 threshold was 0.9441 and the mAP value at the threshold of 0.5-0.95 obtained a value of 0.7357. Based on the testing parameters as a system evaluation, at epoch 200 obtained a mAP value of 90.05% and for epoch 300 a mAP value was obtained at 85%. Based on the overall system performance parameters, the best hyperparameter in this research was found to be 200 epochs. Therefore, the system can be used to detect various unhealthy mango leaves infected with mealybugs, damaged leaves by caterpillar as well as leaves with leaf blight.
Kata Kunci: Deteksi, Hama, Mangga, Penyakit, Prediksi	Mangga ( <i>Mangifera indica L.</i> ) merupakan komoditas pertanian penting di Indonesia yang mengalami penurunan produktivitas dalam beberapa tahun terakhir akibat serangan hama dan penyakit. Pengetahuan yang terbatas tentang identifikasi dan penanganan masalah ini oleh para petani menjadi salah satu faktor penyebabnya. Oleh karena itu, penelitian ini memiliki tujuan untuk menentukan <i>hyperparameter</i> berdasarkan parameter epoch pada kinerja model pra-latih YOLOv5 dalam mendeteksi hama dan penyakit pada daun mangga. Penelitian ini dilakukan di kebun mangga Institut Teknologi Sumatera, Lampung Selatan, pada periode Oktober hingga Desember 2023. Pengambilan

*dataset* dilakukan dengan menggunakan kamera handphone dan melibatkan 1000 gambar yang termasuk dalam empat klasifikasi: daun sehat, daun terserang kutu putih, daun terserang ulat daun, dan daun terkena hawar daun. Proses anotasi data dilakukan menggunakan platform Roboflow, dan *dataset* dibagi menjadi tiga bagian: 70% training, 20% validasi, dan 10% testing. Penelitian ini melakukan 2 kali training dengan menggunakan *hyperparameter epoch* yaitu 200 dan 300. Berdasarkan parameter training untuk total nilai *loss* pada *epoch* 200 adalah 0,0324 sedangkan pada *epoch* 300 didapatkan nilai 0,0342. Parameter validasi menunjukkan nilai mAP pada ambang 0,5 mencapai 0,9546 dan untuk nilai mAP pada ambang 0,5-0,95 memiliki nilai 0,7269 sedangkan pada *epoch* 300 nilai mAP pada ambang 0,5-0,95 adalah 0,9441 serta nilai mAP pada ambang 0,5-0,95 didapatkan nilai sebesar 0,7357. Berdasarkan parameter testing sebagai evaluasi sistem, pada *epoch* 200 didapatkan nilai mAP 90,05% serta untuk *epoch* 300 didapatkan nilai mAP sebesar 85%. Berdasarkan keseluruhan parameter kinerja sistem didapatkan *hyperparameter* terbaik *epoch* pada penelitian ini adalah 200. Oleh karena itu sistem ini dapat digunakan untuk mendeteksi daun mangga yang rusak karena terserang kutu putih, ulat daun serta daun sakit karena hawar daun.

## PENDAHULUAN

Mangga (*Mangifera indica* L.) merupakan tanaman yang berasal dari India dan termasuk keluarga *Anacardiaceae* (Ayu dkk., 2021). Mangga merupakan salah satu komoditas ekspor sehingga komoditas ini banyak dibudidayakan di Indonesia (Sulaiman dkk., 2021). Badan Pusat Statistik (BPS) mencatat, produksi tanaman mangga di Indonesia sebanyak 2,9 juta ton pada tahun 2020. Namun, pada periode tahun 2021, produktivitas tanaman mangga di Indonesia mengalami penurunan rata-rata sebesar 2,07% (BPS, 2021).

Penurunan produktivitas tanaman mangga menjadi salah satu permasalahan utama yang disebabkan oleh serangan hama dan penyakit (Iqbal *et al.*, 2018). Umumnya pada tanaman mangga terdapat dua jenis gangguan pertumbuhan berdasarkan gejala-gejala yang timbul. Patogen, gulma dan hama termasuk pada kategori penyebab gangguan pertumbuhan berupa organisme pengganggu tanaman sedangkan faktor suhu, cahaya, nutrisi dan air merupakan penyebab gangguan berupa non-organisme pengganggu tanaman.

Hama pada tanaman mangga di antaranya kepik mangga (*Cryptorrhynococcus gravis*), kutu putih (*Phenacoccus* sp.), lalat buah (*Bactrocera* sp.), ulat daun (*Lymantria marginata*), wereng (*Idiocerus clypealis*, *I. niveosparsus*, *I. atkinsoni*), tungau (*Paratetranychus yothersi*) dan codot sedangkan penyakit pada tanaman mangga di antaranya penyakit antraknosa (*Colletotrichum* sp.), hawar daun cercospora yang disebabkan jamur (*Cercospora*

*capsici*) atau bakteri yang biasanya menyerang batang, ranting, buah dan daun dan menyebabkan timbulnya gejala hawar (Pristian dkk., 2022). Di antara hama dan penyakit tersebut di atas, penyakit hawar daun, hama kutu putih, dan ulat daun umumnya banyak ditemukan dan menjadi permasalahan pada tanaman mangga (Pristian dkk., 2022).

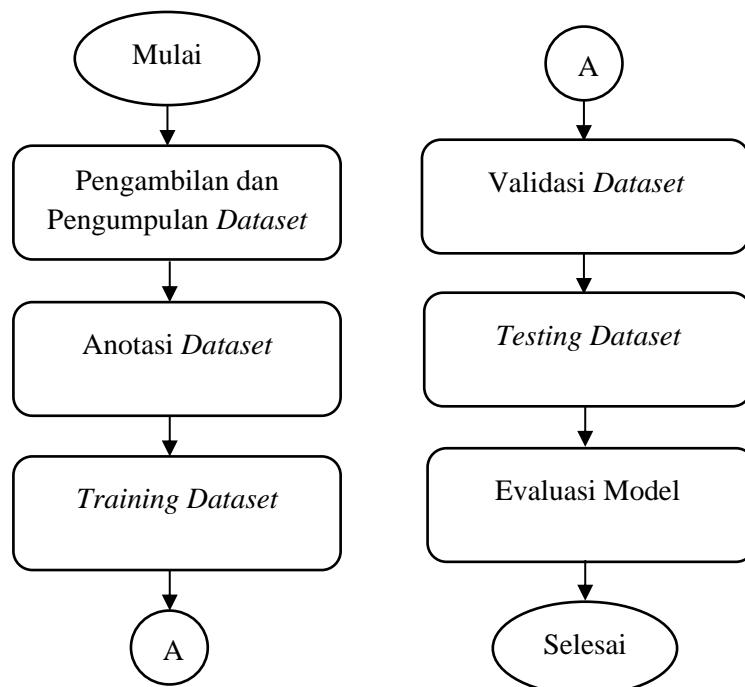
Kurangnya pengetahuan petani dalam mengenali hama dan penyakit yang menyerang tanaman mangga menyebabkan penanganan untuk mengatasi hama dan penyakit pada tanaman mangga menjadi kurang tepat (Efendi, 2017). Hama dan penyakit pada tanaman mangga seringkali sulit diidentifikasi karena gejalanya yang beragam, memerlukan kemahiran khusus yang umumnya hanya dimiliki oleh ahli penyakit tanaman berpengalaman (Pristian dkk., 2022). Salah satu upaya yang dapat dilakukan untuk mengatasi permasalahan tersebut adalah dengan menerapkan sistem deteksi hama dan penyakit berbasis *deep learning*. Sistem Cerdas berbasis Teknologi IT telah dirancang untuk dapat mendeteksi dan mengidentifikasi secara otomatis hama dan penyakit pada daun mangga serta cara penanggulangannya berbasis *deep learning* dengan menggunakan Pralatih YOLOv5 (Pradana dkk., 2018). YOLOv5 merupakan teknologi dalam pengenalan objek dengan kecepatan proses yang cukup cepat dan tingkat akurasi yang cukup tinggi (Susanti dkk., 2023). Penelitian ini menggunakan model YOLOv5 untuk menentukan *hyperparameter* optimal.

*Hyperparameter* merupakan parameter-parameter yang memengaruhi kinerja model *deep learning*, salah satunya adalah parameter *epoch*. Sehingga penelitian ini bertujuan untuk menentukan *hyperparameter* berdasarkan parameter *epoch* pada kinerja model pra-latih YOLOv5 dalam mendeteksi hama dan penyakit daun mangga dalam hal ini daun yang terserang kutu putih, ulat daun serta terkena hawar daun.

## BAHAN DAN METODE

### Lokasi dan Waktu Penelitian

Penelitian ini dilakukan di kebun mangga Institut Teknologi Sumatera, Kabupaten Lampung Selatan, Lampung pada Oktober-Desember 2023. Alat dan bahan yang digunakan yaitu kamera handphone iphone XR, laptop, *Google collaboratory*, *Roboflow*, dan daun tanaman varietas mangga Indramayu (*M. indica L.*). Tahapan penelitian terdapat pada Gambar 1.



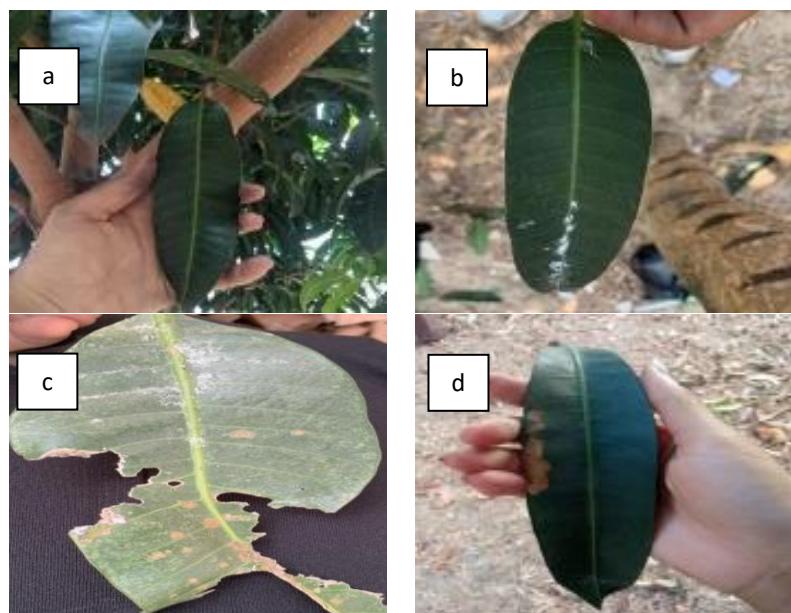
Gambar 1 Tahapan Penelitian

### Pengambilan dan Pengumpulan *Dataset*

Pengambilan *dataset* menggunakan kamera *handphone* dengan jumlah 1000 gambar. Gambar tersebut dikelompokkan ke dalam empat klasifikasi hama dan penyakit daun mangga yaitu gambar daun sehat dengan jumlah gambar 250, daun yang terserang kutu putih dengan jumlah data 250 gambar, daun yang terserang ulat daun sebanyak 250 gambar, dan daun yang terkena hawar daun sebanyak 250 gambar. Klasifikasi daun dapat dilihat pada Gambar 2.

Daun mangga yang terserang hama kutu putih memiliki gejala serangan seperti terdapat kumpulan ulat pada daun yang menyerupai kapas pada bagian bawah dan atas daun (Gambar 2b). Daun yang terserang hama ulat daun memiliki ciri-ciri terdapat

lubang bekas gigitan yang dimulai dari tepi daun hingga ke bagian tengah (Gambar 2c). Serangannya berbentuk lingkaran dengan diameter + 2 cm (Mokodompit dkk., 2018). Pemilihan gambar gejala daun dilakukan dengan melakukan observasi langsung terhadap daun yang terkena serangan dengan memperhatikan keberadaan kotoran yang dapat menjadi indikasi kuat bahwa ulat daun merupakan penyebabnya. Sementara untuk klasifikasi daun yang terkena hawar daun memiliki gejala pada daun bermula berupa bintik-bintik di sela-sela tulang, bersudut, basah kuyup (diameter 1 hingga 3 mm) yang menyatu, menjadi coklat tua hingga hitam (Gambar 2d) (Islam et al., 2013).

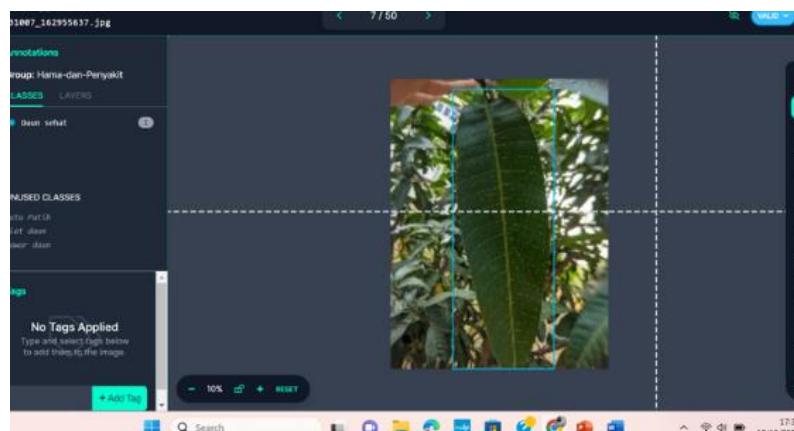


Gambar 2. Klasifikasi daun mangga yang terserang hama dan penyakit, (a) gambar daun sehat, (b) daun yang terserang kutu putih, (c) daun rusak karena ulat daun, dan (d) daun yang terkena hawar daun

#### Anotasi Dataset

Proses dalam mengidentifikasi atau memberikan penanda menggunakan bentuk kotak dengan basis koordinat *ground-truth* pada objek merupakan proses anotasi data atau *Labeling* (Harmiansyah dkk., 2023). Anotasi *dataset* pada

penelitian ini menggunakan *platform roboflow*. *Dataset* yang terdiri dari 1000 gambar dibagi menjadi tiga bagian yaitu 70% *training*, 20% validasi, dan 10% *testing*. Contoh anotasi *dataset* menggunakan *platform roboflow* dapat dilihat pada Gambar 3.



Gambar 3. Anotasi Dataset

#### Training Dataset

Pada *dataset* yang sudah dianotasi kemudian dilakukan *Training dataset deep learning* (DL) untuk melatih model. Model pra-latih yang digunakan adalah YOLOv5. Hasil anotasi *dataset* diunggah dari *roboflow* ke *Google Drive* dengan *script DL* pada *G. Colab*. *Dataset* yang digunakan dalam *training* adalah 70% dari jumlah total keseluruhan *dataset* yaitu 700 gambar yang terdiri dari daun sehat 175 gambar, daun yang terserang kutu putih 175 gambar, daun yang

terserang ulat daun 175 gambar, dan daun yang terkena hawar daun sebanyak 175 gambar. Pada penelitian ini membandingkan hasil sistem yang dirancang berdasarkan nilai hyperparameter *epoch* yaitu 200 dan 300 pada proses *training*. Hasil dari *training* kemudian dibandingkan untuk menentukan nilai *epoch* yang optimum. Jumlah data *training* dapat mempengaruhi nilai total loss, nilai total loss yang rendah menggambarkan proses *training* yang optimal

untuk menghasilkan model terbaik dari sistem deteksi yang dirancang (Sabrina & Maki, 2022).

#### Validasi Dataset

Uji validasi dilakukan dengan menggunakan 200 dataset yang telah dilakukan proses anotasi atau pelabelan. Setiap kelas terdiri dari 50 gambar daun sehat, 50 gambar daun yang terserang kutu putih, 50 daun yang terserang ulat, dan 50 gambar daun yang terkena hawar. Dataset validasi digunakan untuk melihat akurasi model yang dibuat dan mengoptimalkan kemampuan setelah uji *training* diakukan. Uji validasi bertujuan untuk validasi data *training* untuk mendapatkan model *deep learning* yang diinginkan.

#### Uji Testing

Pengujian model *deep learning* dilakukan dengan menggunakan dataset uji, yang merupakan kumpulan data yang digunakan untuk menguji kinerja model. Dataset untuk testing sebesar 10% dari total data atau sebanyak 100 gambar yang terdiri dari daun sehat 25 gambar, daun yang terserang kutu putih 25 gambar, daun yang terserang ulat daun 25 gambar, dan daun yang terkena hawar daun sebanyak 25 gambar. Gambar yang dihasilkan dari uji *testing* selanjutnya digunakan untuk mengevaluasi model.

#### Evaluasi Model

Evaluasi model bertujuan untuk mengetahui nilai *recall*, *accuracy*, mAP, *recall*, dan *confussion matrix* menggunakan data *testing* sebanyak 100 dataset atau gambar. Nilai tersebut didapatkan dari perhitungan persamaan (1), (2), (3), dan (4).

$$Accuracy = \frac{TP + TN}{TP + TN + FN + FP} \times 100\% \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (3)$$

$$mAP = \frac{\sum_{k=1}^K Precision_k}{K} \times 100\% \quad (4)$$

Tabel 1. Confussion Matrix

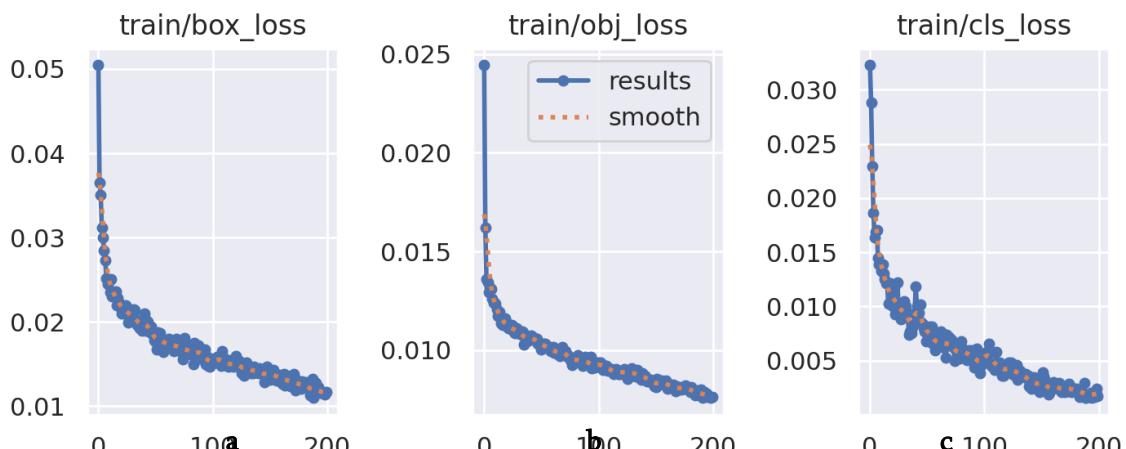
		Actual/Ground Truth	
Predicted Value	Positive	Positive	Negative
	TP (True Positive)	FP (False Positive)	TN (True Negative)
Negative	FN (False Negative)	TN (True Negative)	

## HASIL DAN PEMBAHASAN

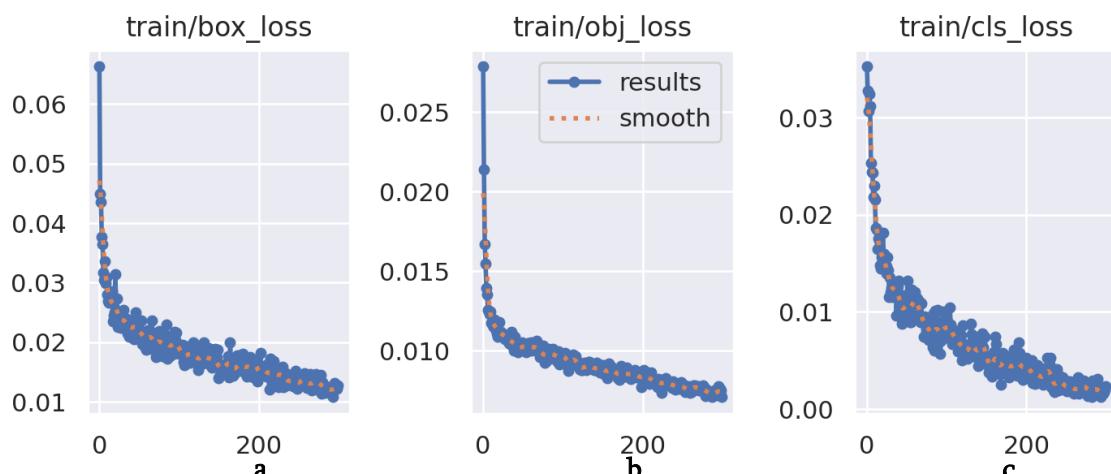
#### Uji Performa Training

Proses *training* penelitian ini menggunakan 700 dataset dengan variasi *epoch* 200 dan 300. Proses *training* mendapat hasil berupa nilai *box loss*, *objectness loss*, *classification loss*, dan total *loss*. Hasil training pada penelitian ini dapat dilihat pada Gambar 4 dan Gambar 5.

Kinerja training dari dataset menggunakan variasi nilai *epoch* 200 dapat dilihat Gambar 4, didapatkan nilai rata-rata *box loss* 0,0167, *objectness loss* 0,0095, *classification loss* 0,006, dan total *loss* 0,0324 untuk training dengan 200 *epoch*. Keseluruhan nilai *loss* kecenderungan menurun mendekati nilai 0 pada saat training.



Gambar 4. Nilai *loss* uji training untuk 200 *epoch*, (a) *training box loss*, (b) *training objectness loss*, (c) *training classification loss*



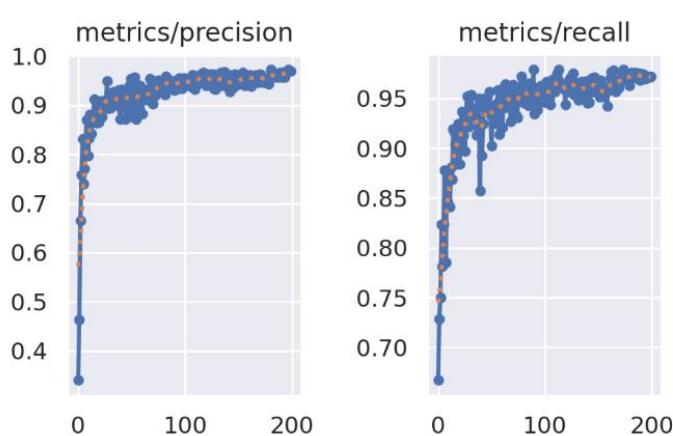
Gambar 5. Nilai *loss* uji training untuk 300 *epoch*, a) *training box loss*, b) *training objectness loss*, c) *training classification loss*

Berdasarkan hasil training pada penelitian ini dapat dilihat pada Gambar 5 didapatkan nilai rata-rata box loss 0,0179, objectness loss 0,0091, classification loss 0,0070, dan total loss 0,0342 untuk training dengan 300 *epoch*. Nilai *loss* mendekati nol mengindikasikan bahwa proses pembentukan model menggunakan *dataset* berjalan dengan baik (Harmiansyah dkk., 2023). Berdasarkan Gambar 4 dan Gambar 5 dapat diketahui bahwa kecenderungan dari nilai loss dari kedua *epoch* turun serta mendekati 0. Nilai *loss* yang rendah menunjukkan indikasi bahwa model yang dirancang memiliki performa optimal dalam pembelajaran awal dan dapat mendeteksi daun yang terserang hama dan penyakit

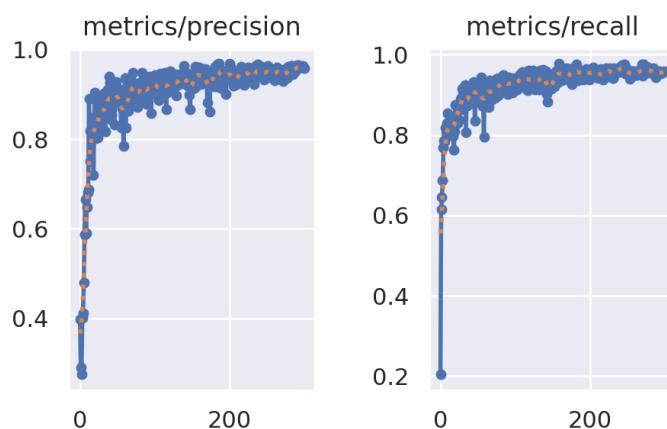
pada fase pelatihan (Ahmad *et al.*, 2022). Pada penelitian ini didapatkan nilai *loss* terbaik untuk training *dataset* berdasarkan total *loss* adalah 200 *epoch*. Nilai *epoch* menggambarkan jumlah pemrosesan seluruh *dataset* yang digunakan untuk menghasilkan model pada sistem deteksi.

#### Uji Performa Validasi

Validasi model pada penelitian ini menggunakan 200 *dataset* dengan variasi 200 dan 300 *epoch*. Proses validasi menghasilkan nilai *precision*, *recall*, *mean average precision*, *confusion matriks*, *box loss*, *objectness loss*, dan *classification loss*.



Gambar 6. Nilai *precision* (kiri) dan *recall* (kanan) hasil uji validasi pada *epoch* 200

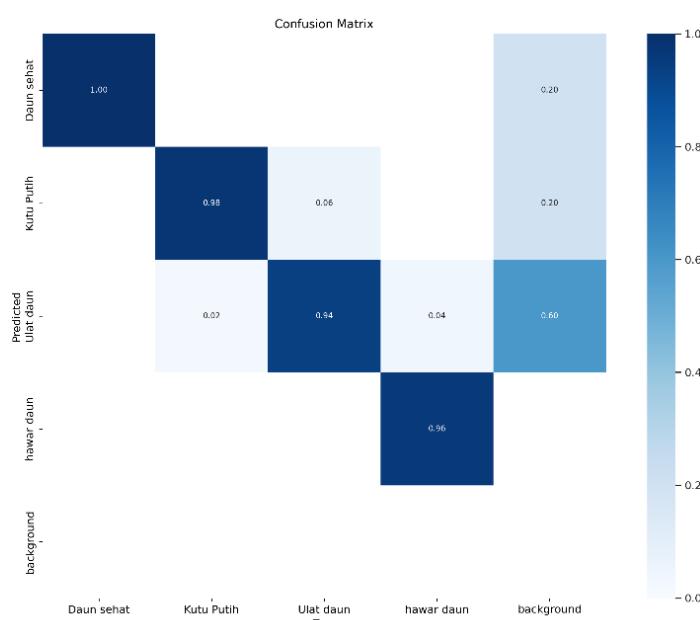


Gambar 7. Nilai *precision* (kiri) dan *recall* (kanan) hasil uji validasi pada *epoch* 300

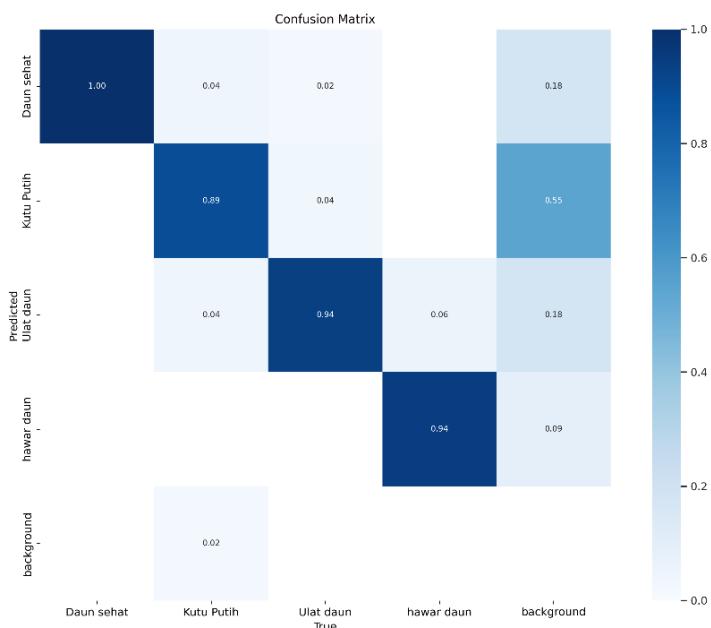
Model memiliki kemampuan untuk memprediksi dengan benar pada objek yang diamati dan keseluruhan hasil prediksi yang bersifat positif dalam bentuk persentase atau pecahan. Berdasarkan Gambar 6 dan Gambar 7 dapat diketahui nilai *precision* yang dihasilkan pada uji validasi model YOLOv5 adalah 0,9258 untuk *epoch* 200 serta didapatkan nilai 0,9061 untuk *epoch* 300. Nilai yang mendekati 1 (satu) pada hasil *precision* atau presisi menunjukkan model memiliki rasio prediksi sangat baik (Diwan dkk., 2023). Rasio atau tingkat keberhasilan sistem untuk menemukan kembali *dataset* yang diinputkan disebut *Recall* (Patel *et al.*, 2022). Nilai *recall* pada penelitian ini untuk *epoch* 200 adalah 0,9430222 dan untuk *epoch* 300 didapatkan nilai sebesar 0,9254109. Kedua nilai *recall* mendekati nilai maksimum yaitu 1 (satu)

menunjukkan bahwa tingkat efektivitas klasifikasi termasuk tinggi.

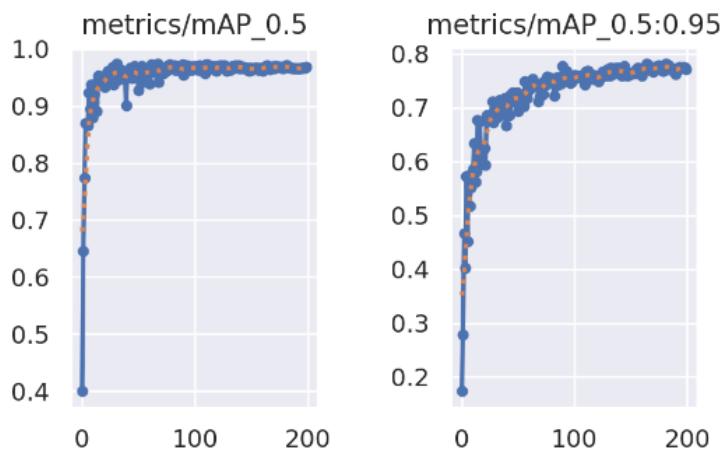
Gambar 8 dan Gambar 9 menunjukkan performa dari model untuk setiap klasifikasi pada *dataset*. Untuk *epoch* 200 dan 300 klasifikasi daun sehat memiliki nilai terbaik yaitu 1 yang menggambarkan model mampu memprediksi dengan baik untuk klasifikasi daun sehat. Secara keseluruhan nilai *confusion matrix* untuk semua klasifikasi pada semua *epoch* di atas 90% kecuali pada klasifikasi daun yang terkena kutu putih sebesar 89%. Nilai *epoch* menggambarkan pengulangan pengolahan *dataset* untuk menentukan model terbaik, menurunnya nilai *confusion matrix* klasifikasi kutu putih pada *epoch* mengindikasikan model terbaik sudah didapatkan pada *epoch*<300.



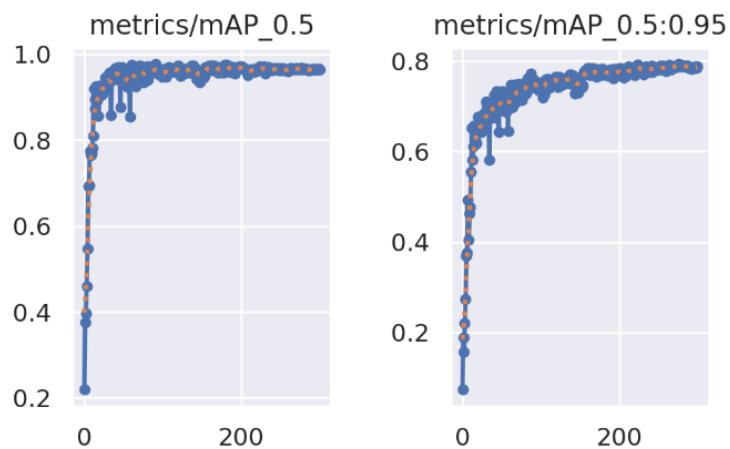
Gambar 8. *Confusion matrix* uji validasi untuk 200 *epoch*



Gambar 9. Confussion matriks uji validasi untuk 300 epoch



Gambar 10. Nilai tren mAP pada ambang 0,5 (kiri) dan 0,5-0,95 (kanan) pada epoch 200

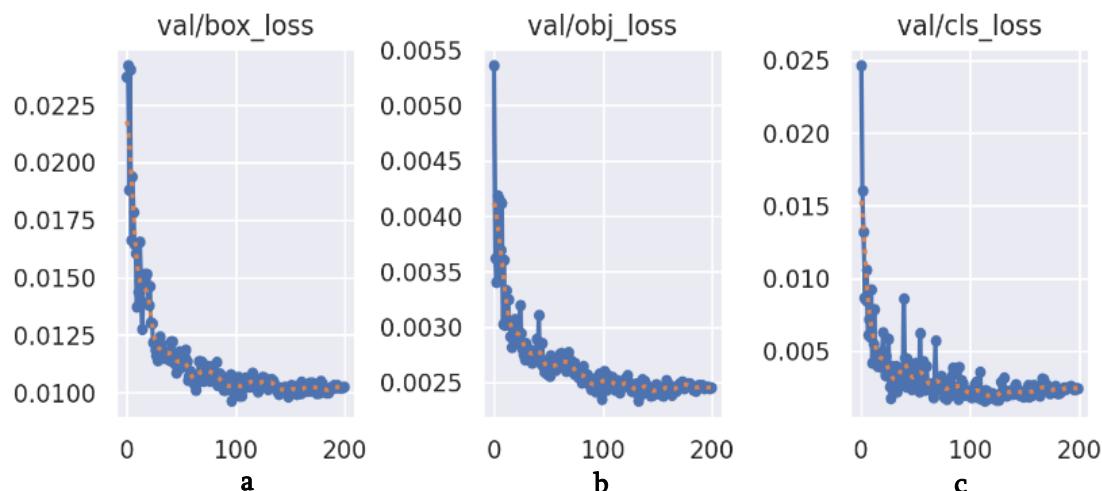


Gambar 11 Nilai tren mAP pada ambang 0,5 (kiri) dan 0,5-0,95 (kanan) pada epoch 300

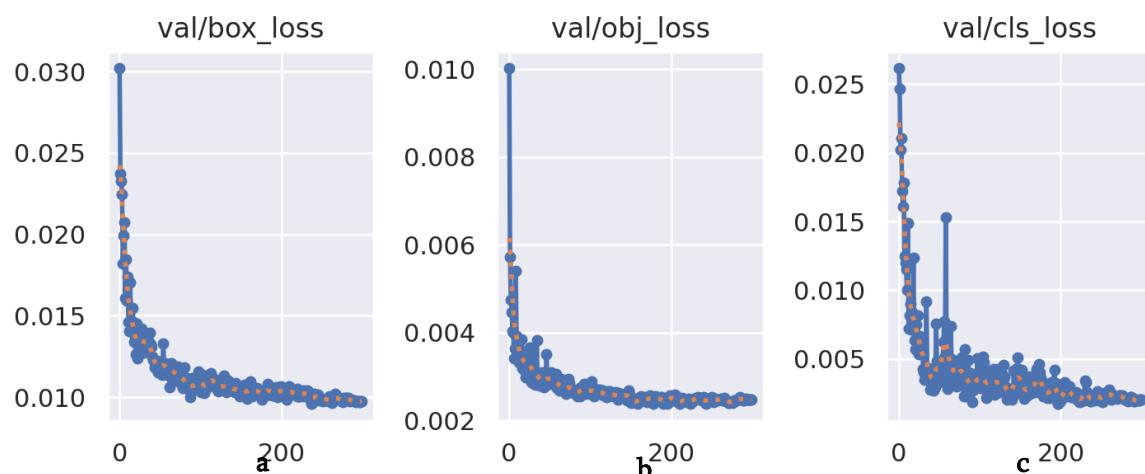
Parameter untuk mengetahui kinerja dari model dalam mendeteksi salah satu parameter adalah menggunakan nilai mAP. Rata-rata presisi dari nilai dalam pembacaan ulang yang diterapkan pada sistem disebut sebagai *Mean Average Precision* (mAP) (Nugroho, 2019). Hasil penelitian ini mendapatkan nilai mAP pada ambang 0,5 yaitu mencapai 0,954 sedangkan untuk nilai mAP pada ambang 0,5-0,95 memiliki nilai 0,7269 untuk *epoch* 200 sedang kan untuk nilai *epoch* 300 didapatkan nilai mAP pada ambang 0,5-0,95 adalah 0,944 serta nilai mAP pada ambang 0,5-0,95 didapatkan nilai sebesar 0,7357. Berdasarkan Gambar 10 dan Gambar 11 kecenderungan semua grafik mengalami kenaikan mendekati nilai 1, untuk nilai mAP pada ambang 0,5 memiliki nilai lebih baik dikarenakan nilai ambang

yang lebih luas untuk nilai IoU. Pada penelitian ini *epoch* 200 lebih baik dari pada *epoch* 300 berdasarkan nilai mAP.

Hasil proses validasi juga didapatkan nilai *box loss*, *objectness loss*, *classification loss*, dan total *loss* yang dapat dilihat pada Gambar 12 untuk *epoch* 200 dan Gambar 13 untuk *epoch* 300. Masing-masing dari rata-rata nilai tersebut adalah 0,0112; 0,0026; 0,0031; dan 0,0171 untuk 200 *epoch*. Untuk nilai *epoch* 300 sebagai berikut 0,0112; 0,0027; 0,0038; dan 0,0177. Rata-rata nilai *loss* dari *epoch* 200 dan *epoch* 300 yaitu mendekati 0. Semakin rendah nilai *loss* menunjukkan bahwa model yang dihasilkan memiliki kinerja yang optimal dan dapat melakukan klasifikasi dengan baik (Thiodorus *et al.*, 2021).



Gambar 12. Nilai loss uji validasi untuk nilai *epoch* 200, a) *box loss*, b) *object loss*, dan c) *classification loss*.



Gambar 13. Nilai loss uji validasi untuk nilai *epoch* 300, a) *box loss*, b) *object loss*, dan c) *classification loss*.

### Uji *Testing* Model dan Evaluasi Model

Hasil uji dari sistem deteksi ini dilakukan dengan melakukan proses *testing* dengan melibatkan 100 *dataset* atau 10% dari total *dataset* yang digunakan. Hasil pengujian *testing* *dataset* yang digunakan diambil satu gambar pada masing-masing

kelas sebagai sampel, sampel hasil deteksi dapat dilihat pada Tabel 3 dan Tabel 4. Hal ini dilakukan untuk mengetahui kemampuan sistem dalam mendeteksi penyakit pada daun mangga hasil deteksi sistem dibandingkan dengan anotasi yang telah ditentukan.

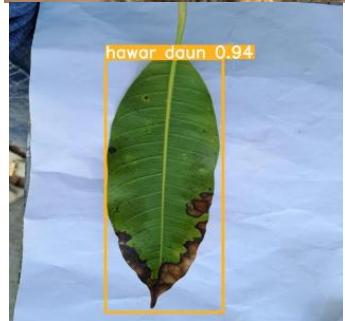
Tabel 1. Hasil uji testing deteksi objek untuk 200 *epoch*

No	Hasil Deteksi Objek	Keterangan	Tingkat Kepercayaan Sistem (%)
1		Anotasi benar (daun sehat)	92
2		Anotasi benar (hawar daun)	90
3		Anotasi benar (kutu putih)	94
4		Anotasi benar (ulat daun)	96

Hasil *testing*, yang dihitung menggunakan persamaan (1), (2), (3), dan (4) pada bagian bahan dan metode, ditampilkan pada Tabel 3 untuk *epoch* 200

dan Tabel 4 untuk *epoch* 300. Kedua tabel tersebut menunjukkan hasil kinerja dari sistem dalam mendeteksi penyakit pada daun mangga.

Tabel 2. Hasil uji testing deteksi objek untuk 300 epoch

No	Hasil Deteksi Objek	Keterangan	Tingkat Kepercayaan Sistem (%)
1		Anotasi benar (daun sehat)	93
2		Anotasi benar (hawar daun)	94
3		Anotasi benar (kutu putih)	95
4		Anotasi benar (ulat daun)	97

Tabel 3. Nilai hasil evaluasi uji testing untuk 200 epoch

Kelas	TP	FP	FN	TN	Persentase (%)	Akurasi (%)	Presisi (%)	Recall (%)	mAP (%)
Daun sehat	88	8	4	0	100	88	91.67	100	
Kutu putih	75	18	7	0	100	75	80.65	100	
Ulat daun	92	8	0	0	100	92	92.00	100	90.05
Hawar daun	93	4	3	0	100	93	95.88	100	
Rata-rata					87	90.05	100		

Tabel 4. Nilai hasil evaluasi uji testing untuk 300 epoch

Kelas	TP	FP	FN	TN	Presentase (%)	Akurasi (%)	Presisi (%)	Recall (%)	mAP (%)
Daun sehat	91	4	4	0	100	91	95	100	
Kutu putih	79	17	3	0	100	79	82	100	
Ulat daun	88	8	4	0	100	88	91	100	85
Hawar daun	68	29	4	0	100	68	70	100	
Rata-rata					81	85	100		

Berdasarkan nilai mAP yang didapatkan (Tabel 3 dan Tabel 4) untuk evaluasi sistem deteksi pada kedua parameter yaitu 200 dan 300 epoch. Diketahui bahwa sistem 200 epoch mendapatkan nilai terendah pada klasifikasi daun terserang kutu putih. Rendahnya nilai mAP dipengaruhi oleh nilai presisi dan akurasi pada pendekripsi hama kutu putih. Hal ini dapat terjadi karena beberapa faktor seperti *dataset*, pencahayaan pada gambar, atau resolusi *dataset*.

Sementara itu, nilai klasifikasi daun yang terkena hawar daun pada 300 epoch mengalami nilai presisi dan akurasi terendah dibandingkan klasifikasi yang lain. Nilai klasifikasi daun terserang kutu putih pada 300 epoch juga masih rendah dan tidak jauh berbeda dengan nilainya pada 200 epoch, meskipun tidak serendah nilai daun yang terkena hawar daun. Hal ini mengindikasikan model terbaik dari klasifikasi hawar daun didapatkan< 300 epoch, sedangkan untuk klasifikasi daun terserang kutu daun belum mendapatkan model terbaik.

## SIMPULAN

Hasil penelitian ini menunjukkan hyperparameter terbaik pada sistem deteksi penyakit pada daun mangga yaitu menggunakan parameter nilai epoch 200 karena berdasarkan parameter training, validasi dan testing menunjukkan epoch 200 memiliki kinerja lebih baik dibandingkan epoch 300. Berdasarkan parameter training untuk total nilai loss pada epoch 200 adalah 0,0324 sedangkan pada epoch 300 didapatkan nilai 0,0342. Parameter validasi menunjukkan nilai mAP pada ambang 0,5 yaitu mencapai 0,9546 dan untuk nilai mAP pada ambang 0,5-0,95 memiliki nilai 0,7269 sedangkan pada epoch 300 nilai mAP pada ambang 0,5-0,95 adalah 0,9441 serta nilai mAP pada ambang 0,5-0,95 didapatkan nilai sebesar 0,7357. Berdasarkan parameter testing sebagai evaluasi sistem pada epoch 200 didapatkan nilai mAP 90,05% serta untuk epoch 300 didapatkan nilai mAP sebesar 85%.

## UCAPAN TERIMA KASIH

Ucapan terima kasih kepada Lembaga Penelitian dan Pengabdian Kepada Masyarakat (LPPM) Institut Teknologi Sumatera yang telah mendanai penelitian ini dengan kontrak penelitian Nomor B/763ac/IT9.C1/PT.01.03/2022.

## DAFTAR PUSTAKA

- Ahmad, I, Y Yang, Y Yue, C Ye, M Hassan, X Cheng, Y Wu, and Y Zhang. 2022. Deep learning based detector YOLOv5 for identifying insect pests. *Applied Sciences*. 12(9): 10167. DOI: <https://doi.org/10.3390/app121910167>
- Ayu, T, V Dwi, and AE Minarno. 2021. Pendiagnosa daun mangga dengan model Convolutional Neural Network. *CESS (Journal of Computer Engineering, System and Science)*. 6: 230–235.
- BPS, 2021. Produksi Mangga Di Indonesia Tahun 2011-2021
- Diwan, T, G Anirudh, and J V Tembhurne. 2023. Object detection using YOLO: Challenges, architectural successors, datasets and applications. *Multimedia Tools and Applications*. 82: 9243–9275.
- Efendi, MZ. (2017). Sistem pakar identifikasi hama dan penyakit buah mangga menggunakan metode inferensi forward chaining berbasis web. *J-INTECH (Journal of Information and Technology)*. 5(02): 110-118.
- Harmiansyah, H, R Fil'aini, Z Mufidah, NWA Utari, J Hendra, D Diptaningsari, M Meidaliyantisa, N Wardani, R Mawardi, and MA Mustafid. 2023. Sistem smart detection penyakit pada tanaman kopi robusta menggunakan SSD MobileNet V2 sebagai model pra-terlatih. *Jurnal Agrikultura*. 34: 154–162.
- Iqbal, Z, MA Khan, M Sharif, JH Shah, MH ur Rehman, and K Javed, 2018. An automated detection and classification of citrus plant diseases using image processing techniques: A

- review. Computers and Electronics in Agriculture. 153: 12–32. DOI: <https://doi.org/10.1016/j.compag.2018.07.032>
- Islam, SIA, MR Islam, KMG Dastogeer, and I Hossain, 2013. Characterization of leaf blight pathogen, *Pseudomonas syringae* pv. *syringae* of mango in Bangladesh. International Research Journal of Biological Sciences. 2(6): 39–45.
- Mokodompit, HS, HN Pollo, dan MT Lasut. 2018. Identifikasi jenis serangga hama dan tingkat kerusakan. Eugenia. 24: 64–75. DOI: <https://doi.org/10.35791/eug.24.2.2018.22794>
- Nugroho, F. 2019. Sistem Rekomendasi Kata Kunci untuk Website Menggunakan Hybrid Semantic Relatedness dan Associative Neural Network. Master Thesis. Universitas Komputer Indonesia
- Patel, K, C Bhatt, and PL Mazzeo. 2022. Improved ship detection algorithm from satellite images using YOLOv7 and graph neural network. Algorithms. 15(12): 473. DOI: <https://doi.org/10.3390/a15120473>
- Pradana, DS, B Rahayudi, dan Suprapto. 2018. Sistem pakar pendekripsi hama dan penyakit tanaman mangga menggunakan metode Iterative Dichotomiser Tree (ID3). Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer. 2: 2713–2720.
- Pristian, DH, DI Mulyana, S Stepanus, dan E Donaldo. 2022. Klasifikasi Deteksi hama pada buah mangga dengan citra digital Sistematic Literatur Review (SLR). Jurnal Pendidikan Tambusai. 6: 1978–1983. DOI: <https://doi.org/10.31004/jptam.v6i1.3243>
- Sabrina, SA, dan WF Al Maki. 2022. Klasifikasi Penyakit pada tanaman kopi robusta berdasarkan citra daun menggunakan Convolutional Neural Network. eProceedings. 9: 1919–1927.
- Sulaiman, S, N Nurhayati, dan JN Sitompul. 2021. Sistem pakar mendiagnosa penyakit tanaman mangga Arumanis dengan metode certainty factor. Jurnal Teknisi. 1: 61–71.
- Susanti, L, NK Daulay, dan B Intan. 2023. Sistem absensi mahasiswa berbasis pengenalan wajah menggunakan algoritma YOLOv5. JURIKOM: Jurnal Riset Komputer. 10: 640–647. DOI: <http://dx.doi.org/10.30865/jurikom.v10i2.6032>
- Thiodorus, G, A Prasetia, LA Ardhani, dan N Yudistira, 2021. Klasifikasi citra makanan/non makanan menggunakan metode Transfer Learning dengan model Residual Network. Teknologi: Jurnal Ilmiah Sistem Informasi. 11: 74–83. DOI: <https://doi.org/10.26594/teknologi.v11i2.2402>