

Sistem *Smart Detection* Penyakit pada Tanaman Kopi Robusta Menggunakan SSD MobileNet V2 sebagai Model Pra-Terlatih

Harmiansyah^{1*}, Raizummi Fil'aini¹, Zunanik Mufidah¹, Ni Wayan Arya Utari¹,
Jekvy Hendra², Danarsi Diptaningsari³, Meidaliyantisyah³, Nila Wardani³,
Rahadian Mawardi³, dan M. Azhar Mustafid⁴

¹ Program Studi Teknik Biosistem, Jurusan Teknologi Produksi dan Industri,
Institut Teknologi Sumatera

Jl. Terusan Ryacudu, Lampung Selatan, 35365

² Balai Penerapan Standar Instrumen Pertanian Lampung

Jl. Hi. Z.A. Pagar Alam No.1a, Bandar Lampung, 35145

³ Badan Riset dan Inovasi Nasional. Cibinong Science Center

Jl. Raya Jakarta-Bogor, KM 46, Cibinong, Bogor, 16915 dan

Jl. Raya Puspiptek-Serpong, Tangerang Selatan, Banten, 15343

⁴ Nanobubble Karya Indonesia

Jl Raya Serpong, Komplek Batan Lama No. 12, Tangerang Selatan, 15314

*Alamat korespondensi: harmibm@gmail.com

INFO ARTIKEL	ABSTRACT/ABSTRAK
Diterima: 21-11-2022 Direvisi: 04-04-2023 Dipublikasi: 30-04-2023	Plant Disease Smart Detection System on Robusta Coffee Using SSD MobileNet V2 as Pre-trained Model
Keywords: Accuracy, Coffee leaf, Disease, Image object, Smart detection	Control of pests and diseases in Robusta coffee must be done early, if control is late it will result in low Robusta coffee production. Coffee farmers tend to be slow in detecting diseases in coffee plants due to limited knowledge. The smart disease identification system uses deep learning, one of the innovations that is able to identify diseases in coffee plants quickly and precisely. The method for creating a smart detection system begins with collecting a dataset consisting of a collection of images of Robusta coffee leaves. The dataset is classified into two classifications, namely healthy leaves and diseased leaves, sick leaves consist of images of leaves affected by spot and rust diseases. Then data annotation was performed to label the dataset, following the labelling, the data was then used for pre-trained model in the training to study the image object. Models that have been used in the training were subjected for evaluation to assess model performance based on average precision and average recall as performance parameters of the model. The results of the training in this study obtained a total loss value of 21.81% in 13100 epochs and had a downward trend. For the average precision value of the coffee plant smart detection system model was 87.3% and the average recall value was 89.6%. After testing the system with 12 samples, the accuracy value of the system in predicting was 96% so that the Robusta coffee plant smart detection system is a reliable system in which has potency to be implemented.
Kata Kunci: Akurasi, Daun kopi, Objek gambar, Penyakit, Smart detection	Pengendalian hama dan penyakit pada kopi robusta harus dilakukan secara dini, jika pengendalian terlambat maka akan berakibat pada produksi kopi robusta yang menjadi rendah. Para petani kopi cenderung lambat dalam mendeteksi penyakit pada tanaman kopi karena keterbatasan pengetahuan. Sistem smart identifikasi penyakit menggunakan deep learning merupakan salah satu inovasi

yang dapat digunakan untuk mengidentifikasi penyakit pada tanaman kopi dengan cepat dan tepat. Metode dalam pembuatan sistem smart detection diawali dengan pengumpulan dataset yang terdiri dari kumpulan gambar daun kopi robusta. Dataset diklasifikasi menjadi dua klasifikasi yaitu daun sehat dan daun sakit, daun sakit terdiri dari gambar daun yang terserang penyakit bercak dan karat. Kemudian dilakukan anotasi data untuk memberikan label pada dataset, setelah data dilabeli, data kemudian digunakan sebagai model pra-terlatih sebagai training untuk mempelajari objek gambar. Model yang telah ditraining kemudian dievaluasi untuk menilai kinerja model berdasarkan nilai *average precision* dan *average recall* sebagai parameter kinerja dari model. Hasil dari training pada penelitian ini didapatkan nilai total *loss* sebesar 21,81% dalam 13100 *epoch* serta memiliki kecenderungan turun. Untuk nilai *average precision* pada model sistem smart detection tanaman kopi adalah 87,3% dan nilai *average recall* sebesar 89,6%. Setelah dilakukan pengujian sistem dengan 12 sample didapatkan nilai akurasi ketepatan sistem dalam memprediksi adalah 96% sehingga sistem smart detection tanaman kopi robusta sudah baik dan mempunyai potensi untuk dapat diimplementasikan.

PENDAHULUAN

Tanaman kopi (*Coffea* sp.) merupakan komoditi subsektor perkebunan yang memiliki nilai ekspor yang tinggi, Indonesia menjadi salah satu negara produsen eksportir terbesar di Asia Tenggara dan terbesar ketiga di dunia setelah Brazil dan Vietnam (Harni dkk., 2015). Menurut BPS pada publikasi Statistik Kopi Indonesia, pada tahun 2020 Indonesia memiliki luas lahan perkebunan kopi mencapai 1.245.359 Ha serta menghasilkan produksi kopi sebesar 752.512 Ton (Badan Pusat Statistik, 2020). Provinsi Lampung menempati posisi kedua di Indonesia dengan memproduksi 15% produksi nasional untuk komoditi tanaman kopi dengan luas tanaman kopi 156.878 ha. Mayoritas perkebunan kopi di Provinsi Lampung merupakan perkebunan milik rakyat yang dikelola dengan metode tradisional (Badan Pusat Statistik, 2020).

Permasalahan utama pada perkebunan kopi rakyat, yaitu rendahnya produktivitas dan kualitas dari tanaman kopi karena serangan penyakit/hama pada tanaman kopi (Harni dkk., 2015; Muliani & Nildayanti, 2015). Serangan penyakit/hama pada tanaman kopi dapat menimbulkan kerugian secara ekonomis, dari segi kualitas maupun kuantitas. Serangan penyakit/hama tidak hanya pada tanaman yang sudah dewasa tetapi juga pada pembibitan, kebun entres, dan penyimpanan. Hama pada tanaman kopi antara lain penggerek buah kopi (*Hypothenemus hampei*), penggerek batang merah (*Zeuzera coffeae*), penggerek cabang dan ranting (*Xylosandrus compactus*), kutu hijau (*Coccus*

Viridis), dan wereng (*Sanurur indecora*). Penyakit tanaman kopi dibagi atas penyakit yang disebabkan oleh jamur, yaitu karat daun (*Hemileia vastatrix*), bercak daun (*Cercospora coffeicola*), jamur upas (*Upasia salmonicolor*), jamur akar (*Rigidoporus lignosus*, *Phellinus noxius*, dan *Rosellina bunodes*), kanker belah (*Armillaria* sp.), penyakit rebah batang (*Rhizoctonia solani*), dan penyakit yang disebabkan oleh nematoda seperti *Pratylenchus coffeae*, *Radopholus similis*, dan *Meloidogyne* spp. (Harni dkk., 2015).

Pengetahuan dan informasi para petani perkebunan kopi yang rendah mengenai jenis penyakit pada tanaman kopi berakibat penanganan serangan penyakit tidak optimal serta sebagian besar petani kopi di Indonesia, khususnya di Provinsi Lampung adalah petani kopi yang kurang terdidik. Para petani masih menggunakan cara tradisional dalam mengidentifikasi hama dan penyakit (Lumbanraja dkk., 2020). Hal ini berdampak terhadap penyebaran penyakit yang cepat sehingga banyak tanaman kopi yang mati dan kualitas kopi akhirnya menurun. Jika hal ini terus dibiarkan, maka akan berakibat menurunnya tingkat produktivitas tanaman kopi tersebut (Gunawan dkk., 2020). Beberapa penelitian sudah dilakukan untuk membantu petani dalam penanganan organisme penyakit tanaman kopi seperti sistem pakar penyakit tanaman kopi berbasis web dengan beberapa metode seperti metode *forward chaining* dan *Breadth First Search* (BFS) (Lumbanraja dkk., 2020; Gunawan dkk., 2020). Akan tetapi metode sistem pakar berbasis web memiliki kekurangan antara lain adalah petani secara


mandiri harus dapat mengidentifikasi gejala yang terjadi pada tanaman kopi. Hal ini menyebabkan akurasi dari identifikasi tidak seragam sesuai dengan kemampuan serta pengalaman petani. Oleh karena itu perlu dikembangkan metode deteksi lainnya seperti penggunaan data latih atau deteksi objek. Penelitian berbasis data latih dalam identifikasi awal penyakit tanaman kopi telah dilakukan menggunakan metode K-Nearest Neighbor (K-NN) (Putri & Sodik, 2019).

Object detection merupakan salah satu teknik untuk mengidentifikasi objek berdasarkan gambar atau video. Salah satu metode untuk membuat *object detection* adalah menggunakan *TensorFlow Object detection* (Aningtiyas dkk., 2020). Metode tersebut menyediakan model pra - terlatih yang dapat dimanfaatkan dalam pembuatan aplikasi deteksi objek, sehingga pada penelitian ini digunakan metode *object detection* berbasis *deep learning* pada aplikasi untuk mengidentifikasi penyakit pengganggu tanaman

yaitu penyakit bercak dan karat pada tanaman kopi robusta menggunakan parameter gambar daun tanaman kopi robusta yang ada di provinsi lampung.

BAHAN DAN METODE

Penelitian ini dilakukan di Kebun Percobaan Natar, Balai Pengkajian Teknologi Pertanian (BPTP) Lampung, Desa Negararatu, Kecamatan Natar, Kabupaten Lampung Selatan. Terdapat beberapa tahapan yang dilakukan dalam penelitian ini sebagaimana pada Gambar 1. Secara umum, tahapan penelitian terdiri dari akuisisi data atau menyusun data menjadi beberapa dataset yang sesuai dengan kebutuhan penelitian, anotasi data, pelatihan serta pengembangan sistem *object detection* dengan menggunakan model pra-terlatih SSD MobileNet V2, evaluasi model (menghitung mAP, *mean Average Precision*), dan implementasi model.



Gambar 1. Tahapan penelitian

Dataset Gambar Daun

Proses pengambilan gambar daun dilakukan dengan memotret daun atau kumpulan daun tanaman kopi Robusta. Gambar yang telah didapatkan diklasifikasikan menjadi 2 klasifikasi gambar yaitu daun normal dan daun sakit, pada gambar daun sakit terdiri dari gambar daun yang terkena penyakit bercak daun dan penyakit karat. Pemotretan daun kopi robusta menggunakan berbagai jenis kamera handphone *smartphone* dengan spesifikasi gambar minimal 24 MP serta kondisi waktu pengambilan yang dilakukan tidak tergantung oleh parameter waktu. Dataset berupa gambar yang diperoleh digunakan untuk proses pengenalan oleh model pra-terlatih SSD MobileNet V2.

Anotasi Data

Anotasi data atau labelling data adalah proses mengidentifikasi atau memberikan tanda berbentuk

box (*bounding box*) berbasis koordinat *ground-truth* pada objek yang terdapat. dalam suatu gambar. Tahap ini dilakukan untuk memberikan 2 label pada gambar daun kopi Robusta yaitu label daun normal dan daun sakit. Pelabelan pada gambar daun kopi robusta berupa koordinat area (x, y, lebar dan tinggi) berbentuk kotak yang menggambarkan lokasi piksel dari objek yang diberikan objek. Data set yang terdiri dari 2 klasifikasi diberikan label menggunakan aplikasi Labellmg (Heartexlabs) satu persatu dengan jumlah keseluruhan data berjumlah 464 gambar dengan komposisi 372 data training dengan rasio 1:1 untuk 2 jenis penyakit bercak dan karat. Data testing menggunakan 92 data dengan rasio 1:1 untuk penyakit karat dan bercak. Seluruh data gambar memiliki format jpg dan XML setelah dilakukan pelabelan.



Gambar 2. Anotasi data pada daun kopi Robusta menggunakan aplikasi LabelImg.

Pelatihan Model

Pelatihan model adalah proses untuk mendapatkan model yang tepat untuk mendeteksi daun kopi Robusta. Pelatihan model menggunakan metode *transfer learning* terhadap model pra-terlatih. *Transfer learning* merupakan istilah pada *machine learning* yang mengacu pada pemanfaatan pengetahuan dari suatu bidang ke bidang yang lain agar model pra-terlatih dapat mempelajari objek yang diberikan (Arifianto & Muhimmah, 2021).

Pada penelitian ini pelatihan data dilakukan dengan melakukan pelatihan kembali pada model pra-terlatih pada dataset yang telah dibuat. Pelatihan dilakukan dengan melatih seluruh Train Set dengan bantuan *Google Drive* sebagai tempat penyimpanan dataset dan *Google Colaboratory* sebagai *Virtual Machine* selama melakukan proses pelatihan data. Pelatihan data dilakukan dengan menginput file *tfrecord* yang akan digunakan. Seluruh data yang diperlukan akan tersimpan ke dalam file *repository Github*. Untuk memanggil file tersebut dilakukan pemanggilan bersamaan dengan konfigurasi *hyperparameter*. Pada konfigurasi *hyperparameter* ditentukan jumlah steps untuk pelatihan data dan pemanggilan model pra-terlatih. Selanjutnya, dilakukan input file *tfrecord* agar dapat dilakukan pelatihan. Proses pelatihan akan memanfaatkan fasilitas GPU yang tersedia pada *Google Colaboratory*. Hasil pelatihan akan dapat di-export untuk diterapkan pada aplikasi (Aningtiyas dkk., 2020).

Evaluasi Model

Evaluasi model dilakukan dengan menghitung *precision* dan *recall* berdasarkan kumpulan data beranotasi berbeda yang digunakan pada *object detection*. Metrik paling umum yang digunakan untuk mengukur keakuratan deteksi adalah *Average*

Precision AP (Padilla *et al.*, 2020). *Recall* didefinisikan sebagai proporsi objek yang terdeteksi dengan benar di antara semua objek yang seharusnya terdeteksi. *Precision* adalah proporsi antara kelas positif yang terdeteksi dengan benar di antara jumlah kelas positif yang terdeteksi (Godil *et al.*, 2014). Berikut adalah definisi dari istilah-istilah konotasi dasar:

- Benar positif (TP): Deteksi yang benar dari kotak pembatas *ground-truth*;
- Positif palsu (FP): Deteksi yang salah dari objek yang tidak ada atau deteksi objek yang ada salah tempat;
- Negatif palsu (FN): Kotak pembatas kebenaran dasar yang tidak terdeteksi

$$Pr = \frac{TP}{TP + FP}$$

$$Re = \frac{TP}{TP + FN}$$

Dimana :

Pr = *Precision* (%)

Re = *Recall* (%)


TP = *True Positif*

FN = *False Negative*

Nilai mAP (*Mean Average Precision*) merupakan *Average Precision* (AP) rata-rata untuk semua kelas objek yang berbeda. Nilai AP merupakan hubungan antara *Precision* (Pr) dan *Recall* (Re) dalam kurva yang direpresentasikan dalam bentuk nilai tunggal. Dalam praktiknya nilai AP yaitu *Precision* rata-rata pada semua nilai *Recall* yang berjarak sama pada nilai 0, 0.1, 0.2, sampai 1 (Mustafid, 2022). Untuk menentukan nilai TP (*True Positive*), FP (*False Positive*) dan FN (*False Negative*) dan juga menentukan kapan deteksi yang benar ataupun yang salah dibuat, maka diperlukan *Intersection over Union* (IoU). IoU digunakan untuk mengukur

overlap antara *bounding boxes*. Hal ini dilakukan untuk menentukan seberapa besar tumpang tindih antara *bounding box* objek terdeteksi dengan *bounding box* sebenarnya yang ditetapkan dalam dataset. Sebuah nilai *threshold* juga telah ditentukan

sebelumnya untuk menentukan apakah objek itu benar-benar terdeteksi, nilai *threshold* yang sering digunakan yaitu lebih dari 50% (Padilla *et al.*, 2020; He *et al.*, 2019).



Gambar 3. *Intersection over Union*

$$IoU = \frac{AO}{AU}$$

Dimana:

IoU = *Intersection over union* (%)

AO = *Area of overlap* (pixel²)

AU = *Area of union* (pixel²)


HASIL DAN PEMBAHASAN

Performance Training Model Pra-Terlatih MobileNet V2


Parameter untuk menentukan kinerja dari training model pra-terlatih ditentukan oleh beberapa nilai *loss* yang terdiri dari *classification loss*, *localization loss*, *regularization loss* dan total *loss*.

Nilai *loss* saat training didapatkan dari hasil program *tensorboard* pada *google colaboratory*. Pada penelitian ini dilakukan 13100 *Epoch* (Gambar 4).

Classification loss adalah nilai *loss* model untuk memprediksi klasifikasi objek yang sudah ditentukan menggunakan proses labelling atau anotasi data. Nilai *classification loss* yang rendah dapat diartikan model akan menjadi semakin optimum. Berdasarkan Gambar 4 didapatkan nilai *classification loss* pada penelitian ini adalah 0,0488 atau 4,88%. Pada Langkah awal *epoch* nilai *Classification loss* tinggi karena model baru mempelajari dataset gambar daun tanaman kopi tetapi untuk keseluruhan training didapatkan tren pada nilai *classification loss* mengalami penurunan.




Gambar 4. Nilai *classification loss* saat training



Gambar 5. Nilai *localization loss* model training

Nilai *localization loss* adalah nilai *loss* yang melambangkan kinerja sistem dalam menentukan lokasi dari suatu objek. Nilai *localization loss* yang semakin rendah menggambarkan model yang dihasilkan baik. Pada penelitian ini berdasarkan Gambar 5 didapatkan nilai rata-rata *localization loss* adalah 0,0189 atau 1,89%. Training model pra-


terlatih SSD MobileNet V2 selama 13100 *epoch* untuk nilai *localization loss* memiliki tren yang menurun karena model pra-terlatih sudah mulai mampu mengenali objek gambar yang diberikan dan mampu menghasilkan koordinat *bounding box* yang mendekati koordinat *bounding box* anotasi.



Gambar 6. Nilai *regularization loss* saat training

Regularisasi merupakan serangkaian teknik berbeda yang bertujuan menurunkan kompleksitas model *neural networks* selama pelatihan, sehingga mencegah *overfitting*. Seperangkat teknik yang dapat mencegah *overfitting* dalam *neural networks* akan berdampak pada meningkatnya akurasi model *Deep Learning* saat menghadapi data yang sama sekali baru dari permasalahan domain. Berdasarkan Gambar 6 didapatkan nilai optimum dari *regularization loss* adalah 0,0458 atau 4,58% dengan nilai rata-rata dari keseluruhan 13100 *epoch* yaitu 0,15 atau 15%. Pergerakan nilai *regularization loss* sangat fluktuatif

pada setiap langkah. Akan tetapi untuk keseluruhan langkahnya didapatkan kecenderungan yang terus menurun yang berarti kompleksitas dari model rendah sehingga model tidak terjadi *overfitting*. Nilai *regularization loss* menggambarkan kompleksitas dari model, semakin kecil nilainya maka model memiliki kemungkinan tidak terjadi *overfitting*. *Overfitting* merupakan kondisi model menjadi sangat kaku, model hanya berfokus pada data yang sudah ada sehingga tidak bisa melakukan prediksi dengan tepat dengan data baru yang serupa.



Gambar 7. Nilai total *loss* saat training

Nilai total *loss* menggambarkan proses training dari model berdasarkan 3 parameter yaitu, *classification loss*, *localization loss*, dan *regularization loss*. Pada penelitian ini nilai total *loss* dapat dilihat pada Gambar 7 dimana nilai total *loss* memiliki kecenderungan menurun dengan nilai rata-rata adalah 0,2181 atau 21,81% dalam 13100 *epoch*. Secara keseluruhan untuk kinerja model SSD MobileNet V2 baik sebagai pra-terlatih karena semua nilai *loss* memiliki kecenderungan yang turun.

Peformance Hasil Uji Sistem Smart Detection

Berdasarkan hasil evaluasi model yang telah dilakukan diperoleh nilai *average precision* (AP) untuk IoU pada rentang 0,50 – 0,95 adalah 87,3%, untuk nilai *average recall* (AR) pada IoU pada rentang 0,50 – 0,95 adalah 89,6%. Nilai AP dan AR sangat tergantung terhadap data gambar daun kopi Robusta

terdapat beberapa parameter kualitas gambar yang dapat memperngaruhi nilai AP dan AR yaitu, cahaya, posisi pengambilan gambar, jumlah gambar dan kejelasan dari gambar.

Pada penelitian ini didapatkan hasil implementasi dari 12 kali percobaan deteksi daun kopi Robusta dapat dilihat pada Tabel 1 dengan nilai rata-rata akurasi sebesar 96%. Tingginya hasil nilai akurasi percobaan deteksi daun kopi menggambarkan bahwa SSD MobileNet V2 sebagai model pra-latih mampu memprediksi dengan tepat bahwa daun kopi tersebut terkena penyakit (karat dan bercak) atau memprediksi daun kopi normal (tidak terserang penyakit). Hasil ini sejalan dengan penelitian (Aningtiyas dkk., 2020) bahwa SSD MobileNet V2 sangat baik untuk mendeteksi gambar yang berfokus pada satu objek. Hasil ini sesuai dengan nilai *total loss* yang rendah pada saat training model.

Tabel 1. Hasil pengujian/implementasi sistem *smart detection* pada daun kopi Robusta

No	Hasil <i>Smart</i> Identifikasi	Keterangan	Akurasi
1		Benar Anotasi (Daun Sakit)	97%
2		Benar Anotasi (Daun Sakit)	98%
3		Benar Anotasi (Daun Sakit)	97%

Tabel 1. Hasil pengujian/implementasi sistem *smart detection* pada daun kopi robusta (Lanjutan)

No	Hasil <i>Smart</i> Identifikasi	Keterangan	Akurasi
4		Benar Anotasi (Daun Sakit)	91%
5		Benar Anotasi (Daun Sakit)	95%
6		Benar Anotasi (Daun Sakit)	97%
7		Benar Anotasi (Daun Sakit)	97%
8		Benar Anotasi (Daun Sakit)	95%
9		Benar Anotasi (Daun Sakit)	96%
10		Benar Anotasi (Daun Sakit)	94%
11		Benar Anotasi (Daun Sehat)	97%
12		Benar Anotasi (Daun Sehat)	98%
Total Akurasi			96%

SIMPULAN

Sistem *smart detection* pada penelitian ini memiliki nilai *average precision* (AP) untuk IoU pada rentang 0,50 – 0,95 adalah 87,3. Untuk nilai *average recall* (AR) pada IoU pada rentang 0,50 – 0,95 adalah 89,6 % serta mendapatkan nilai akurasi sebesar 96% setelah dilakukan testing pada sample gambar daun kopi Robusta. Nilai total *loss* memiliki kecenderungan yang menurun pada setiap *epoch* dengan nilai rata-rata adalah 21,81% sehingga penggunaan model pra-terlatih SSD mobile net V2 sudah tepat untuk mengidentifikasi penyakit berdasarkan gambar daun pada tanaman kopi Robusta.

UCAPAN TERIMA KASIH

Ucapan terima kasih kepada Lembaga Penelitian dan Pengabdian Kepada Masyarakat (LPPM) Institut Teknologi Sumatera yang telah mendanai penelitian ini serta Balai Pengkajian Teknologi Pertanian Lampung dan Badan Riset dan Inovasi Nasional (BRIN) sebagai mitra penelitian.

DAFTAR PUSTAKA

- Aningtiyas, PR, A Sumin, dan S Wirawan. 2020. Pembuatan aplikasi deteksi objek menggunakan TensorFlow *Object Detection* API dengan memanfaatkan SSD MobileNet V2 sebagai model pra-terlatih. Jurnal Ilmiah Komputasi. 19: 421–430
- Arifianto, J, dan I Muhimmah. 2021. Aplikasi web pendeteksi jerawat pada wajah menggunakan algoritma deep learning dengan TensorFlow. Automata. 2: 34–42
- Badan Pusat Statistik. 2020. Statistik Kopi Indonesia. Pages 9–70 in dan P Direktorat Statistik Tanaman Pangan, Hortikultura (ed.) Badan Pusat Statistik. Badan Pusat Statistik, Jakarta
- Godil, A, R Bostelman, W Shackleford, T Hong, and M Shneier. 2014. Performance Metrics for Evaluating Object and Human Detection and Tracking Systems. National Institute of Standards and Technology: 1–16
- Gunawan, MD, A Franz, dan RR Manullang. 2020. Sistem pakar penyakit tanaman kopi (*Coffea* sp.) metode forward chaining berbasis web. Buletin Poltanesa. 21: 26–31
- Harni, R, Samsudin, W Amaria, G Indriati, F Soesanthy, Khaerati, E Taufiq, AM Hasibuan, dan AD Haspari. 2015. Teknologi Pengendalian Hama dan Penyakit Tanaman Kopi. Pages 1–48 Badan Penelitian Dan Pengembangan Pertanian
- He, Y, H Zeng, Y Fan, S Ji, and J Wu. 2019. Application of deep learning in integrated pest management: A real-time system for detection and diagnosis of oilseed rape pests. Mobile Information Systems. 2019: 1–14
- Muliani, S, dan Nildayanti, 2015. Inventarisasi hama dan penyakit pada pertanaman kopi organik. Jurnal Agroplanta. 7: 14–19
- Mustafid, MA, 2022. Rancang Bangun dan Uji Kinerja Robot Autonomous Penyemprot Presisi pada Budidaya Kubis. IPB University
- Padilla, R, SL Netto, and EAB Da Silva. 2020. A survey on performance metrics for object-detection algorithms. International Conference on Systems, Signals, and Image Processing, 2020-July: 237–242
- Putri, AYP, dan A Sodik. 2019. Identifikasi penyakit tanaman kopi Arabika dengan metode K-Nearest Neighbor (K-NN). Pages 759–764 Prosiding Seminar Nasional Sains dan Teknologi Terapan.
- Lumbanraja, RF, S Rosdiana, H Sudarsono, dan A Junaidi. 2020. Sistem Pakar diagnosis hama dan penyakit tanaman kopi menggunakan metode Breadth First Search (Bfs) berbasis web. Explore: Jurnal Sistem Informasi dan Telematika. 11: 1–9.