

Implementasi Metode Faster R-CNN Untuk Deteksi Penyakit Tanaman Mentimun Melalui Citra Daun

^{1*}Rizqi Maulana Mahendra, ²Made Ayu Dusea Widyadara, ³Daniel Swanjaya

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

E-mail: ¹rizqimaulanamahendra10mm@gmail.com, ²madedara@unpkediri.ac.id, ³daniel@unpkediri.ac.id

Penulis Korespondens : Rizqi Maulana Mahendra

Abstrak— Mentimun (*Cucumis Sativus*) merupakan salah satu tanaman hortikultura penting di Indonesia dengan nilai ekonomi tinggi, namun rentan terhadap serangan hama dan penyakit yang dapat menurunkan kualitas dan kuantitas hasil panen. Penelitian ini bertujuan untuk menerapkan metode Faster R-CNN dan arsitektur ResNet50 dalam mendeteksi penyakit pada tanaman mentimun. Alur proses penelitian ini terdiri dari pengumpulan dataset, preprocessing data, pelatihan, dan evaluasi. Dataset yang digunakan berjumlah 799 citra daun mentimun, yang terdiri dari lima kelas: *Fresh Leaf*, *Anthracnose*, *Bacterial Wilt*, *Downy Mildew*, dan *Gummy Stem Blight*. Pelatihan model menggunakan K-Fold Cross Validation sebanyak 5 fold (K=5) dengan optimizer SGD, batch size 2, learning rate 0,007, dan 20 epoch. Hasil menunjukkan menghasilkan rata-rata akurasi sebesar 0.86%, precision 0.87%, recall 0.88%, dan F1-score 0.87%. Hal ini membuktikan bahwa model mampu melakukan generalisasi dengan baik terhadap variasi data.

Kata Kunci—Deteksi, Faster R-CNN, Mentimun, Resnet-50

Abstract— *Cucumber* (*Cucumis sativus*) is one of the important horticultural crops in Indonesia with high economic value but is vulnerable to pest and disease attacks that can reduce both the quality and quantity of yields. This study aims to apply the Faster R-CNN method with the ResNet-50 architecture to detect diseases in cucumber plants. The research workflow consists of dataset collection, data preprocessing, model training, and evaluation. The dataset used contains 799 cucumber leaf images, categorized into five classes: *Fresh Leaf*, *Anthracnose*, *Bacterial Wilt*, *Downy Mildew*, and *Gummy Stem Blight*. The model was trained using 5-Fold Cross Validation (K=5) with the SGD optimizer, a batch size of 2, a learning rate of 0.007, and 20 epochs. The results show that the model achieved an average accuracy of 0.86%, precision of 0.87%, recall of 0.88%, and F1-score of 0.87%. This indicates that the model is capable of generalizing well across varying data.

Keywords— *Detection, Faster R-CNN, Cucumber, ResNet-50.*

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



I. PENDAHULUAN

Mentimun (*Cucumis Sativus*) merupakan salah satu tanaman hortikultura penting di Indonesia dengan nilai ekonomi tinggi. Mentimun tidak hanya dimanfaatkan sebagai bahan pangan, tetapi juga memiliki berbagai khasiat dalam bidang kesehatan sebagai terapi alami untuk beberapa jenis penyakit serta digunakan dalam industri kosmetik. Kebutuhan terhadap buah mentimun cenderung meningkat seiring dengan pertumbuhan jumlah penduduk, perbaikan kualitas hidup, peningkatan tingkat pendidikan, serta kesadaran masyarakat akan pentingnya nilai gizi [1].


Serangan hama dan penyakit menjadi salah satu hambatan utama dalam budidaya mentimun, yang dapat berdampak pada penurunan kualitas dan kuantitas hasil panen. Biasanya, identifikasi penyakit pada tanaman mentimun dilakukan melalui pengamatan visual oleh individu. Namun, sejumlah penyakit menunjukkan gejala yang sulit dikenali, membuat identifikasi menjadi sulit tanpa keahlian khusus [2]. Kemajuan dalam bidang kecerdasan buatan dan teknik pemrosesan citra memberikan peluang untuk memperluas penelitian di bidang pertanian. Belakangan ini, Deep Learning menunjukkan keunggulannya dalam berbagai aspek sektor pertanian, termasuk diagnosis penyakit tanaman, prediksi pertumbuhan tanaman, pengenalan serangan, dan lainnya [3]. Deep learning adalah cabang dari machine learning yang menggunakan jaringan saraf tiruan dengan banyak lapisan (*deep neural networks*) untuk memproses data secara bertahap dan menyelesaikan berbagai tugas kompleks [4].

Ada beberapa penelitian telah dilakukan menggunakan deep learning untuk klasifikasi penyakit pada tanaman. Penelitian yang dilakukan oleh [5] menggunakan metode Convolutional Neural Network (CNN) untuk klasifikasi penyakit tanaman jagung memperoleh akurasi sebesar 97% training, 100% validation, dan 94% data testing. Lalu penelitian yang dilakukan oleh [6] untuk klasifikasi penyakit daun bawang menggunakan algoritma CNN Xception memperoleh akurasi sebesar 100% training, 95% validasi, dan 100% pada data uji. Penelitian lain yang dilakukan [7] menggunakan algoritma CNN untuk klasifikasi penyakit daun sawi hijau memperoleh akurasi sebesar 99%.

Pada penelitian ini, peneliti akan menggunakan metode Faster R-CNN untuk deteksi penyakit tanaman mentimun berdasarkan citra daun. Faster R-CNN mengintegrasikan RPN dan Fast R-CNN dalam satu jaringan terpadu yang menggunakan lapisan konvolusional bersama, sehingga mempercepat proses komputasi tanpa mengurangi tingkat akurasi [8]. Penelitian ini diharapkan dapat memberikan kontribusi positif dalam mendorong peningkatan hasil pertanian melalui deteksi dini terhadap penyakit tanaman.

II. METODE

Penelitian ini dilakukan dengan beberapa tahapan seperti pengumpulan dataset, preprocessing, Pelatihan model dan Evaluasi. Tahapan-tahapan yang dilakukan dalam penelitian ini dapat dilihat pada gambar 1.



Gambar 1. Tahapan Penelitian

A. Pengumpulan Data

Dataset yang digunakan dalam penelitian ini berasal dari dataset publik yang tersedia di platform Roboflow, yaitu Cucumber Leaf Dataset yang dibuat oleh Agridetec. Dataset ini berisi gambar daun mentimun yang sudah diberi label, terdiri dari total 799 gambar yang terbagi ke dalam 5 kelas, yaitu 160 kelas *Fresh Leaf*, 160 kelas *Downy Mildew*, 160 kelas *Antracnose*, 159 kelas *Bacterial Wilt*, dan 160 kelas *Gummy Stem Blight*.


Tabel 1. Dataset

No	Gambar	Jenis Penyakit
1		Anthracnose
2		Bacterial Wilt
3		Downy Mildew
4		Gummy Stem Blight
5		Fresh Leaf

B. Preprocessing Data

Preprocessing merupakan tahapan awal sebelum proses pelatihan atau pengujian model, yang bertujuan untuk meningkatkan kualitas citra, mengurangi gangguan (noise), serta menyesuaikan karakteristik citra agar sesuai dengan kebutuhan analisis atau pemrosesan lebih lanjut [6]. Dalam penelitian ini, preprocessing melibatkan proses resizing,


semua gambar diubah menjadi ukuran 600x600 pixel, kemudian melakukan augmentasi data dengan cara memberikan rotasi, flip, color jitter, random perspective . Tahap selanjutnya anotasi data. Anotasi merupakan proses menandai objek tertentu dengan kotak pembatas (bounding box) berdasarkan koordinat ground truth yang telah ditentukan [9]. Untuk anotasi data memakai website roboflow.com. Proses anotasi dapat dilihat seperti pada gambar 2 .



Gambar 2. Anotasi Data

C. Pelatihan Model


Model yang digunakan dalam penelitian ini adalah Faster R-CNN dengan arsitektur ResNet-50 yang dilatih pada dataset tanaman mentimun. Faster R-CNN merupakan salah satu metode *deep learning* yang digunakan untuk mendeteksi dan mengenali objek pada sebuah citra. Proses pengenalan objek dilakukan dengan menelusuri fitur-fitur yang dimiliki objek melalui sejumlah layer, seperti yang terdapat pada jaringan saraf tiruan (*neural network*), menggunakan proses konvolusi yang dikenal sebagai *Convolutional Neural Network* (CNN). Setelah fitur-fitur objek diekstraksi melalui lapisan konvolusi, Faster R-CNN memanfaatkan *Region Proposal Network* (RPN) untuk menentukan area-area potensial (*region of interest*) yang kemungkinan besar mengandung objek. Area-area ini kemudian digunakan oleh sistem untuk mengklasifikasikan dan menentukan kelas dari objek yang terdeteksi pada citra tersebut yang dapat di ilustrasikan seperti pada gambar 3 [10].



Gambar 3. Arsitektur Faster R-CNN [8]

ResNet-50 merupakan varian dari arsitektur ResNet yang memiliki 50 lapisan. Arsitektur ini terbagi menjadi lima tahap utama, di mana setiap tahap terdiri dari blok

konvolusi dan blok identitas. Pada setiap blok konvolusi terdapat dua lapis konvolusi, sedangkan setiap blok identitas terdiri dari tiga lapis konvolusi. ResNet-50 mengandung lebih dari 23 juta parameter yang dapat dilatih [11]. Secara keseluruhan, ResNet-50 terdiri dari 5 tahap konvolusi yang diakhiri dengan *average pooling* sebagai lapisan prediksi yang dapat diilustrasikan seperti pada gambar 4.



Gambar 4. Arsitektur ResNet-50 [11]

Proses pelatihan dilakukan menggunakan *K-Fold Cross Validation*. *K-Fold Cross Validation* merupakan metode untuk membagi data menjadi beberapa bagian (fold) yang sama besar secara acak. Setiap fold secara bergantian digunakan sebagai data uji, sedangkan fold lainnya menjadi data latih. Proses ini diulang sebanyak K kali [12]. Pada Proses pelatihan dilakukan menggunakan *K-Fold Cross Validation* sebanyak 5 fold (K=5). Selama pelatihan, digunakan *optimizer Stochastic Gradient Descent* (SGD) dengan parameter pelatihan berupa *batch size* 2, *learning rate* 0,007, dan jumlah *epoch* sebanyak 20. Kemudian model evaluasi menggunakan *confusion metrix* untuk memantau kinerja model.

D. Evaluasi Model

Pada tahap ini, performa dari model Faster R-CNN dengan arsitektur ResNet-50 yang digunakan dihitung. Evaluasi performa dilakukan dengan menggunakan confusion matrix untuk menghitung akurasi, presisi, recall, dan F1-score.

$$Precision = \frac{TP+TN}{TP+FP+TN+FN} \quad (1)$$

$$Recall = \frac{TP}{TP+FN} \quad (2)$$


$$F1 \text{ Score} = \frac{recall \times precision}{recall + precision} \quad (3)$$

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

True Positive (TP) adalah data positif yang terklasifikasi dengan benar, sedangkan False Positive (FP) adalah data negatif yang salah terklasifikasi sebagai positif. False Negative (FN) merupakan data positif yang salah diklasifikasikan sebagai negatif, dan True Negative (TN) adalah data negatif yang diklasifikasikan dengan tepat [13].


III. HASIL DAN PEMBAHASAN

Pada bagian hasil dan pembahasan, disajikan gambaran proses dan hasil pelatihan model menggunakan metode Faster R-CNN. Proses pelatihan dilakukan menggunakan *K-Fold Cross Validation* sebanyak 5 fold ($K=5$). Selama pelatihan, digunakan *optimizer Stochastic Gradient Descent* (SGD) dengan parameter pelatihan berupa *batch size 2*, *learning rate 0,007*, dan jumlah *epoch* sebanyak 20.



Gambar 5. Gambaran Proses

Pada gambar 5 menjelaskan tentang gambaran proses pelatihan model menggunakan metode Faster R-CNN, Proses dimulai dengan memuat dataset, dilanjutkan dengan preprocessing dan transformasi data. Data kemudian dibagi menggunakan K-Fold Cross Validation. Model, optimizer, dan scheduler diinisialisasi. selanjutnya dilakukan proses training dan validasi pada setiap fold. Setelah semua fold selesai, model dievaluasi menggunakan confusion matrix. Kemudian proses diakhiri.



Gambar 6. Grafik Pelatihan

Gambar 6 menunjukkan visualisasi grafik pelatihan model Faster R-CNN dengan arsitektur ResNet-50 yang dievaluasi selama 20 epoch. Grafik *Train Accuracy* dan *Validation Accuracy* memperlihatkan tren peningkatan yang konsisten pada seluruh fold, dengan akurasi validasi akhir mencapai lebih dari 80% pada setiap fold, menandakan model mampu melakukan generalisasi dengan baik terhadap data yang belum dilatih. Sementara itu, grafik *Train Loss* dan *Validation Loss* menunjukkan penurunan yang stabil pada nilai loss di setiap fold, yang mengindikasikan proses pelatihan berlangsung konvergen tanpa overfitting yang signifikan. Variasi antar fold yang terlihat pada awal pelatihan mengecil seiring bertambahnya epoch, yang mencerminkan kestabilan model dalam proses pembelajaran lintas subset data yang berbeda.

Tabel 2. Evaluasi

FOLD	Accuracy	Precision	Recall	F1-Score
1	0.85%	0.86%	0.88%	0.87%
2	0.85%	0.89%	0.87%	0.87%
3	0.89%	0.92%	0.89%	0.90%
4	0.85%	0.84 %	0.88%	0.86%
5	0.85%	0.86%	0.86%	0.86%
AVG	0.86%	0.87%	0.88%	0.87%

Tabel 2 menunjukkan model dievaluasi menggunakan confusion matrix untuk menghitung akurasi, presisi, recall, dan F1-score pada setiap fold dalam 5-fold cross validation. Hasil evaluasi menunjukkan performa model yang stabil dengan rata-rata akurasi, presisi, recall, dan F1-score masing-masing sebesar 0.86%, 0.87%, 0.88%, dan 0.87%. Fold ke-3 menunjukkan kinerja terbaik dengan akurasi tertinggi sebesar 0.88%, sedangkan fold ke-1,2,4, dan 5 menunjukkan akurasi yang sama, yaitu sebesar 0.85%.

IV. KESIMPULAN

Penelitian ini menunjukkan bahwa model Faster R-CNN dengan arsitektur ResNet-50 mampu mendeteksi penyakit tanaman mentimun dengan performa yang baik dan konsisten. Hasil evaluasi menggunakan K-Fold Cross Validation sebanyak 5 fold (K=5) menghasilkan rata-rata akurasi sebesar 0.86%, precision 0.87%, recall 0.88%, dan F1-score 0.87%. Hal ini membuktikan bahwa model mampu melakukan generalisasi dengan baik terhadap variasi data.

DAFTAR PUSTAKA

- [1] Ratna Indah Juwita Harahap, Sumi Khairani, and Rismayanti, "Implementasi Metode K-Nearest Neighbor Untuk Klasifikasi Penyakit Tanaman Mentimun Pada Citra Daun," *J. Ilmu Komput. dan Sist. Inf.*, vol. 3, no. 2, pp. 135–145, 2024, doi: 10.70340/jirsi.v3i2.123.
- [2] F. A. Junior and M. R. N. Majiid, "Cucumber Disease Classification with Ensemble Learning Method for Complex Datasets," *J. Tek. Inform.*, vol. 16, no. 2, pp. 161–169, 2023, doi: 10.15408/jti.v16i2.34618.
- [3] M. Arifin, A. Yuniarti, and N. Suciati, "Cucumber Disease Image Classification with A Model Combining LBP and VGG-16 Features," *Int. J. Robot. Control Syst.*, vol. 4, no. 3, pp. 1429–1445, 2024, doi: 10.31763/ijrcs.v4i3.1529.
- [4] A. C. Milano, "Klasifikasi Penyakit Daun Padi Menggunakan Model Deep Learning

- Efficientnet-B6,” *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 1, 2024, doi: 10.23960/jitet.v12i1.3855.
- [5] D. Iswantoro and D. Handayani UN, “Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode Convolutional Neural Network (CNN),” *J. Ilm. Univ. Batanghari Jambi*, vol. 22, no. 2, p. 900, 2022, doi: 10.33087/jiubj.v22i2.2065.
- [6] M. Farij Amrulloh *et al.*, “Klasifikasi Penyakit Daun Bawang Menggunakan Algoritma CNN Xception,” *Pros. SEMNAS INOTEK (Seminar Nas. Inov. Teknol.*, vol. 8, pp. 617-623., 2024, doi: <https://doi.org/10.29407/inotek.v8i1.5011>.
- [7] E. D. Ratnasari, D. A. Rudira, and A. Surya Buana, “Klasifikasi Penyakit Daun Sawi Hijau Dengan Metode Cnn,” *Pros. Semin. Nas. Teknol. Dan Sains*, vol. 3, pp. 338–393, 2024, doi: <https://doi.org/10.29407/8gmc9b37>.
- [8] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 39, no. 6, pp. 1137–1149, 2017, doi: 10.1109/TPAMI.2016.2577031.
- [9] H. Harmiansyah, E. T. Ovia, R. Alpaizon, D. P. Khalifah, and P. Dwirota, “Sistem Deteksi Hama dan Penyakit Tanaman Mangga (*Mangifera indica* L.) Berbasis Deep Learning Menggunakan Model Pra Latih YOLOv5,” *Agrikultura*, vol. 35, no. 1, p. 151, 2024, doi: 10.24198/agrikultura.v35i1.53834.
- [10] Y. Rizki, R. Medikawati Taufiq, H. Mukhtar, and D. Putri, “Klasifikasi Pola Kain Tenun Melayu Menggunakan Faster R-CNN,” *IT J. Res. Dev.*, vol. 5, no. 2, pp. 215–225, 2021, doi: 10.25299/itjrd.2021.vol5(2).5831.
- [11] T. Berliani, E. Rahardja, and L. Septiana, “Perbandingan Kemampuan Klasifikasi Citra X-ray Paru-paru menggunakan Transfer Learning ResNet-50 dan VGG-16,” *J. Med. Heal.*, vol. 5, no. 2, pp. 123–135, 2023, doi: 10.28932/jmh.v5i2.6116.
- [12] P. I. Nainggolan, D. S. Prasvita, and D. S. Bukit, “Klasifikasi Informasi Kesehatan Pada Data Media Sosial Menggunakan Support Vector Machine dan K-Fold Cross Validation,” *Malikussaleh J. Mech. Sci. Technol.*, vol. 5, no. 2, p. 34, 2021, doi: 10.29103/mjmst.v5i2.6317.
- [13] D. Wahyudi Rustanto, F. Liantoni, and N. Pradana Taufik Prakisy, “Identifikasi Penyakit Daun pada Tanaman Padi Menggunakan Ekstraksi Fitur Gray Level Co-occurrence Matrix (GLCM) dan Metode K-Nearest Neighbour (KNN),” *J. Sist. dan Teknol. Inf.*, vol. 12, no. 1, pp. 100–106, 2024, doi: 10.26418/justin.v12i1.69752.