

Performa Model Faster R-Cnn Untuk Klasifikasi Penyakit Daun Jagung

Yuaini Pranajelita¹, Yisti Vita Via.², Hendra Maulana³

^{1,2,3}Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional “Veteran” Jawa Timur

E-mail: ¹21081010204@student.upnjatim.ac.id , ²yistivia.if@upnjatim.ac.id

³hendra.maulana.if@upnjatim.ac.id

Abstrak

Klasifikasi citra merupakan salah satu tantangan utama dalam bidang pengolahan citra digital dan computer vision. Penelitian ini bertujuan untuk membangun sistem klasifikasi citra menggunakan metode deteksi objek Faster R-CNN. Model Faster R-CNN digunakan untuk mendeteksi objek dalam gambar sekaligus di manfaatkan untuk mengklasifikasikan fitur yang telah di ekstraksi dari gambar tersebut. Dataset yang digunakan bersumber dari Kaggle dan data yang diambil secara langsung oleh peneliti. Data yang didapatkan diolah melalui beberapa tahapan, termasuk transformasi data, pembagian data latih / validasi / uji, serta evaluasi performa model berdasarkan metrik seperti akurasi, Presisi, recall, dan F1-Score. Hasil pengujian menunjukkan bahwa metode Faster R-CNN mampu menghasilkan performa klasifikasi yang sangat tinggi yakni dengan akurasi mencapai 98,98% pada rasio data 60:20:20. Selain itu, model juga menunjukkan stabilitas performa pada rasio data lainnya. Penelitian ini membuktikan bahwa metode deep learning dapat menghasilkan performa yang bagus dalam proses klasifikasi. Penelitian ini diharapkan dapat menjadi referensi untuk pengembangan sistem klasifikasi citra lainnya, khususnya yang memerlukan deteksi objek dan klasifikasi yang akurat.

Kata kunci : Klasifikasi citra, Faster R-CNN, ekstraksi fitur, deteksi objek.

Abstract

Image classification is one of the main challenges in the field of digital image processing and computer vision. This study aims to develop an image classification system using the Faster R-CNN object detection method. The Faster R-CNN model is utilized to detect objects in images while also classifying the extracted features from those images. The dataset used in this study was sourced from Kaggle and data taken directly by researcher. The data underwent several preprocessing stages, including data transformation, splitting into training / validation / testing sets, and model performance evaluation based on metrics such as accuracy, precision, recall, and F1-Score. The experimental results demonstrate that the Faster R-CNN method can achieve high classification performance, with accuracy reaching up to 98,98% at a data ratio of 60:20:20. In addition, the model also shows performance stability at other data ratios. This study confirms that deep learning methods can deliver excellent results in image classification tasks. This research is expected to be a reference for the development of other image classification systems, especially those that require accurate object detection and classification.

Keywords : image classification, Faster R-CNN feature extraction, object detection.

1. PENDAHULUAN

Jagung merupakan salah satu sumber pangan utama di Indonesia setelah padi, serta digunakan untuk pakan ternak dan bahan industri. Potensi peningkatan produksi jagung masih besar, namun tantangan seperti penyakit tanaman menjadi hambatan utama

(Sucipto et al., 2019). Berdasarkan data BPS, luas panen jagung turun 10,03% dari 2,76 juta hektare (2022) menjadi 2,49 juta hektare (2023), disertai penurunan produksi sebesar 12,50%. Jawa Tengah dan Jawa Timur sebagai sentra produksi turut terdampak, salah satunya akibat penyakit daun seperti Northern Corn Leaf Blight (NCLB), Gray Leaf Spot (GLS), blight, dan common rust (Li et al., 2021)(Yu et al., 2021).

Deteksi penyakit secara akurat membutuhkan keahlian khusus, sementara gejala antar penyakit sering kali mirip dan dipengaruhi perubahan iklim (Khan et al., 2023). Oleh karena itu, sistem berbasis teknologi pengolahan citra dan machine learning menjadi solusi alternatif. Pendekatan deep learning, khususnya Region-based Convolutional Neural Network (R-CNN), menawarkan segmentasi dan klasifikasi penyakit yang lebih baik dibandingkan metode tradisional berbasis aturan atau thresholding sederhana.

Penelitian terdahulu seperti oleh Helong Yu et al. (2021) menggunakan K-Means clustering dan CNN berbasis VGG-19 dengan hasil akurasi mencapai 93% (Yu et al., 2021), namun terbatas oleh ukuran dataset. W. Setiawan et al. (2022) menerapkan CNN dengan berbagai teknik preprocessing, tetapi juga menghadapi kendala pada ukuran dataset dan keterbatasan jenis penyakit yang diklasifikasikan (Setiawan et al., 2022). Sementara itu, penelitian lain oleh Canhui Xu et al. (2021) mengembangkan Mask R-CNN untuk segmentasi objek dokumen, menunjukkan efektivitas teknik segmentasi lanjutan (Xu et al., 2021). Pendekatan hibrida Faster R-CNN dan SVM juga telah digunakan untuk deteksi tumor otak dengan akurasi mencapai 98,81% (Mohammad Omid Khairandish et al., 2020).

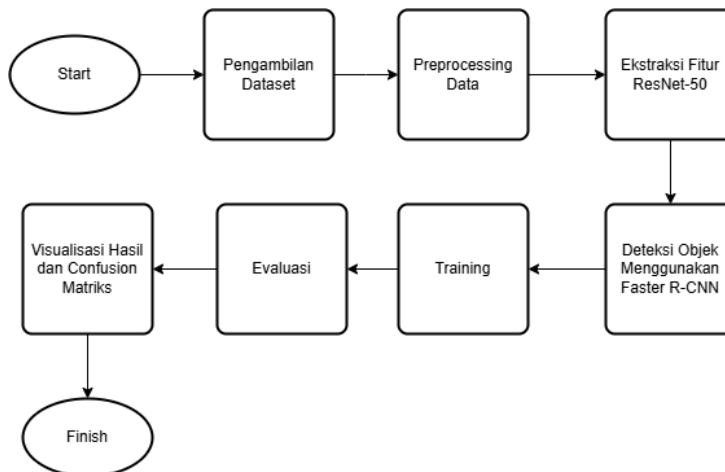
Namun, penelitian-penelitian sebelumnya umumnya belum fokus pada segmentasi bentuk daun jagung secara spesifik. Oleh karena itu, penelitian ini mengusulkan optimasi segmentasi menggunakan R-CNN sebelum klasifikasi penyakit daun dengan metode SVM. Hipotesis penelitian ini adalah bahwa optimasi segmentasi bentuk daun dan klasifikasi menggunakan SVM dapat meningkatkan akurasi klasifikasi penyakit daun jagung dibandingkan pendekatan klasifikasi langsung berbasis citra.

2. METODE PENELITIAN

Pada penelitian ini, peneliti menggunakan metode Faster R-CNN yang merupakan versi lanjutan dari Fast R-CNN yang hadir sebagai generasi terbaru dalam metode deteksi objek, dan telah menunjukkan performa yang unggul dalam tugas deteksi objek (Charli et al., 2020). Faster R-CNN dikembangkan sebagai penerus dari metode R-CNN dan Fast R-CNN, yang sebelumnya mengandalkan *selective search* untuk menghasilkan input berupa *Region of Interest (RoI)* yang kemudian diproses oleh CNN. Meskipun *selective search* mampu menentukan RoI, metode ini menimbulkan bottleneck dalam komputasi karena prosesnya lambat. Untuk mengatasi hal tersebut, Faster R-CNN menggantikan *selective search* dengan *Region Proposal Network (RPN)* yang lebih efisien dalam menghasilkan proposal wilayah (Rahman & Bambang, 2021). Faster R-CNN memanfaatkan *Region Proposal Network (RPN)* untuk menghasilkan *bounding box*. RPN menerima citra dengan berbagai ukuran sebagai input dan menghasilkan sejumlah *rectangular object proposals* yang masing – masing disertai skor kemungkinan objek. Proses ini diimplementasikan menggunakan jaringan *fully convolutional*. RPN membedakan area latar belakang dan objek melalui fungsi aktivasi *softmax*, dan proposal yang lebih akurat diperoleh dengan menerapkan *bounding box regression* terhadap *anchors* yang dihasilkan (Anggara et al., 2021). Penelitian ini dilakukan untuk mengetahui performa dari metode Faster R-CNN dalam pendeteksian dan klasifikasi penyakit daun jagung. Dalam penelitian ini, peneliti melakukan

beberapa proses sebelum melakukan proses implementasi metode yakni dapat dilihat pada **Gambar 2.1**.

Klasifikasi merupakan suatu proses untuk menemukan sekumpulan model maupun fungsi yang menjelaskan dan membedakan data kedalam kelas – kelas tertentu, yang bertujuan untuk Menggunakan model itu dalam menentukan kelas dari suatu objek yang belum diketahui kelasnya. Terdapat dua proses dalam klasifikasi, yakni proses learning / training dengan melakukan pembangunan model Menggunakan data training. Proses testing dilakukan terhadap data testing Menggunakan model dari hasil data training (Raysyah et al., 2021).



Gambar 1 Alur Metodologi Penelitian

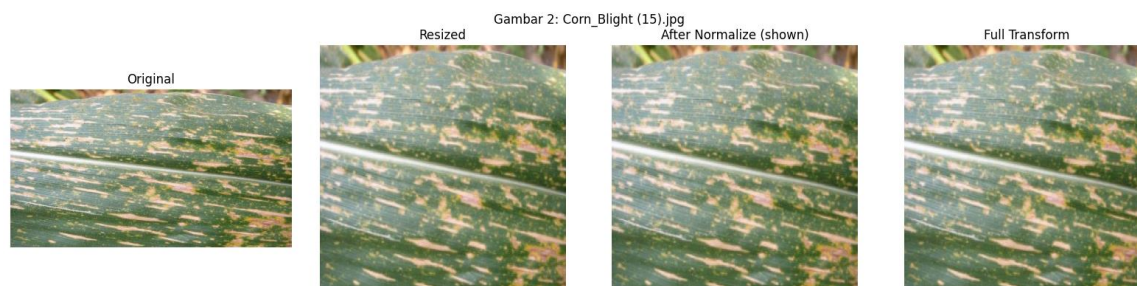
2.1. Pengambilan Dataset

Pada proses pengambilan dataset, peneliti memasukkan ke dalam google drive untuk di proses lebih lanjut. Dataset yang digunakan terdapat tiga kelas dari penyakit daun jagung yakni diantaranya terdapat hawar daun, bercak daun, dan daun sehat.

2.2. Preprocessing Data

Setelah dataset dapat diakses, langkah selanjutnya adalah melakukan preprocessing data yang merupakan tahapan peneliti menerapkan dari proses pengolahan citra. Terdapat banyak macam dari pengolahan citra seperti thresholding, analisis tekstur, dan pengenalan pola yang sering kali digunakan pada proses deteksi penyakit daun (Singh & Misra, 2017). Namun, metode tersebut seringkali tidak efisien untuk berbagai kondisi lapangan yang ada. Menurut studi yang dilakukan oleh Zhang et al. (2018) mengungkapkan bahwa penerapan metode segmentasi pada tahap awal pengolahan citra dapat meningkatkan akurasi klasifikasi, khususnya pada citra tanaman dengan latar belakang yang kompleks (Li et al., 2021). Klasifikasi sendiri merupakan proses untuk membangun model atau fungsi yang mampu menjelaskan dan membedakan data ke dalam kategori atau kelas tertentu, dengan tujuan untuk mengidentifikasi kelas dari data yang belum diketahui. Proses klasifikasi terdiri dari dua tahap, yaitu learning dan training, dimana model dibentuk berdasarkan data latih, serta testing, yaitu pengujian model terhadap data uji menggunakan model yang telah dibangun sebelumnya (Raysyah et al., 2021). Pada proses preprocessing penelitian ini adalah dengan cara mengubah menjadi ukuran 224 x 224 sebagai ukuran standar dalam ekstraksi fitur menggunakan ResNet-50. Setelah itu dilakukan normalisasi yang merupakan proses penyesuaian nilai intensitas piksel dalam citra ke dalam rentang tertentu, biasanya antara 0 hingga 1. Tujuannya

adalah untuk mengurangi variasi intensitas yang disebabkan oleh pencahayaan atau kontras, sehingga meningkatkan konsistensi data untuk analisis lebih lanjut. Menurut penelitian oleh Latumakulita (2013), normalisasi membantu dalam standarisasi citra sebelum dilakukan ekstraksi fitur atau Klasifikasi (Fluorida Fibrianda & Bhawiyuga, 2018). Hasil preprocessing yang dilakukan dapat dilihat pada **Gambar 2** yang merupakan dalam hasil tersebut terlihat perbedaan antara gambar sebelum dilakukan preprocessing dan sesudah dilakukan preprocessing.



Gambar 2 Hasil Preprocessing

2.3. Ekstraksi Fitur ResNet-50

Dari data yang di dapatkan akan dilakukan Ekstraksi fitur yang dilakukan pada data adalah melalui fitur visual pada metode Faster R-CNN dengan menggunakan jaringan backbone CNN yaitu ResNet – 50 yang merupakan arsitektur ini memiliki arsitektur yang cukup dalam mengekstraksi fitur kompleks dan ringan pada saat proses komputasi. Kemudian akan dilakukan segmentasi bentuk untuk megoptimalkan hasil area bounding box untuk fokus pada area yang spesifik atau dianggap mengandung penyakit. Setelah itu ambil fitur geometris dan warna dari area yang tersegmentasi. Setelah data disegmentasi akan dilakukan ekstraksi fitur tambahan yang diambil dari area tersegmentasi untuk masuk pada proses SVM.

2.4. Deteksi Objek Faster R-CNN

Pada proses ini melakukan deteksi objek yang akan menghasilkan bounding box pada objek daun jagung. Skor yang digunakan untuk bounding box hanyalah nilai nya yang lebih dari 0.5 dikarenakan skor 0.5 merupakan standar awal dari model hanya percaya pada deteksi yang probabilitasnya di atas 50%, Apabila skor dibawah 0.5 biasanya lebih rawan pendeteksiannya salah.

2.5. Training

Pada proses pelatihan, dilakukan hanya pada bagian classifier (cnn_classifier), sedangkan fitur dari citra diekstraksi menggunakan model ResNet50 yang telah dilatih sebelumnya (pretrained) dan parameternya dibekukan. Fungsi loss yang digunakan adalah *CrossEntropy* karena sesuai untuk tugas klasifikasi dengan banyak kelas. Optimizer yang dipilih adalah Adam, karena sifatnya yang adaptif dan efisien dalam berbagai kasus klasifikasi citra. Selain itu, digunakan scheduler untuk menurunkan *learning rate* saat *validation loss* tidak menunjukkan perbaikan, guna menghindari jebakan pada minimum local. Strategi *early stopping* juga diterapkan, yaitu menghentikan pelatihan jika tidak ada peningkatan performa dalam beberapa *epoch* berturut – turut, sebagai upaya untuk mencegah overfitting.

2.6. Evaluasi

Pada proses evaluasi ini menggambarkan proses visualisasi dengan menggunakan *bounding box*. Jika tidak terdapat *bounding box* yang terdeteksi, maka seluruh area citra digunakan sebagai *fallback box*. Pada tahap prediksi dan evaluasi, fitur citra diekstraksi menggunakan model ResNet, sedangkan proses klasifikasi dilakukan oleh model classifier yang telah dilatih sebelumnya. Evaluasi performa dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-Score*. Selain itu terdapat fungsi yang digunakan untuk menyaring *bounding box* yang ukurannya terlalu kecil (sebagai noise) atau terlalu besar sehingga tidak merepresentasikan objek utama.

Menurut Han dan Kamber (2011), *confusion matrix* merupakan alat yang digunakan untuk mengevaluasi kinerja sebuah classifier dalam mengidentifikasi tuple dari berbagai kelas. Nilai *True Positive* dan *True Negative* menunjukkan bahwa model berhasil mengklasifikasikan data dengan benar, sedangkan *False Positive* dan *False Negative* mengindikasikan kesalahan dalam proses klasifikasi (Fluorida Fibrianda & Bhawiyuga, 2018)

Tabel 1 Confusion Matrix

		<i>Observed</i>	
		<i>True</i>	<i>False</i>
<i>Predicted Class</i>	<i>True</i>	<i>True Positive (TP)</i>	<i>False Positive (FP)</i>
	<i>False</i>	<i>False Negative (FN)</i>	<i>True Negative (TN)</i>

Keterangan (Pratiwi et al., 2021):

1. TP = *True Positif*

Merupakan jumlah data positif yang terklasifikasi dengan benar oleh sistem

2. TN = *True Negatif*

Merupakan jumlah data negative yang terklasifikasi dengan benar oleh sistem.

3. FN = *False Negatif*

Merupakan jumlah data negative, tetapi terklasifikasi salah oleh sistem.

4. FP = *False Positif*

Merupakan jumlah data positif, tetapi terklasifikasi salah oleh sistem.

Dari *confusion matrix* tersebut, terdapat empat kategori data yang dapat digunakan untuk mengukur performa dari sebuah algoritma, yaitu *Accuracy*, *Precision*, *Recall*, dan *F-1 Score* seperti berikut (Christopher & Mulyana, 2022) :

1. *Accuracy* merupakan persentase benar model ketika melakukan klasifikasi.

Rumus *accuracy* adalah sebagai berikut :

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

2. Precision merupakan persentase model memprediksi benar positif dengan keseluruhan data yang diprediksi positif.

Rumus precision adalah sebagai berikut :

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

3. Recall merupakan persentase prediksi benar positif apabila kelas actual data tersebut positif.

Rumus recall adalah sebagai berikut :

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

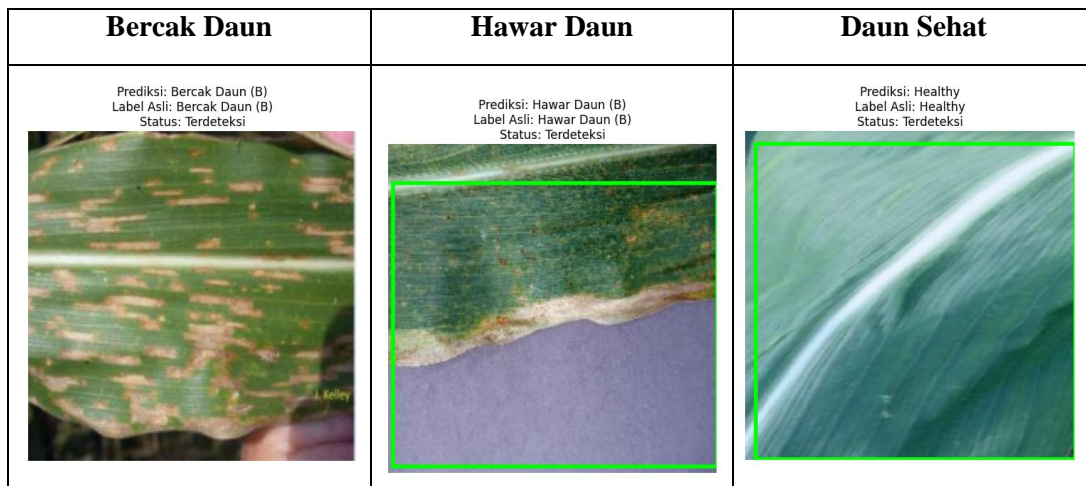
4. F-1 Score merupakan rata – rata antara precision dengan recall yang dibobotkan.

Rumus F-1 Score adalah sebagai berikut :

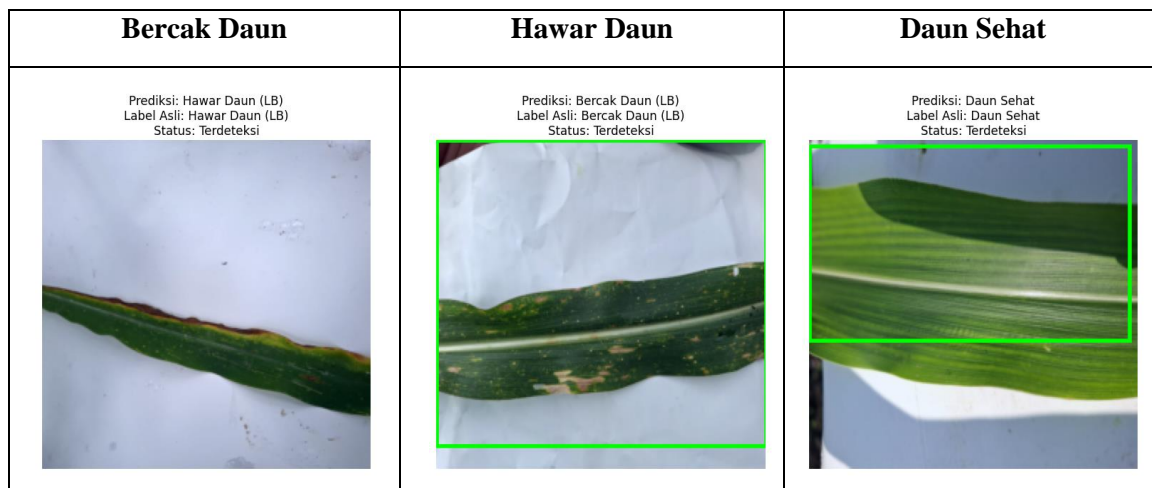
$$F - 1 \text{ Score} = \frac{(2 * Recall * Precision)}{Recall + Precision} \times 100\% \quad (4)$$

2.7. Visualisasi Hasil

Visualisasi hasil yang dihasilkan adalah berupa gambar yang ditampilkan dengan bounding box dan adanya keterangan prediksi, label asli, dan status terdeteksi yang bertujuan untuk menunjukkan secara visual hasil klasifikasi dan deteksi. Hasil visualisasi dapat dilihat pada **Gambar 3** yang merupakan hasil visualisasi dari data Kaggle dan **Gambar 4** yang merupakan hasil visualisasi dari data langsung



Gambar 3 Hasil Visualisasi Data Kaggle



Gambar 4 Hasil Visualisasi Data Langsung

3. HASIL DAN PEMBAHASAN

Hasil yang di dapatkan dari penelitian ini adalah hasil dari metode Faster R-CNN pada objek penelitian daun jagung dengan beberapa rasio atau pembagian data yang telah ditentukan. Performa yang di dapatkan seperti, akurasi, Presisi, recall, dan F1-Score dari metode ini juga bagus. Faktor dari kurangnya performa yang dihasilkan dapat dipengaruhi karena kondisi citra atau pengambilan citra yang posisinya kurang sesuai, seperti kondisi pencahayaan, pengambilan gambar dengan posisi radian yang berbeda-beda.

Pada penelitian ini, peneliti menggunakan dua jenis data yaitu data yang diambil dari Kaggle dan data yang diambil secara langsung oleh peneliti. Pada data Kaggle memperoleh data sebesar 1.494 gambar dan data yang diambil secara langsung oleh peneliti sebanyak 490 gambar dengan tiga kelas penyakit yaitu ada hawar daun, bercak daun, dan daun sehat. Untuk hasil performa yang di dapatkan dari data Kaggle dapat dilihat dalam **Tabel 2** dan hasil dari performa yang di dapatkan oleh data yang diambil secara langsung dapat dilihat dalam **Tabel 3**.

Dari penelitian sebelumnya yaitu penelitian Mohammad Omid Khairandish et al pada tahun 2020 dengan metode yang sama, namun objek penelitiannya adalah deteksi tumor otak. Ternyata metode ini juga menghasilkan akurasi yang cukup tinggi yaitu sebesar 98,787% pada tumor otak jinak dan 98,677% pada tumor ganas (Mohammad Omid Khairandish et al., 2020). Dari penelitian tersebut dapat diketahui bahwa metode ini cocok untuk studi kasus pendeteksian dan klasifikasi.

Tabel 2 Performa Data Kaggle

Metode	Rasio Data	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
Faster R-CNN	80:10:10	97,33%	97,58%	97,33%	97,39%
	70:20:10	96,69%	97,33%	96,69%	96,53%
	60:20:20	97,33%	97,29%	97,33%	97,30%

Tabel 3 Performa Data Langsung

Metode	Rasio Data	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
Faster R-CNN	80:10:10	95,92%	96,35%	95,92%	95,89%
	70:20:10	97,96%	98,06%	97,96%	97,95%
	60:20:20	98,98%	99,01%	98,98%	98,98%

4. KESIMPULAN

Dari penelitian yang telah dilakukan terdapat kesimpulan yang dapat diambil yaitu Faster R-CNN menunjukkan performa yang lebih tinggi pada data yang diambil langsung dibandingkan dengan data dari Kaggle, dengan akurasi tertinggi mencapai 98,98% pada rasio data 60:20:20, sementara pada data Kaggle akurasi maksimal hanya sebesar 97,33%. Rasio data 60:20:20 terbukti memberikan hasil terbaik untuk kedua jenis data, menghasilkan performa yang paling stabil dan tinggi di seluruh metrik evaluasi, terutama pada data langsung. Meskipun variasi rasio data tidak terlalu berpengaruh signifikan terhadap performa pada data Kaggle, tetap terdapat sedikit penurunan, seperti pada rasio 70:20:10 di mana akurasi turun menjadi 96,69%. Selain itu, faktor pengambilan data seperti kondisi pencahayaan dan posisi kamera juga dapat memengaruhi performa model secara keseluruhan.

5. SARAN

Berdasarkan hasil dan proses selama penelitian, terdapat beberapa saran yang bisa peneliti berikan yaitu untuk meningkatkan performa model, disarankan untuk menggunakan lebih banyak data dalam proses pelatihan, karena meskipun hasil yang diperoleh sudah baik, penambahan jumlah data dapat membuat model lebih tahan terhadap variasi data di dunia nyata. Selain itu, penggunaan metode augmentasi data seperti rotasi, flipping, atau penyesuaian kecerahan juga perlu dipertimbangkan agar model tidak hanya belajar dari pola yang umum, sekaligus memperkaya jumlah data ketika data yang tersedia masih terbatas. Eksplorasi terhadap model backbone yang berbeda pada Faster R-CNN, seperti ResNet101 atau EfficientNet, juga penting dilakukan untuk mengetahui apakah terdapat peningkatan performa yang signifikan. Pengujian model dengan data baru di luar dataset pelatihan dan pengujian dapat membantu mengevaluasi kemampuan generalisasi sistem terhadap skenario nyata. Terakhir, melakukan preprocessing yang lebih lanjut atau seleksi data yang lebih ketat dapat berkontribusi dalam meningkatkan akurasi dan kualitas hasil klasifikasi.

DAFTAR PUSTAKA

- Anggara, T., Irawan, B., Setianingsih, C., & Telkom, U. (2021). *Human Detection Counting With Faster R-Cnn Architecture for Central Air Conditioner (AC) Temperature Control*. 8(5), 6130–6141.
- Charli, F., Syaputra, H., Akbar, M., Sauda, S., & Panjaitan, F. (2020). Implementasi Metode Faster Region Convolutional Neural Network (Faster R-CNN) Untuk Pengenalan Jenis Burung Lovebird. *Journal of Information Technology Ampera*, 1(3), 185–197. <https://doi.org/10.51519/journalita.volume1.issue3.year2020.page185-197>
- Christopher, A., & Mulyana, T. M. S. (2022). Klasifikasi Tumbuhan Angiospermae Menggunakan Algoritma K-Nearest Neighbor Berdasarkan Pada Bentuk Daun. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 7(4), 1233–1243.

<https://doi.org/10.29100/jipi.v7i4.3211>

- Fluorida Fibrianda, M., & Bhawiyuga, A. (2018). Analisis Perbandingan Akurasi Deteksi Serangan Pada Jaringan Komputer Dengan Metode Naïve Bayes Dan Support Vector Machine (SVM). *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 2(9), 3112–3123. <http://j-ptiik.ub.ac.id>
- Khan, F., Zafar, N., Tahir, M. N., Aqib, M., Waheed, H., & Haroon, Z. (2023). A mobile-based system for maize plant leaf disease detection and classification using deep learning. *Frontiers in Plant Science*, 14(May), 1–18. <https://doi.org/10.3389/fpls.2023.1079366>
- Li, L., Zhang, S., & Wang, B. (2021). Plant Disease Detection and Classification by Deep Learning - A Review. *IEEE Access*, 9(Ccv), 56683–56698. <https://doi.org/10.1109/ACCESS.2021.3069646>
- Mohammad Omid Khairandish et al., M. O. K. et al. . (2020). A Hybrid Model of Faster R-CNN and SVM for Tumor Detection and Classification of MRI Brain Images. *International Journal of Mechanical and Production Engineering Research and Development*, 10(3), 6863–6876. <https://doi.org/10.24247/ijmperdjun2020651>
- Pratiwi, B. P., Handayani, A. S., & Sarjana, S. (2021). Pengukuran Kinerja Sistem Kualitas Udara Dengan Teknologi Wsn Menggunakan Confusion Matrix. *Jurnal Informatika Upgris*, 6(2), 66–75. <https://doi.org/10.26877/jiu.v6i2.6552>
- Rahman, M. F., & Bambang, B. (2021). Deteksi Sampah pada Real-time Video Menggunakan Metode Faster R-CNN. *Applied Technology and Computing Science Journal*, 3(2), 117–125. <https://doi.org/10.33086/atcsj.v3i2.1846>
- Raysyah, S. R., Veri Arinal, & Dadang Iskandar Mulyana. (2021). Klasifikasi Tingkat Kematangan Buah Kopi Berdasarkan Deteksi Warna Menggunakan Metode Knn Dan Pca. *JSiI (Jurnal Sistem Informasi)*, 8(2), 88–95. <https://doi.org/10.30656/jsii.v8i2.3638>
- Setiawan, W., Rochman, E. M. S., Satoto, B. D., & Rachmad, A. (2022). Machine Learning and Deep Learning for Maize Leaf Disease Classification: A Review. *Journal of Physics: Conference Series*, 2406(1), 0–11. <https://doi.org/10.1088/1742-6596/2406/1/012019>
- Singh, V., & Misra, A. K. (2017). Detection of plant leaf diseases using image segmentation and soft computing techniques. *Information Processing in Agriculture*, 4(1), 41–49. <https://doi.org/10.1016/j.inpa.2016.10.005>
- Sucipto, A., Ahdan, S., & Abyasa. (2019). Usulan Sistem untuk Peningkatan Produksi Jagung menggunakan Metode Certainty Factor. *Senter, November 2019*, 478–488.
- Xu, C., Shi, C., Bi, H., Liu, C., Yuan, Y., Guo, H., & Chen, Y. (2021). A Page Object Detection Method Based on Mask R-CNN. *IEEE Access*, 9, 143448–143457. <https://doi.org/10.1109/ACCESS.2021.3121152>
- Yu, H., Liu, J., Chen, C., Heidari, A. A., Zhang, Q., Chen, H., Mafarja, M., & Turabieh, H. (2021). Corn Leaf Diseases Diagnosis Based on K-Means Clustering and Deep Learning. *IEEE Access*, 9, 143824–143835. <https://doi.org/10.1109/ACCESS.2021.3120379>