



Model Transfer Learning Dalam Klasifikasi Penyakit Daun Jagung Menggunakan Arsitektur Densenet-201

M Sandy Tirta¹, Rudi Kurniawan^{2*}, Antoni Zulius³

^{1,2,3}Fakultas Ilmu Teknik, Prodi Rekayasa Sistem Komputer, Universitas Bina Insan, Lubuklinggau, Indonesia

Email: ¹2102010026@gmail.com, ^{2,*}rudi.kurniawan@univbinainsan.ac.id, ³antoni.zulius@univbinainsan.ac.id

Email Penulis Korespondensi: rudi.kurniawan@univbinainsan.ac.id

Abstrak— Produktivitas tanaman jagung dapat menurun secara signifikan akibat serangan penyakit pada daun yang sering kali tidak terdeteksi secara dini oleh para petani. Deteksi manual yang bergantung pada pengalaman subjektif petani memiliki keterbatasan dalam akurasi dan efisiensi, sehingga diperlukan solusi berbasis teknologi untuk mendukung praktik pertanian presisi. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi otomatis penyakit daun jagung dengan menggunakan pendekatan *Transfer Learning* berbasis arsitektur DenseNet-201. Dataset yang digunakan terdiri dari gambar daun jagung yang terbagi dalam beberapa kategori, termasuk daun sehat dan daun yang terinfeksi penyakit seperti *blight*, *rust*, dan *gray leaf spot*. Untuk meningkatkan performa model dan mengurangi risiko *overfitting*, dilakukan teknik augmentasi data seperti rotasi, flipping, dan zooming. Proses pelatihan model dilakukan dengan pembagian data ke dalam set pelatihan dan pengujian. Hasil evaluasi menunjukkan bahwa model DenseNet-201 berhasil mencapai akurasi sebesar 96,65% pada data uji, serta menunjukkan keunggulan dalam hal efisiensi komputasi dan kemampuan generalisasi dibandingkan dengan arsitektur lain yang lebih dangkal. Dengan hasil tersebut, penelitian ini membuktikan bahwa DenseNet-201 merupakan solusi efektif untuk deteksi penyakit daun jagung secara cepat dan akurat, sehingga dapat diintegrasikan ke dalam sistem pendukung pengambilan keputusan di bidang pertanian modern.

Kata Kunci: Penyakit Daun Jagung; Transfer Learning; DenseNet-201; Klasifikasi Citra; Deteksi Penyakit Daun Jagung

Abstract— Corn productivity can decline significantly due to leaf disease attacks that are often not detected early by farmers. Manual detection that relies on farmers' subjective experience has limitations in accuracy and efficiency, so technology-based solutions are needed to support precision agriculture practices. This study aims to develop an automatic classification system for corn leaf diseases using a Transfer Learning approach based on the DenseNet-201 architecture. The dataset used consists of corn leaf images divided into several categories, including healthy leaves and leaves infected with diseases such as blight, rust, and gray leaf spot. To improve model performance and reduce the risk of overfitting, data augmentation techniques such as rotation, flipping, and zooming were used. The model training process was carried out by dividing the data into training and testing sets. The evaluation results showed that the DenseNet-201 model successfully achieved an accuracy of 96.65% on the test data, and demonstrated superior computational efficiency and generalization capabilities compared to other, shallower architectures. With these results, this study proves that DenseNet-201 is an effective solution for fast and accurate corn leaf disease detection, so it can be integrated into decision support systems in modern agriculture.

Keywords: Corn Leaf Diseases; Transfer Learning; DenseNet-201; Image Classification; Detection of Corn Leaf Diseases

1. PENDAHULUAN

Jagung (*Zea mays L.*) merupakan salah satu komoditas strategis dalam sektor pertanian yang memiliki peran penting sebagai sumber pangan, pakan ternak, dan bahan baku industri [1]. Di Indonesia, jagung menjadi tanaman pangan kedua setelah padi yang banyak dibudidayakan, baik oleh petani skala kecil maupun besar [2]. Namun, produktivitas jagung sering kali terhambat oleh berbagai faktor, salah satunya adalah serangan penyakit pada bagian daun seperti hawar, bercak, dan karat daun yang dapat menyebabkan penurunan hasil panen secara signifikan [3]. Penyakit bercak daun ditandai dengan bercak coklat kemerahan atau klorotik yang dapat menyebar ke seluruh bagian tanaman [4]. Gejala hawar daun diawali dengan bercak kecil berwarna hijau tua atau kehijauan kebasahan, yang kemudian menjadi coklat kehitaman dan membesar membentuk kumparan atau perahu dengan ukuran hingga 5 cm × 15 cm [5]. Sementara itu, karat daun ditandai dengan munculnya uredinia berbentuk bulat hingga oval di permukaan atas dan bawah daun, yang menghasilkan uredospora sebagai sumber inokulum utama dan menyebar melalui angin. Serangan dini dapat menyebabkan bibit mati, tongkol rontok, dan biji membusuk, hingga menyebabkan kegagalan panen. Penyakit-penyakit ini dapat berkembang di berbagai ketinggian dan musim, baik hujan maupun kemarau [6]. Sebaliknya, daun jagung sehat berwarna hijau cerah, tebal, kuat, bebas dari bercak atau hama, serta tumbuh sesuai fase pertumbuhan tanaman. Kondisi ini menunjukkan kecukupan nutrisi dan mendukung proses fotosintesis yang sangat penting bagi produktivitas tanaman jagung secara keseluruhan [7].

Untuk memastikan keakuratan model dalam mengenali penyakit, digunakan metode evaluasi seperti *Confusion Matrix* dan *K-Fold Cross Validation*. *Confusion Matrix* menampilkan jumlah prediksi benar dan salah dalam bentuk tabel, sedangkan *K-Fold* membagi data menjadi beberapa bagian untuk pelatihan dan validasi bergantian, sehingga hasil menurunkan efisiensi fotosintesis, yang berdampak pada kualitas dan kuantitas hasil panen [8]. Penanganan penyakit evaluasi lebih stabil dan andal [9]. Penyakit daun jagung menyebabkan gangguan fisiologis tanaman karena menurunkan efisiensi fotosintesis, yang berdampak pada kualitas dan kuantitas hasil panen [10]. Penanganan penyakit daun secara dini menjadi sangat penting agar petani dapat melakukan tindakan pencegahan dan pengobatan tepat waktu. Namun, proses diagnosis penyakit secara manual membutuhkan tenaga ahli dan waktu yang tidak sedikit, sehingga tidak efisien untuk skala pertanian luas. Oleh karena itu, dibutuhkan solusi teknologi yang mampu mendeteksi penyakit secara otomatis,



cepat, dan akurat. Perkembangan teknologi kecerdasan buatan (*Artificial Intelligence/AI*) dan pembelajaran mesin (*Machine Learning*) membuka peluang besar dalam bidang pertanian presisi [11]. Salah satu penerapannya adalah *computer vision*, yaitu teknik pemrosesan citra untuk mengenali pola tertentu pada gambar tanaman. Dengan *computer vision*, proses identifikasi penyakit daun dapat dilakukan secara otomatis hanya dengan menggunakan gambar, yang diproses oleh sistem berbasis model pembelajaran mesin [12][13]. Model yang umum digunakan dalam pengolahan citra digital adalah *Convolutional Neural Network (CNN)*, yang terbukti efektif dalam klasifikasi gambar [14]. Salah satu arsitektur CNN yang menonjol dalam beberapa tahun terakhir adalah *Densely Connected Convolutional Network (DenseNet)*, yang menghubungkan setiap lapisan jaringan dengan semua lapisan sebelumnya, sehingga mengurangi hilangnya informasi dan memperbaiki aliran gradien [15][16]. DenseNet-201 adalah salah satu varian DenseNet dengan kedalaman 201 lapisan konvolusi. Arsitektur ini mampu mengekstraksi fitur visual kompleks dari citra dan menghasilkan performa tinggi dalam berbagai tugas klasifikasi [17]. Keunggulan lain dari DenseNet-201 adalah efisiensi penggunaan parameter serta stabilitas model saat pelatihan, yang menjadikannya pilihan tepat untuk klasifikasi citra penyakit daun tanaman [18]. DenseNet-201 efisien dalam penggunaan parameter, mengatasi vanishing gradient, dan mampu menghasilkan fitur visual rinci. Dengan pretraining pada ImageNet, model ini efektif untuk klasifikasi penyakit daun jagung dengan akurasi tinggi dan proses diagnosis yang cepat [19][20].

Beberapa penelitian sebelumnya telah mengkaji klasifikasi penyakit tanaman menggunakan pendekatan CNN dan transfer learning. Misalnya, Furaiwan et al. (2022) mengembangkan model klasifikasi penyakit jagung menggunakan arsitektur InceptionV3, ResNet101, dan VGG16, dan berhasil mencapai akurasi sebesar 98,6% pada tiga jenis penyakit dan satu kategori daun sehat [21]. Adhinata et al. (2021) memanfaatkan DenseNet-201 dan membandingkan dua skema akhir klasifikasi, yaitu menggunakan Global Average Pooling dan *flatten*, dengan akurasi terbaik sebesar 93% [22]. Penelitian oleh Waheed et al. (2024) juga menunjukkan efektivitas DenseNet dalam mendeteksi penyakit jagung seperti hawar dan karat dengan akurasi tinggi (98,06%) serta efisiensi parameter yang baik [23]. Meskipun hasil-hasil tersebut menunjukkan bahwa pendekatan transfer learning memberikan hasil yang menjanjikan, masih terdapat beberapa kekurangan. Sebagian besar studi belum memanfaatkan teknik validasi silang seperti *K-Fold Cross Validation*, yang penting untuk mengurangi bias dan memastikan model dapat di-*generalize* dengan baik. Selain itu, proses augmentasi data yang terbatas juga membuat model cenderung *overfitting* pada data pelatihan. Oleh karena itu, penelitian ini menawarkan pendekatan yang lebih komprehensif. Penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit daun jagung berbasis DenseNet-201 dengan pendekatan transfer learning, serta menerapkan teknik augmentasi data yang beragam untuk meningkatkan generalisasi model. Evaluasi model dilakukan secara menyeluruh menggunakan *Confusion Matrix* dan *K-Fold Cross Validation* untuk memperoleh hasil yang akurat dan andal. Dengan pendekatan ini, diharapkan hasil penelitian dapat memberikan kontribusi dalam pengembangan sistem deteksi dini penyakit tanaman secara otomatis, cepat, dan efisien, serta mendukung implementasi teknologi dalam pertanian presisi di Indonesia.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini terdiri dari enam tahapan utama, yaitu: *problem scoping*, *data acquisition*, *data exploration*, *modelling*, *evaluation*, *deploy & finishing*. Setiap tahap dijelaskan secara sistematis untuk menghasilkan sistem klasifikasi penyakit daun jagung berbasis citra digital. Gambar 1 berikut ini menggambarkan alur proses penelitian secara keseluruhan



Gambar 1. Framework AI Lifecycle

Gambar 1 menunjukkan framework AI Lifecycle yang terdiri dari enam tahap utama, mulai dari identifikasi permasalahan hingga proses deployment dan penyelesaian proyek. Framework ini merangkum proses kerja dalam pengembangan sistem berbasis kecerdasan buatan.

2.2 Problem Scoping

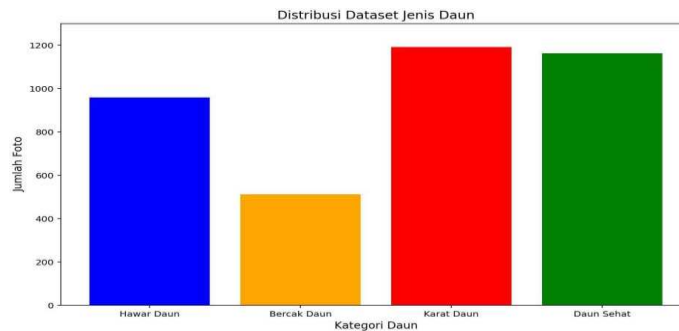
Pendekatan berbasis AI, seperti *transfer learning*, menawarkan solusi efisien untuk identifikasi dini penyakit daun jagung melalui klasifikasi gambar. Dengan memanfaatkan model pretrained seperti DenseNet-201, sistem dapat mendeteksi pola



dan fitur spesifik untuk membedakan antara daun sehat dan terinfeksi. Ini meningkatkan efisiensi identifikasi dan mengurangi ketergantungan pada metode manual.

Namun, tantangan utama adalah ketersediaan dan kualitas dataset citra yang memadai. Data yang kurang bervariasi atau berisik dapat mempengaruhi akurasi model. Proses *preprocessing* seperti augmentasi dan normalisasi juga penting untuk pelatihan optimal. Selain itu, kebutuhan komputasi tinggi menjadi tantangan, terutama pada perangkat dengan sumber daya terbatas. Desain pendekatan harus mempertimbangkan ketersediaan data dan sumber daya pengguna akhir.

2.3 Data Acquisition




Gambar 2. Grafik Dataset

Gambar 2 adalah grafik jumlah dataset yang digunakan dalam penelitian ini, yang berasal dari platform Mendeley Data. Dataset tersebut terdiri dari total 3.852 citra daun jagung yang terbagi ke dalam empat kelas, yaitu: hawar daun sebanyak 985 citra, bercak daun 513 citra, karat daun 1.192 citra, dan daun sehat 1.162 citra. Setiap citra disediakan dalam format JPG dengan resolusi yang bervariasi.

2.4 Data Exploration

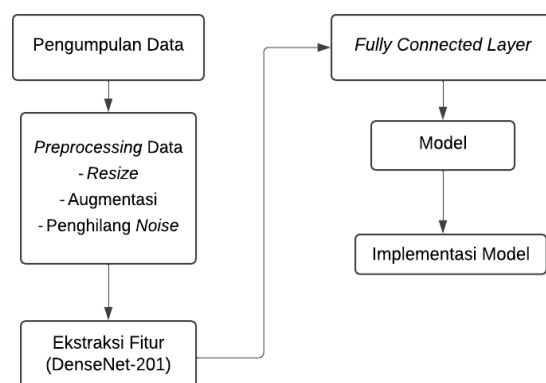
Tahapan *preprocessing data* dilakukan dengan teknik data *augmentation* untuk memperkaya data pelatihan dan mencegah *overfitting*. *Data augmentation* adalah manipulasi citra untuk menambah variasi tanpa perlu mengumpulkan data baru. Teknik yang digunakan meliputi *flip*, *crop*, *grayscale*, *saturation*, dan *blur*. Hasil augmentasi menciptakan keragaman kondisi gambar, membantu model mengenali pola dan fitur dengan lebih baik, serta meningkatkan generalisasi pada data uji. Berikut ini adalah contoh dari hasil augmentasi :



Gambar 3. Hasil Augmentasi

Gambar 3 menunjukkan beberapa teknik augmentasi citra yang digunakan untuk meningkatkan variasi dataset tanpa menambah data baru. Teknik a) Flip membalik gambar untuk menciptakan sudut pandang berbeda, b) Crop memotong sebagian gambar agar model belajar dari bagian tertentu, c) Grayscale menghilangkan warna agar fokus pada tekstur, d) Saturation mengubah intensitas warna untuk menyesuaikan kondisi pencahayaan, dan e) Blur mensimulasikan gambar kabur seperti pada citra lapangan. Augmentasi ini penting untuk mencegah *overfitting* dan meningkatkan akurasi model.

2.5 Modelling



Gambar 4. Flowchart Modelling



2.6 Evaluation

Evaluasi dilakukan dengan metode *10-fold cross-validation* untuk memastikan bahwa model tidak hanya cocok pada subset data tertentu, melainkan dapat digeneralisasi pada seluruh dataset [4]. Model dievaluasi menggunakan metrik:

$$\text{Accuracy} = \frac{(TP+TN)}{(TP+FP+FN+TN)} \quad [1]$$

$$\text{Precision} = \frac{TP}{(TP+FP)} \quad [2]$$

$$\text{Recall} = \frac{TP}{(TP+FN)} \quad [3]$$

$$\text{F1-score} = 2 \times \frac{(\text{Precision} \times \text{Recall})}{(\text{Precision} + \text{Recall})} \quad [4]$$

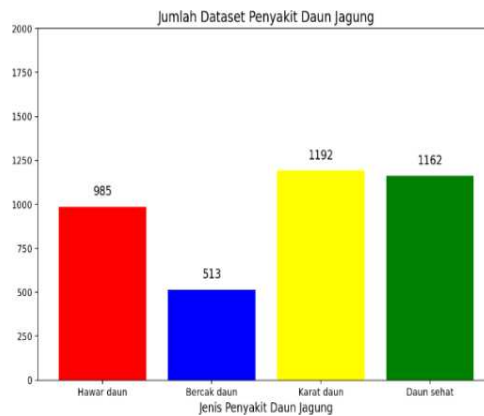
3. HASIL DAN PEMBAHASAN

Pada bagian ini menyajikan penelitian yang telah dilakukan untuk klasifikasi penyakit daun jagung menggunakan arsitektur Densenet-201. Penelitian ini bertujuan untuk mengembangkan model berbasis *transfer learning* dengan arsitektur DenseNet-201 untuk mendeteksi penyakit daun jagung seperti hawar daun, karat daun, dan bercak daun.

3.1 Pembahasan

Pada penelitian ini ada beberapa tahapan yang di lakukan sebelum akhirnya di peroleh hasil. Langkah awal tentunya pengambilan data set, dimana toatal data set terdiri dari 3.852 citra.

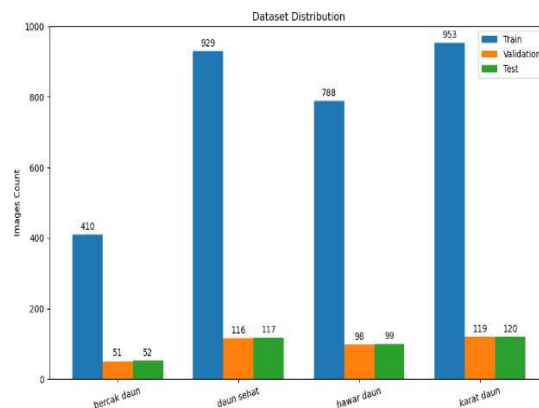
3.1.1 Pengambilan Dataset



Gambar 5. Jumlah Dataset Penyakit Daun Jagung

Gambar 5 menunjukkan dataset citra penyakit daun jagung yang digunakan dalam penelitian ini, yang bersumber dari platform Mendelely Data. Dataset terdiri atas total 3.852 citra yang terbagi dalam empat kategori, yaitu: 985 citra hawar daun, 513 citra bercak daun, 1.192 citra karat daun, dan 1.162 citra daun sehat.

3.1.2 Split Data



Gambar 6. Hasil Split Data



Gambar 6 adalah proses *split* data menjadi tiga subset, yaitu *train*, *validation*, dan *test*. Untuk kelas bercak daun terdapat 410 citra *train*, 51 *validation*, dan 52 *test*; daun sehat terdiri atas 929 *train*, 116 *validation*, dan 117 *test*; hawar daun sebanyak 788 *train*, 98 *validation*, dan 99 *test*; serta karat daun mencakup 953 *train*, 119 *validation*, dan 120 *test*.

3.1.3 Pre-processing Data

a. Labelling Gambar

Perlabelan gambar dilakukan menggunakan Denset201 yang memberikan nama pada gambar untuk keperluan dataset. Dalam penelitian ini, terdapat empat kategori : bercak daun, hawar daun, karat daun, dan daun sehat.

b. Resize Gambar

Resize gambar adalah proses mengubah ukuran gambar agar memiliki dimensi konsisten, memudahkan pemrosesan oleh model transfer learning seperti DenseNet-201. Dengan resize, beban komputasi berkurang, sehingga mempercepat waktu pelatihan model.

c. Augmentation


Setelah resize, langkah selanjutnya adalah augmentasi, yaitu memperbanyak data dengan transformasi seperti rotasi dan flipping. Proses ini menggunakan Keras atau *TensorFlow* untuk meningkatkan variasi dan akurasi model *transfer learning* seperti DenseNet-201.

3.1.4 Membangun Model


DenseNet201 adalah arsitektur jaringan saraf untuk klasifikasi gambar, menggunakan koneksi dens antar lapisan. Setiap lapisan terhubung ke semua lapisan sebelumnya, meningkatkan aliran informasi dan mengurangi masalah vanishing gradient. Model ini terdiri dari blok konvolusi, lapisan pooling, dan diakhiri dengan lapisan fully connected untuk klasifikasi [20].

3.1.5 Pelatihan Model

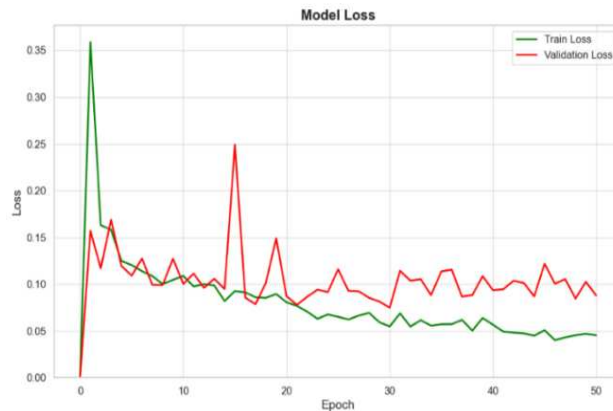

Pelatihan model dilakukan selama sejumlah epoch yang ditentukan, di mana setiap epoch mencakup satu siklus penuh melalui dataset pelatihan. Model belajar dari data dan mengoptimalkan bobot untuk meminimalkan kesalahan klasifikasi. Lebih banyak epoch memungkinkan model menangkap pola lebih baik, tetapi perlu diimbangi untuk menghindari overfitting.



Gambar 7. Training Model



Gambar 8. Grafik Model Accuracy



Gambar 9. Grafik Model Loss


3.1.6 Hasil Evaluasi Model

12/12 ————— 12s 1s/step - accuracy: 0.9783 - loss: 0.1100
 Fold 1 - Validation Loss: 0.1509, Validation Accuracy: 0.9661

Gambar 10. Hasil Evaluasi Model

Gambar 10 menunjukkan hasil evaluasi model, termasuk kecepatan, akurasi, dan loss. Model mencapai akurasi 0.9783 dan loss 0.1100 pada data training. Hasil fold pertama validasi silang menunjukkan loss 15.09 dan akurasi 0.9661, menandakan kemampuan model menggeneralisasi data baru.

3.1.7 Visualisasi Confusion Matrix



Gambar 11. Visualisasi Confusion Matrix

Gambar 11 menunjukkan *Confusion Matrix* yang menampilkan kinerja model klasifikasi dalam mengklasifikasikan label yang berbeda. Di sepanjang diagonal utama, angka-angka menunjukkan jumlah prediksi yang benar untuk setiap kelas, seperti 45 untuk bercak daun, 117 untuk daun sehat, 94 untuk hawar daun, dan 119 untuk karat daun. Sementara itu, angka-angka di luar diagonal menunjukkan jumlah kesalahan klasifikasi, seperti 7 bercak daun yang salah diklasifikasikan sebagai hawar daun.

Classification Report

	precision	recall	f1-score	support
bercak daun	0.88	0.87	0.87	52
daun sehat	1.00	1.00	1.00	117
hawar daun	0.93	0.95	0.94	99
karat daun	1.00	0.99	1.00	120
accuracy			0.97	388
macro avg	0.95	0.95	0.95	388
weighted avg	0.97	0.97	0.97	388

Gambar 12. Hasil Classification Report



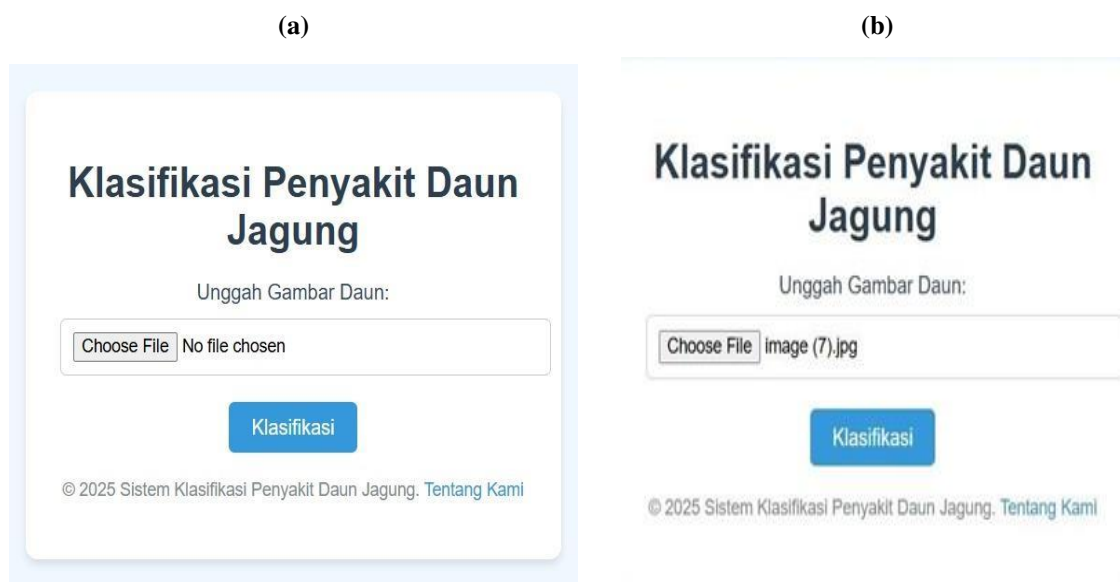
Gambar 12 menunjukkan Classification Report dengan metrik presisi, recall, dan f1-score. Kelas bercak daun mencatat presisi 0.88 dan recall 0.87. Kelas daun sehat memiliki nilai 1.00 untuk recall dan f1-score. Kelas hawar daun presisi 0.93 dan recall 0.95, sedangkan karat daun mencapai presisi 1.00 dan recall 0.99. Akurasi keseluruhan model adalah 0.97, menunjukkan efektivitas klasifikasi.

3.1.8 Klasifikasi



Gambar 13. Hasil Klasifikasi Penyakit Daun Jagung

3.2 Implementasi



Gambar 14. (a) Tampilan Awal Website (b) Memasukkan Gambar Penyakit Daun Jagung



Gambar 15. (a) Hasil Klasifikasi Penyakit Bercak Daun (b) Hasil Klasifikasi Penyakit Hawar Daun



Gambar 16. (a) Hasil Klasifikasi Penyakit Karat Daun (b) Hasil Klasifikasi Daun Sehat

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa model klasifikasi penyakit daun jagung berbasis *transfer learning* dengan arsitektur DenseNet-201 yang dapat memberikan hasil yang sangat akurat dengan tingkat akurasi yang mencapai 97%. Selama proses pelatihan dan pengujian, digunakan dataset sebanyak 3.852 gambar yang telah melalui beberapa tahap pra-pemrosesan seperti resize, pelabelan, dan augmentasi. Hasil evaluasi model juga menunjukkan nilai precision, recall, dan f1-score yang tinggi, menandakan bahwa model ini mampu bekerja secara konsisten dalam mengenali masing-masing jenis penyakit. Meski hasil yang diperoleh cukup memuaskan, penelitian ini tetap memiliki keterbatasan, terutama pada jumlah dan keragaman data yang digunakan. Oleh karena itu, pengembangan di masa mendatang sangat mungkin dilakukan, misalnya dengan memperluas variasi dataset dan mengeksplorasi arsitektur *deep learning* lain sebagai pembanding. Harapannya, sistem ini bisa terus dikembangkan hingga benar-benar bisa diterapkan secara langsung di lapangan untuk membantu petani dalam mendeteksi penyakit daun jagung secara lebih cepat, efisien, dan akurat.

REFERENCES

- [1] M. F. Naufal, D. H. Prasetyo, And F. H. Ramadhan, "Rekomendasi Peralatan Camping Menggunakan Metode Complex Proportional Assesment," *J. Sains Komput. & Inform.*, Vol. 6, No. 2, Pp. 931–937, 2022, Doi: 10.21009/Jskki.062.13.
- [2] P. Erviyana, "Faktor-Faktor Yang Memengaruhi Produksi Tanaman Pangan Jagung Di Indonesia," *Jejak J. Ekon. Dan Kebijak.*, Vol. 7, No. 2, 2019, Doi: 10.15294/Jejak.V7i2.3900.
- [3] F. A. C. H. A. Safitri, M. Martosudiro, "Pengaruh Beberapa Jenis Dan Dosis Fungisida Terhadap Penyakit Hawar Daun (*Helminthosporium Sp.*) Dan Keanekaragaman Jamur Endofit Pada Daun Tanaman Jagung," *J. Hpt (Hama Penyakit Tumbuhan)*, Vol. 11, No. 4, Pp. 188–200, 2023, Doi: 10.21776/Ub.Jurnalhpt.2023.011.4.3.
- [4] M. I. Rosadi And M. Lutfi, "Identifikasi Jenis Penyakit Daun Jagung Menggunakan Deep Learning Pre-Trained Model," *J. Explor. It!*, Vol. 13, No. 2, Pp. 36–42, 2021, [Online]. Available: <https://doi.org/10.35891/Explorit>
- [5] R. D. C. F. F. Costa, L. G. Silva, "Characterization Of Exserohilum Turcicum Infection Sites In Maize Genotypes," *Trop. Plant Pathol.*, Vol. 45, No. 3, Pp. 301–312, 2020, Doi: 10.1007/S40858-020-00417-X.
- [6] A. Y. R. Ruimassa, E. A. Martanto, D. K. Erari, "Ketahanan Beberapa Varietas Jagung (*Zea Mays L.*) Terhadap Penyakit Karat Daun (*Puccinia Sorghi*) Di Dusun Copti, Distrik Prafi, Kabupaten Manokwari," *Agrotek*, Vol. 10, No. 1, P., 2021, Doi: 10.46549/Agrotek.V10i1.240.
- [7] A. A. Kariman Aqla Sistem, Maulana Zidan Rakhmatullah, Muchammad Yusuf Efendi, "Klasifikasi Kualitas Daun Sehat Dan Tidak Sehat Pada Tanaman Jagung Dengan Menggunakan Metode Morfologi Gradien Di Python," *J. Sist. Apl. Dan Teknol. Inf.*, Vol. 1, No. 2, Pp. 85–94, 2024, Doi: 10.53567/Josiati.V1i2.18.
- [8] D. A. I. P. Putra, R. Rusbandi, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network," *J. Algoritm.*, Vol. 2, No. 2, Pp. 102–112, 2022, Doi: 10.35957/Algoritme.V2i2.2360.
- [9] B. Priyatna, T. K. A. Rahman, A. L. Hananto, A. Hananto, And A. Y. Rahman, "Mobilenet Backbone Based Approach For Quality Classification Of Straw Mushrooms (*Volvariella Volvacea*) Using Convolutional Neural Networks (Cnn)," *Int. J. Informatics Vis.*, Vol. 8, No. 3–2, Pp. 1749–1754, 2024, Doi: 10.62527/Joiv.8.3-2.2998.
- [10] H. Mohammed Et Al, "Epidemic Development And Management Of Common Leaf Rust (*Puccinia Sorghi* Schwein) And Turcicum Leaf Blight [*Exserohilum Turcicum* (Pass.)] Of Maize (*Zea Mays L.*) In Eastern Ethiopia," *Agrosystems, Geosci. Environ.*, Vol. 9, No. 1, 2023, Doi: 10.1002/Agg2.20451.
- [11] J. Srikanthnaik, "Artificial Intelligence And Machine Learning For Precision In Agriculture: A Comprehensive Systematic Review," *Int. J. Res. Agron*, Vol. 7, No. 6, Pp. 762–767, 2024, Doi: 10.33545/2618060x.2024.V7.I6j.2794.
- [12] A. B. M. R. R. E. Pramesti, "Implementation Of Deep Learning Using Convolutional Neural Network For Skin Disease Classification With Densenet-201 Architecture," *J. Ilm. Ilmu Komput.*, Vol. 6, No. 1, 2022, Doi: 10.30645/Jikon.V6i1.140.



- [13] W. Arrank Tonapa, P. D.K. Manembu, And F. D. Kambey, “Klasifikasi Ikan Cakalang Dan Tongkol Menggunakan Convolutional Neural Network,” *J. Tek. Inform.*, Vol. 19, No. 01, Pp. 31–36, 2024, Doi: 10.35793/Jti.V19i01.52013.
- [14] B. Suswati, “Implementasi Convolutional Neural Network Pada Klasifikasi Citra Daun Tanaman Hias,” *J. Pendidik. Teknol. Inf.*, Vol. 4, No. 2, Pp. 41–51, 2024, Doi: 10.51454/Decode.V4i2.590.
- [15] N. Huda, A. Mahiruna, W. Sulistijanti, And R. C. N. Santi, “Analisis Performa Inceptionv3 Convolutional Network Pada Klasifikasi Varietas Daun Grapevine,” *J. Sains Komput. Dan Teknol. Inf.*, Vol. 5, No. 2, Pp. 47–53, 2023, Doi: 10.33084/Jsakti.V5i2.5022.
- [16] A. V. Y. N. Maulana, C. Rozikin, “Implementasi Metode Cnn Untuk Klasifikasi Penyakit Tanaman Kentang Dengan Arsitektur Densenet,” *J. Lentera*, Vol. 23, No. 3, Pp. 301–309, 2024, Doi: 10.29138/Lentera.V23i3.1455.
- [17] J. Z. R. A. Mas’ud, “Optimasi Convolutional Neural Networks Untuk Deteksi Kanker Payudara Menggunakan Arsitektur Densenet,” *Edumatic J. Pendidik. Inform.*, Vol. 8, No. 1, Pp. 310–318, 2024, Doi: 10.29408/Edumatic.V8i1.25883.
- [18] A. Agustina, F. Yanto, E. Budianita, I. Iskandar, And F. Syafria, “Klasifikasi Penyakit Tanaman Padi Menggunakan Metode Cnn Arsitektur Densenet-121 Dan Augmentasi Data,” *J. Inf. Syst. Informatics Eng.*, Vol. 8, No. 1, Pp. 124–134, 2024, [Online]. Available: <https://doi.org/10.35145/Joisie.V8i1.4256>
- [19] M. H. M. Bakr, S. Abdel-Gaber, M. Nasr, “Densenet-201 Based Model For Plant Diseases Diagnosis,” *Eur. J. Electr. Eng. Comput. Sci.*, Vol. 6, No. 5, Pp. 458–470, 2022, Doi: 10.24018/Ejece.2022.6.5.458.
- [20] Z. Gu *Et Al.*, “Assessing Breast Cancer Volume Alterations Post-Neoadjuvant Chemotherapy Through Densenet-201 Deep Learning Analysis On Dce-Mri,” *J. Radiat. Res. Appl. Sci.*, Vol. 17, No. 3, P. 100971, 2024, Doi: 10.1016/J.Jrras.2024.100971.
- [21] N. K. M. Fraiwan And E. Faouri, “Classification Of Corn Diseases From Leaf Images Using Deep Transfer Learning,” *Plants*, Vol. 11, No. 23, Pp. 1–15, 2022, Doi: 10.3390/Plants11233241.
- [22] M. P. K. P. F. D. Adhinata, G. F. Fitriana, A. Wijayanto, “Corn Disease Classification Using Transfer Learning And Convolutional Neural Network,” *Juita J. Inform.*, Vol. 9, No. 2, Pp. 211–217, 2021, Doi: 10.30595/Juita.V9i2.11686.
- [23] A. K. S. R. M. A. Waheed, S. U. Rehman, “Optimized Densenet Architecture For Detection And Classification Of Maize Leaf Diseases,” *Complex Intell. Syst.*, Vol. 10, No. 2, Pp. 123–130, 2024, Doi: 10.1007/S40747-023-01000-X.