

Klasifikasi Jenis Penyakit Tanaman Jagung Berdasarkan Citra Daun dengan Algoritma EfficientNetV2-S

Rizky Kurniawan^{1*}, Dedy Hermanto²

¹Program Studi Informatika, Universitas Multi Data Palembang

²Program Studi Teknik Elektro, Universitas Multi Data Palembang

¹⁻²Jl. Rajawali No.14, 9 Ilir, Kec. Ilir Tim. II, Kota Palembang, Sumatera Selatan 30113

Email: rizky.kurniawan@mhs.mdp.ac.id¹, dedy@mdp.ac.id²

Abstract

Corn is one of the important food commodities in Indonesia, which is susceptible to leaf diseases such as leaf rust, gray leaf spot, and leaf blight. These disease attacks can reduce both productivity and farmers' income. Manual classification carried out by field officers is still constrained by speed and consistency, necessitating an automated classification system based on digital images. This study proposes a corn leaf disease classification model using a Convolutional Neural Network (CNN) algorithm with the EfficientNetV2-S architecture. The dataset used consists of 2,256 corn leaf images from Kaggle, divided into four classes: Leaf Blight, Common Rust, Gray Leaf Spot, and Healthy Leaf. All images were resized to 224×224 pixels, augmented, and then split into 80% training data and 20% validation data. The training process was carried out with a batch size of 32, a learning rate of 0.000005, and 200 epochs. Performance evaluation was conducted using a confusion matrix with accuracy, precision, recall, and F1-score metrics. The best result was obtained at the 150th epoch with 96% accuracy, with no signs of overfitting. These findings indicate that EfficientNetV2-S can serve as an effective model approach for classifying corn leaf diseases.

Key Words: CNN, Deep Learning, EfficientNetV2-S, Corn Leaf Disease.

Abstrak

Jagung adalah salah satu komoditas pangan penting di Indonesia, yang rentan terhadap penyakit daun seperti karat daun, bercak daun abu-abu, dan hawar daun. Serangan penyakit ini dapat menurunkan produktivitas sekaligus pendapatan petani. Klasifikasi manual yang dilakukan oleh petugas lapangan masih terbatas oleh kecepatan dan konsistensi, sehingga diperlukan sistem klasifikasi otomatis berbasis citra digital. Penelitian ini mengusulkan model klasifikasi penyakit daun jagung menggunakan algoritma *Convolutional Neural Network* (CNN) dengan arsitektur EfficientNetV2-S. Dataset yang digunakan terdiri dari 2.256 gambar daun jagung dari Kaggle, dibagi menjadi empat kelas: hawar daun, karat daun, bercak daun abu-abu, dan daun sehat. Semua gambar diubah ukurannya menjadi 224×224 piksel, dilakukan augmentasi, dan kemudian dibagi menjadi 80% data pelatihan dan 20% data validasi. Proses pelatihan dilakukan dengan *batch size* 32, *learning rate* 0,000005, dan 200 *epoch*. Evaluasi kinerja dilakukan menggunakan *confusion matrix* dengan akurasi, presisi, *recall*, dan *F1-score*. Hasil terbaik diperoleh pada epoch ke-150 dengan akurasi 96%, tanpa tanda-tanda *overfitting*. Temuan ini menunjukkan bahwa EfficientNetV2-S dapat menjadi model pendekatan yang efektif untuk mengklasifikasikan penyakit daun jagung.

Kata Kunci: CNN, Deep Learning, EfficientNetV2-S, Penyakit Daun Jagung.

Pendahuluan

Pertanian merupakan sektor penting dalam kebutuhan pangan masyarakat. Di Indonesia tanaman *Zea Mays* atau jagung merupakan sumber pangan utama nomor dua setelah beras. Tanaman ini tingkat produktivitas yang tinggi dan banyak kegunaannya seperti pakan hewan, minyak jagung, dan bahan baku industri. Akan tetapi, serangan penyakit tanaman jagung merupakan salah satu rasa khawatir para petani jagung karena dapat menimbulkan kerugian hasil produksi jagung dan menurunkan pendapatan para petani jagung [1].

Beberapa penyakit utama yang menyerang tanaman jagung meliputi karat daun, bercak daun abu-abu, dan hawar daun. Karat daun, yang disebabkan oleh jamur *Puccinia sorghi*, ditandai dengan bintik

kemerahan yang menghasilkan serbuk kekuningan-cokelatan. Jika tidak segera ditangani, penyakit ini dapat menghambat fotosintesis, mengerdilkan pertumbuhan jagung, dan berpotensi menyebabkan kematian [2]. Bercak daun abu-abu disebabkan oleh jamur *Cercospora zea-maydis*, menghasilkan lesi gelap berbentuk bintik dengan tepi kekuningan, yang secara bertahap menyebabkan jaringan daun mati [3]. Sementara itu, hawar daun disebabkan oleh jamur *Bipolaris maydis*, ditandai dengan bintik memanjang berwarna cokelat kehijauan yang terus berkembang dan menyatu, akhirnya menyebabkan bagian daun yang terkena mati [4].

Kurangnya pengetahuan petani serta lambatnya penanganan penyakit dapat mempengaruhi penularan penyakit ke tanaman jagung lainnya sehingga akan menyebabkan meningkatnya biaya perawatan. Kondisi ini seharusnya ditangani oleh tenaga ahli di bidang pertanian, namun ketersediaan ahli tanaman jagung di berbagai daerah masih terbatas [5]. Mengklasifikasi penyakit secara manual oleh petugas POPT (Pengamat Organisme Pengganggu Tanaman) dilakukan melalui pengamatan visual juga memiliki keterbatasan, seperti membutuhkan waktu yang cukup lama dan adanya potensi perbedaan persepsi antar pengamat yang dapat memengaruhi konsistensi hasil klasifikasi. Berdasarkan kondisi tersebut, penelitian ini difokuskan untuk mengembangkan model klasifikasi penyakit tanaman jagung yang mampu dievaluasi secara kuantitatif melalui metrik kinerja seperti akurasi, presisi, *recall*, dan *F1-score*, sehingga dapat menjadi dasar dalam pengembangan sistem diagnosis otomatis di masa mendatang [6].

Berdasarkan kebutuhan untuk mengembangkan model klasifikasi penyakit tanaman jagung yang memiliki kinerja tinggi, pengolahan citra digital menjadi salah satu pendekatan yang relevan untuk diterapkan. Menurut [7] pengolahan citra digital adalah salah satu bidang yang memainkan peran penting dalam otomatisasi klasifikasi penyakit tanaman. Teknik ini memungkinkan ekstraksi fitur penting dari citra daun, seperti pola, tepi, dan tekstur, yang kemudian dapat digunakan untuk identifikasi penyakit. Salah satu metode yang paling banyak digunakan adalah *Convolutional Neural Network* (CNN). CNN mampu secara otomatis mengekstraksi fitur citra melalui jaringan saraf berlapis-lapis, sehingga sangat cocok untuk masalah klasifikasi citra [8].

EfficientNetV2-S merupakan bagian baru dari CNN yang dikembangkan dari ruang pencarian yang diperkaya dengan operasi baru seperti Fused-MB *Convolution*. Hasil uji menunjukkan bahwa model EfficientNetV2-S berlatih jauh lebih cepat daripada model sebelumnya dan ukurannya 6,8 kali lebih kecil [9].

Penelitian yang dilakukan [10] dengan pemanfaatan metode *deep learning* untuk mengklasifikasi penyakit tanaman jagung menggunakan arsitektur EfficientNetB0 berdasarkan citra pelepah daun jagung yang sehat maupun yang sakit. Penelitian ini menghasilkan akurasi sebesar 96% dengan harapan tingkat akurasi tersebut mampu membantu petani dalam pengendalian penyakit tanaman jagung.

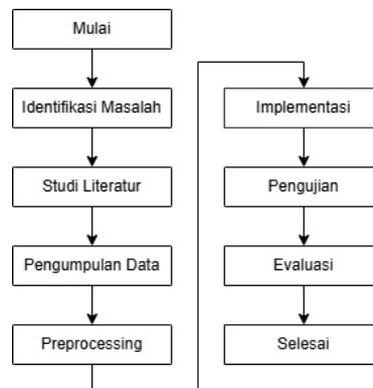
Penelitian yang dilakukan [11] dengan pemanfaatan metode *deep learning* untuk mengklasifikasi daun herbal menggunakan arsitektur EfficientNetV2B0 berdasarkan citra daun herbal dengan 10 kelas menghasilkan akurasi sebesar 99,14% dan nilai loss sebesar 1,95%. Hasil ini menunjukkan bahwa arsitektur EfficientNetV2B0 mampu mengurangi waktu pelatihan dengan tetap mempertahankan tingkat akurasi yang tinggi.

Penelitian yang dilakukan [12] dengan meneliti sistem pengklasifikasian jenis penyakit daun mangga menggunakan arsitektur EfficientNetV2-S. Penelitian ini menghasilkan aplikasi web yang mampu melakukan klasifikasi dengan akurasi yang tinggi sehingga dapat membantu petani dalam mengklasifikasi daun jagung secara cepat dan akurat.

Berdasarkan hasil-hasil tersebut, penelitian ini difokuskan pada penerapan EfficientNetV2-S dalam membangun model klasifikasi penyakit daun jagung untuk memperoleh performa yang optimal.

Metode Penelitian

Penelitian ini melalui beberapa tahap, yang terdiri dari identifikasi masalah, tinjauan pustaka, pengumpulan data, perancangan sistem, implementasi, pengujian, dan evaluasi. Urutan tahap-tahap ini ditunjukkan pada Gambar 1.



Gambar 1 Tahap Penelitian

A. Identifikasi Masalah

Pada tahap pertama, identifikasi masalah dilakukan dalam penelitian mengenai klasifikasi penyakit daun pada tanaman jagung dengan memverifikasi masalah tersebut melalui narasumber dari BPP (Balai Penyuluhan Pertanian). Masalah yang umum ditemui di lapangan adalah lambatnya klasifikasi serangan penyakit jamur pada tanaman jagung, seperti karat daun, bercak daun abu-abu, dan hawar daun, yang masih dilakukan secara visual dan memakan waktu lama.

B. Studi Literatur

Studi literatur dilakukan dengan mengumpulkan data dari jurnal dan artikel yang membahas klasifikasi penyakit daun tanaman jagung serta metode CNN, khususnya arsitektur EfficientNetV2-S. Tujuan dari studi ini adalah mengelompokkan jenis penyakit daun jagung dengan menerapkan arsitektur EfficientNetV2-S.

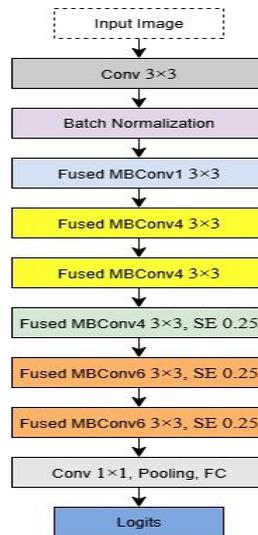
a. CNN (Convolutional Neural Networks)

CNN merupakan metode dalam *machine learning* yang dirancang untuk memproses data dua dimensi seperti citra. Model ini bekerja dengan mengekstraksi fitur penting (tepi, pola, tekstur) secara otomatis, sehingga dapat digunakan untuk membedakan objek dalam gambar [13]. CNN digunakan untuk pengenalan pola pada data gambar yang terdiri dari kumpulan neuron yang disusun berlapis-lapis secara berurutan [8].

b. EfficientNetV2-S

EfficientNetV2 merupakan pengembangan dari EfficientNet yang dirancang untuk menghasilkan model yang lebih cepat dalam pelatihan serta lebih efisien dalam jumlah parameter. EfficientNetV2 ditemukan melalui *training-aware neural architecture search* yang mengoptimalkan kecepatan pelatihan sekaligus efisiensi parameter dengan memanfaatkan blok Fused-MBConv pada lapisan awal. Selain itu, arsitektur ini juga menerapkan metode *progressive learning* dengan *adaptive regularization*. Metode *progressive learning* dilakukan dengan meningkatkan ukuran citra pelatihan secara bertahap selama proses *training*, dimulai dari resolusi kecil hingga besar. Strategi ini mempercepat konvergensi awal dan membantu model beradaptasi secara efisien terhadap fitur beresolusi tinggi pada tahap akhir pelatihan [14]. Sementara itu, *adaptive regularization* bertujuan menyesuaikan parameter regularisasi pada lapisan CNN secara adaptif berdasarkan variasi fitur yang diekstraksi di tiap lapisan, sehingga distribusi bobot menjadi lebih seimbang dan performa model tetap stabil [15]. Pada penelitian ini

digunakan EfficientNetV2-S, yang memiliki ukuran model 88 MB dengan 43 layer dan sekitar 22 juta parameter. Arsitektur EfficientNetV2-S dapat dilihat pada Gambar 2.

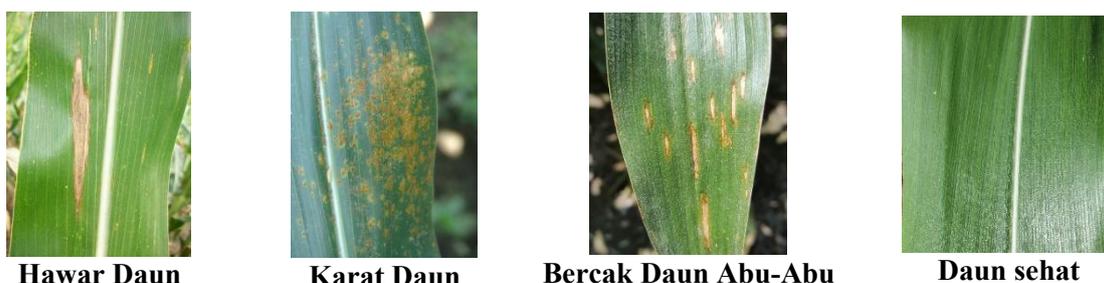


Gambar 2 Arsitektur EfficientNetV2-S

Pada Gambar 2, tahapan arsitektur model EfficientNetV2-S terdiri dari beberapa blok konvolusi dan tahapan utama. Pada tahapan awal, digunakan konvolusi 3×3 sebagai lapisan dasar untuk mengekstraksi fitur sederhana dari citra masukan, yang kemudian distabilkan dengan *Batch Normalization* sebelum masuk ke tahap berikutnya. Selanjutnya, jaringan dibagi ke dalam beberapa tahapan dengan kombinasi blok *Fused MBConv* dan *MBConv*, dimulai dari *Fused MBConv1* untuk menangkap pola dasar, kemudian dilanjutkan dengan beberapa blok *Fused MBConv4* yang berfungsi mengekstraksi fitur menengah. Pada tahap berikutnya, digunakan *Fused MBConv4* dengan mekanisme *SE (Squeeze and Excitation)* untuk memberikan perhatian lebih pada kanal fitur penting, serta *Fused MBConv6* dengan *SE* yang memiliki kompleksitas lebih tinggi untuk memperoleh representasi citra tingkat lanjut. Setelah melewati rangkaian blok tersebut, arsitektur diakhiri dengan lapisan konvolusi 1×1 untuk mereduksi dimensi fitur, dilanjutkan dengan *Global Average Pooling* untuk merangkum informasi spasial, kemudian diproses melalui lapisan *FE (Fully Connected)*. Hasil akhir diproyeksikan ke dalam *Logits* dengan aktivasi *Softmax* untuk menentukan kelas penyakit daun jagung.

C. Pengumpulan Data

Dataset yang digunakan berasal dari *Corn or Maize Leaf Disease Dataset* yang tersedia di Kaggle [16]. Total terdapat 2.256 citra daun jagung yang dikelompokkan ke dalam empat kelas: Hawar Daun, Karat Daun, Bercak Daun Abu-Abu, dan Daun Sehat. Masing-masing kelas terdiri dari 754 gambar. Contoh citra dataset ditunjukkan pada Gambar 3.



Hawar Daun

Karat Daun

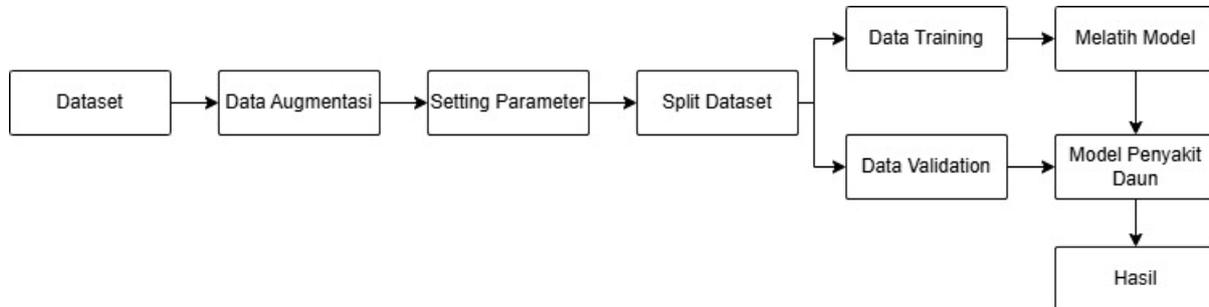
Bercak Daun Abu-Abu

Daun sehat

Gambar 3 Citra Dataset

D. Preprocessing

Tahapan *preprocessing* dimulai dengan proses pengumpulan dataset dan diakhiri dengan memperoleh hasil berupa model yang dapat digunakan untuk pengembangan aplikasi untuk pengembangan kegiatan penelitian selanjutnya, proses ini dapat dilihat pada Gambar 4.



Gambar 4 Preprocessing

Seperti terlihat pada Gambar 4, alur *preprocessing* ditunjukkan melalui sejumlah tahap, yaitu: (1) Dataset diaugmentasikan untuk meningkatkan variasi dataset. (2) Persiapan pelatihan model dilakukan *setting* parameter dengan mengkonfigurasi hyperparameter untuk meningkatkan hasil performa yang terbaik. (3) Dataset dibagi menjadi 2 bagian yaitu data pelatihan untuk melatih model mengenali pola penting pada gambar daun jagung, dan data validasi guna menilai kinerja model melalui metrik evaluasi seperti akurasi, presisi, *recall*, serta *F1-score*.

E. Implementasi

Implementasi model arsitektur EfficientNetV2-S ke dalam kode program akan menggunakan *platform google colab* dengan bahasa pemrograman *python*.

F. Pengujian

Pada tahap ini, penulis melakukan pengujian dengan membuat model dengan menggunakan variasi epoch-50, epoch-150, dan epoch 200. Kegiatan ini dilakukan dengan tujuan memperoleh model terbaik dengan nilai epoch yang sesuai.

G. Evaluasi

Pada tahap ini, evaluasi performa sistem dilakukan dengan menggunakan *confusion matrix* [17]. Matriks ini menjadi dasar untuk memperoleh berbagai metrik evaluasi, di antaranya akurasi, presisi, *recall*, dan *F1-score*. Nilai-nilai tersebut dihitung berdasarkan distribusi prediksi yang dihasilkan model, sebagaimana dirumuskan pada Persamaan (1), (2), (3), dan (4).

Akurasi menunjukkan seberapa andal sistem dalam mengklasifikasikan objek. Dengan kata lain, akurasi menilai kedekatan hasil prediksi model terhadap nilai sebenarnya. Perhitungan nilai akurasi dapat dilakukan menggunakan Persamaan (1).

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

Presisi merupakan perbandingan antara jumlah kasus positif yang berhasil diprediksi dengan benar (*True Positive*) dan keseluruhan data yang diprediksi positif oleh model. Metrik ini digunakan untuk menilai ketepatan model dalam mengenali kasus positif. Nilai presisi dihitung melalui Persamaan (2).

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

Recall digunakan untuk mengukur kemampuan model dalam mengenali semua data yang seharusnya positif. Dengan kata lain, recall menunjukkan rasio kasus positif yang diprediksi dengan benar (*True Positives*) terhadap semua kasus positif yang sebenarnya. Nilai *recall* dapat diperoleh menggunakan Persamaan (3).

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

F1-Score merepresentasikan keseimbangan antara nilai presisi dan *recall*. Rentang metrik ini berada pada 0 hingga 1, dengan nilai yang semakin mendekati 1 menandakan kinerja sistem yang semakin optimal. Perhitungannya dilakukan menggunakan Persamaan (4).

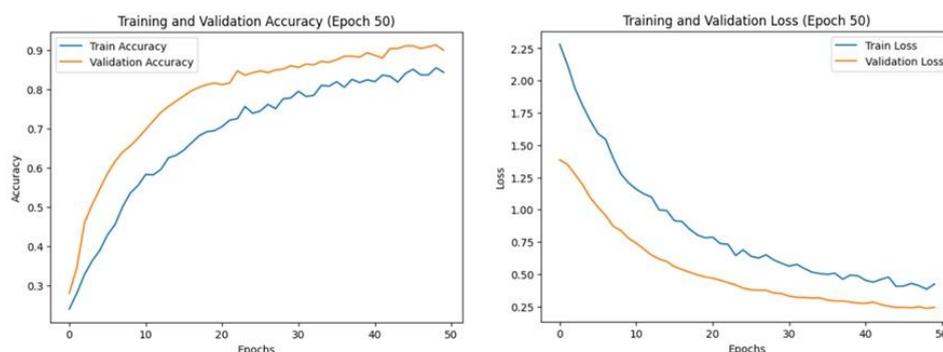
$$F1 - Score = 2 \times \frac{Recall \times Presisi}{Recall + Presisi} \quad (4)$$

Hasil dan Pembahasan

Pada tahap ini disajikan hasil pengujian model klasifikasi penyakit daun jagung menggunakan arsitektur EfficientNetV2-S. Pengujian dilakukan dengan menggunakan dataset berjumlah 2.256 citra daun jagung yang dikelompokkan ke dalam 4 kelas, yaitu hawar daun, karat daun, bercak daun abu-abu, dan daun sehat, dengan masing-masing kelas berisi 754 gambar. Sebelum dilakukan pelatihan, dataset melalui proses augmentasi dengan melakukan rotasi, pergeseran posisi, perubahan skala, distorsi, serta pembalikan citra secara horizontal. Selanjutnya dilakukan *preprocessing* dengan mengubah ukuran citra menjadi 224×224 piksel, kemudian dataset dibagi menjadi 2 bagian, yaitu 80% untuk data pelatihan dan 20% untuk data validasi. *Setting* parameter model meliputi *batch size* 32, optimizer Adam, *learning rate* 0,000005, *dense layer* 256 dan 128, *dropout rate* 0,4 dan 0,3, dengan total pelatihan sebanyak 200 *epoch* dengan perbandingan kinerja pada saat mencapai *epoch*-50, *epoch*-150 dan *epoch*-200. Berikut hasil dari pengujian proses pelatihan model yang telah dilakukan dengan beberapa variasi *epoch*:

Tabel 1 Hasil Perbandingan Kinerja Berdasarkan *Epoch*

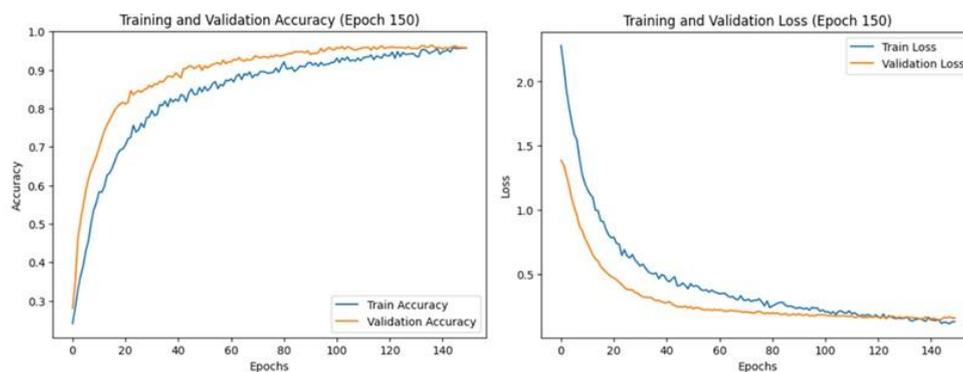
Epoch	Akurasi	Loss	Validasi Akurasi	Validasi Loss
50	0.8412	0.4246	0.8991	0.2445
150	0.9610	0.1118	0.9561	0.1563
200	0.9766	0.0794	0.9627	0.1570



Gambar 5 Grafik Akurasi dan Loss pada Epoch-50

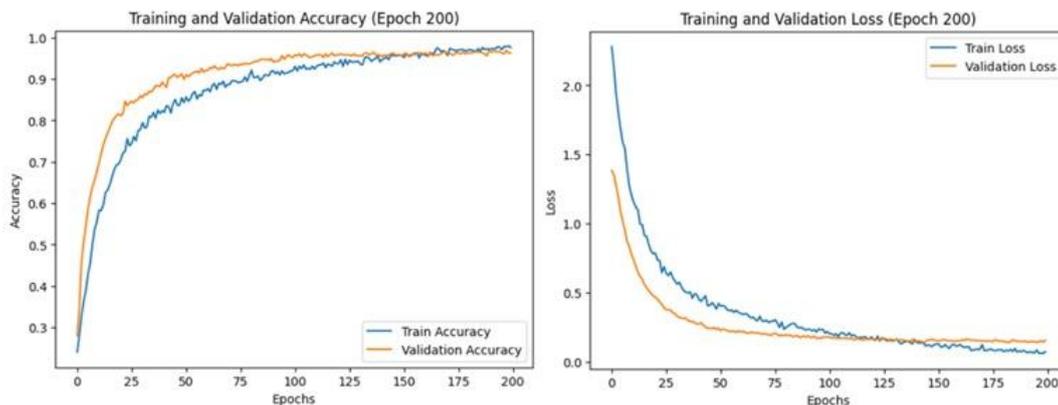
Hasil pada Tabel 1 menunjukkan bahwa performa model meningkat seiring bertambahnya *epoch*. Namun, titik optimal justru dicapai pada *epoch* ke-150, dengan akurasi 96,10% dan *loss* 0,1118, serta akurasi validasi 95,61% dan *loss* validasi 0,1563. Pada *epoch* ke-200, meskipun akurasi pelatihan terus meningkat hingga 97,66%, nilai *loss* validasi cenderung stagnan, yang menandakan potensi terjadinya *overfitting*.

Pada Gambar 5 *epoch* ke-50 menunjukkan bahwa model masih dalam tahap peningkatan performa yang dapat dilihat pada grafik *training loss* dan *validation loss* menunjukkan tren menurun yang cukup konsisten.



Gambar 6 Grafik Akurasi dan *Loss* pada Epoch-150

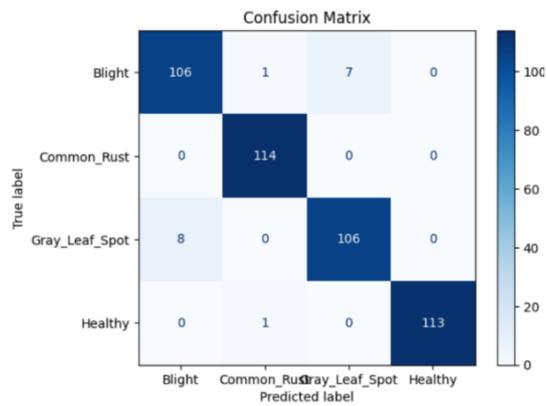
Pada Gambar 6 *epoch* ke-150 memperlihatkan bahwa akurasi pelatihan dan validasi sudah sangat tinggi mendekati 96%. Jarak antar kurva akurasi pelatihan dan validasi relatif kecil menandakan model stabil. Grafik *training loss* dan *validation loss* sudah cukup rendah dan stabil. Ini adalah titik optimal model mencapai performa tertinggi tanpa *overfitting*.



Gambar 7 Grafik Akurasi dan *Loss* pada Epoch-200

Pada Gambar 7 *epoch* ke-200 memperlihatkan kurva akurasi yang terus naik melebihi 97% dan kurva validasi merata di 96%. *Training loss* terus turun tetapi *validation loss* merata di 0.1474. pada *epoch* ke-200 ada potensi *overfitting* dari segi performa pelatihan meningkat tetapi validasinya tidak berkembang.

Confusion matrix menunjukkan hasil pengujian model menggunakan data pelatihan dan validasi, dengan memprediksi keluaran untuk kelas daun sehat, hawar daun, karat daun, dan bercak daun abu-abu sesuai dengan label aslinya, seperti ditunjukkan pada Gambar 8.



Gambar 8 Confusion Matrix Melatih Model

Pada hasil *classification report* didapatkan hasil pengujian model berupa nilai presisi, *recall*, *F1-score* pada tiap-tiap kelas dan nilai akurasi dari model ini yang dapat dilihat pada Tabel 2.

Tabel 2 Classification Report Model

	Precision	Recall	F1-Score
Blight	0.93	0.93	0.93
Common Rust	0.98	1.00	0.99
Gray Leaf Spot	0.94	0.93	0.93
Healthy	1.00	0.99	1.00
Accuracy			0.96

Hasil yang diperoleh yaitu menggunakan epoch 50 menghasilkan akurasi sebesar 0,8412, loss sebesar 0,4246, validasi akurasi sebesar 0,8991 dan validasi loss sebesar 0,2445, untuk epoch 150 menghasilkan akurasi sebesar 0,9610, loss sebesar 0,1118, validasi akurasi sebesar 0,9561 dan validasi loss sebesar 0,1567. Serta untuk epoch 200 menghasilkan akurasi sebesar 0,9766, loss sebesar 0,0794, validasi akurasi sebesar 0,9627 dan validasi loss sebesar 0,1570. Untuk hasil evaluasi yang dilakukan terhadap setiap kelas yang ada dengan menggunakan Precesion, Recall dan F1-Score menghasilkan seperti tersaji pada Tabel 2.

Kesimpulan

Berdasarkan penelitian yang telah dilakukan yaitu tentang klasifikasi tanaman jagung berdasarkan citra daun dengan menggunakan Algoritma EfficientNetV2-S serta dataset daun jagung sebanyak 2256 citra dan kelas yang digunakan 4 yaitu blight, common rust, grey leaf spot dan healthy, dengan parameter meliputi *batch size* 32, *epoch* yang digunakan yaitu 50, 150 dan 200, *learning rate* 0,000005, *dense* 256 dan 128, *dropout rate* 0,4 dan 0,3. Hasil yang diperoleh yaitu epoch 200 memiliki akurasi yang cukup tinggi yaitu sebesar 97,66%. Akan tetapi, jika epoch terus ditingkatkan, terlihat pada grafik hasil yang diperoleh akan menuju ke titik overfitting. Pilihan terbaik untuk model yang digunakan yaitu dengan epoch 150, hal ini dikarenakan di epoch 150 sudah mendekati titik puncak perpotongan akurasi testing dan akurasi validasi.

Saran

Penelitian ini memberikan beberapa saran untuk pengembangan pada penelitian selanjutnya. Pertama, menggunakan dataset yang lebih beragam sehingga proses klasifikasi dapat mencapai tingkat akurasi yang lebih tinggi. Selain itu, untuk meminimalkan kemungkinan terklasifikasinya objek selain daun jagung, penelitian selanjutnya dapat difokuskan pada klasifikasi berbasis karakteristik morfologi daun, seperti struktur tulang daun atau ukuran serta bentuk daun jagung.

Daftar Pustaka

- [1] U. D. Rosiani, C. Rahmad, M. A. Rahmawati, and F. Tupamahu, "Segmentasi berbasis k-means pada deteksi citra penyakit daun tanaman jagung," *Jurnal Informatika Polinema*, vol. 6, no. 3, pp. 37–42, May 2020, doi: 10.33795/jip.v6i3.331.
- [2] D. Iswanto and D. Handayani UN, "Klasifikasi penyakit tanaman jagung menggunakan metode convolutional neural network (CNN)," *Jurnal Ilmiah Universitas Batanghari Jambi*, vol. 22, no. 2, p. 900, Jul. 2022, doi: 10.33087/jiubj.v22i2.2065.
- [3] F. U. Rehman *et al.*, "Seed-borne fungal diseases of maize (*Zea mays* L.): A review," *Agrinula : Jurnal Agroteknologi dan Perkebunan*, vol. 4, no. 1, pp. 43–60, Feb. 2021, doi: 10.36490/agri.v4i1.123.
- [4] H. Hamidson, S. Suwandi, and T. A. Effendy, *Perkembangan beberapa penyakit daun jagung disebabkan oleh jamur di kecamatan indralaya utara kabupaten ogan ilir*. 2019. Accessed: Oct. 23, 2024. [Online]. Available: <https://conference.unsri.ac.id/index.php/lahansuboptimal/article/view/1585>
- [5] W. G. Pamungkas, M. I. P. Wardhana, Z. Sari, and Y. Azhar, "Leaf image identification: CNN with efficientnet-b0 and resnet-50 used to classified corn disease," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 7, no. 2, pp. 326–333, Mar. 2023, doi: 10.29207/resti.v7i2.4736.
- [6] M. Fadli and R. A. Saputra, "Klasifikasi dan Evaluasi Performa Model Random Forest untuk Prediksi Stroke," *Jurnal Teknik*, vol. 12, no. 2, pp. 72–80, Oct. 2023, [Online]. Available: <http://jurnal.umt.ac.id/index.php/jt/index>
- [7] N. Z. Munantri, H. Sofyan, and M. Y. Florestiyanto, "Aplikasi pengolahan citra digital untuk identifikasi umur pohon," *Telematika*, vol. 16, no. 2, p. 97, Jan. 2020, doi: 10.31315/telematika.v16i2.3183.
- [8] Z. J. Wang *et al.*, "CNN explainer: Learning convolutional neural networks with interactive visualization," *IEEE Trans Vis Comput Graph*, vol. 27, no. 2, pp. 1396–1406, Feb. 2021, doi: 10.1109/TVCG.2020.3030418.
- [9] M. Tan and Q. V. Le, "Efficientnetv2: Smaller models and faster training," Apr. 2021, [Online]. Available: <http://arxiv.org/abs/2104.00298>
- [10] F. Sarasati, F. S. Nugraha, and U. Radiyah, "Pemanfaatan metode deep learning untuk klasifikasi penyakit pada tanaman jagung," *Jurnal Infortech*, vol. 4, no. 2, pp. 133–138, Dec. 2022, Accessed: Oct. 25, 2024. [Online]. Available: <https://ejournal.bsi.ac.id/ejournal/index.php/infortech/article/view/13898/0>
- [11] R. P. S. Putra, C. S. K. Aditya, and G. W. Wicaksono, "HERBAL LEAF CLASSIFICATION USING DEEP LEARNING MODEL EFFICIENTNETV2B0," *JITK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, vol. 9, no. 2, pp. 301–307, Feb. 2024, doi: 10.33480/jitk.v9i2.5119.
- [12] K. Putri Ramadhani and M. Tarigan, "IMPLEMENTASI METODE CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI PENYAKIT DAUN MANGGA MENGGUNAKAN ARSITEKTUR EFFICIENTNETV2-S DAN RESNET50," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 3, pp. 4135–4143, May 2025, doi: 10.36040/jati.v9i3.13571.
- [13] Audy and Zaini, "Analisis Kualitas Jagung Berbasis IoT dengan Penerapan Model SSD Mobilenet dan Histogram," *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, vol. 11, no. 2, pp. 79–87, May 2022, doi: 10.22146/jnteti.v11i2.3434.

- [14] R. S. Sandhya Devi, V. R. Vijay Kumar, and P. Sivakumar, “EfficientNetV2 Model for Plant Disease Classification and Pest Recognition,” *Computer Systems Science and Engineering*, vol. 45, no. 2, pp. 2249–2263, 2023, doi: 10.32604/csse.2023.032231.
- [15] A. Samavat, E. Khalili, B. Ayati, and M. Ayati, “Deep Learning Model With Adaptive Regularization for EEG-Based Emotion Recognition Using Temporal and Frequency Features,” *IEEE Access*, vol. 10, pp. 24520–24527, 2022, doi: 10.1109/ACCESS.2022.3155647.
- [16] S. Ghose, “Corn or Maize Leaf Disease Dataset,” Kaggle.
- [17] A. B. Prakosa, Hendry, and R. Tanone, “IMPLEMENTASI MODEL DEEP LEARNING CONVOLUTIONAL NEURAL NETWORK (CNN) PADA CITRA PENYAKIT DAUN JAGUNG UNTUK KLASIFIKASI PENYAKIT TANAMAN,” *Jurnal Pendidikan Teknologi Informasi (JUKANTI)*, vol. 6, no. 1, pp. 107–116, Apr. 2023.