

KLASIFIKASI CITRA PENYAKIT DAUN JAGUNG MENGGUNAKAN ALGORITMA CNN EFFICIENTNET

Rajnapramitha Kusumastuti¹⁾, Tommy Dwi Putra²⁾, Zaky Zulfahmi Yudam³⁾

STMIK AMIKOM Surakarta, Sukoharjo

Jawa Tengah

Email: ¹⁾rajna.paramitha@gmail.com, ²⁾tommy.1242@students.amikom.ac.id,

³⁾zaky.zul@mhs.amikomsolo.ac.id

Dikimkan: 26 Pebruari 2024

Diterima: 25 April 2024

Abstrak

Tanaman jagung termasuk jenis makanan pokok dengan jumlah konsumsi tinggi sebagai makanan pokok yang ada di Indonesia. Dengan jumlah konsumsi yang tinggi, maka produksi tanaman jagung juga memiliki tingkat tanam yang juga tinggi. Untuk mengidentifikasi jenis penyakit daun dalam skala tanam yang besar tidak mudah dilakukan dengan cara manual karena membutuhkan ketelitian dan memakan waktu yang cukup lama. Penelitian ini bertujuan untuk mengidentifikasi penyakit daun jagung menggunakan metode convolutional neural network (CNN) dengan arsitektur efficientNetB1, efficientNetB2, dan efficientNetB3. Penelitian menggunakan dataset sebanyak 4118 citra dengan ukuran 260 x 260 dan membagi dataset dengan persentase data pelatihan sebesar 80% dengan 10% data uji dan 10% data validasi. Hasil pengujian menunjukkan arsitektur dari efficientNet memiliki nilai akurasi yang tinggi sebesar 97.77%.

Kata kunci: CNN, Penyakit Daun Jagung, Karat Daun, efficientNet.

Abstract

Maize is a staple food with high consumption as the main staple food in Indonesia. With a high amount of consumption, the production of corn plants also has a high planting level. Identifying the type of leaf disease on a large planting scale is not easy to do manually because it requires accuracy and takes a long time. This study aims to identify corn leaf diseases using the convolutional neural network (CNN) method with efficientNetB1, efficientNetB2, and efficientNetB3 architectures. The study used a dataset of 4118 images with a size of 260 x 260 and divided the dataset with a training data percentage of 80% with 10% test data and 10% validation data. The test results show that the architecture of efficientNet has a high accuracy value of 97.77%.

Keyword: CNN, Maize Leaf Disease, Leaf Rust, efficientNet.

PENDAHULUAN

Tumbuhan, sebagai anggota *kingdom Plantae*, hadir dalam berbagai macam organisme yang dapat dikenali, seperti semak, pohon, tumbuhan, alga, pakis, lumut, dan rerumputan. Salah satu bagian penting pada tubuh tumbuhan adalah daun. Daun mempunyai ciri warna hijau dan mengandung

klorofil, zat yang memungkinkan tumbuhan menangkap sinar matahari untuk fotosintesis. Fungsi utama daun selain mengumpulkan cahaya juga memberikan energi bagi pertumbuhan dan perkembangan tanaman. Dengan melakukan fotosintesis, daun berperan penting dalam menyediakan nutrisi dan energi yang diperlukan

untuk pertumbuhan dan kelangsungan hidup tanaman[1].

Tumbuhan jagung merupakan salah satu sumber pangan utama dunia, termasuk Indonesia, tumbuh optimal di daerah dengan curah hujan rendah hingga sedang, dengan memberikan perhatian khusus pada curah hujan pada tahun-tahun sebelumnya. Meskipun jagung memiliki kemampuan beradaptasi yang baik terhadap kondisi lingkungan, namun dalam siklus pertumbuhannya, setiap bagian tanaman rentan terhadap penyakit yang berbeda-beda. Penyakit-penyakit tersebut dapat menurunkan kualitas dan kuantitas hasil panen. Oleh karena itu, pengelolaan tanaman jagung memerlukan perhatian yang cermat terhadap upaya pencegahan dan pengendalian penyakit agar dapat menjamin hasil yang optimal pada masa pertumbuhan[2].

Patologi mengenai penyakit tumbuhan merupakan ilmu tentang perlindungan tumbuhan yang menjelaskan tentang faktor-faktor yang dapat merugikan tumbuhan. Kerusakan akibat serangan biologis pada bagian tubuh tumbuhan, terutama bagian luar atau sekitarnya. Organisme ini menginfeksi bagian tubuh tumbuhan misalnya daun, batang dan akar misalnya jamur, bakteri, virus, serangga seperti ulat. Gangguan seperti pengaruh gulma yang berkompetisi dalam mendapatkan air, nutrisi, cahaya dan kebutuhan biologis. Penelitian tersebut menjelaskan bahwa penyakit tanaman merupakan penyakit yang paling sering merugikan tanaman. Pada tanaman sejenis kita melihat penyakit serupa yang memiliki nama serupa, misalnya karat daun kopi. Serangan ini akan menurunkan kemampuan tanaman dalam melakukan fotosintesis, sehingga ketika kemampuan fotosintesis menurun 20-40%, bahkan mungkin lebih besar lagi, membuat usaha petani menjadi kurang efektif, bahkan hilang[3].

Penyakit jagung yang penting antara lain karat daun yang disebabkan oleh *Puccinia Sorghi Schwein* dan hawar daun yang disebabkan oleh *Helmithosporium turcicum*. Karat daun disebabkan oleh jamur *Puccinia sorghi*. Tanda-tanda pertama muncul berupa bintik-bintik merah dan penampakan seperti bubuk berwarna kuning

kecokelatan. Akibat penyakit ini, tanaman tidak dapat melakukan fotosintesis dengan sempurna, perkembangannya melambat bahkan bisa mati. *Puccinia sorghi* paling umum ditemukan di pegunungan tropis dan daerah beriklim sedang. Kerusakan akibat penyakit ini mencapai 70%. Hawar daun merupakan penyakit penting pada jagung dan telah menyebar ke banyak negara di Amerika, Asia, Afrika dan Eropa. Kerusakan akibat penyakit ini mencapai 50%. Pada tahap awal peradangan, gejalanya tampak berupa bercak kecil berbentuk oval, kemudian bercak tersebut terus memanjang berbentuk elips dan menjadi nekrotik disebut luka bakar yang berwarna biru, abu-abu atau coklat[4].

Ada berbagai cara mengidentifikasi penyakit pada tanaman jagung, selama ini Petani menggunakan observasi manual untuk mengidentifikasi penyakit pada tanaman jagung. Dengan perkembangan teknologi informasi yang sangat pesat di era ini, dapat memberikan solusi terhadap permasalahan-permasalahan umum yang muncul khususnya di berbagai aspek kehidupan manusia, tentu menjadi tantangan bagi seorang pengembang teknologi informasi untuk menciptakan suatu sistem yang mampu menyelesaikan permasalahan di atas. Pemanfaatan teknologi informasi untuk mendukung identifikasi penyakit yang dahulu dilakukan petani secara manual, kini dapat dilakukan dengan cepat dan akurat. Berdasarkan permasalahan tersebut tentunya menjadi tantangan bagi seorang pengembang teknologi informasi untuk menciptakan suatu sistem yang dapat menyelesaikan permasalahan di atas. Teknologi informasi diharapkan dapat membentuk suatu sistem yang mampu mengenali penyakit. Dalam teknik pengolahan citra, terdapat metode untuk mendeteksi penyakit pada daun tanaman agar dapat membedakan antara citra daun yang sehat dan yang tidak. Salah satu metode untuk mengidentifikasi penyakit pada tanaman jagung adalah *Convolutional Neural Network (CNN)*[5].

Pengolahan citra digital merupakan suatu teknik pengolahan citra yang bertujuan untuk meningkatkan kualitas suatu citra agar mudah diinterpretasikan oleh manusia atau komputer, baik

dalam bentuk foto maupun gambar animasi. Pengolahan citra merupakan salah satu cabang ilmu kecerdasan buatan yang menggunakan objek visual dalam bentuk digital untuk memecahkan masalah. Metode gambar dapat digunakan untuk perhitungan matematis pada piksel atau objek geometris. Setiap objek gambar mempunyai nilai tersendiri yang dapat dihitung secara matematis, sehingga mewakili karakteristik yang berbeda antara satu objek dengan objek lainnya. Ciri khas setiap benda dapat ditentukan dari warna, tekstur atau bentuknya. Dengan menggunakan informasi numerik ini, pengelompokan atau pengelompokan dapat dilakukan pada objek[6].

Klasifikasi adalah pengelompokan secara sistematis terhadap benda, gagasan, buku, dan benda lain ke dalam kategori atau kelompok tertentu berdasarkan kesamaan ciri. Dalam klasifikasi, dua tugas utama yang dilakukan adalah membangun model sebagai prototipe untuk disimpan dalam memori dan menggunakannya untuk melakukan pengenalan/klasifikasi/prediksi pada objek data lain untuk menemukan objek data tersebut termasuk dalam kelompok manakah model telah disimpan. Klasifikasi dikenal juga dengan metode alokasi dengan tujuan menyeleksi atau memasukkan pengamatan (objek baru) ke dalam kelompok-kelompok yang telah mempunyai label kelompok[7].

Convolutional Neural Network (CNN) merupakan salah satu jenis algoritma *Deep Learning* yang khusus dirancang untuk memproses dan mengenali informasi dalam gambar. Dalam konteks ini, CNN memiliki kemampuan untuk menerima input berupa gambar dan secara otomatis menentukan aspek atau obyek yang ada dalam gambar tersebut. Melalui proses pembelajaran, CNN memungkinkan mesin untuk mengenali pola-pola yang kompleks dan membedakan antara satu gambar dengan gambar lainnya. Keunggulan utama CNN terletak pada kemampuannya meniru sistem pengenalan citra di korteks visual manusia, yang membuatnya sangat efektif dalam mengolah informasi citra. Dengan hasil yang signifikan dalam pengenalan citra, CNN telah menjadi fondasi penting dalam berbagai

aplikasi, termasuk pengenalan objek, klasifikasi gambar, dan pemrosesan citra secara umum[8].

Beberapa penelitian lainnya terkaikait klasifikasi CNN antara lain, Penelitian terkait penyakit jagung yang mendapatkan data utama dari Github dan setelah mengumpulkan data, dataset tersebut diklasifikasikan secara manual. Pemrosesan dan analisis data dilakukan menggunakan model dasar CNN dan pembelajaran transfer menggunakan VGG16. Hasil implementasi menunjukkan kinerja sangat baik, akurasi dan validasi mencapai 98% dan 97%. Akurasi model dan grafik kerugian, seperti yang ditunjukkan, memberikan representasi visual keberhasilan model. Dengan hasil tersebut, dapat disimpulkan bahwa jaringan saraf konvolusional mampu mendeteksi penyakit pada jagung secara efektif, mencapai akurasi lebih dari 90%, dan dapat diuji bersama dengan banyak kumpulan data lainnya[9].

Penelitian lainnya berikaitan dengan klasifikasi menggunakan arsitektur *EfficiencyNetB0* pada jagung dan penyakit daun jagung. Hasil klasifikasi menunjukkan tingkat akurasi yang baik, mencapai 96%, dipengaruhi oleh *hyperparameter* yang ditentukan dalam arsitektur. Hyperparameter ini mencakup parameter seperti include top, bobot *Imagenet*, ukuran kumpulan, lapisan, pengoptimal, kecepatan pembelajaran dasar, aktivasi, kehilangan, ukuran gambar, ukuran *file batch*, *epoch.raw*, dan simpan model. Dengan menggunakan metode konfusi matriks untuk mengevaluasi performa model, ditemukan bahwa setiap kelas memiliki tingkat akurasi di atas 90%, namun terdapat juga prediksi yang tidak akurat pada beberapa gambar. Kesimpulannya, penelitian tersebut berhasil mengklasifikasikan penyakit jagung menggunakan deep learning, dengan akurasi maksimum sebesar 96%, dan menunjukkan bahwa hasil evaluasi secara umum menunjukkan model fit yang baik[10].

Peneliti lainnya menguraikan data gambar yang digunakan dalam penelitian, terdiri dari 900 data gambar dengan tiga jenis penyakit jagung, yaitu hawar daun, bercak daun, dan karat daun. Proses training melibatkan penggunaan arsitektur CNN dengan variasi ukuran kernel dan algoritma optimasi. Hasil pengujian menunjukkan bahwa

ukuran kernel 3x3 dengan algoritma optimasi Adam mencapai tingkat akurasi tertinggi, yaitu 89% untuk data train dan 84% untuk data test. Proses testing menghasilkan nilai presisi tertinggi sebesar 97% untuk model dengan ukuran kernel 3x3. Penelitian ini memberikan simpulan bahwa model CNN dengan konfigurasi tersebut efektif dalam mengklasifikasikan penyakit pada daun jagung. Meskipun demikian, penelitian ini masih memiliki ruang untuk pengembangan, seperti mencoba model atau algoritma optimasi lainnya, serta mempertimbangkan penambahan jenis penyakit dalam klasifikasi untuk meningkatkan keakuratan sistem[11].

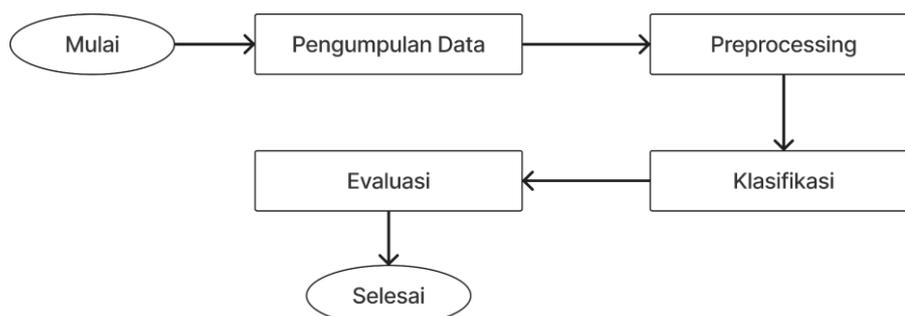
Penelitian lainnya menggali potensi penerapan Convolutional Neural Network (CNN) dengan fokus pada arsitektur *EfficientNet* (B3, B4, dan B5), dalam mengidentifikasi penyakit pada berbagai macam daun tanaman. Prosesnya mencakup pra-pemrosesan dataset untuk menangani ketidakseimbangan data, pelatihan model dengan empat tahap yang berbeda, dan pengujian untuk mengevaluasi keberhasilan model. Hasil pelatihan menunjukkan kinerja yang baik, terutama pada versi *EfficientNet-B4* dengan akurasi mencapai 99.78%. Evaluasi model menggunakan matriks dan hasil klasifikasi menghasilkan gambaran yang jelas mengenai presisi, *recall*, *f1-score*, dan akurasi.

Temuan ini menunjukkan potensi besar model *deep learning*, terutama *EfficientNet*, dalam memprediksi penyakit tanaman melalui analisis gambar daun dengan tingkat akurasi yang tinggi[12].

Penelitian ini fokus pada penerapan Convolutional Neural Network (CNN) dengan arsitektur *EfficiencyNet* untuk mengidentifikasi penyakit yang befokus pada tanaman jagung. Daun sebagai salah satu bagian penting tubuh tumbuhan berperan penting dalam fotosintesis dan menyediakan energi bagi pertumbuhan tanaman. Tanaman jagung yang merupakan sumber pangan utama rentan terhadap berbagai penyakit seperti karat dan hawar daun yang dapat menurunkan hasil panen secara signifikan. Penelitian ini menyajikan solusi komputasi untuk mengatasi tantangan tersebut, menggunakan metode (CNN) dan arsitektur *EfficiencyNet* untuk mengklasifikasikan penyakit pada daun jagung.

METODE PENELITIAN

Dalam penelitian ini, terdapat 4 tahapan penelitian yang dimulai dari pengumpulan data, *preprocessing*, klasifikasi, dan evaluasi. Rancangan model pada penelitian ini seperti pada gambar 1.



Gambar 1. Alur Penelitian

1. Pengumpulan Data

Dataset yang digunakan berupa data citra dari 4 jenis kelas daun jagung sebanyak 4.188 data yang diperoleh dari kaggle. Untuk jumlah data tiap kelasnya sendiri berjumlah 1146 pada kelas *Blight*, *Common_Rust* berjumlah 1306, *Gray_Leaf_Spot*

berjumlah 574. Kelas dari jenis daun yang digunakan diantaranya jenis *Blight*, *Common_Rust*, *Gray_leaf_spot*, dan *Healty*. Sampel dari dataset yang digunakan dapat dilihat pada gambar 2. Pada penelitian ini, data gambar yang digunakan memiliki ukuran yang sama yaitu 260 x 260.



Gambar 2. Citra digital daun jagung

2. Preprocessing

Dalam penelitian yang berkaitan dengan klasifikasi penyakit daun jagung menggunakan model *EfficientNet*, *preprocessing* gambar merupakan langkah krusial untuk memastikan bahwa model dapat belajar dengan efektif dari data. Proses *preprocessing* gambar ini meliputi beberapa tahapan. Pertama, gambar-gambar dari daun jagung diubah ukurannya agar sesuai dengan input yang diperlukan oleh model *EfficientNet*, yang memastikan keseragaman dan memungkinkan model untuk memproses data secara efisien[13].

Kedua, teknik normalisasi diterapkan pada gambar untuk menyesuaikan skala piksel. Normalisasi ini penting untuk mengurangi varians dalam dataset dan membantu model untuk lebih fokus pada fitur penting dari gambar daripada perbedaan dalam intensitas atau distribusi warna. Selanjutnya, augmentasi data juga digunakan sebagai bagian dari *preprocessing*. Dalam konteks pengolahan gambar, augmentasi melibatkan modifikasi gambar melalui teknik seperti rotasi, pencerminan, pemotongan, atau penyesuaian warna. Ini membantu dalam menghasilkan dataset yang lebih beragam dan mengurangi risiko *overfitting*, karena model tidak

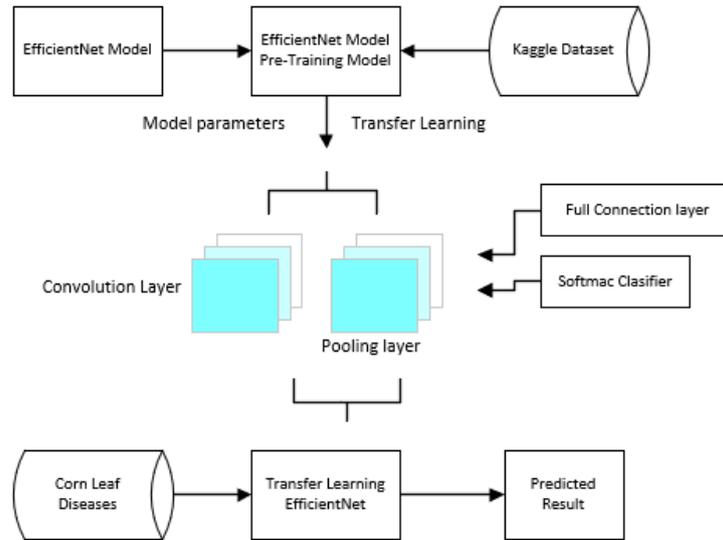
hanya belajar dari gambar asli tetapi juga dari variasi mereka[14].

Analisis ini digunakan untuk melakukan *preprocessing* gambar dengan merubah dimensi menjadi 260 x 260 Pixel. Setelah itu dilakukan *rescale* dan *perbesaran* serta *membalik* gambar. Dalam penelitian ini penulis menggunakan metode CNN dengan memanfaatkan model *EfficientNet-B1*, *EfficientNet-B2*, dan *EfficientNet-B3* sebagai model dasar dan membagi dataset dengan persentase data pelatihan sebesar 80% dengan 10% data uji dan 10% data validasi.

3. Klasifikasi

Convolutional Neural Network (CNN) merupakan salah satu metode pengembangan JST yang banyak diterapkan paa pengolahan citra. CNN telah mengalami perkembangan yang signifikan dalam pengenalan objek dan klasifikasi citra dibandingkan dengan metode yang lebih sederhana [8].

EfficientNet merupakan arsitektur dalam *Convolutional Neural Network* (CNN) yang dapat memprediksi dan mengklasifikasikan citra secara akurat [9]. Arsitektur dari *EfficientNet* dapat diperhatikan pada gambar 3.



Gambar 3. Arsitektur EfficientNet

EfficientNet memperkenalkan pendekatan baru dalam *scaling* model CNN. Tidak seperti pendekatan konvensional yang hanya meningkatkan kedalaman atau lebar model, *EfficientNet* secara sistematis menskalakan ketiga dimensi jaringan: kedalaman (*depth*), lebar (*width*), dan resolusi gambar (*resolution*). Ini dilakukan dengan menggunakan pendekatan yang disebut "*compound scaling*".

Arsitektur dasar *EfficientNet*, *EfficientNet-B0*, dikembangkan melalui proses pencarian arsitektur otomatis (*Neural Architecture Search, NAS*) yang berfokus pada optimasi efisiensi. Dari baseline ini, versi lain dari *EfficientNet* (B1-B7) dihasilkan melalui *compound scaling*, menawarkan keseimbangan antara akurasi dan efisiensi untuk berbagai ukuran dan kebutuhan [*Enhancing the performance of transferred efficientnet models in leaf image-based plant disease classification*]. Pada penelitian ini, percobaan yang dilakukan adalah menggunakan jenis model *EfficientNet-B1*, *EfficientNet-B2*, dan *EfficientNet-B3*.

4. Evaluasi

Matriks evaluasi merupakan sebuah matriks yang berisi nilai-nilai dari hasil pelatihan yang dilakukan. Matriks evaluasi digunakan untuk menentukan apakah model *machine learning* bekerja dengan baik atau perlu ditingkatkan. Dalam penelitian yang menggunakan *machine learning* dan *deep learning*, umumnya menggunakan 4 macam matriks untuk mengukur kinerja model, yaitu *accuracy*, *precision*, *recall* dan *f1-score*[15].

Accuracy mengukur seberapa banyak prediksi yang benar dari total prediksi, *precision* mengukur seberapa banyak data positif yang terklasifikasi benar dari total data yang diprediksi sebagai positif, *recall* mengukur seberapa banyak data positif yang terklasifikasi benar dari total data yang benar-benar positif, dan *F1 score* memberikan gambaran keseluruhan tentang kinerja model yang seimbang antara presisi dan *recall*. Pengukuran kinerja menggunakan Confusion Matrix, terdapat 4 (empat) istilah sebagai representasi hasil proses klasifikasi dapat diperhatikan pada Tabel 1.

Tabel 1. Perbandingan Nilai Matriks Evaluasi Ketiga Jenis Transfer Learning

Kelas	Terklasifikasi Positif	Terklasifikasi Negatif
Positif	TP (<i>True Positive</i>) data positif yang terdeteksi benar sebagai data positif	FN (<i>False Negative</i>) data positif namun terdeteksi sebagai data negative

Negatif	FP (<i>False Positive</i>) data negative namun terdeteksi sebagai data positif	TN (<i>True Negative</i>) data negative namun terdeteksi sebagai benar negatif
---------	--	--

HASIL DAN PEMBAHASAN

Berikut diberikan evaluasi dan pembahasan dari estimasi DoA menggunakan estimator AML baik untuk radar PA dan MIMO yang secara berurutan menggunakan ekspresi (7) dan (11). Di lain sisi untuk ekspresi estimator LS seperti yang diberikan oleh [10]. Baik estimator LS dan AML dari kedua jenis radar hasil evaluasinya disajikan dalam grafik dari modulus-amplitudo-kompleks (MAK) sebagai fungsi DoA dimana MAK ini sebanding dengan RCS target yang dinotasikan dengan $\hat{\sigma}(\theta)$. Untuk

kedua jenis radar multi-antena ini diberikan jumlah elemen antenanya adalah $K = L = 8$ elemen baik di Tx dan Rx yang spasinya antar elemen antena Tx-Rx berukuran setengah panjang gelombang.

Penelitian ini berhasil mengimplementasikan metode CNN dengan model transfer learning *EfficientNet-B1*, *EfficientNet-B2*, dan *EfficientNet-B3* untuk melakukan klasifikasi jenis penyakit daun jagung. Hasil dari penelitian ini dapat dilihat pada tabel 2 yang berisikan perbandingan dari tiap jenis transfer learning yang digunakan.

Tabel 2. Perbandingan Nilai Matriks Evaluasi Ketiga Jenis Transfer Learning

Matriks Evaluasi	EfficientNet B-1	EfficientNet B-2	EfficientNet B-3
Accuracy training value	0.9719	0.9788	0.9785
Accuracy validation value	0.9472	0.9777	0.9640
Training loss value	0.1072	0.0952	0.0939
Loss validation value	0.1178	0.0536	0.0891

Berdasarkan hasil eksperimen yang dilakukan pada Tabel 2 didapatkan bahwa arsitektur *EfficientNet-B2* mendapatkan accuracy training value tertinggi. Namun jika dibandingkan dengan arsitektur *EfficientNet-B1* dan *EfficientNet-B3*, ketiganya memiliki nilai yang tidak berselisih jauh. *Loss Value* memiliki fungsi untuk menghitung nilai kesalahan dari model yang dijalankan. Nilai *loss* paling rendah terdapat pada arsitektur *EfficientNet-B2*, hal ini menunjukkan bahwa dari percobaan ketiga tipe dari *EfficientNet*, model dari *EfficientNet-B2* memiliki hasil pengujian yang lebih baik dibandingkan dengan *EfficientNet-B1* dan *EfficientNet-B3*. Akan tetapi, dari ketiga arsitektur *EfficientNet* yang diuji tetap memiliki hasil akurasi yang baik.

Gambar 4, 5, dan 66 menunjukkan grafik dari hasil percobaan yang dilakukan. *EfficientNet-B1*, *B2*, dan *B3* menampilkan variasi dalam performa mereka yang dapat dijelaskan melalui karakteristik unik masing-masing model. Gambar 5 menunjukkan hasil dari percobaan menggunakan *EfficientNet-B1*,

akurasi pelatihan yang tinggi (0.9719) berbanding dengan akurasi validasi yang lebih rendah (0.9472), serta loss pelatihan (0.1072) yang lebih rendah dibanding loss validasi (0.1178), hal tersebut menjelaskan bahwa terjadinya kemungkinan overfitting ringan. Ini menunjukkan bahwa model pertama ini belajar dengan baik tetapi namun terlalu spesifik terhadap data pelatihan.

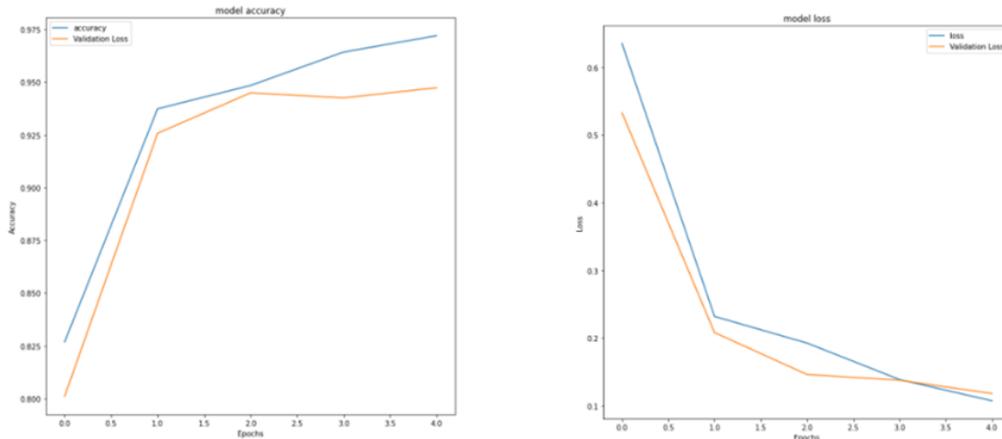
Merujuk pada gambar 5 pada percobaan menggunakan *EfficientNet-B2* menunjukkan konsistensi yang luar biasa antara pelatihan dan validasi, dengan akurasi pelatihan sebesar 0.9788 dan akurasi validasi 0.9777, serta loss pelatihan yang lebih rendah (0.0952) dibandingkan loss validasi (0.0536). Konsistensi ini menandakan bahwa model ke 2 ini menggeneralisasi dengan sangat baik, menghindari overfitting secara signifikan.

Sedangkan percobaan pada gambar 6 menggunakan *EfficientNet-B3*, meski memiliki akurasi pelatihan yang sangat tinggi (0.9785), terdapat penurunan

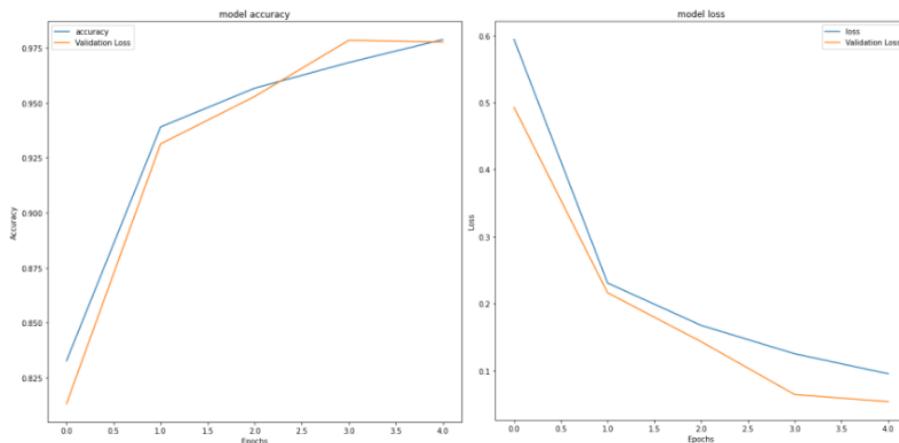
yang tidak terlalu besar dalam akurasi validasi (0.9640). Nilai *Loss* yang hampir setara antara pelatihan (0.0939) dan validasi (0.0891) menunjukkan bahwa model ini masih mampu melakukan generalisasi yang cukup baik, meskipun ada tanda-tanda awal *overfitting*.

Perbedaan dalam performa ini dapat dikaitkan dengan ukuran dan kompleksitas masing-masing model. Misalnya, *EfficientNet-B2* mungkin

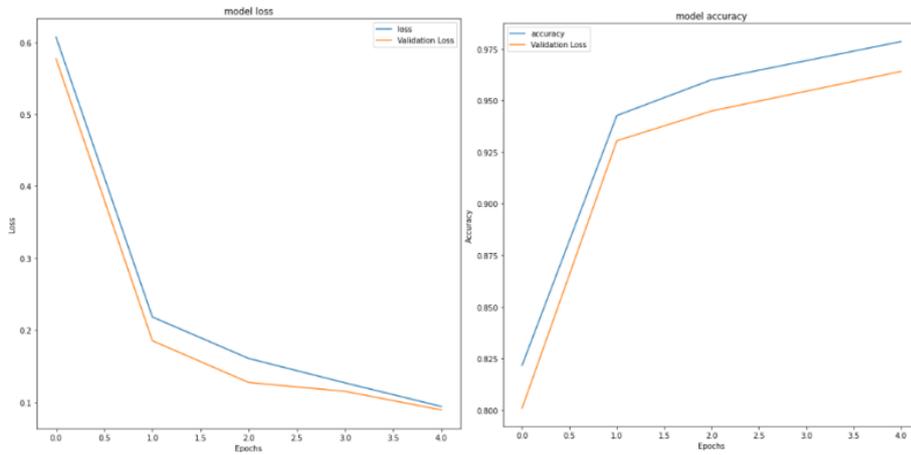
memiliki lebih banyak parameter atau struktur yang lebih kompleks dibandingkan *B1*, memungkinkannya menggeneralisasi lebih efektif. Di sisi lain, *B3* mungkin terlalu kompleks untuk dataset tertentu, yang menghasilkan *overfitting* ringan dan akurasi validasi yang sedikit lebih rendah.



Gambar 4. Hasil Akurasi, *Loss Training* dan *Validation Data EfficientNet B-1*



Gambar 5. Hasil Akurasi, *Loss Training* dan *Validation Data EfficientNet B-2*



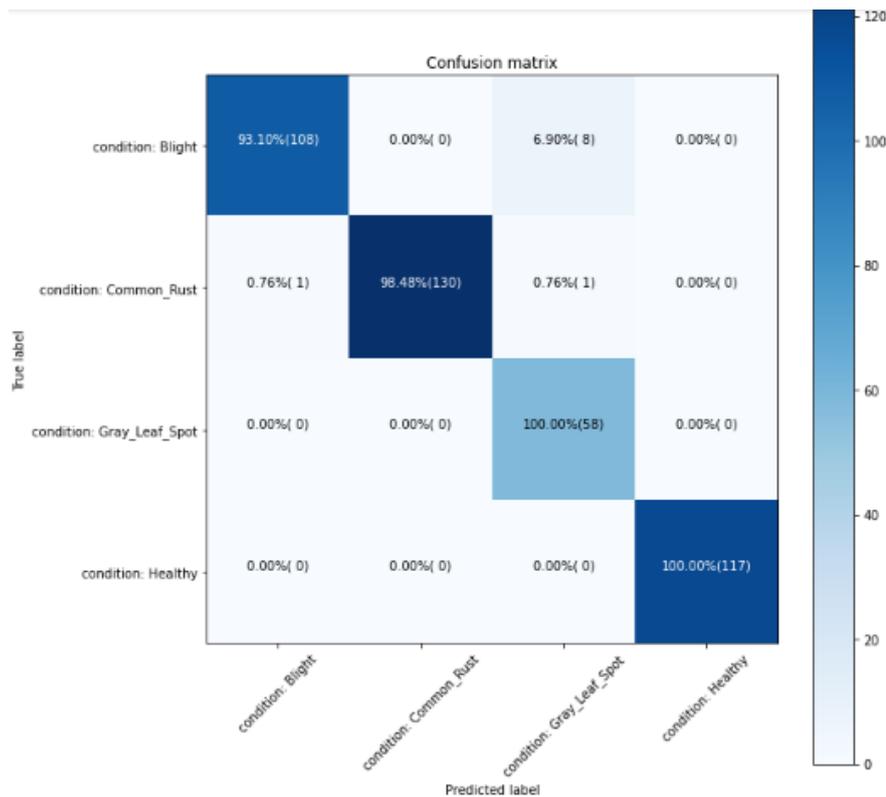
Gambar 6. Hasil Akurasi, Loss Training dan Validation Data *EfficientNet B-3*

Tabel 3. Perbandingan Nilai Akurasi dengan Penelitian Sebelumnya

Model	Dataset	Akurasi	Sumber
VGG16	3.846	98%	[9]
EfficientNet-B0	4.188	96%	[10]
EfficientNet-B2	4.188	97.77%	Proposed Model

Hasil Akurasi pada Proposed Model berhasil mendapatkan nilai akurasi sebesar 97.88%, lebih tinggi dari penelitian sebelumnya dengan dataset sama yang menggunakan *EfficientNet-B0* sehingga pada model *EfficientNet-B2* dapat dijadikan sebagai model transfer learning untuk melakukan deteksi penyakit pada daun jagung. Perbandingan nilai akurasi tersebut dapat dilihat pada tabel 3. Model

EfficientNet-B2 diambil menjadi Proposed Model dikarenakan memiliki nilai akurasi yang paling baik dibandingkan percobaan yang dilakukan antara *EfficientNet-B1* dan *EfficientNet-B3*. Untuk gambaran lebih lanjut tentang matrik evaluasi dari percobaan menggunakan model *EfficientNet-B2* dapat diperhatikan pada gambar Confusion matrix pada gambar 7.



Gambar 7. Hasil Akurasi, Loss Training dan Validation Data *EfficientNet B-3*

Pengujian menggunakan *confusion matrix* pada gambar 7, yang menunjukkan hasil untuk empat kelas penyakit daun jagung, yaitu *Blight*, *Common Rust*, *Gray Leaf Spot*, dan *Healthy*, menunjukkan hasil yang cukup tinggi. Persentase keberhasilan klasifikasi untuk masing-masing kelas adalah 93.10% untuk *Blight*, 98.48% untuk *Common Rust*, dan sempurna 100% untuk *Gray Leaf Spot* dan *Healthy*. Ini menunjukkan bahwa model yang digunakan sangat efektif dalam mengidentifikasi *Gray Leaf Spot* dan *Healthy*, sedangkan sedikit kurang akurat untuk *Blight* dan *Common Rust*

KESIMPULAN

Penelitian ini berhasil mengimplementasikan model pembelajaran transfer *EfficientNet-B1*, *EfficientNet-B2*, dan *EfficientNet-B3* dengan mencapai tingkat akurasi pelatihan yang memuaskan khususnya untuk model pembelajaran transfer *EfficientNet* yaitu sebesar 97,88%. Pengujian juga menunjukkan hasil *F1 Score* sebesar 98%, dengan AUC ROC mencapai 98%. Pencapaian ini memberikan kontribusi penting dalam konteks klasifikasi penyakit daun jagung menggunakan citra digital

menggunakan algoritma CNN *EfficiencyNet*. Model-model tersebut terbukti handal dalam mengidentifikasi dan mengklasifikasikan penyakit pada daun jagung dengan akurasi tinggi. Hasil ini menandai sebuah terobosan penerapan teknologi digital untuk meningkatkan kemampuan mendeteksi penyakit tanaman, khususnya daun jagung, sehingga mendorong pengelolaan pertanian yang efektif.

Berdasarkan penelitian ini, eksplorasi model pembelajaran transfer *EfficientNet* harus diperluas ke berbagai penyakit daun jagung untuk lebih memahami efektivitasnya. Penting juga untuk mempertimbangkan penggunaan kumpulan data yang lebih besar agar model lebih andal dan representatif. Analisis lebih lanjut mengenai perbedaan kinerja antara model *EfficiencyNet B1*, *B2*, dan *B3*, serta evaluasi model di lapangan secara nyata, dapat memberikan wawasan tambahan. Kolaborasi interdisipliner yang melibatkan pakar pertanian, pakar penyakit tanaman, dan pakar teknologi informasi diharapkan dapat meningkatkan penerapan solusi ini untuk mendukung pertanian berkelanjutan.

DAFTAR PUSTAKA

- [1] Jumanta, *Buku Pintar: Tumbuhan*. Jakarta: Elex Media Komputindo, 2019. [Online]. Available: <https://elexmedia.id/produk/detail/elex-kidz/jumanta/buku-pintar-tumbuhan/9786230001345>
- [2] 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>
- [3] I. P. Putra, R. Rusbandi, and D. Alamsyah, "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.
- [4] 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/jjubj.v22i2.2065.
- [5] E. H. Rachmawanto and H. P. Hadi, "OPTIMASI EKSTRAKSI FITUR PADA KNN DALAM KLASIFIKASI PENYAKIT DAUN JAGUNG," vol. 22, no. 2, pp. 58–67, 2021.
- [6] J. Jumadi, Y. Yupianti, and D. Sartika, "Pengolahan Citra Digital Untuk Identifikasi Objek Menggunakan Metode Hierarchical Agglomerative Clustering," *JST (Jurnal Sains dan Teknol.*, vol. 10, no. 2, pp. 148–156, 2021, doi: 10.23887/jstundiksha.v10i2.33636.
- [7] F. N. Ramaulidyah, "Perbandingan Metode Klasifikasi Naive Bayes Dan K-Nearest Neighbor Pada Data Status Pembayaran Pajak Pertambahan Nilai Di Kantor Pelayanan Pajak Pratama Smarinda Ulu," vol. 12, 2020.
- [8] S. Sena, "Pengenalan Deep Learning Part 7 : Convolutional Neural Network (CNN)," *medium.com*, 2018. <https://medium.com/@samuelsena/pengenalan-deep-learning-part-7-convolutional-neural-network-cnn-b003b477dc94>
- [9] M. Wafa Akhyari, A. Suyoto, and F. Wahyu Wibowo, "Klasifikasi Penyakit Pada Daun Jagung Menggunakan Convolutional Neural Network," *J. Inf. J. Penelit. dan Pengabd. Masyarakat.*, vol. 7, no. 2, pp. 12–15, 2021, [Online]. Available: <https://github.com>.
- [10] F. Sarasati, F. S. Nugraha, and U. Radiyah, "Pemanfaatan Metode Deep Learning untuk Klasifikasi Penyakit pada Tanaman Jagung," *J. Infortech*, vol. 1, no. 1, pp. 133–138, 2022, [Online]. Available: <https://ejournal.bsi.ac.id/ejurnal/index.php/infortech/article/view/13898>
- [11] A. D. Nurcahyati, R. M. Akbar, and S. Zahara, "Klasifikasi Citra Penyakit pada Daun Jagung Menggunakan Deep Learning dengan Metode Convolution Neural Network (CNN)," *SUBMIT J. Ilm. Teknol. Infomasi dan Sains*, vol. 2, no. 2, pp. 43–51, 2022, doi: 10.36815/submit.v2i2.1877.
- [12] S. Prajapati, S. Qureshi, Y. Rao, S. Nadkarni, M. Retharekar, and A. Avhad, "Plant Disease Identification Using Deep Learning," *2023 4th Int. Conf. Emerg. Technol. INCET 2023*, vol. 1, no. 1, pp. 29–40, 2023, doi: 10.1109/INCET57972.2023.10170463.
- [13] F. Zhuang *et al.*, "A Comprehensive Survey on Transfer Learning," *Proc. IEEE*, vol. 109, no. 1, pp. 43–76, 2021, doi: 10.1109/JPROC.2020.3004555.
- [14] C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," *J. Big Data*, vol. 6, no. 1, 2019, doi: 10.1186/s40537-019-0197-0.
- [15] M. Grandini, E. Bagli, and G. Visani, "Metrics for Multi-Class Classification: an Overview," pp. 1–17, 2020, [Online]. Available: <http://arxiv.org/abs/2008.05756>