

Explainable Deep Learning Untuk Klasifikasi Penyakit Tanaman Cabai Menggunakan EfficientNetB4 Dan Visualisasi Grad-CAM

Reza Putri Angga¹, Wahyu Syaifullah Jauharis Saputra², Alfian Rizaldy Pratama³

^{1,2,3}Sains Data, Universitas Pembangunan Nasional Veteran Jawa Timur

¹22083010006@student.upnjatim.ac.id

³alfan.fasilkom@upnjatim.ac.id

Corresponding author email: wahyu.s.j.saputra.if@upnjatim.ac.id

ABSTRAK

Abstrak— Tanaman cabai (*Capsicum Annuum*) merupakan komoditas dengan tingkat konsumsi tinggi di Indonesia. Namun, produktivitasnya sering menurun akibat penyakit yang sulit diidentifikasi secara manual. Proses diagnosis yang bergantung pada observasi visual seringkali memerlukan waktu dan bersifat subjektif, sehingga diperlukan sistem klasifikasi otomatis yang cepat, tepat, dan dapat dijelaskan. Penelitian ini mengusulkan pendekatan *Explainable Deep Learning* menggunakan *Convolutional Neural Network* (CNN) arsitektur EfficientNetB4 untuk mengklasifikasikan penyakit tanaman cabai melalui citra daun yang dikombinasikan dengan visualisasi *Gradient Weight Class Activation Mapping* (Grad-CAM) untuk interpretasi visual. Dataset terdiri atas 2.000 citra daun tanaman cabai dari lahan budidaya yang terbagi dalam lima kategori, dengan empat kategori penyakit, *yellowish*, *leaf curl*, *leaf spot*, *whitefly* dan satu kategori sehat, *healthy*. Hasil pengujian menunjukkan akurasi 92.19% dengan *loss* 0.2573. Evaluasi metrik menghasilkan presisi 0.93, *recall* 0.92, dan *F1-Score* 0.92. Visualisasi Grad-CAM menyoroti area citra yang berpengaruh terhadap hasil klasifikasi. Hasil tersebut menunjukkan bahwa pendekatan yang diterapkan tidak hanya dapat mengklasifikasikan penyakit tanaman cabai secara tepat, tetapi juga memberikan interpretabilitas visual yang meningkatkan transparansi dan kepercayaan terhadap hasil klasifikasi.

Keywords: Cabai, EfficientNetB4, *Explainable Deep Learning*, *Gradient Weight Class Activation Mapping*, Penyakit Tanaman

I. PENDAHULUAN

Perkembangan teknologi mendorong hadirnya berbagai solusi untuk mengatasi permasalahan di berbagai sektor, termasuk pertanian [1]. Salah satu tantangan utamanya adalah kebutuhan untuk mengidentifikasi penyakit tanaman secara cepat dan tepat guna mencegah penurunan produktivitas. Tantangan tersebut semakin krusial pada komoditas bernilai ekonomi tinggi, seperti tanaman cabai. Tanaman cabai (*Capsicum Annuum*) memiliki tingkat konsumsi yang menunjukkan tren peningkatan di setiap tahun, sehingga gangguan penyakit memberikan dampak signifikan [2]. Dalam praktik budidaya, petani mengalami kesulitan dalam mengidentifikasi jenis penyakit secara tepat karena keterbatasan metode identifikasi yang bergantung pada pengamatan visual, sementara tenaga ahli tidak selalu tersedia, terutama di wilayah pedesaan [3]. Kondisi tersebut mengakibatkan identifikasi sering terlambat, sehingga meningkatkan risiko penurunan hasil produksi dan potensi gagal panen.

Untuk mencegah kondisi tersebut, identifikasi dini penyakit tanaman menjadi langkah penting dalam menjaga produktivitas tanaman cabai. Proses identifikasi penyakit tanaman dapat dilakukan melalui klasifikasi citra daun dengan memanfaatkan

karakteristik visual untuk membedakan setiap jenis penyakit [4], [5]. Pendekatan berbasis *Deep Learning* banyak digunakan karena dapat mempelajari pola visual yang kompleks secara otomatis tanpa memerlukan ekstraksi fitur manual, salah satunya melalui metode *Convolutional Neural Network* (CNN) [6]. CNN merupakan jaringan saraf yang dirancang khusus untuk mengolah data citra melalui beberapa komponen utama, yaitu *convolutional layer* untuk mengekstraksi fitur visual, *pooling layer* untuk mereduksi dimensi, dan *fully connected layer* untuk memetakan fitur hasil ekstraksi menjadi *output* klasifikasi [7]. Berbagai penelitian telah menerapkan CNN untuk mengklasifikasikan penyakit tanaman.


Kusuma, dkk., mengklasifikasikan penyakit tanaman padi menggunakan metode CNN dengan hasil penelitian menunjukkan akurasi sebesar 75% [8]. Pangestu, dkk., mengklasifikasikan penyakit tanaman jagung, kentang, padi, tomat menggunakan metode CNN dengan hasil penelitian menunjukkan rata-rata akurasi sebesar 80% [9]. Selain CNN konvensional, sejumlah penelitian juga memanfaatkan arsitektur CNN *pretrained* melalui pendekatan *transfer learning*. Lata, dkk., mengklasifikasikan penyakit tanaman tomat menggunakan metode CNN arsitektur ResNet50 dengan hasil penelitian akurasi sebesar 85% [10]. Simanjutak, dkk., mengklasifikasikan penyakit tanaman cabai rawit menggunakan metode CNN arsitektur LeNet-5 dengan hasil penelitian akurasi sebesar 86% [11]. Pratap & Umar mengklasifikasikan penyakit tanaman cabai menggunakan metode CNN dengan berbagai arsitektur dengan akurasi, yaitu DesNet121 sebesar 87.5%, VGG-16 sebesar 83.1%, MobileNetV2 80.8% [12].

Meskipun berbagai arsitektur CNN konvensional dan *pretrained* telah menunjukkan hasil yang baik dalam klasifikasi penyakit tanaman, terdapat *trade-off* antara kompleksitas model dan akurasi [13]. CNN konvensional umumnya cepat dilatih namun memiliki akurasi lebih rendah, sementara CNN *pretrained* menawarkan akurasi lebih tinggi dengan kebutuhan komputasi yang lebih besar [14]. Untuk mengatasi hal tersebut, penelitian ini mengusulkan penggunaan metode CNN dengan arsitektur EfficientNet. EfficientNet merupakan arsitektur CNN yang dirancang untuk menyeimbangkan efisiensi komputasi dan akurasi melalui *compound scaling*, yaitu peningkatan kedalaman (*depth*), lebar (*width*), dan resolusi secara bersamaan [15]. EfficientNetB4 sebagai varian menengah, mengekstraksi fitur visual secara mendalam dengan parameter efisien. Pemrosesan citra dimulai dari *convolutional layer* dan *squeeze-and-excitation block* sebelum masuk *fully connected layer* untuk hasil klasifikasi [16].

Selain itu, penelitian sebelumnya berfokus pada akurasi tanpa memperhatikan aspek *explainability*. Dalam pemrosesan citra, *explainability* menunjukkan bagian citra yang menjadi fokus model agar hasil klasifikasi dapat dipahami secara visual. Salah satu teknik yang umum digunakan yaitu *Gradient-Weighted Class Activation Mapping*. Grad-CAM memvisualisasikan kontribusi fitur pada lapisan konvolusi terakhir dengan menghitung rata-rata gradien terhadap *output* klasifikasi [17]. Berdasarkan permasalahan tersebut, penelitian ini mengusulkan penerapan EfficientNetB4 yang tidak hanya mengutamakan peningkatan akurasi klasifikasi penyakit tanaman cabai, tetapi juga mengintegrasikan *explainability* menggunakan Grad-CAM. Dengan pendekatan ini, diharapkan model tidak hanya memberikan hasil klasifikasi yang tepat, tetapi juga menjelaskan bagian citra yang menjadi dasar hasil klasifikasi, sehingga memudahkan pemahaman dalam proses deteksi dini penyakit tanaman.

II. METODOLOGI PENELITIAN

Penelitian ini mengikuti alur metodologi yang disusun secara sistematis untuk mendukung proses pengembangan model klasifikasi penyakit tanaman cabai menggunakan EfficientNetB4. Tahapan penelitian meliputi identifikasi masalah, pengumpulan data, eksplorasi data, *pre-processing* data, pembagian data, pembangunan dan pelatihan model, evaluasi performa, serta penerapan interpretabilitas menggunakan Grad-CAM. Alur lengkap metodologi ditunjukkan pada Gambar 1.



Gambar 1. Metodologi Penelitian

Tahapan detail setiap metodologi penelitian dijabarkan lebih lanjut sebagai berikut.

II.1 Identifikasi Masalah

Identifikasi masalah dilakukan dengan meninjau kendala dalam budidaya tanaman cabai, yaitu proses identifikasi penyakit yang mengandalkan pengamatan visual [3]. Metode konvensional tersebut membuat petani kesulitan mengenali penyakit secara cepat dan tepat, sehingga hasil identifikasi sering terlambat, terutama ketika tenaga ahli tidak tersedia. Di sisi lain, meskipun metode CNN telah banyak diterapkan, sebagian besar penelitian hanya berfokus pada peningkatan akurasi tanpa mempertimbangkan interpretabilitas model. Oleh karena itu, diperlukan solusi yang tidak hanya akurat dalam mengklasifikasikan penyakit tanaman cabai, tetapi juga mampu memberikan penjelasan visual mengenai area citra yang memengaruhi keputusan model.

II.2 Pengumpulan Data

Data yang digunakan dalam penelitian ini yaitu data citra daun tanaman cabai yang dikumpulkan secara langsung dari lahan budidaya di wilayah Jawa Tengah. Proses pengambilan citra dilakukan pada kisaran waktu 08.00–10.00 WIB dengan intensitas pencahayaan rata-rata 3.000 lux. Dataset terdiri atas lima jenis, yaitu empat jenis penyakit meliputi *yellowish*, *leaf curl*, *leaf spot*, *whitefly* dan satu kategori sehat, yaitu *healthy*. Dengan jumlah distribusi pada setiap kategori direpresentasikan pada Tabel 1.

Tabel 1. Distribusi Data Citra Daun

Jenis Kategori	Total Data
<i>Healthy</i>	400
<i>Yellowish</i>	400
<i>Leaf Curl</i>	400
<i>Leaf Spot</i>	400
<i>Whitefly</i>	400
Total Keseluruhan	2.000

Pengambilan data didasarkan pada beberapa pertimbangan, yaitu kesesuaian data dengan kondisi lapangan dan keberagaman tingkat keparahan penyakit yang membantu meningkatkan generalisasi model. Variasi tersebut memungkinkan model mempelajari

karakteristik visual, sehingga lebih representatif untuk proses deteksi penyakit tanaman. Cuplikan data setiap jenis kategori direpresentasikan pada Gambar 2.



Gambar 2. Data Citra Daun Tanaman Cabai

II.3 Eksplorasi Data

Eksplorasi data dilakukan untuk memahami kondisi awal dataset yang digunakan dalam penelitian [18]. Proses ini mencakup analisis distribusi kelas untuk memastikan tidak terdapat ketidakseimbangan data, pemeriksaan kualitas citra, serta identifikasi variasi visual seperti perbedaan pencahayaan, warna daun, fokus gambar, dan latar belakang. Seluruh citra juga diperiksa dari segi format dan resolusi untuk memastikan kompatibilitas dengan ukuran *input* EfficientNetB4. Eksplorasi penting untuk mengidentifikasi adanya data yang tidak relevan, sekaligus menjadi dasar dalam menentukan langkah *pre-processing* yang akan diterapkan pada tahap berikutnya.

II.4 Pembagian Data

Pembagian data dilakukan dengan tiga skenario untuk mengevaluasi konsistensi performa model dan mendapatkan performa akurasi tertinggi pada proporsi data pelatihan, data validasi, dan data pengujian yang berbeda. Tiga skenario tersebut, meliputi skenario pertama yaitu 80%, 10%, 10%, skenario kedua yaitu 70%, 15%, 15%, dan skenario ketiga yaitu 60%, 20%, 20%. Pada setiap skenario, pembagian dilakukan menggunakan *stratified splitting* agar jumlah citra pada setiap jenis kategori tetap seimbang. Dengan total 2.000 citra dan 400 citra untuk setiap kategori, pembagian jumlah data untuk setiap skenario direpresentasikan pada Tabel 2.

Tabel 2. Skenario Pembagian Data

Skenario	Subset Pelatihan	Subset Validasi	Subset Pengujian
80:10:10	1.600	200	200
75:15:15	1.400	300	300
60:20:20	1.200	400	400

Detail proporsi pada setiap skenario direpresentasikan pada Tabel 3.

Tabel 3. Proporsi Pembagian Data

Skenario	Subset Pelatihan	Subset Validasi	Subset Pengujian
80:10:10	320 Per-Jenis	40 Per-Jenis	40 Per-Jenis
75:15:15	280 Per-Jenis	60 Per-Jenis	60 Per-Jenis

Skenario	Subset Pelatihan	Subset Validasi	Subset Pengujian
60:20:20	240 Per-Jenis	80 Per-Jenis	80 Per-Jenis

Skenario dengan akurasi tertinggi pada tahap pemodelan selanjutnya akan dipilih untuk proses lanjutan, yaitu penerapan aspek *explainability* menggunakan Grad-CAM guna memberikan interpretasi visual terhadap hasil klasifikasi model.

II.5 Pre-Processing Data

Pre-processing dilakukan untuk menyiapkan data citra agar sesuai dengan kebutuhan arsitektur EfficientNetB4 sekaligus meningkatkan kualitas data yang digunakan pada proses pelatihan pada subset data pelatihan dan data validasi [19]. Langkah pertama adalah melakukan *resizing*, yaitu mengubah resolusi seluruh citra menjadi ukuran 380×380 piksel, sesuai dengan ukuran input standar EfficientNetB4 [20]. Selanjutnya, dilakukan proses augmentasi data untuk meningkatkan keragaman pola visual. Augmentasi yang diterapkan meliputi rotasi hingga 30°, *flipping* horizontal dan vertikal, *zooming* hingga 20%, serta penyesuaian tingkat kecerahan (*brightness*) pada rentang 0.8–1.2. Seluruh augmentasi diterapkan secara *on-the-fly* selama proses pelatihan, sehingga data yang efektif menjadi lebih beragam tanpa memerlukan penyimpanan tambahan [21]. Selanjutnya dilakukan normalisasi untuk mengubah nilai piksel ke rentang –1 hingga 1. Rangkaian proses ini memastikan bahwa model menerima masukan yang terstandarisasi dengan variasi visual yang diperluas.

II.6 Pemodelan Klasifikasi EfficientNetB4

Model klasifikasi yang digunakan dalam penelitian ini adalah EfficientNetB4, salah satu varian EfficientNet yang dirancang untuk memberikan keseimbangan optimal antara akurasi dan efisiensi komputasi. EfficientNet diperkenalkan oleh Google AI melalui konsep *compound scaling*, yaitu mekanisme penskalaan yang secara proporsional menyesuaikan tiga aspek utama jaringan *depth*, *width*, dan *resolution* untuk meningkatkan kapasitas model tanpa menambah kompleksitas secara berlebihan. Dengan persamaan penskalaan [15]:

$$d = 2^{\alpha\phi}, w = 2^{\beta\phi}, r = 2^{\gamma\phi} \quad (1)$$

Berdasarkan persamaan tersebut setiap dimensi diskalakan secara seimbang melalui *compound scaling*. Lebar jaringan (w) ditentukan oleh ϕ dengan eksponen α , kedalaman jaringan (d) ditentukan oleh ϕ dengan eksponen β , dan resolusi (r) ditentukan oleh ϕ dengan eksponen γ . Sehingga terdapat persamaan umum:

$$2^{\alpha\phi} \cdot 2^{\beta\phi} \cdot 2^{\gamma\phi} \approx 2^{\phi} \geq 1, \beta \geq 1, \gamma \geq 1 \quad (2)$$

Persamaan tersebut menjelaskan bahwa *compound scaling* memastikan bahwa pertambahan kompleksitas model berlangsung secara proporsional di ketiga dimensi. Arsitektur EfficientNetB4 direpresentasikan pada Gambar 3.

Gambar 3. Arsitektur EfficientNetB4

EfficientNetB4 tersusun dari rangkaian *Mobile Inverted Bottleneck* (MBConv), yang menggabungkan *depthwise convolution* dan *pointwise convolution* untuk

mengeksktraksi pola tekstur, warna, dan struktur daun secara efisien [22]. Arsitektur dimulai dari lapisan konvolusi sebagai penangkap fitur dasar, dilanjutkan dengan beberapa tingkat MBConv, kemudian diakhiri dengan konvolusi, serta *Global Average Pooling*. Tahapan ini mereduksi peta fitur menjadi vektor berdimensi rendah namun tetap kaya informasi sebelum memasuki lapisan *fully connected* untuk mengklasifikasikan lima jenis kategori penyakit tanaman cabai. Dalam penelitian ini, EfficientNetB4 diimplementasikan menggunakan bobot pra-latih (*pretrained*) dari ImageNet untuk memanfaatkan representasi awal yang sudah stabil. Proses *fine-tuning* dilakukan dengan membuka sebagian lapisan akhir agar dapat dilatih ulang menggunakan dataset penyakit tanaman cabai.

Strategi ini memungkinkan model menyesuaikan fitur agar lebih sesuai dengan karakteristik visual setiap penyakit, tanpa mengubah fitur dasar yang telah diperoleh dari pra-pelatihan. Proses pelatihan dilakukan menggunakan ukuran *batch* 32, yang memberikan keseimbangan antara stabilitas gradien dan efisiensi komputasi. Jumlah *epoch* sebesar 50, namun mekanisme *Early Stopping* digunakan untuk menghentikan pelatihan lebih awal apabila nilai *validation loss* tidak menunjukkan perbaikan dalam tiga iterasi. Pada tahap optimisasi, digunakan Adam dengan *learning rate* awal $1e-5$, yang dianggap sesuai untuk proses *fine-tuning* karena nilai yang terlalu besar berisiko merusak bobot *pretrained*. Selain itu, digunakan juga *ReduceLROnPlateau* untuk menurunkan *learning rate* secara adaptif ketika perbaikan kinerja berhenti. Kombinasi tersebut membantu model mencapai konvergensi yang lebih stabil. Dengan demikian, model dapat mengenali pola khas tiap kategori secara lebih efektif.

II.7 Evaluasi Model

Evaluasi model dilakukan untuk menilai kinerja model klasifikasi dalam mengidentifikasi jenis penyakit tanaman cabai. Proses evaluasi menggunakan confusion matrix, yaitu matriks yang membandingkan antara prediksi model dengan label aktual. Matriks ini menghasilkan empat komponen utama, yaitu *True Positive* (TP), *False Positive* (FP), *False Negative* (FN), dan *True Negative* (TN), yang menjadi dasar dalam perhitungan metrik evaluasi direpresentasikan pada Tabel 4 [23].

Tabel 4. *Confusion Matrix*

		Aktual	
		Positif (1)	Negatif (0)
Prediksi	Positif (1)	<i>True Positive</i> (TP)	<i>False Positive</i> (FP)
	Negatif (0)	<i>False Negative</i> (TN)	<i>True Negative</i> (TN)

Berdasarkan komponen tersebut, beberapa metrik dihitung untuk memberikan gambaran komprehensif mengenai performa model. Akurasi digunakan untuk mengukur proporsi prediksi yang benar terhadap seluruh data, dengan persamaan:

$$Akurasi = \frac{TP + TN}{TP + FP + FN + TN} \quad (3)$$

Presisi digunakan untuk menilai ketepatan model dalam memprediksi suatu jenis kategori, dengan persamaan:

$$Presisi = \frac{TP}{TP + FP} \quad (4)$$

Recall digunakan untuk mengukur kemampuan model dalam mengenali seluruh data yang tepat masuk ke dalam suatu jenis kategori, dengan persamaan:

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

F1-Score digunakan untuk memberikan penilaian seimbang antara presisi dan recall, dengan persamaan:

$$F1 - Score = 2 \frac{\frac{Precision \cdot Recall}{Precision + Recall}}{Precision + Recall} \quad (6)$$

Melalui rangkaian metrik ini, kinerja model pada setiap skenario dapat di evaluasi, sehingga memberikan pemahaman secara menyeluruh mengenai kemampuan model dalam mengklasifikasikan penyakit tanaman cabai.

II.8 Explainable Deep Learning Menggunakan Grad-CAM

Explainable Deep Learning diperlukan untuk memberikan interpretasi terhadap keputusan model, sehingga proses klasifikasi tidak bersifat *black box* sepenuhnya. Dalam konteks pengolahan citra daun tanaman cabai, interpretabilitas membantu menjelaskan area pada citra yang paling berkontribusi terhadap keputusan klasifikasi penyakit. Salah satu metode interpretabilitas yang paling umum digunakan pada arsitektur CNN adalah Grad-CAM [24]. Grad-CAM bekerja dengan memanfaatkan gradien dari kelas yang diprediksi terhadap *feature map* pada lapisan konvolusi terakhir. Gradien tersebut dirata-ratakan secara global untuk menghasilkan bobot kontribusi setiap *channel* fitur. Bobot Grad-CAM dihitung dengan persamaan [25]:

$$w_{\text{Grad-CAM}} = \frac{1}{Z} \sum_{\text{channel}} \frac{\partial Y}{\partial \text{feature map}} \quad (7)$$

Bobot tersebut kemudian dikalikan dengan setiap *channel feature map* dan dijumlahkan untuk menghasilkan peta relevansi. Selanjutnya, fungsi aktivasi diterapkan untuk kontribusi positif yang mendukung keputusan model, dengan persamaan:

$$L_{\text{Grad-CAM}}^{\text{class}} = \text{ReLU}(\sum_{\text{channel}} w_{\text{Grad-CAM}} \cdot \text{feature map}_{\text{channel}}) \quad (8)$$

Hasil Grad-CAM berupa *heatmap* yang menyoroti area dari citra daun yang berpengaruh terhadap hasil klasifikasi jenis penyakit. *Heatmap* tersebut di *overlay* ke data citra untuk menghasilkan visualisasi interpretatif yang mudah dipahami. Melalui tahapan ini, penelitian tidak hanya menghasilkan model klasifikasi yang tepat, tetapi juga menyediakan penjelasan visual yang menunjukkan bagian citra daun yang menjadi fokus model pada saat melakukan klasifikasi.

III. HASIL DAN ANALISIS

Pada bagian ini disajikan rangkaian hasil pengujian model yang diperoleh dari tahapan penelitian, meliputi evaluasi model klasifikasi untuk setiap skenario pembagian data dan interpretabilitas (*explainability*) model menggunakan Grad-CAM. Seluruh hasil disampaikan secara sistematis untuk mengetahui efektivitas model dalam mengidentifikasi dan mengklasifikasikan penyakit tanaman cabai serta konsistensi kerjanya pada setiap skenario dengan dijabarkan lebih lanjut sebagai berikut.

III.1 Hasil Pemodelan Pada Setiap Skenario

Pemodelan pada setiap skenario dilakukan dengan menerapkan teknik *fine tuning* dan arsitektur EfficientNetB4 yang telah dijelaskan pada bagian metodologi. Hasil


pemodelan menunjukkan bahwa setiap skenario menghasilkan performa yang berbeda pada tahap pelatihan, validasi, maupun pengujian. Ringkasan nilai akurasi dan *loss* untuk setiap skenario disajikan pada Tabel 5.

Tabel 5. Akurasi Pemodelan Setiap Skenario

Skenario	Akurasi	Akurasi	Akurasi	Loss
	Pelatihan	Validasi	Pengujian	Pengujian
80:10:10	0.9650	1.0000	0.9219	0.2573
75:15:15	0.9715	1.0000	0.9120	0.2642
60:20:20	0.9565	1.0000	0.8655	0.3466

Hasil pemodelan pada setiap skenario menunjukkan adanya perbedaan tingkat generalisasi yang dipengaruhi oleh proporsi data. Pada skenario 80:10:10, model menghasilkan performa terbaik dengan akurasi pengujian 92.19%, akurasi pelatihan 96.50% dan akurasi validasi 100%. Nilai *loss* pengujian rendah 0.2573 menunjukkan bahwa model dapat mengenali pola visual secara konsisten pada data baru. Skenario 75:15:15 juga menunjukkan performa yang kompetitif, dengan akurasi pengujian 91.20%, akurasi pelatihan 97.15%, dan akurasi validasi 100%. Skenario 60:20:20 menunjukkan proporsi data pelatihan yang lebih sedikit berdampak pada penurunan akurasi pengujian 86.55%, meskipun akurasi pelatihan 95.65%, dan akurasi validasi 100%. Kondisi tersebut menunjukkan bahwa jumlah data pelatihan yang lebih terbatas memengaruhi kemampuan model dalam mempelajari keragaman fitur secara optimal.

Secara keseluruhan, skenario 80:10:10 menjadi skenario paling optimal karena memberikan keseimbangan terbaik antara jumlah data pelatihan dan performa model pada data pengujian. Grafik perubahan akurasi dan *loss* pada setiap skenario ditampilkan pada Gambar 4. Grafik tersebut merepresentasikan bahwa ketiga skenario mencapai proses pelatihan yang stabil, dengan pola konvergensi yang jelas. Stabilitas ini didukung oleh penerapan mekanisme *Early Stopping* dan penyesuaian *learning rate* otomatis, sehingga proses optimasi berlangsung lebih efektif.




Gambar 4. Grafik Akurasi & Loss

Untuk mengevaluasi kemampuan model dalam mengenali setiap jenis kategori penyakit secara spesifik, dilakukan analisis menggunakan *confusion matrix* yang dirumuskan dalam bentuk metrik presisi, *recall*, dan *F1-Score*. Ketiga metrik tersebut memberikan gambaran tingkat ketepatan klasifikasi model untuk setiap jenis kategori. Ringkasan performa model pada ketiga skenario direpresentasikan pada Tabel 6.

Tabel 6. *Confusion Matrix* Setiap Skenario

Skenario	Confusion Matrix	Healthy	Yellowish	Leaf Curl	Leaf Spot	Whitefly
80:10:10	Presisi	1.00	0.80	1.00	0.97	0.89
	Recall	0.88	1.00	1.00	0.72	1.00
	F1-Score	0.93	0.89	1.00	0.83	0.94
75:15:15	Presisi	1.00	0.74	1.00	1.00	0.95
	Recall	0.92	1.00	0.95	0.73	1.00
	F1-Score	0.96	0.85	0.97	0.85	0.98
60:20:20	Presisi	1.00	0.78	1.00	1.00	0.82
	Recall	0.84	1.00	0.89	0.79	1.00
	F1-Score	0.91	0.88	0.94	0.88	0.90

Berdasarkan Tabel 6, ketiga skenario menunjukkan performa yang konsisten tinggi. Jenis kategori *leafspot* dan *yellowish* cenderung memiliki nilai *recall* yang lebih rendah, mengindikasikan bahwa model membutuhkan informasi visual yang lebih kuat untuk membedakan kedua penyakit tersebut. Meski demikian, *F1-Score* pada seluruh kelas tetap berada pada kategori baik. Secara keseluruhan, skenario 80:10:10 memberikan stabilitas terbaik karena menghasilkan sebaran *recall* dan *F1-Score* yang lebih merata serta akurasi pengujian tertinggi dibandingkan dua skenario lainnya. Visualisasi *confusion matrix* untuk setiap skenario direpresentasikan pada Gambar 5.




Gambar 5. *Confusion Matrix* Setiap Skenario

Berdasarkan hasil tersebut, skenario 80:10:10 dipilih sebagai skenario yang paling optimal dan digunakan pada tahap analisis lanjutan. Skenario ini kemudian diterapkan pada bagian berikutnya, yaitu hasil *explainable deep learning* menggunakan Grad-CAM.

III.2 Hasil Explainable Deep Learning Menggunakan Grad-CAM

Untuk memahami bagian citra yang menjadi fokus model dalam pengambilan keputusan klasifikasi, dilakukan analisis interpretabilitas menggunakan *Gradient Weighted Class Activation Mapping* (Grad-CAM). Teknik ini menghasilkan *heatmap* yang menyoroti area pada daun yang memberikan kontribusi terbesar terhadap prediksi model. Dengan demikian, Grad-CAM memungkinkan evaluasi apakah model memang memusatkan perhatian pada gejala visual yang relevan dengan penyakit tanaman cabai.

Hasil visualisasi Grad-CAM menunjukkan bahwa model secara konsisten dapat menyoroti area penting pada daun yang berkaitan dengan karakteristik penyakit.



Gambar 6. Hasil Grad-CAM Setiap Jenis Kategori

Visualisasi Grad-CAM untuk setiap jenis kategori direpresentasikan pada Gambar 6. Pada jenis *leaf curl*, model memfokuskan perhatian pada pola keriting tepi daun. Untuk jenis *leaf spot*, model memfokuskan perhatian pada area bercak. Pada jenis *whitefly*, model memfokuskan perhatian pada permukaan daun yang menunjukkan titik-titik kecil atau perubahan warna putih. Sementara itu, pada jenis *yellowish*, model memberikan perhatian pada bagian daun yang mengalami perubahan pigmentasi menjadi kuning. Untuk jenis *healthy*, Grad-CAM menampilkan distribusi warna hijau yang merata, menandakan bahwa model mengenali pola daun sehat tanpa adanya anomali. Visualisasi beberapa contoh citra per-jenis kategori menunjukkan konsistensi model dalam menyoroti bagian daun yang relevan. Model tidak menunjukkan kecenderungan untuk memfokuskan perhatian pada area yang tidak signifikan, seperti latar belakang atau bagian daun tanpa gejala penyakit.

Hal ini menandakan bahwa model tidak hanya memberikan hasil klasifikasi yang tepat, tetapi juga mempelajari fitur visual yang bermakna sesuai karakteristik penyakit tanaman cabai. Secara keseluruhan, hasil Grad-CAM meningkatkan interpretabilitas model dan memastikan bahwa proses pengambilan keputusan sejalan dengan gejala visual yang digunakan dalam diagnosa penyakit oleh ahli. Selain itu, visualisasi ini berfungsi sebagai alat evaluasi tambahan untuk mendeteksi potensi bias atau kesalahan fokus model. Dengan demikian, analisis Grad-CAM tidak hanya memperkuat kepercayaan terhadap akurasi prediksi model, tetapi juga menyediakan wawasan visual yang dapat digunakan sebagai dasar untuk perbaikan model di masa depan maupun sebagai referensi bagi penelitian terkait klasifikasi penyakit tanaman cabai.

IV. KESIMPULAN

Penelitian ini menunjukkan bahwa penerapan arsitektur EfficientNetB4 pada klasifikasi penyakit tanaman cabai mampu menghasilkan performa tinggi, dengan akurasi pengujian tertinggi 92.19% pada skenario pembagian data 80:10:10. Evaluasi menggunakan *confusion matrix* mengindikasikan bahwa model dapat mengenali berbagai jenis kategori dengan akurasi, presisi, dan *F1-Score* yang baik, meskipun beberapa jenis kategori, seperti *leaf spot* dan *yellowish* memerlukan informasi visual yang lebih jelas untuk meningkatkan recall. Integrasi Grad-CAM dalam penelitian ini

berhasil menjelaskan *explainability* model, dengan visualisasi *heatmap* yang menyoroti area daun paling relevan untuk setiap jenis kategori. Hasil Grad-CAM memperlihatkan bahwa model tidak hanya fokus pada gejala visual, tetapi juga menghindari area tidak relevan, sehingga proses pengambilan keputusan menjadi transparan. Secara keseluruhan, penelitian ini menunjukkan bahwa kombinasi EfficientNetB4 dengan Grad-CAM tidak hanya memberikan klasifikasi yang akurat, tetapi juga menyediakan wawasan visual yang dapat mendukung deteksi dini penyakit tanaman cabai.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada seluruh pihak yang telah memberikan dukungan dalam pelaksanaan penelitian ini. Apresiasi khusus disampaikan kepada Tim DISCOVER atas bantuan dalam penyediaan template dan fasilitas pendukung. Selain itu, penulis juga menyampaikan terima kasih kepada para dosen, rekan peneliti, serta pihak-pihak terkait yang telah memberikan masukan, saran, dan dukungan selama proses penelitian hingga terselesaikannya naskah ini.

REFERENSI

- [1] D.-C. Rodríguez-Lira, D.-M. Córdova-Esparza, J. M. Álvarez-Alvarado, J. Terven, J.-A. Romero-González, and J. Rodríguez-Reséndiz, “Trends In Machine And Deep Learning Techniques For Plant Disease Identification: A Systematic Review,” *Agriculture*, vol. 14, no. 12, p. 2188, 2024, doi: 10.3390/agriculture14122188.
- [2] Pusat Data Dan Sistem Informasi Pertanian Sekretariat Jenderal Kementerian Pertanian, *Outlook Komoditas Pertanian Subsektor Hortikultura Cabai*. 2023.
- [3] Y. Budiawati, G. Gunawan, and Suherna, “Smart Agriculture VS Pertanian Konvensional: Tantangan Atau Peluang Pertanian Masa Depan Di Indonesia?,” *AGRI WIRALODRA Jurnal Agribisnis*, vol. 17, no. 1, pp. 16–28, 2025.
- [4] E. Alpaydin, *Introduction To Machine Learning*. The MIT Press, 2020.
- [5] X. Fan, P. Luo, Y. Mu, R. Zhou, T. Tjahjadi, and Y. Ren, “Leaf Image Based Plant Disease Identification Using Transfer Learning And Feature Fusion,” *Comput Electron Agric*, vol. 196, p. 106892, 2022.
- [6] C. Janiesch, P. Zschech, and K. Heinrich, “Machine Learning And Deep Learning,” *Electronic Markets*, vol. 31, no. 3, pp. 685–695, 2021.
- [7] G. Rangel, J. C. Cuevas-Tello, J. Nunez-Varela, C. Puente, and A. G. Silva-Trujillo, “A Survey On Convolutional Neural Networks And Their Performance Limitations in Image Recognition Tasks,” *J Sens*, vol. 2024, no. 1, 2024.
- [8] B. Kusuma, T. I. Hermanto, and C. D. Lestari, “Klasifikasi Jenis Penyakit Pada Tanaman Padi Menggunakan Algoritma Convolutional Neural Network,” *JIKO (Jurnal Informatika dan Komputer)*, vol. 9, no. 1, p. 40, 2025.
- [9] D. A. Pangestu, O. Q. Aziz, and C. Crysdian, “Klasifikasi Penyakit Pada Tanaman Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network,” *JISKA (Jurnal Informatika Sunan Kalijaga)*, vol. 10, no. 2, pp. 235–248, 2025.
- [10] M. A. Lata, M. Sultana, I. A. Badhan, M. J. Maria, and F. T. Nuha, “Deep Transfer Learning Based Disease Detection And Classification Of Tomato Leaves - A Comparative Analysis,” *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, vol. 23, no. 5, p. 1353, 2025.

- [11] T. Josafat Simanjutak, K. Saputra S, H. Syahputra, S. Iskandar Al Idrus, and D. Febrian, "Identifikasi Jenis Penyakit Pada Tanaman Cabai Rawit Menggunakan Algoritma Convolutional Neural Network (CNN) Di Desa Bintang Kecamatan Sidikalang," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 1, pp. 584–591, 2024.
- [12] V. K. Pratap and N. S. Kumar, "High-Precision Multiclass Classification Of Chili Leaf Disease Through Customized Effecientnetb4 From Chili Leaf Images," *Smart Agricultural Technology*, vol. 5, pp. 1–11, 2023.
- [13] L. Alzubaidi *et al.*, "Review Of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions," *J Big Data*, vol. 8, no. 1, p. 53, 2021.
- [14] H.-C. Shin *et al.*, "Deep Convolutional Neural Networks For Computer-Aided Detection: CNN Architectures, Dataset Characteristics And Transfer Learning," *IEEE Trans Med Imaging*, vol. 35, no. 5, pp. 1285–1298, 2016.
- [15] M. Tan and Q. V Le, "EfficientNet: Rethinking Model Scaling For Convolutional Neural Networks," *ArXiv*, pp. 1–11, 2020.
- [16] Ü. Atila, M. Uçar, K. Akyol, and E. Uçar, "Plant Leaf Disease Classification Using EfficientNet Deep Learning Model," *Ecol Inform*, vol. 61, p. 101182, 2021.
- [17] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, "Grad-CAM: Visual Explanations From Deep Networks Via Gradient-Based Localization," *Int J Comput Vis*, vol. 128, no. 2, pp. 336–359, 2020.
- [18] A. T. Jebb, S. Parrigon, and S. E. Woo, "Exploratory Data Analysis As A Foundation Of Inductive Research," *Human Resource Management Review*, vol. 27, no. 2, pp. 265–276, 2017.
- [19] D. Tribuana, Hazriani, and A. L. Arda, "Image Preprocessing Approaches Toward Better Learning Performance with CNN," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 8, no. 1, pp. 1–9, 2024.
- [20] S. Srinivasan, S. M. Prabin, S. K. Mathivanan, H. Rajadurai, S. Kulandaivelu, and M. A. Shah, "Sugarcane Leaf Disease Classification Using Deep Neural Network Approach," *BMC Plant Biol*, vol. 25, no. 1, p. 282, 2025.
- [21] A. Buslaev, V. I. Iglovikov, E. Khvedchenya, A. Parinov, M. Druzhinin, and A. A. Kalinin, "Albumentations: Fast And Flexible Image Augmentations," *Information*, vol. 11, no. 2, p. 125, 2020.
- [22] A. G. Pradana, D. R. I. M. Setiadi, and A. R. Muslikh, "Fine Tuning Model Convolutional Neural Network Efficientnet-B4 Dengan Augmentasi Data Untuk Klasifikasi Penyakit Kakao," *Journal Of Information System And Application Development*, vol. 2, no. 1, pp. 1–11, 2024.
- [23] G. Zeng, "Invariance Properties And Evaluation Metrics Derived From The Confusion Matrix In Multiclass Classification," *mathematics*, vol. 13, no. 2609, pp. 1–26, 2025.
- [24] K. Wei *et al.*, "Explainable Deep Learning Study For Leaf Disease Classification," *Agronomy*, vol. 12, no. 5, p. 1035, 2022.
- [25] S. A. and S. R., "A Systematic Review Of Explainable Artificial Intelligence Models And Applications: Recent Developments And Future Trends," *Decision Analytics Journal*, vol. 7, no. 100230, pp. 1–14, 2023.