



Optimasi Hyperparameter EfficientNet-B1 untuk Klasifikasi Penyakit Bawang Merah Berbasis Citra Digital

Adlu Aghnia^{1*}, Nur Ariesanto Ramdhan², Otong Saeful Bachri³

^{1,2,3}Teknik Informatika, Universitas Muhadi Setiabudi Brebes, Indonesia

Email author: aghniaadl@gmail.com¹, ariesantoramdhan@gmail.com², otongsaifulbahriumus@gmail.com³

Article Info

Article history:

Received July 9, 2026

Revised July 11, 2026

Accepted July 13, 2026

Available July 14, 2026

Published July 30, 2026

Keywords:

EfficientNet

Klasifikasi Citra

Deep Learning

Penyakit Bawang Merah

Transfer Learning.

ABSTRACT

Penyakit bawang merah merupakan salah satu faktor yang dapat menurunkan produktivitas dan kualitas hasil panen. Identifikasi penyakit secara manual sering kali memerlukan waktu dan bergantung pada keahlian pengamat. Penelitian ini bertujuan menganalisis performa arsitektur EfficientNet-B0 dan EfficientNet-B1 dalam klasifikasi penyakit bawang merah berbasis citra digital. Dataset yang digunakan berasal dari *Onion Leaf Disease Dataset* dan dibagi menjadi 2.700 data pelatihan, 332 data validasi, dan 201 data pengujian. Model dibangun menggunakan pendekatan *transfer learning* dengan bobot awal ImageNet serta diuji menggunakan variasi *learning rate* (0,0001 dan 0,001) dan *dropout* (0,3 dan 0,5). Hasil penelitian menunjukkan bahwa EfficientNet-B1 dengan *learning rate* 0,001 dan *dropout* 0,3 memberikan performa terbaik dengan *training accuracy* 99,94%, *validation accuracy* 89,13%, dan *test accuracy* 93,03% serta *test loss* 0,2572. Analisis *confusion matrix* menunjukkan bahwa model mampu mengklasifikasikan 187 dari 201 citra pengujian dengan benar. Hasil penelitian membuktikan bahwa EfficientNet-B1 efektif digunakan untuk klasifikasi penyakit bawang merah dan berpotensi mendukung sistem deteksi penyakit tanaman secara otomatis.

Corresponding Author:

Adlu Aghnia,

Universitas Muhadi Setiabudi

Jl. Pangeran Diponegoro, KM2 Pesantunan, Brebes, Kec. Brebes, Kabupaten Brebes, Jawa Tengah.

Email: aghniaadl@gmail.com



1. PENDAHULUAN

Bawang merah merupakan salah satu komoditas hortikultura penting di Indonesia yang memiliki nilai ekonomi tinggi dan berperan besar dalam memenuhi kebutuhan pangan masyarakat. Produksi bawang merah sering mengalami penurunan akibat serangan penyakit tanaman seperti bercak ungu, antraknosa, dan fusarium yang dapat menurunkan kualitas maupun kuantitas hasil panen. Identifikasi penyakit bawang merah secara manual umumnya dilakukan melalui pengamatan visual oleh petani atau pakar pertanian. Namun, metode tersebut memiliki keterbatasan karena bergantung pada pengalaman pengamat, membutuhkan waktu yang relatif lama, serta rentan terhadap kesalahan identifikasi.

Perkembangan teknologi kecerdasan buatan, khususnya deep learning, telah memberikan solusi baru dalam bidang pertanian cerdas (smart agriculture). Metode deep learning berbasis

Convolutional Neural Network (CNN) mampu melakukan ekstraksi fitur secara otomatis dari citra digital dan menunjukkan performa yang sangat baik pada berbagai kasus klasifikasi citra tanaman. Penelitian terbaru menunjukkan bahwa pendekatan CNN efektif digunakan dalam deteksi penyakit tanaman karena mampu mengenali pola visual kompleks pada daun maupun bagian tanaman lainnya.


Salah satu arsitektur CNN yang banyak digunakan dalam klasifikasi citra adalah EfficientNet. EfficientNet dikembangkan dengan pendekatan compound scaling yang menyeimbangkan dimensi kedalaman (depth), lebar (width), dan resolusi citra sehingga menghasilkan model yang efisien dan memiliki akurasi tinggi. Dibandingkan dengan arsitektur CNN konvensional, EfficientNet mampu memberikan performa klasifikasi yang lebih baik dengan jumlah parameter yang lebih sedikit. Beberapa penelitian terkini menunjukkan bahwa EfficientNet berhasil diterapkan pada klasifikasi penyakit tanaman seperti singkong, padi, jagung, kentang, dan apel dengan tingkat akurasi yang tinggi.

Penelitian oleh Liu et al. (2022) menunjukkan bahwa EfficientNet mampu meningkatkan akurasi klasifikasi penyakit daun singkong melalui mekanisme feature extraction yang lebih optimal. Selain itu, Bhujel dan Shakya (2022) menerapkan EfficientNet pada klasifikasi penyakit daun padi dan memperoleh performa klasifikasi yang baik melalui proses fine-tuning dan optimasi hyperparameter. Penelitian lainnya juga menunjukkan bahwa modifikasi EfficientNet dapat meningkatkan akurasi deteksi penyakit tanaman kentang dan apel secara signifikan.

Berdasarkan penelitian-penelitian tersebut, penggunaan EfficientNet memiliki potensi besar untuk diterapkan pada klasifikasi penyakit bawang merah berbasis citra digital. Namun, penelitian yang secara khusus membandingkan performa varian EfficientNet-B0 dan EfficientNet-B1 pada klasifikasi penyakit bawang merah masih relatif terbatas. Oleh karena itu, penelitian ini bertujuan untuk menganalisis performa arsitektur EfficientNet-B0 dan EfficientNet-B1 dengan variasi hyperparameter learning rate dan dropout dalam proses klasifikasi penyakit bawang merah menggunakan deep learning. Evaluasi dilakukan menggunakan parameter akurasi dan loss pada data pelatihan, validasi, dan pengujian untuk menentukan model terbaik dalam mengenali penyakit bawang merah secara otomatis.

2. METODE PENELITIAN

Penelitian ini mengusulkan pendekatan berbasis deep learning untuk klasifikasi otomatis penyakit daun bawang merah menggunakan beberapa varian arsitektur EfficientNet. Alur kerja penelitian secara keseluruhan terdiri dari persiapan dataset, preprocessing citra, pengembangan model, pelatihan model, dan evaluasi performa.




Gambar 1. Alur Penelitian

2.1. Dataset

Penelitian ini menggunakan dataset citra penyakit daun bawang merah yang diperoleh dari platform Hugging Face dengan nama dataset *Onion Leaf Disease Dataset* (Appdevop666, 2024). Dataset terdiri dari beberapa kelas penyakit bawang merah yang direpresentasikan dalam bentuk citra digital. Setiap citra dikelompokkan berdasarkan jenis penyakit sehingga dapat digunakan dalam proses klasifikasi berbasis deep learning.

Data dibagi menjadi tiga bagian, yaitu data pelatihan (*training*), data validasi (*validation*), dan data pengujian (*testing*). Pembagian dataset dilakukan untuk memastikan model dapat melakukan proses pelatihan dan evaluasi secara optimal.



Gambar 2. Sampel Dataset

2.2. Pemrosesan Citra

Sebelum tahap pelatihan, seluruh citra melalui proses prapemrosesan untuk memastikan konsistensi data dan meningkatkan kinerja pembelajaran model deep learning. Tahap prapemrosesan merupakan langkah penting dalam klasifikasi citra karena berfungsi untuk menstandarkan data masukan sehingga model dapat melakukan proses pembelajaran secara lebih optimal (Goodfellow et al., 2016).

Tahap pertama yang dilakukan adalah mengubah ukuran (*resize*) seluruh citra sesuai dengan resolusi input yang dibutuhkan oleh masing-masing varian EfficientNet. Setiap arsitektur EfficientNet memiliki ukuran input yang berbeda berdasarkan skala model yang digunakan. Pada penelitian ini, ukuran input yang digunakan adalah 224×224 piksel untuk EfficientNet-B0 dan 240×240 piksel untuk EfficientNet-B1 sesuai dengan konfigurasi asli arsitektur EfficientNet (Tan & Le, 2019). Penyesuaian ukuran citra dilakukan agar seluruh data kompatibel dengan struktur jaringan sehingga model dapat mengekstraksi fitur visual secara efektif.

Tabel 1 Model dan Ukuran Input

Model	Input Size
EfficientNet-B0	224x224
EfficientNet-B1	240x240

Setelah penyesuaian ukuran, nilai piksel dinormalisasi dengan menskalakannya ke rentang 0–1 menggunakan faktor penskalaan sebesar $1/255$. Proses normalisasi ini membantu menstabilkan pembaruan gradien selama pelatihan dan mempercepat konvergensi dengan memastikan bahwa semua fitur masukan memiliki rentang numerik yang serupa [12].

Dalam studi ini, prosedur prapemrosesan dan pemuatan data diimplementasikan menggunakan utilitas ImageDataGenerator dari kerangka kerja pembelajaran mendalam Keras. Kumpulan data dimuat menggunakan metode `flow_from_dataframe`, yang membaca jalur file gambar

dan label kelas yang sesuai secara langsung dari tabel data terstruktur. Pendekatan ini memungkinkan pengelolaan kumpulan data yang fleksibel sekaligus memungkinkan pelatihan berbasis batch yang efisien.

Selama proses pelatihan, gambar dimuat secara bertahap dan ukurannya disesuaikan secara otomatis sesuai dengan ukuran masukan yang ditentukan. Generator ini juga mengubah label kelas menjadi format kategorikal yang sesuai untuk tugas klasifikasi multi-kelas. Selain itu, kumpulan data pelatihan dan validasi diacak saat dimuat untuk memastikan pengambilan sampel secara acak dan mengurangi potensi bias selama pelatihan model. Sebaliknya, kumpulan data pengujian tidak diacak untuk menjaga urutan evaluasi yang konsisten.

Pipa prapemrosesan ini memastikan bahwa semua gambar diubah menjadi format standar yang kompatibel dengan model EfficientNet, sehingga memungkinkan ekstraksi fitur yang efisien dan pelatihan jaringan klasifikasi yang stabil.

2.3. Pembagian Data

Pembagian data dilakukan untuk memastikan proses pelatihan, validasi, dan pengujian model dapat berjalan secara optimal. Dataset penyakit bawang merah yang digunakan dalam penelitian ini dibagi menjadi tiga subset, yaitu data pelatihan (*training set*), data validasi (*validation set*), dan data pengujian (*testing set*). Data pelatihan digunakan untuk membangun dan mempelajari pola dari citra penyakit bawang merah, sedangkan data validasi digunakan untuk memantau kinerja model selama proses pelatihan serta membantu dalam pemilihan model terbaik. Selanjutnya, data pengujian digunakan untuk mengevaluasi kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya.

Berdasarkan hasil pembagian dataset, diperoleh sebanyak 2.700 citra untuk data pelatihan, 332 citra untuk data validasi, dan 201 citra untuk data pengujian. Dengan demikian, total dataset yang digunakan dalam penelitian ini berjumlah 3.233 citra. Proporsi pembagian data tersebut dirancang untuk memberikan jumlah data yang memadai pada proses pembelajaran model sekaligus mempertahankan data yang cukup untuk validasi dan pengujian sehingga hasil evaluasi yang diperoleh dapat merepresentasikan performa model secara objektif.

2.4 Arsitektur EfficientNet dan Compound Scaling

EfficientNet merupakan arsitektur *Convolutional Neural Network* (CNN) yang dirancang untuk mencapai performa klasifikasi yang tinggi dengan tetap mempertahankan efisiensi komputasi. Berbeda dengan arsitektur CNN konvensional yang umumnya melakukan penskalaan dimensi jaringan secara terpisah, EfficientNet memperkenalkan metode *compound scaling* yang menyeimbangkan kedalaman (*depth*), lebar (*width*), dan resolusi input (*resolution*) secara sistematis. Pendekatan ini memungkinkan model memperoleh akurasi yang lebih tinggi dengan jumlah parameter yang lebih sedikit serta kebutuhan komputasi yang lebih rendah dibandingkan model CNN tradisional (Tan & Le, 2019).

Arsitektur EfficientNet dibangun menggunakan blok *Mobile Inverted Bottleneck Convolution* (MBConv) yang pertama kali diperkenalkan pada arsitektur MobileNetV2. Blok MBConv memanfaatkan *depthwise separable convolution* dan *inverted residual connection* untuk mengurangi kompleksitas komputasi tanpa mengurangi kemampuan model dalam mengekstraksi fitur penting dari citra (Sandler et al., 2018). Selain itu, EfficientNet juga mengintegrasikan modul *Squeeze-and-Excitation* (SE) yang berfungsi untuk melakukan kalibrasi ulang fitur pada setiap kanal secara adaptif sehingga model dapat memberikan perhatian yang lebih besar terhadap fitur-fitur yang relevan selama proses pembelajaran (Hu et al., 2018).

Dalam penelitian ini digunakan dua varian EfficientNet, yaitu EfficientNet-B0 dan EfficientNet-B1. Kedua varian tersebut memiliki struktur dasar yang sama, namun berbeda pada ukuran jaringan dan resolusi input yang digunakan. EfficientNet-B0 menggunakan ukuran input sebesar 224×224 piksel, sedangkan EfficientNet-B1 menggunakan ukuran input sebesar 240×240 piksel. Perbedaan tersebut bertujuan untuk meningkatkan kapasitas representasi fitur sekaligus mempertahankan efisiensi komputasi melalui pendekatan *compound scaling* yang diterapkan pada setiap varian model (Tan & Le, 2019).

Untuk menyesuaikan model dengan tugas klasifikasi penyakit bawang merah, penelitian ini

menerapkan metode *transfer learning* menggunakan bobot awal (*pre-trained weights*) yang diperoleh dari dataset ImageNet. Lapisan klasifikasi bawaan EfficientNet dihilangkan dan digantikan dengan lapisan klasifikasi baru yang dirancang khusus untuk mengidentifikasi beberapa kelas penyakit bawang merah. Setelah proses ekstraksi fitur menggunakan model dasar EfficientNet, keluaran model diproses melalui lapisan *Global Average Pooling*, *Batch Normalization*, lapisan *Dense* sebanyak 256 neuron, serta *Dropout* sebelum diteruskan ke lapisan keluaran (*output layer*) dengan fungsi aktivasi *softmax*.

Salah satu keunggulan utama EfficientNet adalah metode *compound scaling* yang memungkinkan penskalaan jaringan dilakukan secara seragam pada dimensi kedalaman, lebar, dan resolusi input. Berbeda dengan pendekatan konvensional yang hanya meningkatkan salah satu dimensi jaringan, metode ini menghasilkan keseimbangan yang lebih baik antara akurasi dan efisiensi komputasi. Dengan demikian, EfficientNet mampu memberikan performa klasifikasi yang tinggi tanpa memerlukan peningkatan jumlah parameter secara berlebihan (Tan & Le, 2019).

$$depth = \alpha^\phi, width = \beta^\phi, resolution = \gamma^\phi \quad (1)$$

Dengan batasan :

$$\alpha \cdot \beta^2 \cdot \gamma^2 \approx 2 \quad (2)$$

Dimana :

α mewakili koefisien penskalaan kedalaman

β mewakili koefisien penskalaan lebar

γ mewakili koefisien penskalaan resolusi

ϕ adalah faktor penskalaan gabungan yang mengatur ukuran model secara keseluruhan

Dengan melakukan penskalaan bersama pada ketiga dimensi ini, EfficientNet mampu meningkatkan akurasi model sekaligus mempertahankan efisiensi komputasi. Peningkatan faktor penskalaan gabungan ϕ menghasilkan varian jaringan yang lebih besar, seperti EfficientNet-B1 hingga EfficientNet-B7, yang masing-masing menawarkan kapasitas dan kinerja model yang semakin tinggi.

Strategi penskalaan yang seimbang ini memungkinkan model EfficientNet mencapai kinerja yang unggul dibandingkan dengan banyak arsitektur CNN konvensional, sekaligus menggunakan parameter dan sumber daya komputasi yang jauh lebih sedikit. Akibatnya, EfficientNet telah menjadi salah satu arsitektur yang paling banyak digunakan dalam tugas klasifikasi gambar, termasuk deteksi penyakit tanaman dan analisis gambar pertanian.

2.5. Arsitektur Model

Arsitektur model yang digunakan dalam penelitian ini dibangun menggunakan pendekatan *transfer learning* dengan memanfaatkan model EfficientNet-B0 dan EfficientNet-B1 yang telah dilatih sebelumnya pada dataset ImageNet. Penggunaan *pre-trained model* bertujuan untuk memanfaatkan kemampuan ekstraksi fitur yang telah dipelajari dari jutaan citra sehingga dapat meningkatkan performa klasifikasi pada dataset penyakit bawang merah.

Berdasarkan Gambar 2, citra masukan (*input image*) terlebih dahulu diubah ukurannya sesuai dengan kebutuhan model, yaitu 224×224 piksel untuk EfficientNet-B0 dan 240×240 piksel untuk EfficientNet-B1. Citra tersebut kemudian diproses oleh model dasar EfficientNet dengan konfigurasi *include_top=False*. Pengaturan ini dilakukan untuk menghilangkan lapisan klasifikasi bawaan ImageNet sehingga model hanya berfungsi sebagai ekstraktor fitur.

Keluaran dari model EfficientNet selanjutnya diproses menggunakan lapisan *Global Average Pooling (GAP)*. Lapisan ini berfungsi untuk mereduksi dimensi fitur hasil ekstraksi menjadi vektor fitur yang lebih ringkas tanpa menghilangkan informasi penting yang telah dipelajari oleh jaringan. Penggunaan *Global Average Pooling* juga membantu mengurangi jumlah parameter dibandingkan penggunaan lapisan *flatten*.


Setelah proses *pooling*, fitur yang dihasilkan dinormalisasi menggunakan lapisan *Batch Normalization*. Lapisan ini bertujuan untuk menjaga stabilitas distribusi data selama proses pelatihan sehingga mempercepat konvergensi model dan mengurangi risiko terjadinya *overfitting*.

Tahap berikutnya adalah lapisan *Dense* dengan 256 neuron dan fungsi aktivasi ReLU (*Rectified Linear Unit*). Lapisan ini berfungsi untuk mempelajari representasi fitur tingkat tinggi yang relevan dengan proses klasifikasi penyakit bawang merah. Untuk meningkatkan kemampuan generalisasi model, setelah lapisan *Dense* ditambahkan lapisan *Dropout* dengan variasi nilai 0,3 dan 0,5. Teknik

dropout bekerja dengan menonaktifkan sebagian neuron secara acak selama proses pelatihan sehingga model tidak terlalu bergantung pada neuron tertentu.

Pada bagian akhir model digunakan lapisan keluaran (*output layer*) dengan fungsi aktivasi *softmax*. Jumlah neuron pada lapisan ini disesuaikan dengan jumlah kelas penyakit yang terdapat pada dataset. Fungsi *softmax* menghasilkan distribusi probabilitas untuk setiap kelas sehingga model dapat menentukan kelas penyakit dengan probabilitas tertinggi sebagai hasil prediksi.

Model dikompilasi menggunakan optimizer Adamax dengan variasi *learning rate* sebesar 0,0001 dan 0,001. Fungsi kerugian (*loss function*) yang digunakan adalah *categorical crossentropy* karena penelitian ini merupakan permasalahan klasifikasi multikelas. Kinerja model dievaluasi menggunakan metrik *accuracy* pada data pelatihan, validasi, dan pengujian.



Gambar 4. Arsitektur Model

2.6. Konfigurasi Pelatihan

Proses pelatihan model dilakukan menggunakan dua varian arsitektur EfficientNet, yaitu EfficientNet-B0 dan EfficientNet-B1. Pelatihan dilakukan dengan menerapkan pendekatan *transfer learning* menggunakan bobot awal (*pre-trained weights*) dari dataset ImageNet. Seluruh model dilatih menggunakan data pelatihan (*training set*) dan dievaluasi menggunakan data validasi (*validation set*) untuk memantau performa selama proses pembelajaran.

Data citra diproses menggunakan *ImageDataGenerator* dengan teknik normalisasi (*rescaling*) sebesar $1/255$ sehingga nilai piksel berada pada rentang 0 hingga 1. Proses pelatihan dilakukan dengan ukuran *batch* sebesar 16 citra untuk setiap iterasi. Penggunaan ukuran *batch* ini dipilih untuk menjaga keseimbangan antara penggunaan memori komputasi dan stabilitas proses optimasi.

Pada penelitian ini digunakan optimizer Adamax karena memiliki kemampuan yang baik dalam menangani pembaruan bobot pada jaringan saraf dalam serta lebih stabil terhadap variasi gradien. Untuk mengetahui pengaruh parameter optimasi terhadap performa model, dilakukan pengujian menggunakan dua nilai *learning rate*, yaitu 0,0001 dan 0,001. Selain itu, diterapkan dua variasi nilai *dropout*, yaitu 0,3 dan 0,5, untuk mengurangi risiko *overfitting* selama proses pelatihan.

Fungsi kerugian (*loss function*) yang digunakan adalah *categorical crossentropy* karena permasalahan yang diteliti termasuk klasifikasi multikelas. Sementara itu, metrik evaluasi yang digunakan selama proses pelatihan adalah *accuracy* untuk mengukur tingkat ketepatan model dalam mengklasifikasikan citra penyakit bawang merah.

Untuk memperoleh model terbaik, penelitian ini menerapkan mekanisme *Model Checkpoint* yang secara otomatis menyimpan model dengan nilai *validation accuracy* tertinggi selama proses pelatihan. Selain itu, digunakan callback *Reduce Learning Rate on Plateau* untuk menyesuaikan nilai *learning rate* secara adaptif ketika *validation loss* tidak mengalami penurunan dalam beberapa epoch berturut-turut. Pada konfigurasi ini, nilai *learning rate* dikurangi sebesar 20% dari nilai sebelumnya (*factor* = 0,2) dengan nilai minimum *learning rate* sebesar 1×10^{-5} .

Tabel 3. Konfigurasi Pelatihan Model

Optimasi Hyperparameter EfficientNet-B1 untuk Klasifikasi Penyakit Bawang Merah Berbasis Citra Digital Adlu Aghnia ¹ , Nur Ariesanto Ramdhan ² , Otong Saeful Bachri ³	358
--	-----

Parameter	Nilai
Arsitektur Model	EfficientNet-B0, EfficientNet-B1
Transfer Learning	ImageNet Pre-trained Weights
Ukuran Input B0	$224 \times 224 \times 3$
Ukuran Input B1	$240 \times 240 \times 3$
Batch Size	16
Optimizer	Adamax
Learning Rate	0,0001 dan 0,001
Dropout	0,3 dan 0,5
Loss Function	Categorical Crossentropy
Evaluation Metric	Accuracy
Normalisasi	Rescale = $1/255$
Model Checkpoint	Berdasarkan Validation Accuracy
ReduceLROnPlateau	Factor = 0,2
Patience	2 Epoch
Minimum Learning Rate	1×10^{-5}

Berdasarkan kombinasi parameter yang digunakan, penelitian ini menghasilkan delapan skenario pelatihan yang terdiri atas kombinasi dua arsitektur EfficientNet, dua nilai *learning rate*, dan

dua nilai *dropout*. Seluruh skenario dievaluasi menggunakan data pengujian (*testing set*) untuk menentukan model terbaik berdasarkan nilai *accuracy* dan *loss*.

2.7. Evaluasi Metrik

Untuk mengevaluasi performa model yang diusulkan, digunakan beberapa metrik klasifikasi standar, antara lain akurasi, presisi, *recall*, dan *F1-score*. Akurasi mengukur proporsi keseluruhan sampel yang diklasifikasikan dengan benar, sedangkan presisi menunjukkan proporsi prediksi positif yang benar di antara semua prediksi positif. *Recall* mengukur kemampuan model untuk mengidentifikasi sampel positif dengan benar, dan *F1-score* merupakan rata-rata harmonis dari presisi dan *recall*. Metrik evaluasi ini memberikan penilaian yang komprehensif terhadap performa klasifikasi model dan banyak digunakan dalam studi *machine learning* serta pengenalan pola untuk tugas klasifikasi [20][21].

Akurasi mengukur proporsi keseluruhan sampel yang diklasifikasikan dengan benar dan didefinisikan sebagai:

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

Presisi mengukur proporsi sampel positif yang diprediksi dengan benar di antara semua sampel yang diprediksi sebagai positif:

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

Recall mengukur kemampuan model untuk mengidentifikasi dengan benar semua sampel positif yang relevan dan didefinisikan sebagai:

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

F1-Score merupakan rata-rata harmonik dari presisi dan recall, serta berfungsi sebagai metrik evaluasi yang seimbang untuk mengukur kinerja klasifikasi:

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

Metrik evaluasi ini memberikan penilaian yang komprehensif terhadap kemampuan model untuk mengklasifikasikan penyakit daun bawang merah secara akurat dan andal.

3. HASIL DAN ANALISIS

3.1. Hasil Pelatihan dan Pengujian Model

Penelitian ini melakukan pengujian terhadap dua varian EfficientNet, yaitu EfficientNet-B0 dan EfficientNet-B1. Setiap arsitektur diuji menggunakan kombinasi dua nilai *learning rate* (0,0001 dan 0,001) serta dua nilai *dropout* (0,3 dan 0,5). Evaluasi dilakukan menggunakan metrik *accuracy* dan *loss* pada data pelatihan, validasi, dan pengujian.


Tabel 4. Hasil Evaluasi Model

Optimasi Hyperparameter EfficientNet-B1 untuk Klasifikasi Penyakit Bawang Merah Berbasis Citra Digital Adlu Aghnia ¹ , Nur Ariesanto Ramdhan ² , Otong Saeful Bachri ³	360
--	-----

Model	Learning Rate	Dropout	Train Acc (%)	Validation Acc (%)	Test Acc (%)	Test Loss
EfficientNet-B0	0,0001	0,3	99,94	89,13	91,54	0,3323
EfficientNet-B0	0,0001	0,5	99,40	88,51	90,55	0,2691
EfficientNet-B0	0,001	0,3	99,97	88,82	89,55	0,3614
EfficientNet-B0	0,001	0,5	99,68	87,58	89,55	0,3457
EfficientNet-B1	0,0001	0,3	97,20	84,78	81,59	0,4316
EfficientNet-B1	0,0001	0,5	99,65	86,65	87,56	0,3501
EfficientNet-B1	0,001	0,3	99,94	89,13	93,03	0,2572
EfficientNet-B1	0,001	0,5	99,84	89,75	87,56	0,3805


Berdasarkan hasil pengujian pada Tabel 4, model EfficientNet-B1 dengan *learning rate* 0,001 dan *dropout* 0,3 menghasilkan performa terbaik dengan nilai *test accuracy* sebesar 93,03% dan *test loss* sebesar 0,2572. Hasil tersebut menunjukkan bahwa kombinasi parameter tersebut mampu menghasilkan kemampuan generalisasi yang lebih baik dibandingkan konfigurasi lainnya.

3.2. Perbandingan Akurasi dan Loss Model



Gambar 3. Perbandingan Test Accuracy Seluruh Model EfficientNet

Gambar 3 menunjukkan perbandingan nilai *test accuracy* dari seluruh konfigurasi model yang diuji. Model EfficientNet-B1 dengan *learning rate* 0,001 dan *dropout* 0,3 menghasilkan akurasi tertinggi sebesar 93,03%, sedangkan model EfficientNet-B1 dengan *learning rate* 0,0001 dan *dropout* 0,3 memperoleh akurasi terendah sebesar 81,59%.



Gambar 4. Perbandingan Test Loss Seluruh Model EfficientNet


Gambar 4 menunjukkan perbandingan nilai *test loss* dari seluruh konfigurasi model. Model EfficientNet-B1 dengan *learning rate* 0,001 dan *dropout* 0,3 menghasilkan nilai *loss* terendah sebesar 0,2572, yang menunjukkan kemampuan generalisasi terbaik pada data pengujian. Sebaliknya, model EfficientNet-B1 dengan *learning rate* 0,0001 dan *dropout* 0,3 menghasilkan nilai *loss* tertinggi sebesar 0,4316.

3.3. Evaluasi Model Terbaik

Gambar 5 menunjukkan confusion matrix dari model terbaik yang diperoleh pada penelitian ini. Nilai pada diagonal utama menunjukkan jumlah data yang berhasil diklasifikasikan dengan benar oleh model, sedangkan nilai di luar diagonal menunjukkan kesalahan klasifikasi. Berdasarkan confusion matrix, kelas Busuk Daun berhasil diklasifikasikan dengan benar sebanyak 27 dari 28 citra. Hanya terdapat satu citra yang salah diklasifikasikan sebagai kelas Trotol. Kelas Moler menunjukkan performa yang baik dengan 25 citra berhasil dikenali dengan benar dari total 27 citra, sedangkan masing-masing satu citra salah diklasifikasikan sebagai kelas Sehat dan Trotol.

Kelas Sehat merupakan kelas dengan jumlah data terbanyak dan memiliki tingkat pengenalan yang sangat tinggi. Sebanyak 116 citra berhasil diklasifikasikan dengan benar dari total 123 citra. Kesalahan klasifikasi terjadi pada dua citra yang diprediksi sebagai Busuk Daun, tiga citra sebagai Moler, dan dua citra sebagai Trotol. Pada kelas Trotol, model berhasil mengklasifikasikan 19 citra dengan benar dari total 23 citra. Kesalahan klasifikasi terjadi pada empat citra yang diprediksi sebagai Busuk Daun. Hal ini mengindikasikan adanya kemiripan karakteristik visual antara gejala penyakit Trotol dan Busuk Daun pada beberapa citra.

Hasil tersebut menunjukkan bahwa model EfficientNet-B1 dengan *learning rate* 0,001 dan *dropout* 0,3 memiliki kemampuan yang sangat baik dalam mengenali penyakit bawang merah berdasarkan citra digital. Dominasi nilai pada diagonal utama menunjukkan bahwa sebagian besar citra berhasil diklasifikasikan ke kelas yang benar. Meskipun masih terdapat beberapa kesalahan klasifikasi, terutama antara kelas Trotol dan Busuk Daun, performa model secara keseluruhan dapat dikategorikan sangat baik dengan tingkat akurasi di atas 90%.



Gambar 5. Hasil Confusion Matrix Model Terbaik

Tabel 5. Hasil Analisis Perkelas

Kelas	Benar	Total	Recall (%)
Busuk Daun	27	28	96,43
Moler	25	27	92,59
Sehat	116	123	94,31
Trotol	19	23	82,61

Berdasarkan nilai recall, kelas Busuk Daun memiliki kemampuan deteksi terbaik dengan nilai 96,43%, sedangkan kelas Trotol memiliki nilai recall terendah sebesar 82,61%. Hal ini menunjukkan bahwa model masih mengalami kesulitan dalam membedakan sebagian citra Trotol dengan Busuk Daun karena kemiripan pola visual pada daun yang terinfeksi. Namun secara umum seluruh kelas berhasil mencapai nilai recall di atas 80%, yang menunjukkan kemampuan klasifikasi yang baik pada seluruh kategori penyakit bawang merah.

4. KESIMPULAN

Penelitian ini telah berhasil menerapkan arsitektur EfficientNet-B0 dan EfficientNet-B1 untuk melakukan klasifikasi penyakit bawang merah berdasarkan citra digital. Pengujian dilakukan menggunakan delapan kombinasi parameter yang terdiri dari dua varian arsitektur EfficientNet, dua nilai *learning rate* (0,0001 dan 0,001), serta dua nilai *dropout* (0,3 dan 0,5). Evaluasi model dilakukan menggunakan metrik *accuracy* dan *loss* pada data pelatihan, validasi, dan pengujian.

Hasil penelitian menunjukkan bahwa arsitektur EfficientNet-B1 memberikan performa yang lebih baik dibandingkan EfficientNet-B0. Konfigurasi terbaik diperoleh pada EfficientNet-B1 dengan *learning rate* 0,001 dan *dropout* 0,3 yang menghasilkan *training accuracy* sebesar 99,94%, *validation accuracy* sebesar 89,13%, dan *test accuracy* sebesar 93,03% dengan *test loss* sebesar 0,2572. Hasil

tersebut menunjukkan bahwa kombinasi parameter tersebut mampu memberikan kemampuan generalisasi yang lebih baik dibandingkan konfigurasi lainnya.

Berdasarkan analisis *confusion matrix*, model terbaik mampu mengklasifikasikan 187 dari 201 citra pengujian dengan benar. Nilai *recall* yang diperoleh untuk kelas Busuk Daun, Moler, Sehat, dan Trotol masing-masing sebesar 96,43%, 92,59%, 94,31%, dan 82,61%. Meskipun masih terdapat beberapa kesalahan klasifikasi, terutama pada kelas Trotol yang memiliki kemiripan karakteristik visual dengan kelas lainnya, secara keseluruhan model menunjukkan kemampuan klasifikasi yang sangat baik.

Dengan demikian, dapat disimpulkan bahwa EfficientNet-B1 dengan *learning rate* 0,001 dan *dropout* 0,3 merupakan model yang paling optimal untuk klasifikasi penyakit bawang merah berbasis citra digital. Hasil penelitian ini menunjukkan bahwa pendekatan *deep learning* berbasis EfficientNet memiliki potensi untuk diterapkan sebagai sistem pendukung diagnosis penyakit bawang merah secara otomatis guna membantu petani dan praktisi pertanian dalam melakukan deteksi penyakit secara lebih cepat dan akurat.

REFERENCES

- [1] S. Bhujel and S. Shakya, "Rice leaf diseases classification using discriminative fine tuning and CLR on EfficientNet," *Journal of Soft Computing Paradigm*, vol. 4, no. 3, pp. 172–187, 2022. doi: [10.36548/jscp.2022.3.006](https://doi.org/10.36548/jscp.2022.3.006)
- [2] M. Liu, H. Liang, and M. Hou, "Research on cassava disease classification using the multi-scale fusion model based on EfficientNet and attention mechanism," *Frontiers in Plant Science*, vol. 13, p. 1088531, 2022. doi: [10.3389/fpls.2022.1088531](https://doi.org/10.3389/fpls.2022.1088531)
- [3] S. Albahli and M. Masood, "Efficient attention-based CNN network (EAnet) for multi-class maize crop disease classification," *Frontiers in Plant Science*, vol. 13, p. 1003152, 2022. doi: [10.3389/fpls.2022.1003152](https://doi.org/10.3389/fpls.2022.1003152)
- [4] T. Nazir, M. M. Iqbal, S. Jabbar, A. Hussain, and M. Albathan, "EfficientPNet—An optimized and efficient deep learning approach for classifying disease of potato plant leaves," *Agriculture*, vol. 13, no. 4, p. 841, 2023. doi: [10.3390/agriculture13040841](https://doi.org/10.3390/agriculture13040841)
- [5] H. You, Y. Lu, and H. Tang, "Plant disease classification and adversarial attack using SimAM-EfficientNet and GP-MI-FGSM," *Sustainability*, vol. 15, no. 2, p. 1233, 2023. doi: [10.3390/su15021233](https://doi.org/10.3390/su15021233)
- [6] M. H. Ashmafee, T. Ahmed, S. Ahmed, M. B. Hasan, M. N. Jahan, and A. B. M. A. Rahman, "An efficient transfer learning-based approach for apple leaf disease classification," *arXiv*, 2023. [Online]. Available: <https://arxiv.org/abs/2304.06520>
- [7] appdevop666, "Onion leaf disease dataset," Hugging Face, 2024. [Online]. Available: <https://huggingface.co/datasets/appdevop666/onion-leaf-disease>
- [8] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016.
- [9] M. Tan and Q. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," in *Proc. 36th Int. Conf. Mach. Learn. (ICML)*, 2019, pp. 6105–6114.
- [10] J. Hu, L. Shen, and G. Sun, "Squeeze-and-excitation networks," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2018, pp. 7132–7141. doi: [10.1109/CVPR.2018.00745](https://doi.org/10.1109/CVPR.2018.00745)
- [11] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, "MobileNetV2: Inverted residuals and linear bottlenecks," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2018, pp. 4510–4520. doi: [10.1109/CVPR.2018.00474](https://doi.org/10.1109/CVPR.2018.00474)
- [12] M. Tan and Q. V. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," in *Proc. 36th Int. Conf. Mach. Learn. (ICML)*, vol. 97, 2019, pp. 6105–6114. [Online]. Available: <https://proceedings.mlr.press/v97/tan19a.html>

- [13] P. S. A. Kumar, S. Pathmanaban, and J. Mahalakshmi, "An enhanced EfficientNet framework for automated waste classification using cosine annealing and label smoothing," *Scientific Reports*, 2026. doi: [10.1038/s41598-026-60126-4](https://doi.org/10.1038/s41598-026-60126-4).
- [14] A. W. Putra, "Penerapan arsitektur EfficientNet-B1 untuk klasifikasi jenis jamur dengan metode Convolutional Neural Network," Skripsi, Univ. Lambung Mangkurat, 2026. [Online]. Available: <https://digilib.ulm.ac.id/archive/digital/detailed.php?code=47142>
- [15] I. M. Ramadhan, "Image classification of beef and pork using Convolutional Neural Network architecture EfficientNet-B1," *Journal of Applied Informatics and Computing*, vol. 6, no. 1, pp. 54–62, 2023. [Online]. Available: <https://repository.uin-suska.ac.id/72286/>
- [16] M. Tan and Q. V. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," in *Proc. 36th Int. Conf. Mach. Learn. (ICML)*, vol. 97, 2019, pp. 6105–6114. [Online]. Available: <https://arxiv.org/abs/1905.11946>
- [17] L. M. Torres, "Classificação e segmentação de pólipos em imagens de colonoscopia utilizando redes EfficientNet e CAM," *Trabalho de Conclusão de Curso*, Univ. Federal do Amazonas, 2024. [Online]. Available: https://riu.ufam.edu.br/bitstream/prefix/7353/2/TCC_LucasModestoTorres.pdf