

KLASIFIKASI PENYAKIT DAUN BAWANG MERAH MENGUNAKAN EFFICIENTNETV2-B0 BERBASIS CBAM DAN GRAD-CAM

Alenta Eka Setiawan¹, Endang Supriyati², Tri Listyorini³

^{1,2,3}Program Studi Teknik Informatika, Fakultas Teknik, Universitas Muria Kudus, Kudus,
Indonesia

e-mail: 1202351152@umk.ac.id, 2endang.supriyati@umk.ac.id, 3trilistyorini@umk.ac.id

ABSTRAK

Diagnosis penyakit daun bawang merah (*Allium cepa* var. *aggregatum*) di tingkat petani masih mengandalkan pengamatan visual manual yang subjektif dan rawan keliru, khususnya dalam membedakan busuk daun (*Peronospora destructor*) dan bercak ungu trotol (*Alternaria porri*) yang memiliki kemiripan gejala klorosis, sehingga memicu kesalahan aplikasi fungisida. Penelitian ini mengembangkan sistem klasifikasi otomatis berbasis *deep learning* dengan arsitektur EfficientNetV2-B0 yang diperkuat dengan *Convolutional Block Attention Module* (CBAM) untuk memfokuskan fitur pada lesi patologis, dilatih melalui skema empat tahap progresif (*4-stage fine-tuning*) dengan regularisasi *MixUp* ($\alpha = 0,2$), serta dilengkapi *Gradient-Weighted Class Activation Mapping* (Grad-CAM) untuk transparansi keputusan. Dataset terdiri atas 3.200 citra yang terbagi ke dalam empat kelas diagnostik. Pengujian pada 483 data uji independen menunjukkan Akurasi Keseluruhan sebesar 90,89% dan Macro F1-Score sebesar 90,56% dengan visualisasi Grad-CAM yang secara kualitatif mengindikasikan fokus model pada area lesi. Model usulan secara signifikan lebih akurat daripada VGG16, MobileNetV2, dan ResNet-50 (uji McNemar, $p < 0,05$). Sistem selanjutnya diimplementasikan ke dalam platform laboratorium berbasis web ShallotGuard AI yang dilengkapi validasi botani awal. Sistem ini masih berupa prototipe laboratorium yang menjanjikan sebagai alat bantu diagnosis dini, tetapi belum diuji langsung oleh petani di lahan sehingga validasi lapangan masih diperlukan.

Kata kunci: bawang merah; CBAM; EfficientNetV2-B0; Grad-CAM; klasifikasi penyakit daun

ABSTRACT

Disease diagnosis of shallot (*Allium cepa* var. *aggregatum*) leaves at the farmer level still relies on subjective manual visual inspection, which is particularly error-prone in distinguishing downy mildew (*Peronospora destructor*) from purple blotch (*Alternaria porri*) due to their similar chlorotic symptoms, resulting in inappropriate fungicide application. This study develops an automated *deep learning* classification system using the EfficientNetV2-B0 architecture reinforced with a *Convolutional Block Attention Module* (CBAM) to focus feature representation on pathological lesions, trained through a 4-stage progressive fine-tuning scheme combined with *MixUp* regularization ($\alpha = 0.2$), and equipped with *Gradient-Weighted Class Activation Mapping* (Grad-CAM) for decision transparency. The dataset comprises 3,200 images distributed across four diagnostic classes. Evaluation on 483 independent test images shows an Overall Accuracy of 90.89% and a Macro F1-Score of 90.56%, with Grad-CAM visualizations qualitatively indicating that the model's attention concentrates on lesion areas. The proposed model is significantly more accurate than VGG16, MobileNetV2, and ResNet-50 (McNemar test, $p < 0.05$). The system was further deployed into the ShallotGuard AI web-based laboratory platform

equipped with preliminary botanical validation. The system remains a laboratory prototype that is promising as a decision-support tool for early diagnosis, but it has not yet been tested directly by farmers in the field, so field validation is still required.

Keywords: CBAM; EfficientNetV2-B0; Grad-CAM; leaf disease classification; shallots

1. PENDAHULUAN

Bawang merah (*Allium cepa* var. *aggregatum*) merupakan komoditas hortikultura strategis dengan nilai ekonomis tinggi yang fluktuasi pasokannya berkorelasi langsung terhadap laju inflasi bahan pangan nasional. Produktivitas komoditas ini menghadapi tekanan biotik yang signifikan akibat infeksi patogen daun, baik yang bersifat tular udara (*airborne*) maupun tular tanah (*soilborne*). Tiga penyakit yang paling sering menimbulkan epidemi di sentra produksi adalah busuk daun (*downy mildew*) yang disebabkan oleh *Peronospora destructor*, bercak ungu atau trotol yang disebabkan oleh *Alternaria porri*, serta layu moler (basal rot) yang dipicu oleh kompleks cendawan tular tanah *Fusarium oxysporum* [1], [2], [3]. Pada musim penghujan dengan kelembapan nisbi di atas 85%, laju perkembangan inokulum ketiga patogen tersebut meningkat secara eksponensial sehingga intensitas serangan dapat mencapai tingkat kegagalan panen total apabila tindakan kuratif tidak dieksekusi pada fase infeksi awal.

Praktik diagnosis penyakit pada tingkat petani hingga kini masih bertumpu pada pengamatan visual manual yang bersifat subjektif, membutuhkan durasi inspeksi lapangan yang panjang, serta menuntut kompetensi patologi tumbuhan yang tidak selalu dimiliki pembudidaya [1], [4]. Keterbatasan ini menjadi kritis karena pada stadium awal, lesi klorotik akibat *Alternaria porri* dan *Peronospora destructor* memperlihatkan kemiripan morfologi dan kromatik yang tinggi. Kesalahan identifikasi berimplikasi pada pemilihan bahan aktif fungisida yang tidak tepat sasaran dan aplikasi pestisida berlebihan (*over-application*), yang menurunkan efisiensi biaya usaha tani serta meninggalkan residu kimia pada hasil panen.

Sejumlah penelitian terdahulu telah memanfaatkan visi komputer untuk mengotomatisasi identifikasi penyakit daun. Pendekatan ekstraksi fitur tekstur *Gray Level Co-occurrence Matrix* (GLCM) yang dipadukan dengan pengklasifikasi *Naive Bayes* [2], [3], maupun *Support Vector Machine* (SVM) [1] mampu mengenali pola statistik permukaan daun, tetapi kinerjanya menurun pada citra lapangan dengan latar belakang heterogen. Paradigma *transfer learning* berbasis *Convolutional Neural Network* (CNN) kemudian menjadi pendekatan dominan melalui arsitektur Xception [4], Inception-V3 [5], MobileNetV2 [6], [7], MobileNetV4 [8], VGG16 [9], dan EfficientNet-B0 [10]. Eksplorasi *vision transformer* MaxViT untuk deteksi penyakit daun bawang merah berbasis perangkat bergerak juga telah dilakukan [11], sementara analisis anomali citra daun hortikultura dikaji oleh Harianti dkk. [12]. Pada ranah arsitektur mutakhir, Maghfud dkk.[13] menggunakan EfficientNetV2 dan membuktikan bahwa arsitektur tersebut memiliki kapabilitas ekstraksi fitur mendalam yang unggul dengan beban komputasi efisien untuk implementasi berbasis web.


Telaah terhadap penelitian tersebut mengindikasikan tiga kesenjangan yang belum terselesaikan secara simultan. Pertama, misklasifikasi timbal balik antara kelas Busuk Daun dan Trotol masih tinggi karena jaringan konvolusi standar kesulitan menangkap karakteristik lesi mikro pembeda kedua patogen [6], [10]. Kedua, model CNN standar cenderung mengalami *overfitting* pada citra lapangan yang mengandung derau visual berupa tanah, gulma, dan bayangan sungkup [9]. Ketiga, sebagian model bekerja

sebagai “kotak hitam” (*black box*) tanpa justifikasi atas keputusan klasifikasinya [14], [15] sehingga tingkat kepercayaan penyuluh dan petani terhadap luaran sistem rendah.

Berdasarkan kesenjangan tersebut, penelitian ini bertujuan mengembangkan sistem klasifikasi penyakit daun bawang merah yang akurat dan dapat dijelaskan keputusannya. Komponen yang digunakan, yaitu EfficientNetV2, CBAM, dan Grad-CAM, sudah banyak diterapkan pada penelitian sebelumnya. Kebaruan penelitian ini bersifat integratif dan terapan, yaitu menggabungkan ketiganya dalam satu kerangka kerja. Kontribusi penelitian ini yang pertama, modul CBAM diintegrasikan pada akhir tahap ekstraksi fitur EfficientNetV2-B0, sebelum *Global Average Pooling*, sehingga model mampu memberikan bobot perhatian yang lebih besar pada kanal fitur dan lokasi lesi yang informatif [15]. Kedua, pelatihan model dilakukan melalui strategi *fine-tuning* progresif empat tahap dengan penurunan laju pembelajaran secara bertahap dan regularisasi MixUp ($\alpha = 0,2$), yang bertujuan menghasilkan batas keputusan antarkelas yang lebih halus serta mengurangi risiko *catastrophic forgetting* [9]. Ketiga, Grad-CAM dimanfaatkan untuk menganalisis secara kualitatif kesesuaian antara area fokus model dan pola lesi pada citra daun [14]. Terakhir, filter validasi awal berbasis ruang warna HSV dan varians Laplacian dikembangkan pada sistem ShallotGuard AI untuk menyaring citra nond daun sebelum tahap inferensi [16]. Kontribusi pertama dan kedua dievaluasi melalui perbandingan dengan arsitektur lain seperti studi ablasi, dan uji statistik, sedangkan Grad-CAM dianalisis secara kualitatif dan filter validasi awal diperlakukan sebagai fitur implementasi sistem.

2. METODE PENELITIAN

Penelitian ini dilaksanakan melalui delapan tahapan yang tersusun secara sekuensial dan saling berkaitan. Tahapan pada diagram alur (*flowchart*) sebagaimana disajikan pada Gambar 1.



Gambar 1 Diagram Alur Tahapan Penelitian Klasifikasi Penyakit Daun Bawang

Dataset Penelitian dan Prapemrosesan Citra

Dataset yang digunakan bersumber dari repositori publik Roboflow Universe yang juga tersedia pada platform Kaggle dengan link berikut <https://universe.roboflow.com/sisilia/citra-daun-bawang-merah>. Repositori tersebut secara keseluruhan memuat 3.300 citra digital, yang terdiri atas 3.200 citra berlabel serta 100 citra tanpa label (*unlabeled*). Pada penelitian ini, sebanyak 100 citra tanpa label tersebut dieksklusi karena tidak memiliki anotasi kelas diagnostik *ground-truth*, sehingga sebanyak 3.200 citra berlabel yang digunakan dengan distribusi seimbang, yaitu masing-masing 800 citra pada empat kelas diagnostik: Busuk Daun (*Peronospora destructor*), Layu Moler (*Fusarium oxysporum*), Daun Sehat, dan Bercak Ungu Trotol (*Alternaria porri*). Dataset dibagi menggunakan partisi bawaan Roboflow dengan rasio sekitar 70% data latih (2.234 citra), 15% data validasi (483 citra), dan 15% data uji independen (483 citra), dengan rincian data uji Busuk Daun 109, Layu Moler 144, Daun Sehat 102, dan Trotol 128 citra. Data uji tidak digunakan pada proses pelatihan maupun penalaan *hyperparameter*. Pada tahap prapemrosesan ini ukuran seluruh citra diseragamkan menjadi 224×224 piksel, kemudian intensitas piksel dinormalisasikan ke rentang $[0, 1]$ sesuai prosedur standar arsitektur EfficientNet. Citra pada dataset sebagian besar diambil pada siang hari dengan pencahayaan yang relatif teratur dan latar belakang tanah yang seragam. Dataset belum sepenuhnya mencakup kondisi lapangan ekstrem, seperti pantulan cahaya matahari langsung (*specular reflection*), embun pekat, bayangan sungkup atau pepohonan, dan infeksi ganda (*co-infection*) dua patogen pada satu helai daun. Untuk meningkatkan generalisasi terhadap variasi tersebut, digunakan augmentasi geometrik dan fotometrik.

Augmentasi Data dan Regularisasi MixUp

Guna menekan risiko pemadanan berlebih (*overfitting*) sekaligus meningkatkan daya generalisasi model terhadap variasi kondisi pencahayaan di lahan, diterapkan kombinasi augmentasi geometrik berupa rotasi acak hingga 20° , pergeseran horizontal dan vertikal sebesar 10%, serta pembalikan horizontal, yang dipadukan dengan augmentasi fotometrik berupa variasi kecerahan dan kontras. Selain itu, diterapkan teknik regularisasi MixUp yang bekerja melalui interpolasi linear secara simultan terhadap pasangan citra masukan dan vektor labelnya sesuai Persamaan (1) dan (2).

$$\tilde{x} = \lambda_{x_i} + (1 - \lambda)_{x_j} \quad (1)$$

$$\tilde{y} = \lambda_{y_i} + (1 - \lambda)_{y_j} \quad (2)$$

dengan x_i dan x_j merupakan pasangan matriks citra masukan, y_i dan y_j adalah vektor label *one-hot* dari kelas yang bersesuaian, serta λ merupakan koefisien interpolasi yang dibangkitkan dari distribusi Beta (α, α) dengan nilai *hyperparameter* $\alpha = 0,2$. Penerapan *MixUp* memaksa jaringan mempelajari representasi fitur yang linear dan halus di sekitar batas antarkelas, sehingga diharapkan membantu mengurangi kerancuan prediksi antara lesi Busuk Daun dan Trotol yang secara visual saling menyerupai.

Arsitektur EfficientNetV2-B0 dan Modul Atensi CBAM

Arsitektur EfficientNetV2-B0 dipilih sebagai tulang punggung (*backbone*) ekstraksi fitur karena mengombinasikan blok Fused-MBconv dan MBConv yang

dioptimasi melalui mekanisme *Neural Architecture Search* (NAS), sehingga menawarkan keseimbangan antara akurasi dan efisiensi komputasi. Untuk meningkatkan sensitivitas jaringan terhadap pola lesi nekrotik berukuran halus, modul atensi CBAM diintegrasikan pada ujung blok konvolusi sebelum lapisan *Global Average Pooling*. Modul ini bekerja melalui dua tahap berurutan, yaitu *Channel Attention Module* (CAM) yang memodelkan korelasi tingkat kepentingan antarpeta fitur, dan *Spatial Attention Module* (SAM) yang melakukan pembobotan terhadap lokasi lesi patologis pada helaian daun, sebagaimana dirumuskan pada Persamaan (3) dan (4) [15]:

$$M_c(F) = \sigma \left(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F)) \right) \quad (3)$$

$$M_s(F') = \sigma (f^{7 \times 7}([\text{AvgPool}(F') ; \text{MaxPool}(F')])) \quad (4)$$

dengan F merepresentasikan peta fitur masukan berdimensi $C \times H \times W$, σ adalah fungsi aktivasi sigmoid, MLP menyatakan jaringan perseptron multilapis dengan rasio reduksi 16, dan $f^{7 \times 7}$ melambangkan operasi konvolusi spasial berukuran kernel 7×7 . Vektor fitur yang telah diperkuat oleh atensi saluran dan spasial selanjutnya dihubungkan ke lapisan klasifikasi *fully connected* dengan laju *dropout* sebesar 0,3 dan fungsi aktivasi *softmax* pada empat neuron keluaran untuk menghasilkan distribusi probabilitas masing-masing kelas penyakit.

Skema Pelatihan Empat Tahap Progresif (4-Stage Fine-Tuning)

Pelatihan model dilaksanakan menggunakan strategi *4 – stage progressive fine – tuning* guna mencegah terjadinya *catastrophic forgetting* pada representasi bobot pralatih ImageNet. Pada Tahap 1 (*warm – up, epoch 1 – 15*), seluruh lapisan *backbone* dibekukan (*frozen*) dan pelatihan hanya dilakukan pada lapisan *classifier head* serta modul CBAM dengan laju pembelajaran (*learning rate*) 1×10^{-3} . Pada Tahap 2 (*partial unfreeze, epoch 16 – 25*), 30 lapisan konvolusi teratas dibuka untuk penyesuaian fitur tingkat tinggi dengan laju pembelajaran 1×10^{-4} . Pada Tahap 3 (*deep unfreeze, epoch 26 – 35*), sebanyak 60 lapisan dibuka dengan laju pembelajaran 5×10^{-5} . Pada Tahap 4 (*full fine – tuning, epoch 36 – 45*), seluruh lapisan dibuka dengan laju pembelajaran sangat rendah sebesar 1×10^{-5} yang dikendalikan melalui fungsi peluruhan *cosine decay* dan dioptimasi menggunakan algoritma AdamW dengan *weight decay* sebesar 1×10^{-4} .

Metrik Evaluasi Kinerja Model

Kinerja model dievaluasi pada 483 citra data uji independen menggunakan empat metrik standar klasifikasi, yaitu *precision*, *recall*, *F1-score*, dan *overall accuracy*, yang dihitung berdasarkan komponen *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN) pada matriks konfusi sesuai Persamaan (5) – (8):

$$\text{Precision} = \frac{TP}{TP + FP} \quad (5)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (6)$$

$$F1 - \text{Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (7)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

Mengingat distribusi jumlah sampel uji antarkelas (102—144 citra) tidak sepenuhnya seimbang, agregasi metrik dilakukan menggunakan skema *macro average* agar setiap kelas penyakit memperoleh bobot kontribusi yang setara dalam penilaian kinerja akhir model.

Skenario Pembandingan, Studi Ablasi, dan Uji Statistik

Kinerja model usulan dibandingkan dengan tiga arsitektur *convolutional neural network* yang umum digunakan pada klasifikasi penyakit tanaman, yaitu VGG16 [9], MobileNetV2 [6], dan ResNet-50 [17]. Studi ablasi dilakukan dengan mengevaluasi EfficientNetV2-B0 tanpa CBAM dan tanpa MixUp (*baseline*) serta EfficientNetV2-B0 dengan CBAM tanpa MixUp. Seluruh model dievaluasi pada partisi data uji yang sama pada 483 citra menggunakan presisi, recall, *macro F1-Score*, dan akurasi keseluruhan. Interval kepercayaan 95% akurasi dihitung dengan metode *Wilson score*. Perbedaan akurasi antara model usulan dan setiap model pembandingan diuji dengan McNemar pada taraf signifikan $\alpha = 0,05$. Karena dilakukan lima perbandingan berpasangan, hasilnya juga ditinjau dengan koreksi Bonferroni ($\alpha = 0,01$).

Visualisasi Interpretasi Keputusan Model dengan Grad-CAM

Untuk memberikan transparansi saintifik atas keputusan klasifikasi yang dihasilkan, teknik *Gradient – Weighted Class Activation Mapping* (Grad-CAM) diimplementasikan pada lapisan konvolusi terakhir sebelum lapisan klasifikasi [14]. Bobot kepentingan saluran fitur k terhadap kelas target c diperoleh dari gradien skor kelas y^c terhadap peta aktivasi A^k sebagaimana dinyatakan dalam Persamaan (9):

$$\alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{i,j}^k} \quad (9)$$

dengan $Z = H \times W$ menyatakan luas spasial peta fitur, sedangkan α_k^c merepresentasikan besar kontribusi saluran k terhadap kelas target c . Peta panas aktivasi spasial L^c {Grad – CAM} kemudian dibentuk melalui kombinasi linear berbobot dari seluruh fitur yang dilewatkan fungsi penyearah ReLU, sehingga hanya fitur–fitur yang berkontribusi positif terhadap kelas sasaran yang dipertahankan dalam visualisasi.


3. HASIL DAN PEMBAHASAN

Hasil evaluasi terhadap model yang dikembangkan mencakup analisis kurva konvergensi pelatihan, evaluasi metrik kinerja klasifikasi pada 483 data uji independen, analisis matriks konfusi dalam mendiskriminasi lesi patologis antarkelas, interpretasi visualisasi Grad-CAM, serta implementasi operasional model pada sistem laboratorium berbasis web.

Hasil Pelatihan dan Konvergensi Model

Pelatihan model dilaksanakan selama 45 *epoch* dengan ukuran *batch* 32 menggunakan akselerator GPU. Dinamika pembelajaran model pada set pelatihan dan set

validasi diilustrasikan melalui kurva akurasi dan kerugian (*loss*) pada Gambar 2, sedangkan konfigurasi parameter pelatihan dirangkum pada Tabel 1.



Gambar 2 Kurva Akurasi dan Kerugian Pelatihan serta Validasi Model (4 Tahap)

Tabel 1 Konfigurasi Parameter Pelatihan Model Usulan

Parameter	Nilai/ Konfigurasi
Arsitektur <i>Backbone</i>	EfficientNetV2-B0 (Pretrained ImageNet)
Modul Atensi Tambahan	<i>Convolutional Block Attention Module</i> (CBAM)
Dimensi Masukan Citra	224 x 224 x 3 piksel
Fungsi Kerugian (<i>Loss</i>)	<i>Categorical Cross-Entropy</i> + <i>MixUp Regularization</i>
Pengoptimal(<i>Optimizer</i>)	AdamW (<i>Weight Decay</i> = 1e-4)
Skema <i>Learning Rate</i>	<i>Cosine Decay</i> (Rentang 1e-3 hingga 1e-5)
Strategi Pelatihan	<i>4-Stage Progressive Fine-Tuning</i> (45 <i>Epoch</i> Total)
Ukuran Batch (<i>Batch Size</i>)	32 sampel per iterasi
Teknik Regularisasi Tambahan	<i>Dropout</i> (0,3) & <i>Early Stopping</i> (<i>Patience</i> = 10)

Evaluasi Kinerja pada Data Uji Independen

Pengujian independen dilakukan menggunakan 483 citra yang tidak pernah dilibatkan pada tahap pelatihan maupun penalaan *hyperparameter*. Kinerja kuantitatif model diukur melalui empat metrik standar sebagaimana disajikan pada Tabel 2.

Tabel 2 Hasil Evaluasi Kinerja Klasifikasi pada Data Uji (483 Citra)


Kelas Penyakit Daun	Presisi (%)	<i>Recall</i> (%)	<i>F1-Score</i> (%)	Jumlah Sampel Uji
---------------------	-------------	-------------------	---------------------	-------------------

Busuk Daun	80,16	92,66	85,96	109
Layu Moler	100,00	98,61	99,30	144
Daun Sehat	93,94	91,18	92,54	102
Bercak Ungu Trotol	88,79	80,47	84,43	128
Rata-rata Macro	90,72	90,73	90,56	483
Akurasi Keseluruhan (<i>Overall Accuracy</i>)			90,89%	439 / 483

Berdasarkan Tabel 2, model EfficientNetV2-B0 + CBAM memperoleh akurasi keseluruhan (*overall test accuracy*) sebesar 90,89% dengan 439 dari 483 citra uji terklasifikasi secara tepat. Kinerja terbaik dicapai pada kelas Layu Moler dengan *F1-score* sebesar 99,30% dan presisi sempurna 100,00%, yang mengindikasikan bahwa karakteristik distorsi helaian daun akibat *Fusarium oxysporum* berhasil dipelajari jaringan secara konsisten tanpa adanya sampel kelas lain yang keliru diklasifikasikan sebagai Moler. Kelas Daun Sehat juga menunjukkan kinerja yang baik dengan *F1-score* 92,54% dan presisi 93,94%.

Analisis Matriks Konfusi dan Diskriminasi Busuk Daun vs Trotol

Tantangan paling kritis dalam klasifikasi penyakit daun bawang merah di lapangan adalah misklasifikasi timbal balik antara kelas Busuk Daun dan Trotol, mengingat kedua patogen sama-sama menimbulkan lesi klorosis yang berwarna kecoklatan pada permukaan daun [6], [10]. Matriks konfusi hasil pengujian independen disajikan pada Gambar 3 dan dirinci secara numerik pada Tabel 3.



Gambar 3 Matriks Konfusi (*Confusion Matrix*) Pengujian pada Data Test (483 Citra)

Tabel 3 Matriks Konfusi Model Usulan pada Data Uji (483 Citra)

Label Sebenarnya (<i>True</i>)	Busuk Daun	Layu Moler	Daun Sehat	Trotol	Total
Busuk Daun	101	0	1	7	109
Layu Moler	0	142	1	1	144
Daun Sehat	4	0	93	5	102
Bercak Ungu/Trotol	21	0	4	103	128
Total Prediksi	126	142	99	116	483

Berdasarkan Gambar 3 dan Tabel 3, dari 109 sampel Busuk Daun, sebanyak 101 citra (92,66%) diklasifikasikan secara tepat, sebanyak 7 citra salah diklasifikasi sebagai Trotol dan 1 citra sebagai Sehat. Pada kelas Trotol, dari 128 sampel uji, sebanyak 103 citra (80,47%) terklasifikasi akurat, sementara 21 citra keliru teridentifikasi sebagai Busuk Daun dan 4 citra Sehat. Hasil tersebut menunjukkan bahwa model mampu membedakan karakteristik visual kedua penyakit pada sebagian besar sampel. Namun, masih terdapat sejumlah citra yang memiliki kemiripan karakteristik visual sehingga menyebabkan kesalahan klasifikasi, terutama pada kelas Trotol yang diprediksi sebagai Busuk Daun. Dari 44 kesalahan klasifikasi, 21 kasus merupakan citra Trotol yang diprediksi sebagai Busuk Daun, sehingga *recall* Trotol (80,47%) lebih rendah daripada Busuk Daun (92,66%). Kesalahan ini bersifat asimetris, karena hanya 7 citra Daun Busuk yang diprediksi sebagai Trotol, dan presisi Busuk Daun (80,16%) menjadi terendah di antara keempat kelas. Penyebab pasti kesalahan ini belum dianalisis pada penelitian ini. Hipotesis awal adalah kemiripan visual lesi klorotik pada stadium infeksi lanjut, ketika lesi *Alternaria porri* dapat menyatu (*coalescing lesions*) dan mengering sehingga ciri cincin konsentris ungu tidak terlihat lagi. Hipotesis ini belum diuji dan perlu diverifikasi melalui analisis kasus salah klasifikasi (*error analysis*), misalnya dengan memeriksa peta panas Grad-CAM pada ke-21 citra tersebut. Karena kedua penyakit disebabkan oleh patogen berbeda dan memerlukan pengendalian yang berbeda, keluaran sistem sebaiknya diperlakukan sebagai alat bantu keputusan. Pada penelitian lanjutan, kesalahan ini dapat dikurangi melalui analisis kasus salah klasifikasi, fungsi kerugian berbobot seperti *focal loss* atau *class-weighted cross-entropy*, dan penambahan citra latih pada stadium peralihan gejala.

Perbandingan Kinerja, Studi Ablasi, dan Signifikansi Statistik

Kinerja model usulan dibandingkan dengan tiga arsitektur pembanding dan dua varian ablasi sesuai skenario pada subbab Skenario Pembandingan, Studi Ablasi, dan Uji Statistik. Hasilnya disajikan pada Tabel 4.

Tabel 4 Perbandingan Kinerja Model Usulan dengan Model Pembanding dan Uji Ablasi pada Data Uji (483 Citra)

Model / Arsitektur	Presisi (%)	Recall (%)	Macro F1 (%)	Akurasi (%)	95% CI Akurasi	Uji McNemar (p-value)
VGG16 (Transfer Learning)	82,10	82,35	81,85	82,40	[78,75% – 85,54%]	$p < 0,001$
MobileNetV2 (Transfer Learning)	85,42	85,60	85,20	85,71	[82,31% – 88,55%]	$p < 0,001$
ResNet-50 (Transfer Learning)	86,25	86,40	86,12	86,54	[83,21% – 89,30%]	$p = 0,004$
EfficientNetV2- B0 Baseline (Tanpa CBAM & MixUp)	87,30	87,45	87,14	87,58	[84,34% – 90,23%]	$p = 0,018$
EfficientNetV2- B0 + CBAM (Tanpa MixUp)	89,05	89,12	88,90	89,23	[86,15% – 91,69%]	$p = 0,115$
Model Usulan (EfficientNetV2- B0 + CBAM + MixUp + 4- Stage)	90,72	90,73	90,56	90,89	[87,99% – 93,14%]	– (model acuan)

Berdasarkan Tabel 4, model usulan memperoleh akurasi tertinggi, yaitu 90,89%. Nilai ini lebih tinggi 8,49 poin persentase daripada VGG16 (82,40%), 5,18 poin daripada MobileNetV2 (85,71%), dan 4,35 poin daripada ResNet-50 (86,54%). Pada studi ablasi, penambahan CBAM pada *baseline* EfficientNetV2-B0 meningkatkan akurasi dari 87,58% menjadi 89,23% (+1,65 poin), dan konfigurasi akhir yang menambahkan MixUp meningkatkan akurasi menjadi 90,89% (+1,66 poin). Uji McNemar menunjukkan bahwa model usulan secara signifikan lebih akurat daripada VGG16, MobileNetV2, dan ResNet-50 ($p \leq 0,004$), dan hasil ini tetap signifikan setelah koreksi Bonferroni ($\alpha = 0,01$). Terhadap *baseline* EfficientNetV2-B0, perbedaan signifikan pada $\alpha = 0,05$ ($p = 0,018$) tetapi tidak setelah koreksi Bonferroni, sedangkan perbedaan terhadap varian CBAM tanpa MixUp tidak signifikan ($p = 0,115$). Dengan demikian, kontribusi tambahan MixUp belum dapat dipastikan secara statistik pada satu pembagian data ini.


Visualisasi Interpretasi Fitur Menggunakan Grad-CAM

Untuk memeriksa apakah prediksi model didasarkan pada fitur semu (*spurious features*) seperti latar belakang tanah, gulma, atau bayangan sungkup, dihasilkan visualisasi Grad-CAM pada *layer cbam_attention* [14]. Hasil *heatmap* menunjukkan bahwa aktivasi tertinggi berfokus pada area yang berkaitan dengan gejala penyakit. Pada

Trotol, aktivasi terpusat di sekitar bercak nekrotik, pada Layu Moler, mengikuti bagian daun yang menguning dan melengkung, sedangkan pada Daun Sehat, aktivasi tersebar pada jaringan daun. Pengamatan ini bersifat kualitatif dan hanya mencakup contoh terpilih, dan belum ada pengukuran kuantitatif, misalnya tumpang tindih peta panas dengan anotasi lesi. Meskipun demikian, hasilnya mengindikasikan bahwa keputusan model cenderung selaras dengan karakteristik visual penyakit.

Implementasi dan Pengujian pada Sistem Laboratorium Berbasis Web

Untuk merealisasikan hasil penelitian menjadi prototipe instrumen pendukung diagnosis yang berpotensi dimanfaatkan oleh petani dan penyuluh, model EfficientNetV2-B0 + CBAM yang telah dilatih kemudian diintegrasikan ke dalam sistem laboratorium cerdas berbasis web bernama ShallotGuard AI. Sistem dibangun menggunakan *framework Python Flask* pada *backend* dan antarmuka responsif HTML5, CSS kustom, serta JavaScript pada sisi *frontend* [16]. Tampilan halaman beranda aplikasi disajikan pada Gambar 4.



Gambar 4 Tampilan Antarmuka Beranda Sistem Laboratorium ShallotGuard AI

Halaman beranda ShallotGuard AI (Gambar 4) dirancang dengan tata letak yang menampilkan kartu ringkasan pengujian laboratorium meliputi total sampel teruji, rata-rata tingkat keyakinan inferensi, pengingat citra di luar distribusi (*out-of-distribution/ OOD*), serta status kesiapan model. Selain itu, tersedia bilah navigasi yang menghubungkan pengguna ke formulir deteksi daun, repositori riwayat pengujian, ensiklopedia hama dan penyakit bawang merah, FAQ pengendalian agronomi, serta panel manajemen laboratorium.


Proses pengujian dimulai pada antarmuka formulir deteksi (Gambar 5). Sistem menyediakan fleksibilitas *input* dengan mendukung pengunggahan citra daun secara *drag-and-drop* (format JPG, PNG, JPEG, WEBP hingga 16 MB) maupun pengambilan foto secara langsung di lahan menggunakan kamera *smartphone* atau *webcam* laptop. Sebelum citra diproses oleh jaringan, sistem terlebih dahulu menjalankan modul validasi botani awal (*smart botanical heuristic validation*) berbasis evaluasi ruang warna HSV dan deteksi keburaman varians Laplacian. Modul ini berfungsi memverifikasi bahwa citra yang diunggah merupakan objek dedaunan tanaman dengan rasio spektrum klorofil yang memadai dan tingkat ketajaman fokus yang layak. Apabila masukan berupa citra nondaun seperti kulit manusia, dinding beton, atau yang lain maka sistem secara otomatis akan menolak proses inferensi disertai peringatan edukatif, sehingga mencegah pembebanan komputasi model yang tidak diperlukan.

The screenshot displays the 'Diagnosa AI Penyakit Daun Bawang Merah' (AI Diagnosis of Red Onion Leaf Disease) interface. At the top, a navigation bar includes links for 'Beranda', 'Riwayat', 'Ensiklopedia', 'FAQ', 'Tentang', and 'Login Admin'. The main heading is 'Diagnosa AI Penyakit Daun Bawang Merah', with a subtext explaining the process: 'Unggah foto atau gunakan kamera HP/laptop untuk mendeteksi penyakit Busuk Daun, Moler, atau Bercak Ungu (Trotol) dengan interpretasi visual Grad-CAM.' Below this is a disclaimer section. The interface is divided into two main panels. The left panel, titled 'Masukkan Citra Daun Bawang', contains a large dashed box with a green leaf icon and the text 'Klik atau Seret Foto Daun ke Sini' (Click or Drag Leaf Photo Here), supported by formats like JPG, PNG, and WEBP up to 16 MB. It also features a 'Buka Kamera HP/Laptop' button and a 'Tips Pengambilan Foto' (Photo Taking Tips) section with three bullet points: positioning the leaf in even light, ensuring focus and no blur, and avoiding background dominance. A green 'Mulai Analisis AI (EfficientNetV2B0 + CBAM)' button is at the bottom. The right panel, titled 'Hasil Diagnosa & Penjelasan Model', shows a green plant icon and the text 'Menunggu Citra Daun' (Waiting for Leaf Photo), with instructions to upload the photo and click the analysis button to see the diagnosis, Grad-CAM, and treatment recommendations.

Gambar 5 Antarmuka Formulir Pengunggahan Citra Daun dan Pratinjau Analisis

Setelah citra dinyatakan lolos validasi heuristik botani, sistem menjalankan inferensi menggunakan teknik *Test-Time Augmentation* (TTA) untuk menjaga stabilitas diagnosis terhadap variasi pencahayaan lapangan. Hasil analisis disajikan secara komprehensif sebagaimana ditunjukkan pada Gambar 6, meliputi prediksi kelas penyakit utama beserta tingkat keyakinan (*Confidence Score*, misalnya 86,91% untuk kasus Busuk


Daun), grafik distribusi probabilitas lintas empat kelas penyakit, serta visualisasi *Explainable AI* (XAI) berupa perbandingan berdampingan antara citra asli berdimensi 224 x 224 piksel dengan peta panas atensi Grad-CAM. Peta panas berwarna merah-oranye memperlihatkan secara eksplisit fokus inferensi jaringan pada titik infeksi helaian daun. Selain itu, sistem menampilkan informasi patogen penyebab, deskripsi gejala visual, dan rekomendasi penanganan budidaya yang terstruktur, meliputi sanitasi lahan, pengaturan jarak tanam, pengaturan waktu penyiraman, rotasi tanaman, serta anjuran fungisida sesuai ambang ekonomi.



Gambar 6 Visualisasi Hasil Analisis AI, Peta Panas Grad -CAM, dan Distribusi

Probabilitas 4 Kelas

Seluruh hasil pengujian disimpan otomatis dalam riwayat dengan ID berurutan untuk memudahkan penelusuran. Setiap catatan memuat hasil Grad-CAM, waktu pengujian, tingkat keyakinan, rasio area daun, dan ketajaman citra. Data juga dapat difilter berdasarkan kelas penyakit serta diekspor dalam format CSV atau dicetak untuk dokumentasi.



Gambar 7 Dashboard Riwayat Pengujian Laboratorium dan Manajemen Repositori

Diagnosis

4. KESIMPULAN

Penelitian ini menggunakan model EfficientNetV2-B0 dengan CBAM, pelatihan empat tahap progresif, dan MixUp mencapai akurasi 90,89% dan macro *F1-score* 90,56% pada 483 citra uji. Kinerja terbaik ada pada kelas Layu Moler (F1 99,30%), sedangkan Trotol paling rendah (F1 84,43%) dengan kesalahan terbesar adalah 21 citra Trotol yang diprediksi sebagai Busuk Daun. Model usulan lebih akurat secara signifikan daripada VGG16, MobileNetV2, dan ResNet-50 pada (uji McNemar, $p \leq 0,004$), Sedangkan Kontribusi MixUp belum signifikan secara statistik ($p = 0,115$). Grad-CAM secara kualitatif menunjukkan fokus model pada area lesi, dan model telah diimplementasikan sebagai prototipe web ShallotGuard AI. Keterbatasan penelitian ini meliputi dataset sekunder yang belum mencakup kondisi lapangan ekstrem, evaluasi pada satu pembagian data dan satu kali pelatihan, penyebab kesalahan Trotol yang masih berupa hipotesis, evaluasi Grad-CAM yang kualitatif, serta sistem yang belum diuji oleh petani dilahan. Penelitian lanjutan disarankan mencakup dataset lapangan yang lebih beragam, analisis kasus salah klasifikasi Busuk Daun dan Trotol, pengulangan pelatihan dengan beberapa *seed*, serta uji lapangan bersama petani dan tenaga ahli proteksi tanaman.

DAFTAR PUSTAKA

- [1] A. Zalvadila, Purnawansyah, L. Syafie, and Darw, "Klasifikasi Penyakit Tanaman Bawang Merah Menggunakan Metode SVM dan CNN," *J. Inform. J.*

-
- Pengemb. IT*, vol. 8, no. 3, pp. 255–260, 2023, doi: 10.30591/jpit.v8i3.5341.
- [2] Jumrayanti, Purnawansyah, H. Darwis, and S. Ramdan, “Klasifikasi Penyakit Bawang Merah Menggunakan Naive Bayes dan CNN dengan Fitur GLCM,” *Indones. J. Comput. Sci.*, vol. 12, no. 2, pp. 284–301, 2023, [Online]. Available: <http://ijcs.stmikindonesia.ac.id/ijcs/index.php/ijcs/article/view/3135>
 - [3] F. K. Fikriah, M. Burhanis Sulthan, N. Mujahidah, and M. Khoirur Roziqin, “Naïve Bayes untuk Klasifikasi Penyakit Daun Bawang Merah Berdasarkan Ekstraksi Fitur Gray Level Cooccurrence Matrix (GLCM),” *J. Komtika (Komputasi dan Inform.)*, vol. 6, no. 2, pp. 133–141, 2022, doi: 10.31603/komtika.v6i2.7925.
 - [4] M. Farij Amrulloh and D. P. Pamungkas, “Klasifikasi Penyakit Daun Bawang Menggunakan Algoritma CNN Xception,” *INOTEK*, vol. 8, 2024.
 - [5] R. Marsevin, T. H. B. Aviani, A. T. Martadinata, and B. Santoso, “Penerapan Metode Transfer Learning untuk Klasifikasi Penyakit Tanaman Kembang Kol dengan Arsitektur Inception V3,” *Indones. J. Appl. Technol.*, vol. 2, no. 4, p. 10, 2025, [Online]. Available: <https://journal.pubmedia.id/index.php/ijat/article/view/5167>
 - [6] W. A. Arabiaih and H. Mustafidah, “Klasifikasi Penyakit Daun Bawang Merah Menggunakan MobileNetV2 Convolutional Neural Network (CNN),” *JOSH*, vol. 7, no. 4, pp. 1129–1142, 2026, doi: 10.47065/josh.v7i4.10516.
 - [7] P. Sari, D. Purwarningtias, and Ali Mustopa, “Analisis Komparatif Kinerja MobileNetV2 dan EfficientNet-B0 pada Klasifikasi Penyakit Daun Paprika dengan Teknik CLAHE,” *J. Komput. Teknol. Inf. Sist. Komput.*, vol. 5, no. 2, pp. 1390–1401, 2026, doi: 10.62712/juktisi.v5i2.1365.
 - [8] Muhammad Naufal Anugrah and Nur Rachmat, “Klasifikasi Penyakit Daun Tanaman Jagung Menggunakan Pendekatan Transfer Learning Arsitektur MobileNetV4,” *J. Teknol. dan Manaj. Ind. Terap.*, vol. 4, no. 4, pp. 2174–2182, 2025, doi: 10.55826/jtmit.v4i4.1393.
 - [9] Suhesi, D. A. Kurnia, Y. Arie Wijaya, S. Anwar, and U. Hayati, “Peningkatan Robustness Model Klasifikasi Penyakit Daun Semangka Menggunakan Fine-Tuning VGG16 dan Augmentasi Data Sintetis Berbasis Generative Adversarial Network,” *J. Comput. Sci. Artif. Intell.*, vol. 6, no. 2, pp. 1–8, 2025.
 - [10] S. Azis and B. Irawan, “EVALUASI KLASSIFIKASI PENYAKIT DAUN TEH MENGGUNAKAN TRANSFER LEARNING EFFICIENTNETB0,” *JITET (Jurnal Inform. dan Tek. Elektro Ter.)*, vol. 14, no. 1.
 - [11] A. Khoiroma and S. R. Nudin, “Implementasi Model MaxVit Untuk Deteksi Penyakit Daun Tanaman Bawang Merah Berbasis Mobile,” *KONSTELASI*, vol. 6, no. 1, pp. 77–91, 2026.
 - [12] N. Harianti, Y. S. Siregar, and M. Khairani, “Pendeteksian anomali pada daun tanaman jambu biji menggunakan isodata cluster,” *JIKSTRA*, vol. 7, no. 02, 2025.
 - [13] S. Maghfud, U. Khaira, and A. Waladi, “MULTIMODAL LEARNING MENGGUNAKAN EFFICIENTNETV2 DAN DISTILBERT UNTUK DETEKSI WEBSITE ILEGAL DAN IMPLEMENTASINYA PADA BROWSER EXTENSION,” *JIKSTRA*, vol. 8, no. 01, 2026.
 - [14] W. Sofiyah, B. S. Negara, M. Irsyad, I. Iskandar, and F. Yanto, “Lung Disease Detection Using Gradient-Weighted Class Activation Mapping (Grad-CAM),”

-
- J. Artif. Intell. Softw. Eng.*, vol. 5, no. 2, pp. 720–730, 2025, doi: 10.30811/jaise.v5i2.7041.
- [15] I. K. Rizqi and C. Supriyanto, “Chest X-Ray Based Pulmonary Tuberculosis Classification Using Transfer Learning with DenseNet121 and Convolutional Block Attention Module (CBAM),” *J. Appl. Informatics Comput.*, vol. 10, no. 2, pp. 1905–1919, 2026, doi: 10.30871/jaic.v10i2.12523.
- [16] S. H. Dewanto, T. Listyorini, and E. Supriyati, “Klasifikasi Perilaku Kucing Menggunakan Arsitektur Hybrid YOLOv8 dan CNN Berbasis Web,” *SCAN*, vol. 21, pp. 1–10, 2026.
- [17] H. Imelia Grasia, “JURNAL MEDIA INFORMATIKA [JUMIN] Komparasi CNN dan Pretrain ResNet50 pada Klasifikasi Penyakit Daun Kentang,” vol. 7, pp. 432–441, 2026.