

KLASIFIKASI PENYAKIT DAUN ANGGUR MENGGUNAKAN *EFFICIENTNETV2-B0* DENGAN OPTIMIZER ADAMW DAN SGD

Dewa, Abdul Rahman

Informatika, Universitas Multi Data Palembang
Jl. Rajawali 14 Palembang, Sumatera Selatan
dewa_2226250101@mhs.mdp.ac.id

ABSTRAK

Penyakit yang menyerang daun tanaman anggur dapat berdampak signifikan terhadap penurunan kualitas dan kuantitas hasil produksi, sehingga dibutuhkan sistem deteksi yang mampu bekerja secara cepat dan akurat. Permasalahan yang dikaji dalam penelitian ini adalah penerapan metode klasifikasi otomatis berbasis *Convolutional Neural Network (CNN)* dengan pendekatan *transfer learning* untuk mengenali jenis penyakit daun anggur secara optimal, serta menentukan *optimizer* yang memberikan kinerja terbaik. Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi perbandingan kinerja *optimizer AdamW* dan *Stochastic Gradient Descent (SGD)* dalam mengklasifikasikan penyakit daun anggur. Metode yang digunakan memanfaatkan arsitektur *EfficientNetV2-B0 pretrained* yang dilatih menggunakan *dataset* citra daun anggur yang terdiri dari empat kelas, yaitu *Black Rot*, *ESCA*, *Healthy*, dan *Leaf Blight*, melalui tahapan *feature extraction* dan *fine-tuning*. Kinerja model dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, dan *f1-score*. Hasil pengujian menunjukkan bahwa kedua *optimizer* mampu memberikan performa yang baik, namun *AdamW* menunjukkan hasil yang lebih optimal dengan akurasi pengujian sebesar 97.00%, sementara *SGD* memperoleh akurasi sebesar 91.00%. Temuan ini menunjukkan bahwa penggunaan *EfficientNetV2-B0* dengan *optimizer AdamW* lebih efektif dalam klasifikasi penyakit daun anggur.

Kata kunci: *EfficientNetV2-B0*, *AdamW*, *SGD*, Penyakit daun anggur.

1. PENDAHULUAN

Buah anggur termasuk komoditas pangan yang memiliki nilai kesehatan tinggi, karena kaya akan nutrisi yang berkontribusi dalam menjaga kebugaran tubuh serta membantu mengurangi risiko berbagai penyakit [1]. Meskipun demikian, produktivitas tanaman anggur kerap mengalami penurunan akibat serangan penyakit pada daun yang sulit diidentifikasi secara cepat dan tepat oleh petani. Infeksi penyakit dan gangguan hama dapat menghambat pertumbuhan tanaman hingga 40–70%, menurunkan kualitas buah terutama dari segi tingkat kemanisan, mengurangi kuantitas hasil panen, serta menyebabkan buah tumbuh tidak sempurna atau mengalami keriput. [2]. Kondisi tersebut menunjukkan perlunya penerapan solusi berbasis teknologi untuk mendukung proses deteksi dini penyakit daun anggur secara efektif dan efisien.

Oleh karena itu, dibutuhkan solusi berbasis teknologi yang dapat membantu deteksi penyakit daun anggur secara cepat dan efisien sehingga dapat memberikan hasil panen buah anggur yang lebih maksimal bagi petani. Seiring berkembangnya teknologi *computer vision*, metode *Convolutional Neural Network (CNN)* semakin banyak diterapkan dalam pengolahan dan klasifikasi citra, termasuk pada sektor pertanian. *CNN* merupakan salah satu pendekatan dalam *deep learning* yang memiliki kemampuan tinggi dalam mengekstraksi fitur visual untuk tugas pengenalan pola, segmentasi citra, dan deteksi objek [3]. Namun, performa optimal *CNN* umumnya dicapai dengan dukungan *dataset* besar dan kebutuhan komputasi yang signifikan. Untuk

mengatasi keterbatasan tersebut, pendekatan *transfer learning* menjadi alternatif yang efektif dengan memanfaatkan model *CNN* yang telah dilatih sebelumnya, seperti *EfficientNetV2-B0*. Arsitektur ini dirancang untuk mengoptimalkan keseimbangan antara akurasi dan efisiensi komputasi melalui mekanisme *compound scaling*.

Beberapa studi terkait telah mengimplementasikan metode *transfer learning CNN* pada objek penyakit daun tanaman. Seperti, pada penelitian yang menggunakan metode *Convolutional Neural Network Transfer Learning DenseNet-121* pada objek penyakit *leaf mold* daun tomat memiliki hasil yang sangat baik yaitu nilai akurasi terbaik pada 93,3% [4]. Sedangkan untuk penelitian serupa dengan menggunakan metode *Convolutional Neural Network Transfer Learning ResNet-50* dengan objek penyakit daun anggur mendapatkan akurasi yang lebih tinggi yaitu menghasilkan akurasi mencapai 99% [5].

Berdasarkan uraian tersebut, permasalahan yang dikaji dalam penelitian ini adalah penerapan model *CNN* berbasis *transfer learning* menggunakan arsitektur *EfficientNetV2-B0* untuk klasifikasi penyakit daun anggur, serta analisis perbandingan kinerja *optimizer AdamW* dan *Stochastic Gradient Descent (SGD)*. Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi performa kedua *optimizer* tersebut dalam meningkatkan akurasi klasifikasi. Penyelesaian permasalahan dilakukan dengan melatih model *pretrained EfficientNetV2-B0* pada *dataset* citra daun anggur yang terdiri atas empat kelas, yaitu *Black Rot*, *ESCA*, *Healthy*, dan *Leaf Blight*, melalui tahapan *feature extraction* dan *fine-*

tuning, kemudian mengevaluasi kinerja model menggunakan metrik *accuracy*, *precision*, *recall*, dan *f1-score*.

2. TINJAUAN PUSTAKA

Landasan teori berguna sebagai pijakan ilmiah dalam pelaksanaan penelitian ini. Bagian tersebut memuat kajian teori, konsep dasar, serta temuan penelitian sebelumnya yang berkaitan dengan topik klasifikasi penyakit daun anggur menggunakan *Convolutional Neural Network (CNN)* melalui pendekatan transfer learning dengan *EfficientNetV2-B0*. Teori-teori yang dipaparkan di dalamnya mencakup Klasifikasi, Anggur, Pengolahan Citra Digital, *Convolutional Neural Network*, *Transfer Learning*, *EfficientNetV2-B0*, *SGD Optimizer*, dan *AdamW Optimizer*.

2.1. Anggur


Buah anggur (*Vitis vinifera* dan *V. Labrusca L.*) merupakan salah satu jenis tanaman buah yang berasal dari wilayah Armenia dan Rusia, yang kini telah dikenal luas serta banyak dimanfaatkan oleh masyarakat di Indonesia [6]. Buah anggur diketahui mengandung berbagai senyawa aktif yang berperan dalam meningkatkan metabolisme tubuh. Selain itu, anggur juga memiliki kemampuan untuk membantu mencegah penyakit kanker, yang dikenal sebagai salah satu penyakit paling berbahaya [7]. Anggur mengandung nilai gizi yang tinggi, meliputi vitamin, mineral, karbohidrat, serta senyawa fitokimia yang bermanfaat bagi kesehatan [3].

2.2. Penyakit Daun Anggur

Penyakit daun anggur merupakan salah satu masalah utama pada budidaya tanaman anggur karena dapat mengganggu proses fotosintesis, menurunkan kualitas daun, serta berdampak langsung pada hasil dan mutu buah yang dihasilkan [8]. Tiga jenis penyakit daun anggur yang umum ditemukan yaitu *Esca*, *Black Rot*, dan *Leaf Blight*. Penyakit *Esca* disebabkan oleh jamur dari genus *Phaeoacremonium* dan *Fomitiporia*, yang menyerang jaringan pembuluh kayu sehingga menimbulkan gejala seperti bercak nekrosis, perubahan warna daun menjadi kekuningan, serta pengeringan cabang secara bertahap [8]. Sementara itu, penyakit *Black Rot* disebabkan oleh jamur *Guignardia bidwellii*, ditandai dengan munculnya bercak berwarna cokelat gelap hingga hitam pada permukaan daun yang dapat menyebar ke buah dan menyebabkan pembusukan serius [9]. Adapun penyakit *Leaf Blight* atau hawar daun umumnya disebabkan oleh jamur *Alternaria spp* yang memicu munculnya bercak tidak beraturan berwarna cokelat pada daun dan dapat berkembang menjadi nekrosis luas apabila kondisi lingkungan mendukung pertumbuhan patogen tersebut [10].

2.3. Convolutional Neural Network

Convolutional Neural Network (CNN) adalah salah satu arsitektur *deep learning* yang dirancang untuk mempelajari pola dari data dalam jumlah besar dengan mengintegrasikan proses ekstraksi fitur dan tahap klasifikasi secara otomatis [11]. Lapisan-lapisan inilah yang menyusun arsitektur *Convolutional Neural Network (CNN)* sehingga sesuai untuk menangani data masukan berupa citra. Gambaran umum arsitektur CNN ditunjukkan pada Gambar 2.



Gambar 1. Model lapisan *convolutional neural network* [12]

2.4. Convolutional Layer

Convolutional layer (lapisan konvolusi) merupakan lapisan yang berfungsi melakukan operasi konvolusi terhadap *output* dari lapisan sebelumnya. Lapisan ini merupakan komponen utama dalam *Convolutional Neural Network (CNN)*, yang terdiri atas sejumlah *filter* yang dipelajari secara acak untuk melakukan ekstraksi fitur, dengan tujuan mempelajari representasi fitur dari lapisan *input* [12]. Operasi konvolusi pada data citra bertujuan untuk mengekstraksi fitur-fitur utama dari citra masukan. Proses ini menghasilkan transformasi linear dengan memanfaatkan informasi spasial pada citra. Bobot pada lapisan konvolusi berperan sebagai kernel yang dapat dipelajari dan disesuaikan secara adaptif berdasarkan data *input* dalam *Convolutional Neural Network (CNN)*.

2.5. Pooling Layer

Pooling layer merupakan komponen jaringan yang bertugas memperkecil ukuran spasial dari *feature map* hasil proses konvolusi. Proses ini dilakukan melalui teknik *downsampling* sehingga mampu mengurangi dimensi data dan menekan kebutuhan komputasi. Dengan berkurangnya jumlah parameter yang harus dipelajari, waktu pemrosesan menjadi lebih efisien. Selain itu, *pooling layer* membantu mempertahankan fitur-fitur utama yang paling representatif. Dua jenis *pooling layer* yang paling sering diterapkan adalah *max pooling* dan *average pooling* [12]. *Max pooling* bekerja dengan memilih nilai terbesar dari setiap area citra yang diproses oleh kernel, sementara *average pooling* menghitung nilai rata-rata dari seluruh piksel yang berada dalam area cakupan *kernel* tersebut.


2.6. Fully Connected Layer

Fully connected layer merupakan lapisan yang berfungsi untuk mentransformasikan dimensi data sehingga data tersebut dapat diklasifikasikan secara linear [12]. Untuk memperoleh keluaran dari lapisan ini, tidak digunakan operasi konvolusi melainkan dilakukan komputasi berupa perkalian matriks yang disertai dengan bias *offset*. Melalui operasi tersebut, setiap neuron memiliki koneksi penuh terhadap seluruh aktivasi pada lapisan sebelumnya, sehingga lapisan ini disebut *fully connected layer*.

2.7. Transfer Learning

Transfer learning adalah pendekatan yang bertujuan untuk mempersingkat proses pelatihan serta menekan kebutuhan biaya komputasi dalam penerapan model *deep learning* [4]. *Transfer learning* merupakan salah satu metode dalam pembelajaran mesin yang menggunakan model pra-latih untuk menangani klasifikasi pada *dataset* baru, sehingga proses pelatihan tidak harus dilakukan kembali dari tahap awal [1]. *Transfer Learning* merupakan teknik dalam machine learning yang memanfaatkan model yang telah dilatih sebelumnya untuk menyelesaikan suatu tugas, kemudian diterapkan kembali untuk menangani tugas lain yang masih berhubungan dengan tugas awal. Teknik ini umumnya digunakan ketika jumlah *dataset* yang tersedia terbatas [13].

2.8. EfficientNetV2



Gambar 2. Struktur MBConv & Fused-MBConv [14]

EfficientNetV2 pertama kali dikenalkan oleh [14]. *EfficientnetV2* merupakan pengembangan dari versi terdahulunya, yaitu *EfficientNet*. Perbedaan paling terlihat adalah dari struktur arsitekturnya, dengan tambahan sebuah operasi baru, yaitu *Fused-MBConv* [15]. Arsitektur *EfficientNetV2* memiliki beberapa layer tambahan diawal yang merupakan ciri khas dari *EfficientNetV2*, yakni *MBConv* dan *Fused-MBConv*. Layer tambahan pada *EfficientNetV2* diusulkan karena pada *EfficientNet* masih berfokus pada efisiensi parameter dan *FLOP*, sehingga dengan adanya layer tambahan dapat meningkatkan fungsi

akselerator agar lebih optimal [15]. Gambar 3 menunjukkan struktur *MBConv* dan *Fused-MBConv* dari arsitektur *EfficientNetV2*.

2.9. SGD Optimizer

Stochastic Gradient Descent (SGD) merupakan salah satu metode *optimizer* standar dalam proses *backpropagation*, yang digunakan untuk memperbarui nilai bobot pada setiap iterasi (*epoch*) dengan tujuan meminimalkan nilai fungsi *loss* [16]. *Stochastic Gradient Descent (SGD)* adalah metode iteratif yang sering digunakan dalam pembelajaran mesin untuk mengoptimalkan penurunan *gradien*. Algoritma ini membantu model dalam melatih lebih cepat dan mencegah terjebak dalam *local minima* [17]. Proses pembaruan parameter pada *SGD* dapat didefinisikan sebagai berikut:

$$\theta = \theta - \eta * \nabla \theta J(\theta; x(i), y(i)) \dots (1)$$

Keterangan:

θ	: Parameter model
η (eta)	: <i>Learning rate</i>
$\nabla \theta J(\theta; x^{(i)}, y^{(i)})$	: Gradien fungsi biaya (<i>cost function</i>) terhadap parameter θ
$x^{(i)}, y^{(i)}$	: Data <i>input</i> dan label ke- <i>i</i>

dengan θ adalah parameter hasil pembaruan, η adalah *learning rate*, $x(i)$ dan $y(i)$ merupakan data yang sedang dilakukan pelatihan.

2.10. AdamW

AdamW merupakan algoritma optimasi yang banyak diterapkan dalam proses pelatihan jaringan saraf tiruan. Metode ini dikembangkan dari *optimizer Adam* dengan menambahkan mekanisme *weight decay* secara terpisah untuk meningkatkan kemampuan regularisasi model. Pada *Adam*, regularisasi L2 yang sering kali kurang optimal karena terpengaruh oleh mekanisme pembaruan *gradien*. Sebaliknya, *AdamW* memisahkan proses *weight decay* dari pembaruan *gradien*, sehingga mampu menghasilkan regularisasi yang lebih efektif [18]. Rumus *AdamW* adalah sebagai berikut:

$$\theta_{t+1} = \theta_t - \frac{\alpha \cdot \hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}} - \alpha \omega d \theta_t \dots (2)$$

Di mana ωd adalah *weight decay* yang diterapkan pada parameter.

2.11. Penelitian Terkait

Dalam penelitian ini, dilakukan kajian terhadap sejumlah jurnal ilmiah yang relevan dengan topik klasifikasi penyakit daun anggur menggunakan pendekatan *deep learning* dan *transfer learning*. Berbagai penelitian terdahulu menunjukkan bahwa metode *Convolutional Neural Network (CNN)* banyak digunakan untuk mengatasi permasalahan identifikasi penyakit tanaman berbasis citra digital. Kemampuan *CNN* dalam mempelajari pola visual secara otomatis

menjadikannya efektif dalam mengekstraksi fitur penting dari citra daun dan mengklasifikasikan jenis penyakit dengan tingkat akurasi yang tinggi.

Meskipun demikian, setiap penelitian memiliki pendekatan dan karakteristik yang berbeda, baik dari sisi arsitektur model, teknik pra-pemrosesan, maupun strategi pelatihan yang digunakan. Oleh karena itu, penting untuk memahami kelebihan dan keterbatasan dari masing-masing penelitian sebagai dasar dalam menentukan arah penelitian selanjutnya. Misalnya, penelitian yang dilakukan oleh [1] menerapkan segmentasi warna berbasis *HSV* dan teknik *thresholding* yang dikombinasikan dengan *transfer learning* menggunakan arsitektur *VGG16* untuk mendeteksi tiga jenis penyakit daun anggur, dan berhasil memperoleh akurasi hingga 98%. Hasil tersebut menunjukkan bahwa tahapan pra-pemrosesan citra berperan penting dalam meningkatkan kualitas fitur yang diekstraksi oleh model *CNN*.


Penelitian lain oleh [5] menggunakan arsitektur *ResNet-50* untuk mengidentifikasi penyakit daun anggur di Indonesia dan mencapai akurasi sebesar 99%. Temuan ini menegaskan bahwa arsitektur *CNN* yang lebih dalam dengan mekanisme *residual connection* mampu menangani kompleksitas citra daun anggur dengan sangat baik. Di sisi lain, penelitian yang dilakukan oleh [19] menunjukkan bahwa arsitektur *CNN* yang lebih ringan seperti *AlexNet* tetap mampu memberikan performa klasifikasi yang kompetitif, dengan tingkat akurasi mencapai 97.11%, sehingga menunjukkan efisiensi model tanpa penurunan akurasi yang signifikan.

Selain itu, pendekatan berbasis arsitektur ringan juga ditunjukkan dalam penelitian oleh [20] yang memanfaatkan *MobileNet* untuk klasifikasi penyakit daun anggur. Penelitian tersebut menekankan efisiensi komputasi dan ukuran model yang lebih kecil, sehingga berpotensi untuk diterapkan pada perangkat dengan keterbatasan sumber daya, seperti perangkat bergerak. Namun demikian, hasil penelitian tersebut juga menunjukkan bahwa performa model sangat dipengaruhi oleh kualitas dataset serta kemampuan generalisasi terhadap data di luar data pelatihan. Secara keseluruhan, berbagai penelitian yang telah dikaji menunjukkan bahwa pemilihan arsitektur *CNN* dan strategi pelatihan yang tepat sangat berpengaruh terhadap keberhasilan klasifikasi penyakit daun anggur.

3. METODE PENELITIAN

Pada Gambar 3 tahapan penelitian diatas dapat dilihat serangkaian tahapan dan langkah-langkah penelitian ini. Dalam penelitian ini, metode penelitian yang digunakan dirancang secara sistematis agar hasil penelitian dapat terarah dan sesuai dengan tujuan yang telah ditetapkan. Tahapan penelitian dimulai dari studi

literatur, pengumpulan *dataset*, perancangan model klasifikasi menggunakan *Convolutional Neural Network* dengan pendekatan *transfer learning* *EfficientNetV2-B0*, implementasi, dan pengujian.



Gambar 3. Metode Penelitian

3.1. Studi Literatur

Tahapan ini dimulai dengan melakukan kajian literatur berupa jurnal, buku, serta penelitian terdahulu yang berkaitan dan relevan dengan topik penelitian ini. Fokus kajian literatur diarahkan pada klasifikasi penyakit daun tanaman khususnya pada daun tanaman anggur berbasis *deep learning* dengan menerapkan arsitektur *Convolutional Neural Network (CNN)* melalui pendekatan *transfer learning* menggunakan *EfficientNetV2-B0*.

3.2. Pengumpulan Dataset

Pada tahap ini, dilakukan proses pengumpulan dataset berupa *Grape Leaf Disease -Small-4 Class-500 Samples Each* yang bersifat publik dan tersedia di platform *Kaggle* dengan link <https://www.kaggle.com/datasets/ismetgocer/grape-leaf-disease-small-4-class-500-samples-each/suggestions> [21]. *Dataset* ini terdiri atas citra daun anggur yang terbagi ke dalam beberapa kelas, antara lain daun sehat (*healthy*), daun terinfeksi *black rot*, *esca* (*black measles*), dan *leaf blight*. *Dataset* ini dipilih karena bersifat terbuka, representatif, serta telah digunakan pada berbagai penelitian terkait klasifikasi penyakit tanaman anggur. *Dataset Grape Leaf Disease -Small-4 Class-500 Samples Each* yang digunakan dapat dilihat pada Tabel 1.

Tabel 1. *Dataset Leaf Disease Small*

Kelas	Banyak sample (Train : Validation : Test)	Gambar Sample Citra
Healty	500(350:75:75)	
Blach Rot	500(350:75:75)	
ESCA	500(350:75:75)	
Leaf Blight	500(350:75:75)	


3.3. Perancangan

Pada tahap ini dilakukan perancangan sistem klasifikasi penyakit daun anggur dengan memanfaatkan arsitektur *Convolutional Neural Network (CNN)* berbasis *transfer learning* menggunakan model *EfficientNetV2-B0*. Sistem ini dirancang untuk membandingkan kinerja dua *optimizer*, yaitu *AdamW* dan *Stochastic Gradient Descent (SGD)*. Dataset yang digunakan berasal dari dataset publik yang tersedia pada platform *Kaggle*, terdiri dari empat kategori daun anggur. Dataset tersebut selanjutnya dibagi menjadi data latih, validasi, dan uji menggunakan metode *train-validation-test split* untuk memastikan evaluasi model yang objektif.

Seluruh citra dalam dataset diproses melalui tahap *preprocessing* yang meliputi *resize*, serta *data augmentation* seperti *rotation*, *flip (vertical and horizontal)*, *zoom*, *shear*, dan *brightness adjustment*. Tahapan ini bertujuan untuk meningkatkan variasi data pelatihan, memperkaya representasi fitur, serta mengurangi risiko *overfitting*. Selanjutnya, pemodelan CNN dilakukan dengan memanfaatkan *EfficientNetV2-B0 pretrained* pada dataset *ImageNet* melalui dua pendekatan, yaitu *feature extraction* dan *fine tuning*. Arsitektur model disesuaikan dengan menambahkan *Global Average Pooling*, lapisan *Dense* dengan fungsi aktivasi *ReLU*, *Dropout* sebagai regularisasi, serta *output layer* dengan fungsi aktivasi *Softmax* sesuai jumlah kelas.

Pada tahap optimasi, model dilatih menggunakan *optimizer AdamW* dan *SGD* dengan parameter pelatihan berupa *learning rate* adaptif, *batch size* 32, dan jumlah *epoch* optimal antara 30 hingga 50, serta dilengkapi dengan *early stopping*. Evaluasi model dilakukan menggunakan data uji dengan menghitung nilai *accuracy*, *precision*, *recall*, dan *f1-score* yang

diperoleh dari *confusion matrix*. Rancangan sistem ini diharapkan mampu menghasilkan model klasifikasi penyakit daun anggur yang optimal dan berkontribusi dalam mendukung pengelolaan tanaman anggur secara lebih efektif. Perancangan pada penelitian ini dapat dilihat pada Gambar 4 Skema Perancangan.



Gambar 4. Skema Perancangan

3.4. Implementasi

Pada tahap ini dilakukan implementasi model *Convolutional Neural Network (CNN)* menggunakan metode *transfer learning* dengan arsitektur *EfficientNetV2-B0*. Model dilatih menggunakan data yang telah melalui proses pra-pemrosesan, meliputi *resize* dan *augmentasi*, guna meningkatkan kualitas data dan kemampuan generalisasi model. Selama pelatihan, parameter penting seperti *learning rate*, *batch size*, jumlah *epoch* optimal (30–50), dan jenis *optimizer* diatur secara terstruktur untuk memperoleh performa terbaik. Evaluasi dilakukan pada setiap *epoch* untuk memantau perkembangan akurasi dan *loss*, sehingga model dapat mencapai hasil yang optimal pada tahap pengujian.

3.5. Pengujian

Pada tahap ini, model yang telah dibangun diuji menggunakan data uji. Hasil pengujian digunakan untuk menghitung performa model dalam mengenali dan mengklasifikasikan penyakit daun anggur. Setelah proses pengujian dilakukan, hasil evaluasi dihitung menggunakan *Confusion Matrix* untuk menentukan tingkat keberhasilan metode melalui nilai *precision*, *recall*, dan *accuracy*, sebagaimana ditunjukkan pada Persamaan (3), (4), (5), dan (6).

$$Precision = \frac{TP}{TP + FP} \times 100\% \dots (3)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \dots (4)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \dots (5)$$

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \dots (6)$$

Keterangan:

- TP : Jumlah citra daun anggur berpenyakit yang diklasifikasikan dengan benar oleh model.
 TN : Jumlah citra daun anggur tidak berpenyakit yang diklasifikasikan dengan benar.
 FN : Jumlah citra daun anggur berpenyakit yang salah diklasifikasikan.
 FP : Jumlah citra daun anggur tidak berpenyakit yang salah diklasifikasikan sebagai berpenyakit.

4. HASIL DAN PEMBAHASAN

Pada bab ini menyajikan hasil implementasi, pengujian, dan analisis kinerja model klasifikasi penyakit daun anggur menggunakan arsitektur *transfer learning EfficientNetV2-B0* dengan penerapan *optimizer AdamW* dan *SGD*. Pengujian dilakukan melalui serangkaian skenario dengan variasi pelatihan untuk menilai kestabilan dan efektivitas model. Hasil yang diperoleh kemudian dianalisis berdasarkan metrik akurasi dan loss guna melihat sejauh mana model mampu melakukan klasifikasi penyakit tanaman daun anggur secara optimal.

4.1. Skenario Pengujian

Pengujian pada penelitian ini dilakukan menggunakan dataset sebanyak 2000 citra yang dibagi menjadi data latih, validasi, dan uji dengan proporsi 70%, 15%, dan 15%. Seluruh citra melalui tahap *preprocessing* yang meliputi penyesuaian ukuran menjadi 224×224 piksel, *batch size* 32, serta *data augmentation* berupa *rotation*, *flip* (*vertical* dan *horizontal*), *zoom*, *shear*, dan *brightness adjustment* untuk meningkatkan variasi data dan mengurangi risiko *overfitting*. Model *transfer learning* dengan arsitektur *EfficientNetV2-B0* diuji menggunakan dua *optimizer*, yaitu *AdamW* dan *Stochastic Gradient Descent (SGD)*, dengan konfigurasi parameter yang berbeda pada tahap *feature extraction* dan *fine-tuning*. Pada *AdamW*, digunakan *learning rate* sebesar 0,001 pada tahap *feature extraction* dan 0,001 pada tahap *fine-tuning*, sedangkan *SGD* menggunakan *learning rate* sebesar 0,001 pada kedua tahap pelatihan. Evaluasi dilakukan melalui beberapa variasi jumlah *epoch* untuk memperoleh performa optimal, dengan metrik penilaian berupa *accuracy*, *precision*, *recall*, dan *f1-score* sebagai dasar analisis kinerja model dalam klasifikasi penyakit daun anggur, sebagaimana dirangkum pada Tabel 2.

Tabel 2. Skenario Pengujian Epoch

Skenario Pengujian	Feature Extraction (Epoch)	Fine Tuning (Epoch)	Total Epoch
Pengujian Ke-1	10	20	30
Pengujian Ke-2	15	25	40
Pengujian Ke-3	20	30	50


4.2. Hasil Pengujian

Hasil pengujian pada penelitian ini digunakan untuk mengevaluasi kinerja model *EfficientNetV2-B0* pada dua tahap pelatihan, yaitu *feature extraction* dan *fine-tuning*, dengan membandingkan dua *optimizer* yang digunakan, yaitu *AdamW* dan *SGD*. Setiap langkah pelatihan mengikuti konfigurasi parameter yang telah ditetapkan sebelumnya pada skenario pengujian sehingga perbedaan performa kedua *optimizer* dapat diamati secara terukur. Evaluasi dilakukan dengan mencatat akurasi pada berbagai kombinasi jumlah *epoch* untuk mengetahui pengaruh variasi tahap pelatihan terhadap kinerja akhir model. Ringkasan hasil pengujian yang telah dilakukan untuk seluruh pelatihan dapat dilihat pada Tabel 3 berikut.

Tabel 3. Hasil Pengujian

Feature Extraction (Epoch)	Fine Tuning (Epoch)	Total Epoch	AdamW	SGD
10	20	30	95.67%	87.67%
15	25	40	96.33%	89.67%
20	30	50	97.00%	91.00%


Hasil tersebut menunjukkan bahwa variasi jumlah *epoch* pada tahap *feature extraction* dan *fine-tuning* memberikan pengaruh langsung terhadap peningkatan akurasi model. *Optimizer AdamW* secara konsisten menghasilkan akurasi lebih tinggi pada setiap *epoch* dibandingkan *SGD*, dengan performa terbaik dicapai pada total 50 *epoch*. Sementara itu, meskipun *SGD* tetap menunjukkan akurasi yang tinggi dan stabil, peningkatan performanya tidak sekuat *AdamW*. Temuan ini menegaskan bahwa *AdamW* lebih efektif dalam memanfaatkan proses pelatihan untuk meningkatkan kemampuan generalisasi model pada dataset uji. Visualisasi *confusion matrix* pada epoch ke-50 untuk *optimizer AdamW* dan *SGD* dapat dilihat pada Gambar 5.



Gambar 5. Visualisasi Confusion Matrix


Pada gambar 5 diatas menampilkan visualisasi *confusion matrix* hasil pengujian untuk *optimizer AdamW* dan *Stochastic Gradient Descent (SGD)* pada epoch ke-50. *Confusion matrix AdamW* menunjukkan dominasi prediksi pada diagonal utama dengan jumlah kesalahan yang relatif rendah, yang mengindikasikan kemampuan klasifikasi dan generalisasi model yang baik. Sebaliknya, *confusion matrix SGD* memperlihatkan kesalahan prediksi yang lebih tinggi

pada beberapa kelas, khususnya *Black Rot* dan *ESCA*. Perbandingan ini menegaskan bahwa *AdamW* menghasilkan performa klasifikasi yang lebih stabil dan akurat dibandingkan *SGD*. Selanjutnya, untuk melihat performa pelatihan secara lebih komprehensif, khususnya tren *training accuracy* dan *validation accuracy* hingga *epoch* ke-50 dengan optimizer *AdamW* dan *SGD*, visualisasi tersebut dapat dilihat pada Gambar 6.



Gambar 6. Grafik Training dan Validation Accuracy

Pada Gambar 6 menampilkan perbandingan grafik *training accuracy* dan *validation accuracy* hingga *epoch* ke-50 menggunakan optimizer *AdamW* dan *Stochastic Gradient Descent (SGD)*. Grafik *AdamW* menunjukkan peningkatan akurasi yang cepat dan stabil dengan selisih kecil antara data pelatihan dan validasi, yang mengindikasikan konvergensi dan kemampuan generalisasi yang baik. Sebaliknya, *SGD* memperlihatkan peningkatan akurasi yang lebih lambat dengan selisih yang lebih besar, sehingga menunjukkan stabilitas dan generalisasi yang lebih rendah dibandingkan *AdamW*. Visualisasi tren *training loss* dan *validation loss* hingga *epoch* ke-50 untuk optimizer *AdamW* dan *SGD* dapat dilihat pada Gambar 7.



Gambar 7. Grafik Training dan Validation loss

Pada Gambar 7 menampilkan perbandingan grafik *training loss* dan *validation loss* hingga *epoch* ke-50 menggunakan optimizer *AdamW* dan *Stochastic Gradient Descent (SGD)*. Grafik *AdamW* menunjukkan penurunan *loss* yang lebih cepat dan stabil, sedangkan *SGD* mengalami penurunan yang lebih bertahap dengan laju konvergensi yang lebih lambat. Perbandingan ini menunjukkan bahwa *AdamW* memberikan proses pembelajaran yang lebih efisien, sementara hasil evaluasi klasifikasi model untuk optimizer *adamW* ditunjukkan melalui *confusion matrix* pada Tabel 4.

Tabel 4. Confusion Matrix AdamW

Class	Precision	Recall	F1-Score	Support
Health	0.91	0.98	0.94	75
Black Rot	0.98	0.90	0.94	75
ESCA	1.00	0.98	0.99	75
Leaf Blight	0.98	1.00	0.99	75
Accuracy			0.97	300
Macro avg	0.97	0.97	0.97	300
Weighted avg	0.97	0.97	0.97	300

Pada Tabel 4 menunjukkan bahwa pada *epoch* ke-50, model dengan optimizer *AdamW* mencapai performa klasifikasi yang sangat baik, ditunjukkan oleh nilai *precision*, *recall*, dan *f1-score* yang tinggi pada seluruh kelas. Kelas *Health* dan *Black Rot* masing-masing memperoleh nilai *f1-score* sebesar 0.94, sementara kelas *ESCA* dan *Leaf Blight* menunjukkan performa paling optimal dengan nilai *f1-score* sebesar 0.99. Secara keseluruhan, model mencapai nilai *accuracy* sebesar 0.97, yang didukung oleh nilai *macro average* dan *weighted average f1-score* sebesar 0.97, sehingga menunjukkan kemampuan generalisasi yang baik dan stabil. Adapun hasil evaluasi menggunakan *confusion matrix* untuk optimizer *SGD* dapat dilihat pada Tabel 5.

Tabel 5. Confusion Matrix SGD

Class	Precision	Recall	F1-Score	Support
Health	0.76	0.97	0.85	75
Black Rot	0.98	0.69	0.81	75
ESCA	0.98	0.98	0.98	75
Leaf Blight	0.97	0.98	0.98	75
Accuracy			0.91	300
Macro avg	0.92	0.91	0.90	300
Weighted avg	0.92	0.91	0.90	300

Pada Tabel 5 menunjukkan bahwa pada *epoch* ke-50, optimizer *Stochastic Gradient Descent (SGD)* menghasilkan performa klasifikasi yang cukup baik dengan nilai *accuracy* sebesar 0.91. Kelas *ESCA* dan *Leaf Blight* memiliki nilai *f1-score* tertinggi sebesar 0.98, sedangkan kelas *Health* dan *Black Rot* menunjukkan nilai *f1-score* yang lebih rendah, yaitu 0.85 dan 0.81. Jika dibandingkan dengan optimizer *AdamW*, performa *SGD* memiliki konsistensi prediksi dan kemampuan generalisasi yang lebih rendah pada hasil pengujian yang dilakukan.

Berdasarkan hasil pengujian keseluruhan, optimizer *AdamW* menunjukkan kinerja terbaik dengan capaian *accuracy* tertinggi sebesar 97.00% pada *epoch* ke-50, sedangkan *SGD* hanya mencapai *accuracy* sebesar 91.00% pada *epoch* yang sama. Hal ini menegaskan bahwa *epoch* ke-50 merupakan titik pelatihan yang optimal, serta *AdamW* lebih efektif dalam meningkatkan performa klasifikasi penyakit daun anggur dibandingkan dengan seluruh skenario pengujian lainnya.

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengimplementasikan metode *Convolutional Neural Network* berbasis *transfer learning* dengan arsitektur *EfficientNetV2-B0* menggunakan optimizer *AdamW* dan *Stochastic Gradient Descent (SGD)* untuk klasifikasi penyakit daun anggur. Hasil pengujian menunjukkan bahwa kedua *optimizer* mampu menghasilkan akurasi yang tinggi, namun *AdamW* memperlihatkan kinerja yang lebih baik dengan tingkat akurasi terbaik sebesar 97.00% pada *epoch* ke-50, sedangkan optimizer *SGD* memperoleh akurasi terbaik sebesar 91.00%. Selain dari sisi akurasi, *AdamW* juga menghasilkan distribusi prediksi yang lebih stabil serta nilai *precision*, *recall*, dan *f1-score* yang konsisten pada seluruh kelas penyakit daun anggur, sehingga mencerminkan kemampuan generalisasi model yang lebih baik. Berdasarkan temuan tersebut, penelitian selanjutnya disarankan untuk memperluas variasi dataset menggunakan citra lapangan, mengeksplorasi arsitektur jaringan dan teknik pelatihan yang lebih optimal, serta mengembangkan aplikasi pendukung agar model yang dihasilkan dapat diterapkan secara langsung (*realtime*) dalam proses deteksi penyakit daun anggur.

DAFTAR PUSTAKA

- [1] A. K. Whardana, D. Febriyanto, M. J. Katanka, N. A. Oktavia, and T. Desta, "Klasifikasi Penyakit Daun Anggur dengan Menggunakan Convolutional Neural Network dan Transfer Learning dari VGG16," 2024.
- [2] M. A. Hasan, Y. Riyanto, and D. Riana, "Grape leaf image disease classification using CNN-VGG16 model," *J. Teknol. dan Sist. Komput.*, vol. 9, no. 4, pp. 218–223, 2021, doi: 10.14710/jtsiskom.2021.14013.
- [3] M. A. N. Hidayat, Kusri, and Hanafi, "Convolutional Neural Network Pada Identifikasi Varian Tanaman Anggur Menggunakan Resnet-50," *J. Tek. Inform. dan Sist. Inf.*, vol. 10, no. 3, pp. 61–70, 2023, [Online]. Available: <https://jurnal.mdp.ac.id/index.php/jatiji/article/download/4789/1531>
- [4] N. Awalia and A. Primajaya, "Identifikasi Penyakit Leaf Mold Daun Tomat Menggunakan Model DenseNet-121," *J. Ilm. Ilmu Komput.*, vol. 8, no. 1, pp. 49–54, 2022, [Online]. Available: <http://ejournal.fikom-unasman.ac.id>
- [5] A. Badriyah, M. Sarosa, R. A. Asmara, M. K. Wardani, and D. F. Al Riza, "Grapevine Disease Identification Using Resnet- 50," *BIO Web Conf.*, vol. 117, pp. 1–8, 2024, doi: 10.1051/bioconf/202411701046.
- [6] A. Jovano, M. I. Rosadi, and C. B. Sanjaya, "Klasifikasi jenis penyakit daun anggur menggunakan metode ekstraksi fitur glcm dan neural network," *NJCA (Nusantara J. Comput. Its Appl.)*, vol. 6, no. 2, pp. 11–18, 2021.
- [7] D. T. Utomo, A. Baihaqi, H. Asysyauqi, R. Azizissani, A. H. A. Ash'shobir, and H. S. Wijaya, "Perancangan Sistem Penyiraman Otomatis Pada Greenhouse Guna Meningkatkan Kualitas Bibit Tanaman Anggur (*Vitis vinifera*) Di Daerah Sidoarjo," *JEETCOM J. Electr. Eng. Comput.*, vol. 4, no. 1, pp. 46–50, 2022, doi: 10.33650/jeecom.v4i1.3581.
- [8] Q. Ye et al., "Fomitiporia punicata and Phaeoacremonium minimum associated with Esca complex of grapevine in China," *Phytopathol. Res.*, vol. 3, no. 1, 2021, doi: 10.1186/s42483-021-00087-w.
- [9] M. Szabó et al., "Black Rot of Grapes (*Vitis vinifera*)—A Comprehensive Overview," *Horticulturae*, vol. 9, no. 2, 2023, doi: 10.3390/horticulturae9020130.
- [10] E. Yurchenko, D. Karpova, M. Burovinskaya, and S. Vinogradova, "Leaf Spot Caused by Alternaria spp. Is a New Disease of Grapevine," *Plants*, vol. 13, no. 23, pp. 1–18, 2024, doi: 10.3390/plants13233335.
- [11] Q. N. Azizah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network AlexNet," *J. Tek. Inform.*, pp. 28–33, 2023, doi: <https://doi.org/10.56211/sudo.v2i1.227>.
- [12] M. R. Alwanda, R. P. K. Ramadhan, and D. Alamsyah, "Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle," *J. Algoritma*, vol. 1, no. 1, pp. 45–56, 2020, doi: 10.35957/algoritme.v1i1.434.
- [13] A. E. Putra, M. F. Naufal, and V. R. Prasetyo, "Klasifikasi Jenis Rempah Menggunakan Convolutional Neural Network dan Transfer Learning," *J. Edukasi dan Penelit. Inform.*, vol. 9, no. 1, p. 12, 2023, doi: 10.26418/jp.v9i1.58186.
- [14] M. Tan and Q. V. Le, "EfficientNetV2: Smaller Models and Faster Training Mingxing," 2021.
- [15] M. Ichwan and S. Hadi, "MIND (Multimedia Artificial Intelligent Networking Database Kinerja Model EfficientNetV2M dalam Klasifikasi Citra Tutupan dan Penggunaan Lahan," *J. MIND J. | ISSN*, vol. 8, no. 2, pp. 203–216, 2023, [Online]. Available: <https://doi.org/10.26760/mindjournal.v8i2.203-216>
- [16] G. E. Saputra, Karmilarsari, A. Faisal, and A. Apandi, "Perbandingan Penerapan Algoritma Neural Network Backpropagation Dengan Optimasi Algoritma LBFGS dan SGD Untuk Prediksi Penyakit Jantung," *Semin. Nas. Teknol. Inf. dan Komun. STI&K*, vol. 4, no. 1, pp. 1–10, 2020.
- [17] B. Nugroho, E. Y. Puspaningrum, and M. S. Munir, "Kinerja Algoritma Optimasi Root-Mean-Square Propagation dan Stochastic Gradient Descent pada Klasifikasi Pneumonia

- Covid-19 Menggunakan CNN,” *J. Edukasi dan Penelit. Inform.*, vol. 7, no. 3, p. 420, 2021, doi: 10.26418/jp.v7i3.49172.
- [18] M. D. A. Pranatha, G. H. Setiawan, and M. A. Maricar, “Utilization of ResNet Architecture and Transfer Learning Method in the Classification of Faces of Individuals with Down Syndrome,” *J. Appl. Informatics Comput.*, vol. 8, no. 2, pp. 434–442, 2024, doi: 10.30871/jaic.v8i2.8474.
- [19] M. A. Zia, A. Akram, I. Mumtaz, M. A. Saleem, and M. Asif, “Analysis of Grape Leaf Disease By Using Deep Convolutional Neural Network,” *Agric. Sci. J.*, vol. 5, no. 1, pp. 25–36, 2023, doi: 10.56520/asj.v5i1.242.
- [20] A. N. Sahid and D. R. Cahyadi, “Image Classification Using MobileNet Based on CNN Architecture for Grape Leaf Disease Detection,” *J. Intell. Syst. Technol. Informatics*, vol. 1, no. 1, pp. 15–21, 2025, [Online]. Available: <https://journal.aptika.org/index.php/jistics/article/view/7>
- [21] Ismetgocer, “Grape Leaf Disease -Small-4 Class-500 Samples Each,” *Kaggle*, [Online]. Available: <https://www.kaggle.com/datasets/ismetgocer/grape-leaf-disease-small-4-class-500-samples-each>