

ANALISIS PERBANDINGAN OPTIMIZER ADAMW, ADAGRAD, DAN SGD PADA KLASIFIKASI PENYAKIT DAUN PISANG MENGGUNAKAN MOBILENETV3

Rendy Amarullah, Abdul Rahman

Informatika, Universitas Multi Data Palembang
Jalan Rajawali 14, 30113 Palembang, Indonesia
rendyamarullah_2226250065@mhs.mdp.ac.id

ABSTRAK

Pisang merupakan komoditas strategis di Indonesia, namun produktivitasnya sering terhambat oleh serangan penyakit daun seperti Sigatoka, Cordana, dan Pestalotiopsis. Metode identifikasi visual konvensional memiliki keterbatasan dalam hal subjektivitas dan rentan terhadap kesalahan diagnosis. Penelitian ini bertujuan menganalisis efektivitas klasifikasi penyakit daun pisang menggunakan arsitektur *deep learning* MobileNetV3-Large dengan membandingkan kinerja tiga *optimizer*, yakni AdamW, Adagrad, dan SGD. Metodologi penelitian dimulai dengan *offline augmentation* pada 1.600 citra dari dataset BananaLSD yang dibagi menjadi rasio 80% *training*, 10% *validation*, dan 10% *testing*. Citra distandarisasi ke dimensi 224x224 piksel melalui proses normalisasi data. Kinerja model dievaluasi menggunakan *confusion matrix* dengan pendekatan *macro-average* untuk mengukur akurasi, presisi, *recall*, dan *f1-score*. Hasil penelitian menunjukkan bahwa *optimizer* AdamW mencapai akurasi tertinggi sebesar 99%, disusul SGD sebesar 94%, dan Adagrad sebesar 92%. *Optimizer* AdamW terbukti memberikan stabilitas pelatihan dan generalisasi model yang paling optimal pada arsitektur MobileNetV3-Large dalam klasifikasi penyakit daun pisang.

Kata kunci : *Convolutional Neural Network*, Daun Pisang, MobileNetV3, AdamW, Adagrad, SGD.

1. PENDAHULUAN

Pisang merupakan komoditas hortikultura strategis di Indonesia yang memiliki nilai ekonomi tinggi pada seluruh bagian tanamannya [1]. Namun, produktivitasnya sering terhambat oleh serangan penyakit daun seperti Sigatoka, Cordana, dan Pestalotiopsis yang dapat menyebabkan kehilangan hasil panen 50% hingga 80% per siklus [2], [3]. Permasalahan utama yang dihadapi petani adalah kesulitan melakukan identifikasi penyakit secara akurat karena diagnosis visual yang bersifat subjektif dan rentan terhadap kesalahan, sehingga memicu penanganan yang tidak tepat [4]. Kondisi ini menuntut perlunya sistem deteksi berbasis teknologi untuk meminimalisir kegagalan panen [5].

Convolutional Neural Network (CNN) telah terbukti efektif dalam klasifikasi citra penyakit tanaman [6]. Penelitian sebelumnya telah menunjukkan bahwa arsitektur *lightweight* seperti MobileNetV2 mampu mendeteksi penyakit daun pisang dengan akurasi 90,62%, namun potensi arsitektur MobileNetV3 yang lebih efisien masih minim dieksplorasi pada komoditas ini. Selain arsitektur, performa model sangat bergantung pada pemilihan *optimizer* yang tepat, di mana terdapat inkonsistensi hasil penelitian terdahulu mengenai *optimizer* mana yang paling efektif bagi tanaman dengan karakteristik visual berbeda. [7].

Penelitian ini bertujuan untuk melakukan analisis perbandingan efektivitas *optimizer* AdamW, Adagrad, dan SGD pada arsitektur MobileNetV3-Large dalam klasifikasi penyakit daun pisang. Rencana penyelesaian masalah dilakukan dengan menggunakan dataset BananaLSD yang telah melalui tahapan *offline*

augmentation. Model akan dilatih dengan parameter yang seragam untuk mengukur metrik akurasi, presisi, *recall*, dan *f1-score*. Hasil dari penelitian ini diharapkan dapat menentukan konfigurasi *optimizer* terbaik yang mampu memberikan stabilitas proses pelatihan dan generalisasi model paling optimal untuk mendukung deteksi penyakit daun pisang yang lebih akurat.

2. TINJAUAN PUSTAKA

Penelitian-penelitian sebelumnya telah membuktikan efektivitas algoritma *deep learning* dalam mendeteksi penyakit tanaman, salah satunya menggunakan arsitektur *lightweight* seperti MobileNetV2 yang mampu mencapai akurasi 90,62% pada daun pisang [7]. Meskipun arsitektur generasi terbaru, yaitu MobileNetV3, telah terbukti lebih unggul pada klasifikasi penyakit daun jeruk, eksplorasi arsitektur ini secara spesifik pada domain daun pisang masih sangat minim [8]. Di samping itu, terdapat celah penelitian (*research gap*) terkait inkonsistensi hasil penelitian mengenai algoritma optimasi (*optimizer*) yang paling efektif; di mana Adagrad ditemukan unggul pada daun tomat [8], sementara AdamW terbukti lebih efektif dalam mencegah overfitting pada tanaman jagung [9]. Perbedaan karakteristik visual antar jenis tanaman ini menyebabkan rekomendasi *optimizer* dari penelitian terdahulu tidak dapat serta-merta diadopsi. Oleh karena itu, belum ada studi komparatif yang secara konklusif menentukan apakah stabilitas SGD, adaptivitas Adagrad, atau regularisasi AdamW yang paling optimal untuk dataset daun pisang pada arsitektur MobileNetV3.

2.1. Pisang

Pisang (*Musa paradisiaca*) merupakan komoditas hortikultura utama yang tumbuh subur di wilayah tropis seperti Indonesia dan memiliki nilai ekonomi tinggi karena seluruh bagian tanamannya dapat dimanfaatkan secara strategis. Varietas yang populer di Indonesia antara lain pisang Ambon dan pisang emas (*Lady Finger*) yang memiliki karakteristik kulit serta rasa yang khas [10]. Keberlangsungan produktivitas tanaman ini sangat bergantung pada kesehatan daun yang berperan vital dalam proses fotosintesis, sehingga gangguan akibat serangan patogen dapat menurunkan kualitas dan kuantitas panen secara signifikan.

Secara botani, pisang diklasifikasikan ke dalam famili *Musaceae* yang berbentuk herba raksasa dengan batang semu (*pseudostem*) silindris yang mengandung banyak air [3]. Selain memiliki kandungan nutrisi lengkap seperti vitamin A, B6, dan C, buah pisang juga mengandung senyawa metabolit sekunder berupa dopamin dan katekin yang berfungsi sebagai antioksidan penting untuk kesehatan sel tubuh.

2.2. Penyakit Daun Pisang

Penyakit pada daun merupakan faktor utama yang menghambat produktivitas tanaman pisang. Berdasarkan studi klasifikasi terbaru, terdapat tiga jenis penyakit daun utama yang sering menjadi objek klasifikasi, yaitu *Sigatoka*, *Cordana*, dan *Pestalotiopsis* [2], [11].

Penyakit *Sigatoka*, khususnya *Sigatoka* Kuning (*Mycosphaeraella musicola*), dikenal sebagai salah satu penyakit paling destruktif. Gejala visualnya ditandai dengan munculnya bintik kecil memanjang berwarna kuning pucat yang sejajar dengan tulang daun. Seiring perkembangan infeksi, bintik tersebut menyatu membentuk lesi nekrotik dengan pusat berwarna abu-abu yang menyebabkan daun mengering dan menurunkan efisiensi fotosintesis secara drastis [3].

Selain itu, terdapat penyakit *Cordana* yang disebabkan oleh jamur *Cordana musae* atau *Neocordana musae*. Karakteristik visual penyakit ini sangat khas, berupa bercak berbentuk oval besar dengan pola cincin konsentris (*concentric rings*) di bagian dalamnya. Pusat bercak biasanya berwarna coklat pucat yang dikelilingi oleh batas kuning cerah (*halo*) dan sering ditemukan pada bagian tepi daun atau pada daun yang sudah tua.

2.3. Deep Learning

Deep learning merupakan bagian dari kecerdasan buatan dan machine learning yang dikembangkan berdasarkan konsep neural network dengan banyak lapisan (*multiple layer*). Teknik ini memanfaatkan algoritma yang meniru mekanisme kerja sistem saraf otak manusia [12]. Proses pembelajaran pada deep learning melibatkan dua tahapan utama, yaitu *forward propagation* dan *backpropagation*. Pada tahap *forward propagation*, data mengalir dari lapisan input menuju output melalui

serangkaian operasi matematis seperti perkalian bobot, penambahan bias, dan penggunaan fungsi aktivasi. Sebaliknya, *backpropagation* berfungsi untuk mengukur tingkat kesalahan (*error*) antara hasil prediksi model dengan nilai sebenarnya menggunakan *loss function*, seperti Mean Squared Error (MSE) atau Cross-Entropy Loss, yang kemudian dilanjutkan dengan perhitungan gradien menggunakan aturan rantai (*chain rule*).

2.4. Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan salah satu jenis arsitektur *deep learning* yang dirancang khusus untuk menangani tugas klasifikasi citra [13]. Keunggulan utama CNN terletak pada kemampuan *feature learning*, di mana model dapat mempelajari fitur-fitur penting seperti tepi, tekstur, dan bentuk dari citra secara otomatis tanpa memerlukan ekstraksi fitur manual. Arsitektur ini terdiri dari beberapa lapisan yang dimulai dari *input layer* berupa citra digital, diikuti oleh rangkaian *hidden layer*, dan diakhiri pada *output layer*. Dalam *hidden layer*, terdapat kombinasi dari *convolutional layer* yang berfungsi melakukan operasi linier dan non-linier untuk menciptakan peta fitur (*feature map*), serta *pooling layer* yang menyederhanakan ukuran peta fitur sekaligus mengurangi risiko *overfitting* [14], [15]. Sebelum menuju tahap klasifikasi akhir pada *fully connected layer*, peta fitur *output* harus dikonversi menjadi vektor satu dimensi melalui proses *flattening*.

2.5. Transfer Learning

Transfer learning merupakan teknik pemanfaatan model yang telah dilatih sebelumnya (*pre-trained model*) untuk diterapkan pada *dataset* baru, sehingga tidak memerlukan proses pelatihan dari awal. Pendekatan ini menawarkan keuntungan signifikan berupa efisiensi waktu pelatihan [16]. Keunggulan lain dari *transfer learning* terletak pada arsitekturnya yang memiliki banyak lapisan konvolusi (*convolution*) dan *pooling*. Struktur tersebut memungkinkan ekstraksi fitur dan tekstur citra dilakukan secara menyeluruh, yang berdampak pada tingginya kualitas pemahaman informasi citra tersebut [17].

2.6. Klasifikasi Citra dan Deteksi Objek

Dalam implementasi *computer vision*, terdapat perbedaan mendasar antara tugas klasifikasi citra (*image classification*) dan deteksi objek (*object detection*). Klasifikasi citra bertujuan memberikan label kategori tunggal pada keseluruhan citra *input* untuk mengidentifikasi objek di dalamnya. Sebaliknya, deteksi objek mengidentifikasi kategori sekaligus melokalisasi keberadaan objek menggunakan kotak pembatas (*bounding box*) [18]. Penelitian ini berfokus pada klasifikasi citra, di mana sistem menerima *input* citra daun pisang untuk menentukan satu label keputusan di antara empat kelas (Sehat, *Sigatoka*, *Cordana*, atau *Pestalotiopsis*)

berdasarkan fitur visual global tanpa memberikan koordinat lokasi penyakit secara spesifik.

2.7. MobileNetV3

MobileNetV3 merupakan arsitektur *deep learning* efisien yang dirancang untuk perangkat dengan sumber daya terbatas. Arsitektur ini tersedia dalam dua varian, yaitu MobileNetV3-Large dan MobileNetV3-Small, di mana varian Large dipilih dalam penelitian ini untuk klasifikasi penyakit daun pisang. Keunggulan arsitektur ini terletak pada penggunaan *Network Architecture Search* (NAS) untuk menemukan struktur jaringan paling optimal [12]. Selain itu, MobileNetV3-Large mengintegrasikan berbagai teknik modern untuk menyeimbangkan efisiensi komputasi dan akurasi model [14].

2.8. AdamW

AdamW merupakan algoritma optimasi yang dikembangkan sebagai penyempurnaan dari metode Adam, khususnya dalam penanganan regularisasi. Perbedaan fundamental AdamW terletak pada penerapan *weight decay* yang dilakukan secara terpisah (*decoupled*) dari pembaruan gradien [19]. Hal ini mengatasi kekurangan Adam dalam mengelola regularisasi agar tidak terjadi *overfitting*. Aturan pembaruan parameter pada AdamW didefinisikan pada persamaan (1) [20]:

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

2.9. Adagrad

Adagrad adalah algoritma optimasi berbasis gradien yang menyesuaikan *learning rate* secara otomatis bagi setiap parameter selama pelatihan. Algoritma ini memberikan pembaruan yang lebih kecil pada parameter yang berkaitan dengan fitur yang sering muncul, sehingga sangat efektif untuk menangani fitur yang jarang muncul (*sparse features*) [21]. *Adagrad* memodifikasi *learning rate* secara dinamis berdasarkan akumulasi kuadrat gradien sebelumnya untuk melatih jaringan saraf berskala besar. Pembaruan parameter pada *Adagrad* didefinisikan melalui persamaan(2).

$$\theta_{t+1} = \theta_t - \frac{\alpha}{\sqrt{\epsilon + \sum g_t^2}} \odot g_t \quad (2)$$

2.10. Stochastic Gradient Descent (SGD)

Stochastic Gradient Descent (SGD) merupakan algoritma optimasi fundamental yang memperbarui bobot parameter model secara iteratif untuk meminimalkan *loss function* [22]. Berbeda dengan *Gradient Descent* konvensional, SGD melakukan pembaruan parameter langsung untuk setiap satu sampel data latih yang diproses [23]. Sifat stokastik ini membantu model menghindari titik minimum lokal (*local minima*) untuk mencapai solusi yang lebih optimal [24]. Pembaruan parameter pada SGD dengan *learning rate* (γ) didefinisikan pada persamaan(3).

$$\theta_{t+1} = \theta_t - \gamma \cdot \nabla \theta J(\theta; x^{(i)}, y^{(i)}) \quad (3)$$

2.11. Evaluasi Kinerja Multiclass

Penelitian ini menggunakan teknik rata-rata untuk menyesuaikan metrik evaluasi biner pada klasifikasi empat kelas. Metode *Macro-Average* digunakan karena memberikan bobot setara pada setiap kelas tanpa bias terhadap jumlah sampel, sehingga cocok untuk *dataset* yang seimbang. Perhitungan *Macro F1-Score* dilakukan dengan merata-ratakan nilai F1 dari seluruh kelas kategori seperti pada persamaan (4).

$$\text{Macro F1} = \frac{F1_{\text{Sehat}} + F1_{\text{Sigatoka}} + F1_{\text{Cordana}} + F1_{\text{Pestalotiopsis}}}{4} \quad (4)$$

Metode lainnya adalah *Micro-Average* yang menjumlahkan total *True Positives* (TP), *False Positives* (FP), dan *False Negatives* (FN) dari seluruh kelas secara global, di mana nilainya cenderung setara dengan akurasi pada kasus klasifikasi yang seimbang.

3. METODE PENELITIAN

Metodologi dalam penelitian ini dirancang secara sistematis agar hasil penelitian terarah dan sesuai dengan tujuan yang ditetapkan. Tahapan penelitian meliputi studi literatur, pengumpulan *dataset*, perancangan model klasifikasi menggunakan *Convolutional Neural Network* (CNN) dengan pendekatan *transfer learning* MobileNetV3-Large, implementasi, dan pengujian. Alur tahapan tersebut secara visual ditunjukkan pada Gambar 3



Gambar 1. Tahapan metode penelitian

Berdasarkan gambar 1, Metodologi penelitian dirancang sebagai kerangka kerja sistematis guna menjawab rumusan masalah secara terstruktur dan ilmiah. Penerapan alur penelitian ini bertujuan untuk menjamin validitas hasil eksperimen serta meminimalisir potensi galat teknis selama proses berlangsung. Tahapan kerja disusun secara berurutan yang meliputi studi literatur, akuisisi *dataset*,

perancangan arsitektur model, implementasi sistem, hingga evaluasi performa akhir.

3.1. Studi Literatur

Tahapan ini dilakukan dengan mempelajari berbagai literatur berupa jurnal ilmiah dan buku yang relevan dengan topik klasifikasi penyakit daun pisang menggunakan CNN. Literatur tersebut berfungsi sebagai landasan teori, penentuan metodologi, dan acuan penelitian terdahulu.

3.2. Pengumpulan Dataset

Tahap ini, dilakukan proses pengumpulan *dataset* berupa *dataset* penyakit daun tanaman pisang. *Dataset* yang diambil dari publik di website Mendeley *Dataset* dengan nama “Banana Leaf Spot Diseases (BananaLSD)”. *Dataset* berisi 1600 citra yang terdiri dari 4 kategori, yaitu daun sehat (*healthy*), *Sigatoka*, *Cordana*, dan *Pestalotiopsis*. *Dataset* nantinya akan dibagi menjadi 80% data pelatihan (*training*), 10% data validasi (*validation*), dan 10% data pengujian (*testing*). Sampel data yang digunakan dalam penelitian ini sebagai berikut:



Gambar 2. Gambar Sampel dataset daun pisang

3.3. Perancangan Model

Tahapan perancangan sistem dimulai dengan penggunaan *dataset* citra daun pisang dari kelompok *Augmented Set* yang mencakup empat kelas kategori: *Sigatoka*, *Cordana*, *Pestalotiopsis*, dan *Healthy*. Karena *dataset* telah melalui proses augmentasi secara *offline* (seperti *random flip*, *rotation*, dan *zoom*) serta memiliki dimensi standar 224x224 piksel, maka tahap *preprocessing* difokuskan pada normalisasi data. Proses ini dilakukan dengan mengonversi nilai piksel citra dari skala [0, 255] menjadi rentang [0, 1] untuk mempercepat konvergensi model selama pelatihan. Selanjutnya, *dataset* dibagi menjadi tiga bagian proporsional: 80% sebagai data *training*, 10% sebagai data *validation*, dan 10% sebagai data *testing*. Pada tahap inti, pembangunan model dilakukan menggunakan arsitektur MobileNetV3-Large dengan metode *transfer learning*. Model dilatih menggunakan tiga skenario perbandingan algoritma optimasi, yaitu *optimizer* AdamW, *optimizer* Adagrad, dan *optimizer* SGD, untuk menganalisis pengaruhnya terhadap stabilitas model. Setelah pelatihan selesai, dilakukan pengujian menggunakan data *testing* untuk menghitung nilai *accuracy*, *precision*, *recall*, dan *f1-score*.

3.4. Implementasi

Tahap implementasi dilakukan dengan membangun model *convolutional neural network* (CNN) berbasis arsitektur MobileNetV3-Large menggunakan teknik *transfer learning*. Model tersebut dilatih menggunakan data latih yang telah melewati seluruh rangkaian tahap pra-pemrosesan sebelumnya. Dalam proses ini, berbagai parameter pelatihan seperti *learning rate*, *batch size*, dan pemilihan *optimizer* diatur secara spesifik guna memperoleh performa model yang paling optimal dalam mengklasifikasikan penyakit daun pisang.

3.5. Pengujian Dan Evaluasi

Pada tahapan ini, model yang telah dibangun sebelumnya melalui proses pelatihan akan diuji menggunakan data *testing*. Hasil pengujian tersebut digunakan untuk menghitung performa model dalam mengenali dan mengklasifikasikan penyakit pada daun pisang secara akurat. Mengingat penelitian ini merupakan kasus *multiclass classification* dengan distribusi *dataset* yang seimbang (400 citra per kelas), maka evaluasi kinerja menggunakan pendekatan *Macro-Average* untuk mendapatkan nilai rata-rata performa pada setiap kelas secara objektif tanpa bias. Metrik evaluasi yang digunakan meliputi *precision*, *recall*, *accuracy*, dan *f1-score* yang didefinisikan melalui persamaan (5)(6)(7) dan (8).

$$Precision_{Macro} = \frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FP_i} \times 100\% \quad (5)$$

$$Recall_{Macro} = \frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FN_i} \times 100\% \quad (6)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (7)$$


$$F1_{Macro} = \frac{1}{N} \sum_{i=1}^N 2 \times \frac{Precision_i \times Recall_i}{Precision_i + Recall_i} \quad (8)$$

4. HASIL DAN PEMBAHASAN

Pada bagian ini dijelaskan mengenai hasil eksperimen klasifikasi penyakit daun pisang menggunakan arsitektur MobileNetV3-Large dengan perbandingan tiga algoritma optimasi, yaitu AdamW, Adagrad, dan SGD. Pengujian dilakukan untuk menjawab rumusan masalah mengenai stabilitas pelatihan dan efektivitas *optimizer* pada arsitektur *lightweight*.

4.1. Analisis Hasil Pelatihan dan Validasi

Proses pelatihan dilakukan sebanyak 50 *epoch* untuk memantau konvergensi model. Berdasarkan grafik perbandingan pada Gambar 3, terlihat perbedaan karakteristik stabilitas antara ketiga *optimizer* yang diuji.



Gambar 3. Perbandingan Grafik Akurasi dan Loss Validasi

Berdasarkan Gambar 3, *optimizer* AdamW (garis putus-putus biru) menunjukkan kurva akurasi yang terus meningkat secara stabil hingga mencapai nilai mendekati 99% pada *epoch* ke-50. Sebaliknya, *optimizer* SGD dan Adagrad menunjukkan konvergensi yang lebih cepat di awal namun cenderung stagnan pada tingkat akurasi yang lebih rendah dibandingkan AdamW. Dari sisi *loss*, AdamW berhasil meminimalkan nilai *error* secara konsisten, membuktikan efektivitas regulasi *weight decay* yang terpisah dalam menjaga stabilitas pelatihan.

4.2. Hasil Pengujian dan Perbandingan Performa

Setelah model dilatih, dilakukan pengujian menggunakan 160 citra data *testing* yang terbagi seimbang (40 citra per kelas). Hasil evaluasi kinerja dihitung menggunakan pendekatan *Macro-Average* untuk memastikan objektivitas metrik pada setiap kelas. Perbandingan performa ketiga *optimizer* dirangkum dalam Tabel 1.

Tabel 1. Perbandingan Kinerja Optimizer


Optimizer	Accuracy	Precision	Recall	F1-Score
AdamW	99%	99%	99%	99%
SGD	94%	94%	94%	94%
Adagrad	92%	92%	92%	92%

Berdasarkan Tabel 1, dapat dilihat bahwa AdamW memberikan performa tertinggi dengan akurasi 99%, unggul signifikan dibandingkan SGD (94%) dan Adagrad (92%). Hal ini menunjukkan bahwa arsitektur *lightweight* seperti MobileNetV3 sangat optimal jika dikombinasikan dengan *optimizer* yang memiliki kemampuan adaptivitas dan regularisasi modern seperti AdamW.


4.3. Analisis Confusion Matrix

Analisis mendalam terhadap kemampuan model dalam mengklasifikasikan setiap jenis penyakit dilakukan melalui *confusion matrix*. Perbandingan


hasil untuk masing-masing *optimizer* ditunjukkan pada Gambar 4, 5, dan 6.



Gambar 4. Confusion Matrix AdamW



Gambar 5. Confusion Matrix SGD



Gambar 6. Confusion Matrix Adagrad

Berdasarkan Gambar 4, model dengan AdamW mampu mengklasifikasikan kelas *healthy*, *pestalotiopsis*, dan *sigatoka* dengan sempurna (44/44, 37/37, 44/44). Hanya terdapat satu kesalahan pada kelas *cordana*, di mana satu citra salah terdeteksi sebagai *sigatoka*.

Pada Gambar 5 (SGD), kesalahan klasifikasi lebih bervariasi, terutama pada kelas *cordana* yang sering terdeteksi sebagai *pestalotiopsis*. Sementara itu, Gambar 6 (Adagrad) menunjukkan performa terendah, khususnya pada kelas *pestalotiopsis* yang hanya mencapai *recall* 0.81 karena banyaknya citra yang salah diklasifikasikan ke kelas *cordana* dan *healthy*. Hal ini mengindikasikan bahwa Adagrad kurang mampu menangani kemiripan fitur visual antar penyakit pada arsitektur ini dibandingkan AdamW.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian dan pembahasan, dapat disimpulkan bahwa penggunaan *optimizer* AdamW pada arsitektur MobileNetV3-Large memberikan performa paling optimal dalam mengklasifikasikan empat jenis kondisi daun pisang dengan tingkat akurasi mencapai 99%, mengungguli *optimizer* SGD yang mencapai akurasi 94% dan Adagrad sebesar 92%. Hal ini membuktikan bahwa mekanisme pemisahan *weight decay* pada AdamW sangat efektif dalam meningkatkan stabilitas pelatihan dan generalisasi model pada arsitektur *lightweight* untuk mendeteksi fitur visual penyakit daun pisang. Untuk penelitian selanjutnya, disarankan melakukan pengujian model secara langsung pada perangkat *mobile* guna mengukur waktu inferensi (*inference time*) secara riil atau melakukan eksperimen dengan optimasi *hyperparameter* yang lebih luas untuk mengeksplorasi potensi peningkatan akurasi pada *dataset* citra dengan latar belakang yang lebih kompleks di lingkungan perkebunan.

DAFTAR PUSTAKA

- [1] R. Nadia, S. Gurning, S. H. Puarada, and M. Fuadi, "Pemanfaatan Limbah Buah Pisang Menjadi Selai Kulit Pisang sebagai Peningkatan Nilai Guna Pisang," *J. Pengabd. Kpd. Masy.*, vol. 12, no. 1, pp. 106–111, 2021.
- [2] A. Ridhovan, A. Suharso, and C. Rozikin, "Disease Detection in Banana Leaf Plants using DenseNet and Inception Method Andreanov," *Resti*, vol. 1, no. 1, pp. 19–25, 2022.
- [3] S. Samridhi, M. Kalpana, and R. Parimalarangan, "Identification of Sigatoka Leaf Spot Disease in Banana Using Convolutional Neural Network (CNN)," *Asian J. Agric. Extension, Econ. Sociol.*, vol. 41, no. 9, pp. 931–936, 2023, doi: 10.9734/AJAEES/2023/v41i92123.
- [4] M. D. Pratama, R. Gustriansyah, and E. Purnamasari, "KLASIFIKASI PENYAKIT DAUN PISANG MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN)," *J. Teknol. Terpadu*, vol. 10, no. 1, pp. 1–6, 2024.
- [5] F. Riana and D. Primasari, "Diagnosis Penyakit Utama Pisang karena Jamur Patogen dengan Dempster-Shafer," *J. Tek. Inform.*, vol. 7, no. 2, pp. 72–79, 2019.
- [6] R. Ferdianysah, S. T. Arfian, R. Arrizal, and O. Syah, "KLASIFIKASI PENYAKIT DAUN PISANG BERBASIS CNN MENGGUNAKAN MODEL GLOBALAVERAGEPOOLING2D," *Semin. Nas. Amikom Surakarta*, vol. 2, no. 1, pp. 403–417, 2024.
- [7] N. Helmawati and E. Utami, "Analysis for Detecting Banana Leaf Disease Using the CNN Method," *J. Inform.*, vol. 13, no. 1, pp. 29–36, 2025.
- [8] S. Zulaikha, M. Zaki, M. A. Zulkifley, M. M. Stofa, and N. Azwan, "Classification of tomato leaf diseases using MobileNet V2," *Int. J. Artif. Intell.*, vol. 9, no. 2, pp. 290–296, 2020, doi: 10.11591/ijai.v9.i2.pp290-296.
- [9] C. Bi, S. Xu, N. Hu, S. Zhang, Z. Zhu, and H. Yu, "Identification Method of Corn Leaf Disease Based on Improved Mobilenetv3 Model," *Agronomy*, vol. 13, no. 2, pp. 1–17, 2023, doi: <https://doi.org/10.3390/agronomy13020300>.
- [10] Y. Amrozi, D. Yulianti, A. Susilo, N. Novianto, and R. Ramadhan, "Klasifikasi Jenis Buah Pisang Berdasarkan Citra Warna dengan Metode SVM," *SISFOKOM (Sistem Inf. dan Komputer)*, vol. 11, no. 3, pp. 394–399, 2022, doi: doi.org/10.32736/sisfokom.v11i3.1502.
- [11] M. S. Aryanta, C. A. Sari, and E. H. Rachmawanto, "A Banana Disease Detection Using MobileNetV2 Model Based on Adam Optimizer," *J. Appl. Informatics Comput.*, vol. 9, no. 4, pp. 1207–1218, 2025, doi: 10.30871/jaic.v9i4.9870.
- [12] A. R. Dianto, F. T. Anggraeny, and H. Maulana, "ANALISIS EFEKTIFITAS ALGORITMA MOBILENETV3-," *JITET (Jurnal Inform. dan Tek. Elektro Ter.)*, vol. 13, no. 3, 2025.
- [13] I. Kandel and M. Castelli, "Comparative Study of First Order Optimizers for Image Classification Using Convolutional Neural Networks on Histopathology Images," *J. Imaging*, vol. 6, no. 92, pp. 1–17, 2020, doi: doi.org/10.3390/jimaging6090092.
- [14] D. A. Pramudhita, F. Azzahra, I. K. Arfat, R. Magdalena, and S. Saidah, "Strawberry Plant Diseases Classification Using CNN Based on MobileNetV3-Large and EfficientNet-B0 Architecture," *J. Ilm. Tek. Elektro Komput. dan Inform.*, vol. 9, no. 3, pp. 522–534, 2023, doi: 10.26555/jiteki.v9i3.26341.
- [15] L. Alzubaidi et al., "Review of deep learning : concepts , CNN architectures , challenges , applications , future directions," *J. Big Data*, vol. 8, no. 53, 2021, doi: 10.1186/s40537-021-00444-8.
- [16] M. K. Santosa, M. H. P. Swari, and A. N.

- Sihananto, "Implementasi arsitektur alexnet dan resnet 34 pada klasifikasi citra penyakit daun kentang menggunakan transfer learning," *JATI (Jurnal Mhs. Tek. Inform.,* vol. 7, no. 5, pp. 3293–3301, 2023.
- [17] J. Rozaqi, A. Sunyoto, and R. Arief, "Implementasi Transfer Learning pada Algoritma Convolutional Neural Network Untuk Identifikasi Penyakit Daun Kentang Implementation of Transfer Learning in the Convolutional Neural Network Algorithm for Identification of Potato Leaf Disease," *Procedia Eng. Life Sci.,* vol. 1, no. 1, 2021.
- [18] M. Shoaib, A. Sadeghi-Niaraki, F. Ali, I. Hussain, and S. Khalid, "Leveraging deep learning for plant disease and pest detection: a comprehensive review and future directions," *Front. Plant Sci.,* vol. 16, no. 2, pp. 1–19, 2025, doi: 10.3389/fpls.2025.1538163.
- [19] M. Doddy, 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.
- [20] N. S. Mahajaya, P. Desiana, W. Ayu, and R. R. Huizen, "Pengaruh Optimizer Adam , AdamW , SGD , dan LAMB terhadap Model Vision Transformer pada Klasifikasi," *Pros. Semin. Has. Penelit. Inform. dan Komput.,* vol. 1, no. 2, pp. 818–823, 2024.
- [21] S. Venkatesh and D. Jeyakarthic, M, "Adagrad Optimizer with Elephant Herding Optimization based Hyper Parameter Tuned Bidirectional LSTM for Customer Churn Prediction in IoT Enabled Cloud Environment," *Webology,* vol. 17, no. 2, pp. 631–651, 2020, doi: 10.14704/WEB/V17I2/WEB17057.
- [22] G. E. Saputra, A. Faisal, and U. Gunadarma, "Perbandingan Penerapan Algoritma Neural Network Backpropagation Dengan Optimasi," *Semin. Nas. Teknol. Inf. dan Komun.,* vol. 4, no. 1, pp. 1–10, 2020.