

# PENERAPAN ARSITEKTUR EFFICIENTNET-B3 BERBASIS TRANSFER LEARNING UNTUK KLASIFIKASI PENYAKIT DAUN POHON KARET

Ubang<sup>1\*</sup>, Asril Adi Sunarto<sup>2</sup>, Fathia Frazna Az-Zahra<sup>3</sup>

<sup>123</sup>Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Muhammadiyah Sukabumi; Jl. R. Syamsudin, S.H. No. 50, Sukabumi; 0266-218345

## Keywords:

EfficientNet-B3; Klasifikasi Citra; Penyakit Daun Karet; Transfer Learning; CRISP-DM.

## Correspondent Email:

bangezy@ummi.ac.id

**Abstrak.** Sektor perkebunan karet terancam oleh penyakit daun utama (*Oidium*, *Corynespora*, *Colletotrichum*) yang menurunkan produksi lateks. Identifikasi visual manual di lapangan memiliki keterbatasan kecepatan dan bersifat subjektif. Penelitian ini mengimplementasikan model *Deep Learning* arsitektur EfficientNet-B3 dengan *Transfer Learning* untuk klasifikasi penyakit daun karet berdasarkan metodologi CRISP-DM. Dataset terdiri dari 2.972 citra yang terbagi merata dalam empat kelas (Sehat, *Colletotrichum*, *Corynespora*, *Oidium*). Data diproses melalui penyesuaian dimensi 300x300 piksel, normalisasi, dan augmentasi. Hasil pengujian menggunakan *Confusion Matrix* pada 448 citra uji independen menghasilkan tingkat akurasi keseluruhan sebesar 99,11% dengan nilai presisi rata-rata 0,99. Evaluasi kompleksitas menunjukkan model ini sangat ringan dengan waktu inferensi 80,39 ms per citra. Model ini diintegrasikan ke dalam prototipe aplikasi web lokal menggunakan arsitektur hibrida FastAPI dan PHP yang dilengkapi *Hybrid Validation System*. Hasil integrasi ini menghasilkan sistem deteksi penyakit daun karet yang akurat dan efisien untuk lingkungan komputasi terbatas.



Copyright © 2026 The Author(s), Published by Jurnal Informatika dan Teknik Elektro Terapan. This is an open-access article distributed under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0).

**Abstract.** The rubber plantation sector is threatened by major leaf diseases (*Oidium*, *Corynespora*, *Colletotrichum*) which decrease latex production. Manual visual identification in the field has speed limitations and is subjective. This study implements the EfficientNet-B3 Deep Learning architecture with Transfer Learning for rubber leaf disease classification based on the CRISP-DM methodology. The dataset consists of 2,972 images evenly divided into four classes (Healthy, *Colletotrichum*, *Corynespora*, *Oidium*). The data is processed through 300x300 pixel resizing, normalization, and augmentation. Testing using a Confusion Matrix on 448 independent test images yielded an overall accuracy of 99.11% with an average precision value of 0.99. Complexity evaluation shows this model is very lightweight with an inference time of 80.39 ms per image. This model is integrated into a local web application prototype using a hybrid architecture of FastAPI and PHP equipped with a Hybrid Validation System. This integration produces a highly accurate and efficient rubber leaf disease detection system for limited computing environments.

## 1. PENDAHULUAN

Pohon karet (*Hevea brasiliensis*) merupakan komoditas pertanian strategis yang menopang perekonomian nasional Indonesia sebagai salah satu produsen terbesar di dunia[1]. Lateks yang dihasilkan menjadi bahan baku utama bagi berbagai industri manufaktur global, seperti industri otomotif dan alat medis, sehingga memberikan kontribusi signifikan terhadap penyerapan tenaga kerja dan perolehan devisa negara[1], [2]. Oleh karena itu, menjaga stabilitas volume produksi lateks dari berbagai gangguan biotik merupakan prioritas utama untuk menjamin kesejahteraan petani sekaligus mempertahankan daya saing komoditas nasional di pasar internasional [1], [2], [3].

Namun, produktivitas tanaman karet di lapangan terus terancam oleh penyebaran wabah penyakit daun, khususnya embun tepung (*Oidium heveae*), gugur daun *Corynespora* (*Corynespora cassiicola*), dan bercak daun *Colletotrichum* [3]. Patogen-patogen ini menyerang kanopi pohon secara agresif, menyebabkan gejala nekrotik, dan memicu gugurnya daun secara prematur [4]. Kondisi tersebut merusak kapasitas fotosintesis vegetasi secara parah dan menurunkan hasil lateks secara drastis [1]. Dampak fatal ini menjadikan pemantauan penyakit daun sebagai fokus utama layanan pertanian guna mencegah penurunan kualitas lateks secara nasional [5].

Tantangan utama di perkebunan saat ini terletak pada proses identifikasi yang masih mengandalkan inspeksi visual manual oleh petani atau petugas lapangan [6]. Pendekatan konvensional ini sangat tidak efisien, membutuhkan alokasi waktu yang intensif, tenaga fisik yang besar, serta menghasilkan kesimpulan yang sangat subjektif karena bergantung penuh pada tingkat pengalaman pengamat [7], [8]. Akibatnya, gejala infeksi jamur pada tingkat awal sering kali luput dari pandangan manusia, yang berujung pada keterlambatan intervensi manajemen agronomi dan memperkuat urgensi pengembangan sistem otomatisasi identifikasi yang cepat, konsisten, dan objektif [9].

Untuk mengatasi masalah tersebut, teknologi otomatisasi berbasis *Convolutional Neural Networks* (CNN) dalam ranah *deep learning* berkembang pesat [10], [11]. Di

antara berbagai arsitektur yang ada, arsitektur EfficientNet unggul karena memiliki mekanisme *compound scaling* yang mampu menyeimbangkan kedalaman, lebar, dan resolusi jaringan secara efisien[9]. Meskipun telah terbukti andal dalam mengklasifikasikan penyakit pada komoditas lain seperti padi [12] dan singkong [13], [14], variasi optimasi arsitektur EfficientNet-B3 menggunakan metode *transfer learning* [15], [16] belum dieksplorasi secara luas untuk kasus penyakit daun karet di lingkungan komputasi *edge* yang memiliki keterbatasan sumber daya.

Selain itu, tren integrasi model *deep learning* ke dalam arsitektur berbasis *web* untuk otomatisasi komoditas lokal telah sukses didemonstrasikan di lingkungan Universitas Muhammadiyah Sukabumi. Riset terdahulu berhasil menggunakan algoritma YOLOv8s untuk mengotomatiskan deteksi tingkat kematangan buah manggis lokal [17]. Hal ini membuktikan bahwa penerapan model cerdas berbasis visi melalui arsitektur *web* lokal mampu menjembatani jarak antara kompleksitas komputasi model dengan kebutuhan praktis.

Penelitian ini dirancang untuk mengisi celah tersebut dengan membangun model klasifikasi penyakit daun karet yang akurat dan ringan menggunakan arsitektur EfficientNet-B3 [9], [12]. Signifikansi riset ini diperkuat oleh implementasi dunia nyata, di mana model diintegrasikan ke dalam prototipe aplikasi *web* menggunakan FastAPI dan Laravel PHP yang diperkuat oleh mekanisme *Hybrid Validation System* [18]. Secara praktis, penerapan sistem ini mampu menyediakan solusi deteksi objektif secara *real-time* yang diproyeksikan dapat menekan risiko kehilangan hasil panen melalui intervensi agronomi yang cepat dan tepat sasaran [2].

## 2. TINJAUAN PUSTAKA

### 2.1 Penyakit Pada Daun Pohon Karet

Pohon karet merupakan komoditas utama yang rentan terhadap penurunan produktivitas akibat penyakit daun. Terdapat tiga jenis penyakit utama yang menjadi fokus identifikasi pada daun karet:

1. Embun Tepung (*Oidium heveae*): Ditandai dengan lapisan bercak berwarna putih keabu-abuan seperti

bedak pada permukaan daun, yang menyebabkan daun terlihat kusam dan mengalami penurunan kerapatan hijau [19].

2. *Colletotrichum*: Menunjukkan gejala klinis berupa bercak cokelat kehitaman dengan bentuk tidak beraturan yang menyebar mengikuti pola tulang daun, disertai klorosis (menguningnya daun) di area sekitar bercak[1].
3. Gugur Daun (*Corynespora cassiicola*): Memiliki pola visual khas berupa bercak kecil berbentuk bulat atau oval dengan pusat berwarna gelap dan tepi kekuningan. Pada tingkat infeksi parah, penyakit ini memicu daun gugur lebih dini[2].

## 2.2. Klasifikasi dan *Transfer Learning*

Klasifikasi citra adalah proses identifikasi dan pengelompokan data visual ke dalam kategori tertentu berdasarkan pola fitur yang diekstraksi. Untuk mengatasi tantangan keterbatasan jumlah dataset pada domain pertanian, metode *Transfer Learning* menjadi solusi yang efektif. Pendekatan ini memanfaatkan sebuah model yang telah dilatih secara matang pada dataset berskala masif (seperti *ImageNet*) sebagai ekstraktor fitur generik. Lapisan awal model akan dipertahankan, sementara lapisan klasifikasi akhirnya dilatih ulang menggunakan dataset spesifik, sehingga proses pembelajaran menjadi jauh lebih cepat dan akurat [15].

## 2.3. *Deep Learning* dan CNN

*Deep Learning* merupakan cabang dari *Machine Learning* yang menggunakan jaringan saraf tiruan berlapis (*deep neural networks*) untuk memproses data secara hierarkis. Untuk data berwujud citra, *Convolutional Neural Network* (CNN) adalah metode yang paling optimal. CNN bekerja dengan menggunakan lapisan konvolusi untuk memindai dan mengekstrak fitur lokal (seperti tepi, tekstur, dan warna lesi daun), dipadukan dengan fungsi aktivasi, dan lapisan *pooling* untuk mereduksi dimensi data sebelum diklasifikasikan [20].


## 2.4. EfficientNet-B3

EfficientNet adalah keluarga arsitektur CNN tingkat lanjut yang dikembangkan

dengan mengusung metode *compound scaling*. Berbeda dengan model pendahulunya, metode ini melakukan penskalaan terhadap kedalaman (*depth*), lebar (*width*), dan resolusi (*resolution*) jaringan secara bersamaan dan seimbang [10]. Varian EfficientNet-B3 secara khusus diaplikasikan dalam penelitian ini karena varian ini dirancang untuk memberikan titik keseimbangan (*trade-off*) yang paling optimal antara tingginya nilai akurasi dan efisiensi komputasi parameter. Hal ini menjadikannya sangat relevan dan ideal untuk diimplementasikan pada ekosistem berdaya komputasi terbatas (*edge computing*) di area perkebunan [21].

## 3. METODE PENELITIAN

Penelitian ini dilaksanakan menggunakan kerangka kerja *Cross-Industry Standard Process for Data Mining* (CRISP-DM) yang sistematis dan iteratif. Tahapan penelitian meliputi pemahaman masalah, pengumpulan dan pemahaman data, persiapan data, pemodelan komputasi, evaluasi kinerja, hingga tahap penyebaran (*deployment*) ke dalam bentuk prototipe sistem.



Gambar 1. Alur Tahapan Metode CRISP-DM

### 3.1. Business Understanding

Merumuskan masalah identifikasi manual penyakit daun pohon karet yang subjektif, serta menetapkan tujuan untuk membangun sistem klasifikasi otomatis yang ringan dan akurat menggunakan arsitektur *Deep Learning* EfficientNet-B3 untuk lingkungan komputasi terbatas.

### 3.2 Data Understanding

Mengakuisisi dataset hibrida berkapasitas 2.972 citra, yang terdiri dari 60 citra primer dari observasi lapangan (Daerah Perkebunan warungkiara) dan 2.912 citra sekunder dari *Roboflow Universe*. Citra dikategorikan ke dalam empat kelas target: Sehat, *Colletotrichum*, *Corynespora*, dan *Oidium*.

Tabel 1. Komposisi Sumber Data Penelitian

| Sumber Data                             | Jumlah Citra | Persentase |
|-----------------------------------------|--------------|------------|
| Observasi Lapangan (Mandiri)            | 60           | 2,02%      |
| Roboflow ( <i>Rubber Leaf Dataset</i> ) | 2912         | 97,98%     |
| Total Dataset                           | 2972         | 100%       |


### 3.3 Data Preparation

Memproses citra melalui penyeragaman dimensi ke resolusi  $300 \times 300$  piksel, normalisasi intensitas piksel, dan augmentasi data dinamis (rotasi  $20^\circ$ , perbesaran 20%, dan *horizontal flip*). Data diseimbangkan secara algoritmik menjadi 743 citra per kelas, lalu dipartisi menggunakan *stratified sampling* dengan rasio 70% data latih, 15% data validasi, dan 15% data uji.

Tabel 2. Rincian Pembagian Dataset


| Dataset    | Healthy | Oidium | Colletotrichum | Corynespora | Total |
|------------|---------|--------|----------------|-------------|-------|
| Training   | 520     | 520    | 520            | 520         | 2080  |
| Validation | 111     | 111    | 111            | 111         | 444   |
| Testing    | 112     | 112    | 112            | 112         | 448   |
| Total      | 743     | 743    | 743            | 743         | 2972  |

Citra asli yang diakuisisi memiliki dimensi spasial yang bervariasi. Oleh karena itu, dilakukan proses *resizing* menggunakan metode interpolasi *inter-area* untuk mengubah dimensi seluruh citra menjadi  $300 \times 300$  piksel.



Gambar 2. Contoh Citra Sebelum dan Sesudah Preprocessing

Normalisasi dilakukan untuk mengubah rentang nilai intensitas piksel. Pada format citra digital standar (RGB), setiap piksel memiliki nilai integer antara 0 hingga 255.




Gambar 3. Hasil normalisasi citra

Setelah *di-resize*, dilakukan proses augmentasi data untuk memperkaya variasi dataset dan mencegah *overfitting*.



Gambar 4. Visualisasi Hasil Augmentasi Data

Mengingat data mentah seringkali memiliki jumlah yang tidak merata, penelitian ini menerapkan penyeimbangan kelas secara manual. Peneliti menetapkan jumlah tetap, yaitu 743 citra untuk setiap kelas, sehingga total dataset berjumlah 2972 citra. Langkah ini krusial untuk mencegah model menjadi bias.



Gambar 5. Distribusi Data Penelitian per Kelas

### 3.4 Modelling

Mengimplementasikan *Transfer Learning* dengan membekukan bobot dasar pengekstraksi fitur ImageNet pada EfficientNet-B3. Penyesuaian dilakukan pada lapisan puncak dengan menambahkan *Global Average Pooling 2D*, regularisasi *Dropout* 50%, dan *Dense Layer* berkapasitas 4 neuron dengan fungsi aktivasi *Softmax*. Model dikompilasi menggunakan optimasi *Adam* (laju pembelajaran 0,0001), fungsi kerugian *Categorical Cross-Entropy*, dan mekanisme

*Early Stopping* dengan batas maksimal 25 *epoch*

### 3.5 Evaluation

Mengukur kinerja model komputasi secara independen terhadap 448 data uji menggunakan *Confusion Matrix* untuk mendapatkan nilai Akurasi, Presisi, *Recall*, dan *F1-Score*, serta mengevaluasi efisiensi parameter komputasi dan waktu inferensi sistem.

- Akurasi (*Accuracy*) mengukur rasio prediksi benar terhadap keseluruhan data uji:

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

- Presisi (*Precision*) mengukur ketepatan prediksi kelas positif:

$$Presisi = \frac{TP}{TP+FP} \quad (2)$$

- Recall* mengukur proporsi data positif aktual yang berhasil dideteksi:

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

- F1-Score* merupakan nilai rata-rata harmonik antara Presisi dan *Recall*:

$$F1 - Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} \quad (4)$$

### 3.6 Deployment

Mengintegrasikan model terbaik (berformat .h5) ke dalam prototipe aplikasi *web* lokal berbasis *FastAPI* dan PHP. Sistem ini diperkuat dengan *Hybrid Validation System* yang memadukan filter komponen warna hijau daun (minimal 15%) dan ambang batas keyakinan model (minimal 65%) untuk menyaring input objek non-daun karet.


## 4. HASIL DAN PEMBAHASAN

Pada penelitian ini, model *Deep Learning* arsitektur EfficientNet-B3 dievaluasi secara komprehensif. Pembahasan mencakup proses pelatihan model (*training*), evaluasi pengujian (*testing*) menggunakan instrumen *Confusion Matrix*, analisis efisiensi komputasi, serta pengujian operasional pada prototipe sistem berbasis *web*.

### 4.1. Hasil Pelatihan Model

Proses pelatihan model dieksekusi dengan batasan maksimal 25 *epoch*. Untuk

mengoptimalkan konvergensi dan menghindari *overfitting*, diterapkan mekanisme *Early Stopping* yang dipantau melalui nilai *validation loss*. Pemantauan stabilitas metrik selama fase pelatihan dan validasi dapat dilihat pada Gambar 6.




Gambar 6. Grafik metrik hasil pelatihan model (Akurasi dan *Loss*)

Berdasarkan grafik pada Gambar diatas, pergerakan kurva akurasi pelatihan dan validasi menunjukkan kenaikan yang stabil dan berhimpitan. Model berhasil mencapai titik optimal (best weights) pada epoch ke-19, dengan raihan akurasi validasi tertinggi sebesar 99,55% dan validation loss menyentuh titik terendah sebesar 0,0332. Tidak adanya jarak (gap) yang signifikan antara kurva data latih dan validasi mengonfirmasi bahwa penerapan lapisan Dropout 50% dan mekanisme augmentasi data yang seimbang (743 citra per kelas) terbukti efektif menjaga model dari gejala *overfitting* (menghafal data) maupun *underfitting* (gagal mempelajari pola).

### 4.2. Evaluasi Kinerja Klasifikasi (*Testing*)

Kinerja model yang telah dilatih kemudian diuji secara independen menggunakan *test set* sebanyak 448 citra (112 citra per kelas target) yang belum pernah dikenali oleh jaringan sebelumnya. Evaluasi ini diukur menggunakan *Confusion Matrix* yang divisualisasikan pada Gambar 7.



Gambar 7. Grafik *Confusion Matrix* Pengujian Model EfficientNet-B3

Dari hasil pemetaan matriks pada Gambar 7, model berhasil memprediksi 444 citra dengan tepat dari total 448 data uji. Kesalahan prediksi (misklasifikasi) berjangkauan sangat minor, yakni hanya terjadi pada 4 citra:

1. Pada kelas Sehat (*Healthy*), dari 112 citra, terdapat 2 citra yang keliru diprediksi: 1 citra dikenali sebagai *Corynespora* dan 1 citra dikenali sebagai *Oidium*.
2. Pada kelas *Oidium*, dari 112 citra, terdapat 2 citra yang keliru diprediksi sebagai kelas Sehat (*Healthy*).
3. Kelas *Colletotrichum* dan *Corynespora* masing-masing mencatatkan akurasi deteksi sempurna (112 dari 112 citra berhasil dikenali).

Terjadinya kekeliruan prediksi pada kelas *Healthy* dan *Oidium* memiliki landasan morfologis visual yang jelas. Gejala awal infeksi jamur *Oidium* (embun tepung) ditandai dengan lapisan putih keabu-abuan tipis yang menyerupai serbuk. Fitur visual ini memiliki tingkat kemiripan tekstur yang tinggi dengan pantulan cahaya lokal (*glare*) atau endapan debu alami pada permukaan daun sehat. Filter konvolusi CNN dalam beberapa kasus menginterpretasikan gradasi kontras dari pantulan cahaya tersebut sebagai fitur lesi jamur, sehingga memicu terjadinya *False Positive* dan *False Negative*.

Berdasarkan *Confusion Matrix* di atas, kalkulasi evaluasi performa (Akurasi, Presisi, *Recall*, dan *F1-Score*) dirangkum pada Tabel 3.

Tabel 3. Hasil Evaluasi Performa Klasifikasi Model EfficientNet-B3

| Kelas Citra     | Precision | Recall | F1-Score | Support |
|-----------------|-----------|--------|----------|---------|
| Colletotrichum  | 1.00      | 1.00   | 1.00     | 112     |
| Corynespora     | 0.99      | 1.00   | 1.00     | 112     |
| Healthy (Sehat) | 0.98      | 0.98   | 0.98     | 112     |
| Oidium          | 0.99      | 0.98   | 0.99     | 112     |
| Rata-rata       | 0.99      | 0.99   | 0.99     | 448     |

Tabel 3 menunjukkan bahwa pendekatan *Transfer Learning* berbasis *ImageNet* menghasilkan Akurasi Keseluruhan (*Overall Accuracy*) yang sangat tinggi, yaitu 99,11% dengan *F1-Score* rata-rata 0,99. Kinerja ini

sangat kompetitif dan terbukti melampaui performa studi sejenis di sektor pertanian. Sebagai perbandingan, penggunaan varian arsitektur yang lebih kompleks yakni EfficientNet-B6 pada klasifikasi penyakit daun padi mencatatkan akurasi sebesar 77,05% [22]. Fakta ini menegaskan bahwa penggunaan varian kelas menengah (B3), apabila didukung dengan prapemrosesan dan keseimbangan kelas yang ketat, mampu memberikan hasil klasifikasi yang sangat superior.

#### 4.3. Analisis Efisiensi Komputasi

Akurasi yang tinggi harus diimbangi dengan efisiensi komputasi agar sistem dapat beroperasi pada infrastruktur perangkat keras perkebunan yang umumnya terbatas (*edge computing*). Hasil pengujian konsumsi sumber daya disajikan pada Tabel 4.

Tabel 4. Pengujian Efisiensi Komputasi dan Sumber Daya


| Parameter Pengujian                     | Spesifikasi / Nilai        |
|-----------------------------------------|----------------------------|
| Total Parameter Model                   | 10.789.685 (41,16 MB)      |
| Parameter Dilatih ( <i>Trainable</i> )  | 6.148 parameter (24,02 KB) |
| Parameter Beku ( <i>Non-trainable</i> ) | 10.783.535 (41,14 MB)      |
| Rata-rata Waktu Inferensi               | 80,39 ms / citra           |
| Penggunaan RAM Sistem                   | ~1,77 GB                   |

Berdasarkan Tabel 4, strategi pembekuan (*freezing*) lapisan ekstraksi fitur utama secara terstruktur berhasil menekan beban pemrosesan algoritmik secara drastis. Model hanya memutakhirkan 6.148 parameter pada lapisan puncak (setara dengan 24,02 KB pemrosesan aktif). Skema ini memungkinkan model memproses satu citra daun (waktu inferensi) hanya dalam waktu rata-rata 80,39 milidetik dengan serapan RAM sistem yang stabil di angka 1,77 GB. Parameter ini mengonfirmasi kelayakan operasional sistem untuk berjalan cepat dan ringan tanpa memerlukan perangkat peladen bertenaga komputasi tinggi.

#### 4.4. Implementasi Prototipe Sistem

Sebagai tahap akhir pengujian operasional (*deployment*), model komputasi berformat ekstensi .h5 diintegrasikan ke dalam antarmuka aplikasi *web* fungsional. Sistem ini dibangun dengan arsitektur hibrida menggunakan *backend* layanan *Application*

*Programming Interface (API) Python FastAPI dan frontend antarmuka PHP yang berjalan di atas server lokal Laragon.*



Gambar 8. Respons dinamis sistem berbasis *Hybrid Validation System*

Gambar 8 mengilustrasikan ketahanan skenario sistem terhadap anomali data masukan. Untuk memastikan diagnosis tidak terganggu oleh citra non-objek (seperti gambar manusia atau benda mati), prototipe ini diperkuat dengan *Hybrid Validation System*. Mekanisme ini bekerja secara berlapis:

1. Lapis Pertama (Filter Komponen Klorofil), Sistem memindai rentang warna hijau menggunakan pustaka *Pillow*. Jika representasi warna hijau alami (*klorofil*) berada di bawah persentase ambang batas mutlak 15%, objek ditolak pada tahap awal pemrosesan sebelum mencapai model CNN.

2. Lapis Kedua (Ambang Batas Keyakinan), Jika gambar dikonfirmasi sebagai struktur dedaunan, citra diklasifikasikan oleh *EfficientNet-B3*. Keluaran *Softmax* harus memenuhi *confidence score* minimal 65%.

Objek yang gagal memenuhi salah satu parameter validasi ini akan memicu intersep data secara dinamis berbasis struktur JSON, yang kemudian diterjemahkan oleh PHP menjadi kotak peringatan error visual berwarna merah secara *real-time*. Hasil ini membuktikan bahwa prototipe yang dikembangkan tidak hanya presisi secara diagnostik, melainkan memiliki adaptabilitas dan keamanan pemrosesan (*robustness*) yang memadai di lingkungan operasional terbuka.

## 5. KESIMPULAN

Berdasarkan hasil pengujian dan analisis terhadap sistem klasifikasi penyakit daun pohon karet yang telah dikembangkan, dapat ditarik beberapa kesimpulan utama sebagai berikut:

- a. Hasil yang Diperoleh

Implementasi arsitektur *Deep Learning EfficientNet-B3* berbasis *Transfer Learning* terbukti sangat akurat dalam mengklasifikasikan citra daun karet ke dalam empat kondisi (Sehat, *Colletotrichum*, *Corynespora*, dan *Oidium*). Model berhasil mencapai tingkat Akurasi Keseluruhan (*Overall Accuracy*) sebesar 99,11% dan *F1-Score* rata-rata 0,99 pada 448 data uji independen.

- b. Kelebihan Sistem

Model komputasi yang dihasilkan sangat efisien dan ringan. Dengan hanya melatih 6.148 parameter aktif pada lapisan kustom, waktu inferensi sistem hanya membutuhkan 80,39 milidetik per citra. Selain itu, integrasi *Hybrid Validation System* (memadukan filter komponen warna hijau 15% dan ambang batas keyakinan 65%) pada prototipe *web* lokal memberikan ketahanan sistem yang luar biasa dalam menyaring objek non-daun secara otomatis.

- c. Kekurangan Sistem

Keterbatasan dari penelitian ini adalah masih terdapatnya sensitivitas model terhadap pantulan cahaya lokal (*glare*) atau debu pada permukaan daun sehat. Kondisi pencahayaan ekstrem ini memiliki kemiripan tekstur visual dengan penyakit *Oidium* (embun tepung), yang dapat memicu misklasifikasi pada skala yang sangat minor.

#### d. Pengembangan Selanjutnya

Untuk menyempurnakan penelitian di masa mendatang, disarankan untuk memperluas variabilitas dataset dengan citra pada berbagai kondisi cuaca dan pencahayaan ekstrem di lapangan. Selain itu, perlu dieksplorasi optimasi ekstensi bobot model ke format yang lebih ringkas (seperti TensorFlow Lite atau ONNX) guna mendukung penerapan sistem pada infrastruktur *edge computing* nirkabel secara luas di perkebunan.

### UCAPAN TERIMA KASIH

Ucapan terima kasih saya sampaikan kepada Tuhan Yang Maha Esa, Orang tua, teman-teman dan bapak ibu dosen yang telah mendukung serta membantu dalam menyelesaikan penelitian ini. Serta kepada Program Studi Teknik Informatika Universitas Muhammadiyah Sukabumi dan pengelola Perkebunan Karet Warungkiara sebagai mitra program riset ini

### DAFTAR PUSTAKA

- [1] S. Sagaff, S. Aliya, N. S. Ali, M. M. Mahyudin, W. Mui, and S. Buloh, "Emerging and Existing Major Leaf Diseases of *Hevea brasiliensis* in Malaysia 2 Integrated Pest and Disease Management Unit Experimental Station, Malaysian Rubber Board," vol. 3, no. 1, pp. 34–47, 2022.
- [2] T. R. Febbiyanti and R. Tistama, "Physiological Conditions and Production of Rubber Plant Affected by Pestalotiopsis with Fertilizer and Fungicide Application," *J. Penelit. Karet*, vol. 39, no. 2, pp. 139–150, 2021.
- [3] A. I. C. Nyaka Ngobisa, M. A. Zainal Abidin, M. Y. Wong, and M. W. D. Wan Noordin, "Neofusicoccum ribis associated with leaf blight on rubber (*Hevea brasiliensis*) in Peninsular Malaysia," *Plant Pathol. J.*, vol. 29, no. 1, pp. 10–16, 2023, doi: 10.5423/PPJ.OA.07.2012.0110.
- [4] J. Menezes, A. Aasaithambi, D. Sam, G. Maheswari, and R. Santhosh, "Plant Leaf Disease Detection Using Deep Learning," *Proc. Int. Conf. Sustain. Comput. Integr. Commun. Chang. Landsc. AI, ICSCAI 2024*, pp. 1–24, 2024, doi: 10.1109/ICSCAI61790.2024.10867022.
- [5] S. F. N. Nur Azizah and R. Fikri, "Analisis Perbandingan ALBERT, BERT, dan IndoBERT untuk Deteksi Ujaran Kebencian," *J. Pengolah. Bhs. Alami*, vol. 4, no. 1, pp. 50–58, 2023.
- [6] J. Lu, L. Tan, and H. Jiang, "Review on convolutional neural network (CNN) applied to plant leaf disease classification," *Agric.*, vol. 11, no. 8, pp. 1–18, 2021, doi: 10.3390/agriculture11080707.
- [7] A. Asrafil, A. Paliwang, M. R. D. Septian, M. Cahyanti, and R. Swedia, "Klasifikasi Penyakit Tanaman Apel Dari Citra Daun Dengan," *Sebatik*, no. 1410–3737, pp. 207–212, 2020.
- [8] S. M. Hassan, A. K. Maji, M. Jasiński, Z. Leonowicz, and E. Jasińska, "Identification of Plant-Leaf Diseases Using CNN and Transfer-Learning Approach," *Electron.*, vol. 10, no. 12, p. 1388, 2021.
- [9] Ü. Atila, M. Uçar, K. Akyol, and E. Uçar, "Plant leaf disease classification using EfficientNet deep learning model," *Ecol. Inform.*, vol. 61, p. 101182, 2021, doi: <https://doi.org/10.1016/j.ecoinf.2020.101182>.
- [10] S. S. Dash, S. K. Nayak, and D. Mishra, "A review on machine learning algorithms," *Smart Innov. Syst. Technol.*, vol. 153, pp. 495–507, 2021, doi: 10.1007/978-981-15-6202-0\_51.
- [11] Y. Lecun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2021, doi: 10.1038/nature14539.
- [12] E. Anggiratih, S. Siswanti, S. K. Octaviani, and A. Sari, "Klasifikasi Penyakit Tanaman Padi Menggunakan Model Deep Learning Efficientnet B3 dengan Transfer Learning," *J. Ilm. SINUS*, vol. 19, no. 1, p. 75, 2021, doi: 10.30646/sinus.v19i1.526.
- [13] M. Liu, H. Liang, and M. Hou, "Research on cassava disease classification using the multi-scale fusion model based on EfficientNet and attention mechanism," *Front. Plant Sci.*, vol. 13, no. December, pp. 1–11, 2022, doi: 10.3389/fpls.2022.1088531.
- [14] S. O. Ngesthi and L. A. Wulandhari, "Cassava Diseases Classification using EfficientNet Model with Imbalance Data Handling," *J. Online Inform.*, vol. 9, no. 2, pp. 148–158,

- 2024, doi: 10.15575/join.v9i2.1300.
- [15] M. Iman, H. R. Arabnia, and K. Rasheed, "A Review of Deep Transfer Learning and Recent Advancements," *Technologies*, vol. 11, no. 2, 2023, doi: 10.3390/technologies11020040.
  - [16] T. Kattenborn, J. Leitloff, F. Schiefer, and S. Hinz, "Cnn5.Pdf," vol. 173, no. November 2020, pp. 24–49, 2021.
  - [17] R. Akyas Hifdzi Rahman, A. Adi Sunarto, and A. Asriyanik, "Penerapan You Only Look Once (Yolo) V8 Untuk Deteksi Tingkat Kematangan Buah Manggis," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 5, pp. 10566–10571, 2024, doi: 10.36040/jati.v8i5.10979.
  - [18] G. Mahalaxmi, A. D. Donald, and T. A. S. Srinivas, "A Short Review of Python Libraries and Data Science Tools," *South Asian Res. J. Eng. Technol.*, vol. 5, no. 1, pp. 1–5, 2023, doi: 10.36346/sarjet.2023.v05i01.001.
  - [19] O. E. Oghama, V. I. Omorusi, and E. S. Osazuwa, "Selected Leaf Diseases of Rubber: Symptoms and Control – A Review," *J. Appl. Sci. Environ. Manag.*, vol. 27, no. 11, pp. 2369–2373, 2023, doi: 10.4314/jasem.v27i11.1.
  - [20] B. Tugrul, E. Elfatimi, and R. Eryigit, "Convolutional Neural Networks in Detection of Plant Leaf Diseases: A Review," *Agric.*, vol. 12, no. 8, 2022, doi: 10.3390/agriculture12081192.
  - [21] A. Wongpanich *et al.*, "Training EfficientNets at Supercomputer Scale: 83% ImageNet Top-1 Accuracy in One Hour," *2021 IEEE Int. Parallel Distrib. Process. Symp. Work. IPDPSW 2021 - conjunction with IEEE IPDPS 2021*, pp. 947–950, 2021, doi: 10.1109/IPDPSW52791.2021.00146.
  - [22] A. C. Milano, "Klasifikasi Penyakit Daun Padi Menggunakan Model Deep Learning Efficientnet-B6," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 1, 2024, doi: 10.23960/jitet.v12i1.3855.