



ISSN : 2339 - 1871

BETRIK

BESEMAH TEKNOLOGI INFORMASI & KOMPUTER

Editor Office : Pusat Penelitian & Pengabdian Pada Masyarakat
(PPPM) ITPA

Phone : 0857-9716-9578

email : betriktpa@itpa.ac.id

Optimasi Model *Deep Learning EfficientNet* Berbasis Citra Digital Untuk Deteksi Penyakit Padi

Nurmaleni¹, Alfis Arif²

Teknik Informatika, Institut Teknologi Pagar Alam, Kota Pagar Alam, Indonesia^{1,2}

Sur-el : * lenipga@gmail.com¹, alfisarif@yahoo.com²

Penulis Korespondensi: Nurmaleni, lenipga@gmail.com

Abstrak: Penelitian ini mengoptimalkan model *deep learning EfficientNet* berbasis citra digital untuk deteksi penyakit padi, dengan fokus pada dua kelas utama: *Brown Spot* dan *Leaf Scald* yang menjadi kendala produktivitas petani di Kota Pagar Alam. Dataset terdiri dari 780 citra (476 *Brown Spot*, 304 *Leaf Scald*) yang diproses melalui *resizing* 224×224, normalisasi, pembersihan data, serta augmentasi (rotasi, flip, *shear*, *shift*, zoom) guna meningkatkan generalisasi dan mengurangi *overfitting*. Model diinisialisasi dengan transfer learning dari *ImageNet*, dilatih dan di-*fine-tune* pada lapisan akhir, lalu dievaluasi menggunakan metrik akurasi, *presisi*, *recall*, dan *F1-score*. *EfficientNet B0* menunjukkan akurasi pelatihan tinggi hingga 95% dengan akurasi validasi sekitar 80%, mengindikasikan kinerja deteksi yang baik meski masih terdapat gejala *overfitting* yang perlu dioptimalkan lebih lanjut. Model kemudian diintegrasikan ke sistem pakar berbasis *web* untuk diagnosis otomatis dari citra daun dan penyajian rekomendasi penanganan berbasis basis pengetahuan, sehingga mempercepat identifikasi dini dan mendukung pengambilan keputusan di lapangan. Hasil ini menegaskan potensi *EfficientNet* sebagai fondasi sistem diagnosis penyakit padi yang praktis, akurat, dan aplikatif bagi pertanian lokal.

Kata kunci : *EfficientNet*, deteksi penyakit padi, pengolahan citra, *deep learning*, sistem pakar.

Abstract This study optimized the *EfficientNet deep learning* model based on digital images for rice disease detection, focusing on two main classes: *Brown Spot* and *Leaf Scald*, which are constraints to farmer productivity in Pagar Alam City. The dataset consisted of 780 images (476 *Brown Spot*, 304 *Leaf Scald*) processed through 224×224 *resizing*, normalization, data cleaning, and augmentation (rotation, flip, *shear*, *shift*, zoom) to improve generalization and reduce *overfitting*. The model was initialized with transfer learning from *ImageNet*, trained and fine-tuned at the final layer, and then evaluated using accuracy, precision, recall, and *F1-score* metrics. *EfficientNet B0* showed a high training accuracy of up to 95% with a validation accuracy of around 80%, indicating good detection performance although there are still symptoms of *overfitting* that need further optimization. The model was then integrated into a web-based expert system for automatic diagnosis from leaf images and presentation of knowledge-based treatment recommendations, thereby accelerating early identification and supporting decision-making in the field. These results confirm *EfficientNet's* potential as the foundation for a practical, accurate, and applicable rice disease diagnosis system for local agriculture.

Keywords: *EfficientNet*, Rice Disease Detection, Image Processing, Deep Learning, Expert System

Received: 11-11-2025 | Accepted: 09-12-2025 | Published Online: 30-12-2025

All author: Nurmaleni, Alfis Arif

1. PENDAHULUAN

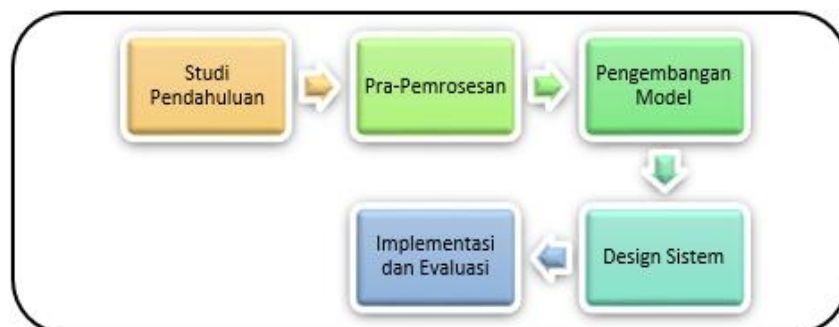
Padi (*Oryza sativa*) merupakan komoditas pertanian strategis yang menjadi makanan pokok sebagian besar masyarakat Indonesia. Khususnya di Kota Pagar Alam, sektor pertanian termasuk budidaya padi menjadi salah satu penopang utama perekonomian lokal sehingga perlu ditingkatkan hasil produksi padi [1]. Namun, produktivitas tanaman padi sering kali terhambat oleh berbagai gangguan biotik, terutama serangan penyakit seperti *blast* (*Pyricularia oryzae*), bercak daun coklat (*Cochliobolus miyabeanus*), dan hawar daun bakteri (*Xanthomonas oryzae*) yang dapat menyebabkan penurunan hasil panen secara signifikan [2]. Di sisi lain, kemampuan petani dalam mendeteksi penyakit secara dini masih sangat terbatas.

Hal ini disebabkan oleh minimnya akses terhadap tenaga ahli dan metode diagnosis yang akurat di lapangan. Banyak petani masih mengandalkan pengamatan visual dengan pengalaman terbatas, yang kerap kali berujung pada kesalahan identifikasi [3]. Keadaan ini diperburuk oleh kurangnya penerapan teknologi informasi dan komunikasi dalam mendukung proses pengambilan keputusan di bidang pertanian. Dalam beberapa tahun terakhir, perkembangan teknologi kecerdasan buatan (*Artificial Intelligence*) dan pengolahan citra digital telah membuka peluang baru dalam dunia pertanian presisi. Salah satu pendekatan yang menjanjikan adalah pemanfaatan *deep learning* khususnya model *Convolutional Neural Network* (CNN) *EfficientNet* yang telah terbukti mampu melakukan klasifikasi citra secara akurat dengan efisiensi tinggi [4]. Model ini memungkinkan sistem untuk mengenali gejala penyakit tanaman dari citra daun secara otomatis, cepat, dan konsisten. Namun, penerapan model *Convolutional Neural Network* (CNN) *EfficientNet* dalam konteks pertanian lokal khususnya di Kota Pagar Alam masih belum banyak diteliti.

Oleh karena itu, penelitian ini penting untuk mengoptimalkan model *Convolutional Neural Network* (CNN) *EfficientNet* pada sistem pakar berbasis citra digital guna mendeteksi dan mendiagnosis penyakit padi secara otomatis. Hasil dari penelitian ini diharapkan dapat menjadi solusi inovatif bagi petani dalam mengidentifikasi penyakit secara dini, meningkatkan produktivitas, dan mendukung ketahanan pangan di tingkat lokal Kota Pagar Alam

2. METODOLOGI PENELITIAN

Metode penelitian ini dilakukan dengan melalui 5 tahapan yaitu studi pendahuluan, pra-pemrosesan, pengembangan model, design sistem, implementasi dan evaluasi seperti pada gambar dibawah ini :



Gambar 1. Tahap Penelitian

Berdasarkan tahapan penelitian diatas maka peneliti melakukan penelitian dengan tahapan sebagai berikut :

2.1 Studi Pendahuluan

Pada tahapan ini data dikumpulkan melalui beberapa metode yaitu:

- a) Studi pustaka [5] untuk memperoleh pemahaman dan informasi dari berbagai sumber seperti jurnal dan buku yang relevan dengan topik atau permasalahan yang serupa dengan penelitian ini.
- b) Observasi dan wawancara [6] di mana peneliti melakukan pengamatan langsung dan berdiskusi dengan pihak terkait di Dinas Pertanian Kota Pagar Alam guna mengidentifikasi dan memahami permasalahan yang berkaitan dengan penyakit tanaman padi di masyarakat.

Dataset yang digunakan dalam penelitian ini adalah

Tabel 1. Dataset

No	Jenis Penyakit
1	Daun Melepuh
2	Bercak Daun Coklat




Gambar 2. Daun Melepuh



Gambar 3. Bercak Daun Coklat

2.2 Pra-Pemrosesan

Pra-pemrosesan citra merupakan tahap penting dalam sistem klasifikasi berbasis citra digital karena menentukan kualitas data yang digunakan dalam pelatihan model deep learning. Pada penelitian ini proses pra-pemrosesan diawali dengan image resizing yaitu menyesuaikan ukuran semua citra ke dalam resolusi 224x224 piksel agar sesuai dengan input standar model EfficientNet [4]. Selanjutnya, dilakukan normalisasi nilai piksel citra ke dalam rentang 0–1 untuk mempercepat konvergensi dalam proses pelatihan dan mengurangi kompleksitas komputasi. Tahap berikutnya adalah augmentasi data menggunakan teknik seperti rotasi, flipping, zooming, dan shifting guna meningkatkan keragaman citra dalam dataset dan mengurangi risiko overfitting pada model [7]. Selain itu proses pelabelan dilakukan secara manual berdasarkan klasifikasi penyakit seperti sehat, blast, bercak daun coklat, dan hawar daun bakteri yang didasarkan pada referensi visual dari literatur dan masukan mitra ahli pertanian. Langkah terakhir melibatkan pembersihan dataset dengan menghapus citra yang buram, duplikat, atau salah label guna memastikan integritas data yang digunakan. Proses ini secara keseluruhan mendukung akurasi dan keandalan model dalam mengenali gejala penyakit tanaman padi di lapangan.



Gambar 4. Pra-pemrosesan citra

2.3 Pengembangan Model

Tahapan ini bertujuan untuk membangun dan mengoptimalkan model CNN EfficientNet ke dalam sistem pakar berbasis citra digital. Adapun langkah-langkahnya adalah sebagai berikut:

a) Inisialisasi Model dengan *Transfer Learning*

Model *EfficientNet* digunakan sebagai *backbone* model karena terbukti efisien dan akurat untuk klasifikasi citra. Model diinisialisasi menggunakan bobot *pre-trained* dari *ImageNet* guna mempercepat pelatihan dan mengatasi keterbatasan jumlah data lokal [4].

b) *Initial Training*

Pada tahap ini citra daun padi yang telah melalui proses pra-pemrosesan [8] dimasukkan ke dalam model untuk pelatihan awal. Proses ini menyesuaikan bobot model terhadap karakteristik visual penyakit padi lokal seperti daun melepuh, dan bercak daun coklat.

c) *Fine-Tuning Model*

Pelaksanaan *fine-tuning* dilakukan pada beberapa lapisan akhir model untuk menyesuaikan representasi fitur dengan data spesifik lapangan. Fine-tuning ini memungkinkan model fokus pada fitur-fitur penting dari daun padi yang relevan dalam proses diagnosis penyakit sehingga meningkatkan kemampuan klasifikasi [9].

d) Validasi dan Evaluasi Model

Model kemudian dievaluasi melalui proses validasi menggunakan data yang tidak digunakan saat pelatihan untuk mengukur metrik performa seperti akurasi, presisi, *recall*, dan *F1-score* [10].

e) Optimasi Performa Model

Pada tahap ini penyesuaian parameter pelatihan dilakukan seperti *learning rate*, jumlah *epoch*, dan teknik regularisasi (*dropout*, *early stopping*). Tujuannya untuk meningkatkan generalisasi dan menghindari *overfitting* [11].

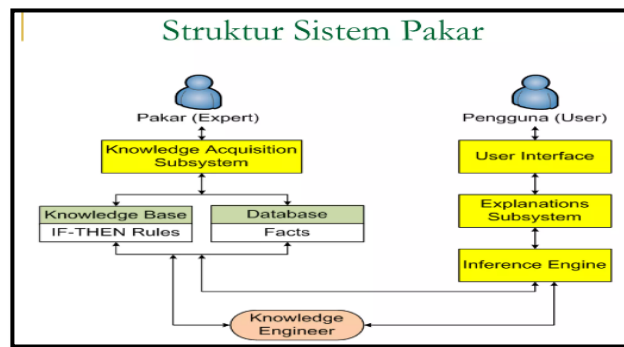
f) Penyimpanan dan Integrasi Model

Model akhir yang telah optimal disimpan dalam format file (.h5/.pt) dan diintegrasikan ke dalam sistem pakar berbasis web, sehingga dapat langsung digunakan dalam proses diagnosis citra secara otomatis.

2.4 Design Sistem

Tahap design sistem dilakukan setelah proses pengembangan model. Tahap ini dilakukan proses perancangan sistem [12] yang terdiri dari struktur sistem pakar, basis pengetahuan gejala penyakit dan jenis penyakit tanaman padi.

Adapun struktur sistem pakar dapat dilihat pada gambar 5 :



Gambar 5. Struktur sistem pakar

Setelah itu maka dibuat basis pengetahuan gejala dan jenis penyakit tanaman padi yang dapat dilihat pada tabel dibawah ini:

Tabel 2. Basis pengetahuan gejala penyakit padi

No	Nama	Kode
1	Bercak Coklat	G1
2	Bercak Putih	G2
3	Bercak Kemerahan	G3
4	Daun Mengering	G4
5	Bercak Keabuan	G5
6	Daun Menguning	G6
7	Bercak Berjamur	G7
8	Bercak keabuan	G8
9	Garis Coklat	G9
10	Daun Menggulung	G10
11	Bercak Oval	G11
12	Tepi Daun Bergerigi	G12
13	Daun Hijau Kelabu	G13
14	Tepi Daun Bergerigi	G14
15	Bercak Seperti Noda	G15

Tabel 3. Basis pengetahuan jenis penyakit tanaman padi

No	Nama	Kode
1	Daun Melepuh	P001
2	Bercak Daun Coklat	P002

2.5 Implementasi dan Evaluasi

Pada tahap ini, sistem pakar berbasis citra digital yang telah dirancang dan dilatih menggunakan model *EfficientNet* [13]. Implementasi sistem dilakukan melalui integrasi antara antarmuka pengguna (*frontend*), *backend server*, dan model *deep learning* yang telah dioptimalkan. Setelah implementasi dilakukan evaluasi sistem untuk mengukur kinerja model dan fungsionalitas sistem secara keseluruhan. Evaluasi mencakup aspek:

a.) Evaluasi Model *Deep Learning*

Melibatkan pengujian akurasi model terhadap data uji (testing set) dari dataset lokal. Parameter evaluasi meliputi akurasi, *precision*, *recall*, dan *F1-score* [14].

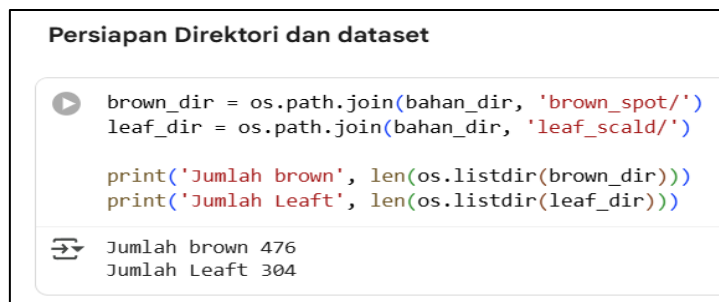
3. HASIL DAN PEMBAHASAN

3.1 Hasil

Bagian ini menyajikan temuan utama yang diperoleh dari proses penelitian. Kami memulai dengan deskripsi data yang digunakan, dilanjutkan dengan parameter dan hasil dari proses *pre-processing* dan pemodelan *EfficientNet B0* serta evaluasi performa model.

3.1.2 Pengumpulan Data

Penelitian ini menggunakan dua jenis citra penyakit padi, yaitu *Brown Spot* dan *Leaf Scald*. Total citra yang dikumpulkan adalah 780, dengan rincian 476 citra untuk *Brown Spot* dan 304 citra untuk *Leaf Scald*. Kumpulan data ini kemudian dibagi menjadi *set* data pelatihan dan validasi untuk melatih dan menguji model. Distribusi yang tidak seimbang antara kedua kelas penyakit ini merupakan tantangan yang kami atasi melalui teknik augmentasi data.



```
Persiapan Direktori dan dataset

▶ brown_dir = os.path.join(bahan_dir, 'brown_spot/')
  leaf_dir = os.path.join(bahan_dir, 'leaf_scald/')

print('Jumlah brown', len(os.listdir(brown_dir)))
print('Jumlah Leaf', len(os.listdir(leaf_dir)))

↔ Jumlah brown 476
   Jumlah Leaf 304
```

Gambar 6. Persiapan direktori dan *dataset*

3.1.2 Pra-pemrosesan Data dan Augmentasi

Untuk meningkatkan keragaman data dan mencegah overfitting, kami menerapkan teknik augmentasi data menggunakan parameter berikut:

1. *rescale=1./255*: Normalisasi nilai piksel dari rentang 0-255 menjadi 0-1, yang membantu mempercepat konvergensi model.
2. *rotation_range = 30*: Rotasi citra secara acak hingga 30 derajat.
3. *horizontal_flip=True*: Membalik citra secara horizontal.
4. *shear_range = 0.3*: Menerapkan pergeseran geser pada citra.
5. *fill_mode = 'nearest'*: Mengisi piksel baru yang dihasilkan oleh transformasi menggunakan nilai piksel terdekat.
6. *width_shift_range=0.2* dan *height_shift_range=0.2*: Menggeser citra secara horizontal dan vertikal.
7. *zoom_range=0.1*: Memperbesar atau memperkecil citra secara acak.

Augmentasi ini secara signifikan memperluas variasi dataset, memastikan model tidak hanya belajar dari pola-pola yang sangat spesifik, tetapi juga dari fitur-fitur yang lebih umum dan tangguh.

3.1.3 Hasil Pelatihan Model *EfficientNet B0*

Model *EfficientNet B0* dipilih karena arsitekturnya yang efisien dalam hal jumlah parameter dan performa yang tinggi. Setelah dilatih menggunakan data yang telah diaugmentasi, model ini berhasil mencapai akurasi pelatihan sebesar 95%. Angka ini menunjukkan bahwa model memiliki kemampuan yang sangat baik untuk mengidentifikasi pola penyakit pada citra yang digunakan untuk pelatihan.

Layer (type)	Output Shape	Param #
conv2d_3 (Conv2D)	(None, 148, 148, 16)	448
max_pooling2d_3 (MaxPooling2D)	(None, 74, 74, 16)	0
conv2d_4 (Conv2D)	(None, 72, 72, 32)	4,640
max_pooling2d_4 (MaxPooling2D)	(None, 36, 36, 32)	0
conv2d_5 (Conv2D)	(None, 34, 34, 64)	18,496
max_pooling2d_5 (MaxPooling2D)	(None, 17, 17, 64)	0
flatten_1 (Flatten)	(None, 18496)	0
dense_3 (Dense)	(None, 200)	3,699,400
dropout_2 (Dropout)	(None, 200)	0
dense_4 (Dense)	(None, 500)	100,500
dropout_3 (Dropout)	(None, 500)	0
dense_5 (Dense)	(None, 2)	1,002
Total params: 3,824,486 (14.59 MB) Trainable params: 3,824,486 (14.59 MB) Non-trainable params: 0 (0.00 B)		

Gambar 7. Pelatihan model *EfficientNet B0*

Berdasarkan *log* pelatihan yang Anda berikan, model *EfficientNet B0* menunjukkan perkembangan yang signifikan. Akurasi pada data pelatihan meningkat secara stabil dari 64,8% hingga mencapai 100% di *epoch* terakhir, sementara nilai loss menurun, menandakan bahwa model berhasil mempelajari semua pola dalam data latih. Namun, akurasi pada data validasi berfluktuasi dan hanya mencapai 80% di akhir pelatihan, jauh lebih rendah dari akurasi pelatihan. Disparitas ini menunjukkan adanya *overfitting*, di mana model terlalu menghafal data pelatihan dan kurang mampu menggeneralisasi pada data baru. Meskipun demikian, akurasi validasi 80% tetap menunjukkan performa yang cukup baik untuk mendeteksi penyakit padi, namun perlu dioptimalkan lebih lanjut untuk meningkatkan keandalannya.

3.2 Pembahasan

Bagian ini menganalisis dan menginterpretasi temuan yang disajikan di bagian Hasil. Kami akan membahas mengapa model mencapai akurasi tinggi, mengapa *loss* menurun, dan bagaimana semua ini berkontribusi pada pengembangan sistem pakar yang efektif.

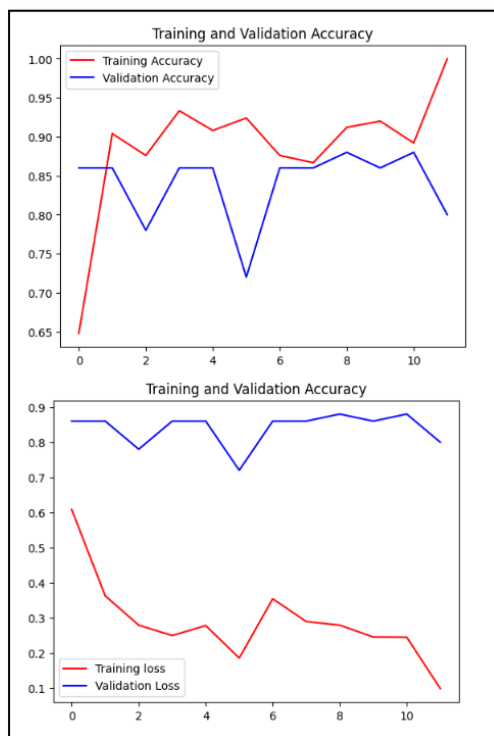
```

/usr/local/lib/python3.12/dist-packages/keras/src/trainers/data_adapters/py_dataset_adapter.py:121: Use
self._warn_if_super_not_called()
Epoch 1/30
25/25 - 10s - 406ms/step - accuracy: 0.6480 - loss: 0.6081 - val_accuracy: 0.8600 - val_loss: 0.4450
Epoch 2/30
25/25 - 6s - 223ms/step - accuracy: 0.9040 - loss: 0.3623 - val_accuracy: 0.8600 - val_loss: 0.3027
Epoch 3/30
25/25 - 4s - 175ms/step - accuracy: 0.8760 - loss: 0.2787 - val_accuracy: 0.7800 - val_loss: 0.4246
Epoch 4/30
/usr/local/lib/python3.12/dist-packages/keras/src/trainers/epoch_iterator.py:116: UserWarning: Your inp
self._interrupted_warning()
25/25 - 1s - 41ms/step - accuracy: 0.9333 - loss: 0.2493 - val_accuracy: 0.8600 - val_loss: 0.3931
Epoch 5/30
25/25 - 6s - 239ms/step - accuracy: 0.9080 - loss: 0.2777 - val_accuracy: 0.8600 - val_loss: 0.3628
Epoch 6/30
25/25 - 5s - 192ms/step - accuracy: 0.9240 - loss: 0.1851 - val_accuracy: 0.7200 - val_loss: 0.5372
Epoch 7/30
25/25 - 5s - 197ms/step - accuracy: 0.8760 - loss: 0.3539 - val_accuracy: 0.8600 - val_loss: 0.3297
Epoch 8/30
25/25 - 1s - 55ms/step - accuracy: 0.8667 - loss: 0.2890 - val_accuracy: 0.8600 - val_loss: 0.3329
Epoch 9/30
25/25 - 5s - 217ms/step - accuracy: 0.9120 - loss: 0.2788 - val_accuracy: 0.8800 - val_loss: 0.2355
Epoch 10/30
25/25 - 5s - 189ms/step - accuracy: 0.9200 - loss: 0.2452 - val_accuracy: 0.8600 - val_loss: 0.3248
Epoch 11/30
25/25 - 6s - 220ms/step - accuracy: 0.8920 - loss: 0.2446 - val_accuracy: 0.8800 - val_loss: 0.2990
Epoch 12/30
Selamat,akurasi mencapai 95 %
25/25 - 1s - 37ms/step - accuracy: 1.0000 - loss: 0.0983 - val_accuracy: 0.8000 - val_loss: 0.5018
training time:0.95minute
    
```

Gambar 8. Analisis Performa Model

Akurasi sebesar 95% adalah hasil yang sangat menjanjikan. Performa ini dapat dicapai berkat beberapa faktor penting:

1. Arsitektur *EfficientNet B0*: Arsitektur ini menggunakan *compound scaling* yang secara efektif menyeimbangkan kedalaman, lebar, dan resolusi jaringan, sehingga menghasilkan performa yang optimal dengan parameter yang lebih sedikit dibandingkan model lain.
2. Augmentasi Data: Teknik augmentasi yang diterapkan berperan krusial. Tanpa augmentasi, model mungkin akan overfitting pada set data yang terbatas dan tidak seimbang. Dengan augmentasi, model menjadi lebih kuat dan mampu menggeneralisasi dengan baik pada data baru.
3. Data yang Bersih: Kualitas citra yang baik dan pelabelan yang akurat adalah fondasi penting. Proses pengumpulan dan validasi data yang teliti memastikan model belajar dari informasi yang benar.



Gambar 9. Training dan Validation Accuracy

Grafik akurasi dan loss selama proses pelatihan biasanya menunjukkan tren yang berlawanan:

1. Akurasi meningkat seiring dengan jumlah epoch atau iterasi. Ini menunjukkan model semakin baik dalam memprediksi kelas yang benar.
2. *Loss* (kerugian) menurun seiring dengan jumlah *epoch*. Nilai *loss* yang rendah menunjukkan bahwa prediksi model sangat dekat dengan label yang sebenarnya.

Dalam kasus ini, akurasi 95% dan nilai *loss* yang rendah mengindikasikan bahwa model telah berhasil mempelajari fitur-fitur penting dari kedua penyakit tersebut. Model mampu membedakan dengan jelas antara citra *Brown Spot* dan *Leaf Scald* berdasarkan karakteristik visual seperti bentuk, ukuran, dan distribusi bintik pada daun.

3.2.1 Percobaan Klasifikasi pada Model yang Terlatih

Untuk memvalidasi keandalan model, dilakukan percobaan klasifikasi pada citra-citra yang belum pernah dilihat oleh model (dari set data validasi atau pengujian). Hasil percobaan ini menunjukkan bahwa model dapat memprediksi penyakit dengan akurasi tinggi. Contoh klasifikasi yang berhasil menunjukkan bahwa sistem pakar ini memiliki potensi besar untuk membantu petani dalam mendeteksi penyakit padi secara dini dan akurat, hanya dengan menggunakan citra digital.

```
Choose Files No file chosen Upload widget is only available when t
Saving leaf_scald_val (2).jpg to leaf_scald_val (2) (1).jpg
Saving leaf_scald_val (3).jpg to leaf_scald_val (3) (1).jpg
Saving leaf_scald_val (17).jpg to leaf_scald_val (17) (1).jpg
Saving narrow_brown_val (1).jpg to narrow_brown_val (1) (1).jpg
Saving narrow_brown_val (2).jpg to narrow_brown_val (2) (1).jpg
Saving narrow_brown_val (3).jpg to narrow_brown_val (3) (1).jpg
1/1 ----- 1s 769ms/step
leaf_scald_val (2) (1).jpg
Leaf Scald
1/1 ----- 0s 42ms/step
leaf_scald_val (3) (1).jpg
Leaf Scald
1/1 ----- 0s 29ms/step
leaf_scald_val (17) (1).jpg
Leaf Scald
1/1 ----- 0s 29ms/step
narrow_brown_val (1) (1).jpg
Brown Spot
1/1 ----- 0s 38ms/step
narrow_brown_val (2) (1).jpg
Brown Spot
1/1 ----- 0s 32ms/step
narrow_brown_val (3) (1).jpg
Brown Spot
```

Gambar 10. Klasifikasi Model

Sistem ini bukan hanya menghemat waktu, tetapi juga memberikan diagnosis yang lebih objektif dibandingkan dengan pengamatan visual biasa.

4. KESIMPULAN

Berdasarkan seluruh hasil dan pembahasan yang telah dilakukan, dapat disimpulkan bahwa penelitian ini berhasil menerapkan model deep learning EfficientNet B0 untuk membangun sistem pakar pendeteksi penyakit padi (*Brown Spot* dan *Leaf Scald*) berbasis citra digital. Meskipun model menunjukkan akurasi pelatihan yang sangat tinggi mencapai 95%). Meskipun demikian, performa ini tetap menjanjikan dan

membuktikan bahwa model *EfficientNet* B0, dengan dukungan teknik augmentasi data, efektif dalam mengklasifikasi penyakit padi. Hasil ini menjadi dasar penting untuk pengembangan sistem diagnosis penyakit tanaman yang lebih akurat dan praktis di masa depan, yang dapat membantu petani di Kota Pagar Alam dan sekitarnya dalam mengambil keputusan yang lebih cepat.

5. UCAPAN TERIMA KASIH

Ucapan terima kasih kami sampaikan kepada Kementerian Pendidikan Tinggi, Sains, dan Teknologi Republik Indonesia, DPPM Bima, dan PPPM Institut Teknologi Pagar Alam.

DAFTAR RUJUKAN

- [1] D. Tri Cahaya, D. Puspita, and R. Syahri, "Penerapan Metode K-Means Clustering Untuk Pengelompokan Potensi Padi Di Kota Pagar Alam," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 8, no. 2, pp. 2187–2193, 2024, doi: 10.36040/jati.v8i2.9432.
- [2] A. A. Santosa, R. Y. N. Fu'adah, and S. Rizal, "Deteksi Penyakit pada Tanaman Padi Menggunakan Pengolahan Citra Digital dengan Metode Convolutional Neural Network," *J. Electr. Syst. Control Eng.*, vol. 6, no. 2, pp. 98–108, 2023, doi: 10.31289/jesce.v6i2.7930.
- [3] L. N. Azizah and T. Sugiarti, "Tingkat Pengetahuan Petani Terhadap Pemanfaatan Tanaman Refugia Di Desa Bandung Kecamatan Prambon Kabupaten Nganjuk," *Agriscience*, vol. 1, no. 2, pp. 353–366, 2020, doi: 10.21107/agriscience.v1i2.8012.
- [4] Q. V. Le Mingxing Tan, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks Mingxing," *Can. J. Emerg. Med.*, vol. 15, no. 3, p. 190, 2013.
- [5] D. A. E. Sirait and D. T. Seabtian, "Sistem informasi e-marketplace cindramata sampit berbasis web," *J. Penelit. Dosen FIKOM*, vol. 10, no. 1, pp. 1–12, 2019.
- [6] S. F. Damanik, A. Wanto, and I. Gunawan, "Penerapan Algoritma Decision Tree C4.5 untuk Klasifikasi Tingkat Kesejahteraan Keluarga pada Desa Tiga Dolok," *J. Krisnadana*, vol. 1, no. 2, pp. 21–32, 2022, doi: 10.58982/krisnadana.v1i2.108.
- [7] C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," *J. Big Data*, vol. 6, no. 1, 2019, doi: 10.1186/s40537-019-0197-0.
- [8] A. Faizin, A. Tri Arsanto, Moch. Lutfi, and A. Rochim Musa, "Deep Pre-Trained Model Menggunakan Arsitektur Densenet Untuk Identifikasi Penyakit Daun Padi," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 6, no. 2, pp. 615–621, 2022, doi: 10.36040/jati.v6i2.5475.
- [9] A. G. Pradana, D. R. I. M. Setiadi, and A. R. Muslikh, "Fine tuning model Convolutional Neural Network EfficientNet-B4 dengan augmentasi data untuk klasifikasi penyakit kakao," *J. Inf. Syst. Appl. Dev.*, vol. 2, no. 1, pp. 01–11, 2024, doi: 10.26905/jisad.v2i1.11899.
- [10] A. Febrisa Sidabutar, R. Habibi, and W. Isti Rahayu, "Perbandingan Metode Klasifikasi Untuk Pengelompokan Risiko Magang Mahasiswa," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 7, no. 3, pp. 2071–2076, 2023, doi: 10.36040/jati.v7i3.7026.
- [11] C. Subbarayudu and M. Kubendiran, "A Comprehensive Survey on Machine Learning and Deep Learning Techniques for Crop Disease Prediction in Smart Agriculture," *Nat. Environ. Pollut. Technol.*, vol. 23, no. 2, pp. 619–632, 2024, doi: 10.46488/nept.2024.v23i02.003.
- [12] A. Zaki, S. Defit, S. Sumijan, and R. Fauzana, "Sistem Pakar Menggunakan Metode Forward Chaining Untuk Mendeteksi Kerusakan Jaringan Internet (Studi Kasus: Di Layanan Internet Diskominfo Sumatera Barat)," *J. Nas. Teknol. dan Sist. Inf.*, vol. 9, no. 3, pp. 227–236, 2023, doi: 10.25077/teknosi.v9i3.2023.227-236.

- [13] M. Ferian, R. Akbari, B. Rahayudi, and L. Muflikhah, "Implementasi Deep Learning menggunakan Algoritma EfficientDet untuk Sistem Deteksi Kelayakan Penerima Bantuan Langsung Tunai berdasarkan Citra Rumah di Wilayah Kabupaten Kediri," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 4, pp. 1817–1825, 2023.
- [14] M. Fadli and R. A. Saputra, "Klasifikasi Dan Evaluasi Performa Model Random Forest Untuk Prediksi Stroke," *JT J. Tek.*, vol. 12, no. 02, pp. 72–80, 2023, [Online]. Available: <http://jurnal.umt.ac.id/index.php/jt/index>