

## ANALISIS HYPERPARAMETER PADA KLASIFIKASI JENIS TANAMAN MENGGUNAKAN ALGORITMA RESNET50 DAN MOBILENETV2

Komang Ratna Mutu Manikam <sup>1</sup>, Luh Joni Erawati Dewi <sup>2</sup>, Kadek Yota Ernanda Aryanto <sup>3</sup>,

Ketut Agus Seputra <sup>4</sup>, Pariwate Varnakovida <sup>5</sup>

<sup>1,2,3,4</sup> Teknik Informatika, Universitas Pendidikan Ganesha

Jl. Udayana No.11, Singaraja, Bali, Indonesia

<sup>5</sup> Department of Mathematics, King Mongkut's University of Technology Thonburi

126 Prachauthit Road, Bangmod Subdistrict, Thung Khru District, Bangkok 10140, Thailand

ratna.mutu@student.undiksha.ac.id

### ABSTRAK

Pertanian merupakan sektor penting dalam pembangunan ekonomi. Penerapan teknologi, khususnya *machine learning*, diperlukan untuk mengelola data pertanian. Penelitian ini bertujuan mengembangkan model klasifikasi citra empat jenis tanaman utama di Indonesia, yaitu padi, jagung, singkong, dan tebu, dengan memanfaatkan dua arsitektur *deep learning* yakni *ResNet50* dan *MobileNetV2*. Dataset citra tanaman dibagi menjadi data latih dan uji, kemudian diproses dengan variasi *hyperparameter* meliputi ukuran citra (*image size*) dan jumlah *epoch*. Evaluasi dilakukan untuk mengetahui pengaruh pengaturan *hyperparameter* terhadap akurasi model. Hasil menunjukkan bahwa pemilihan *hyperparameter* yang tepat berpengaruh signifikan terhadap performa. *ResNet50* mencapai akurasi tertinggi 63,83% pada *image size* 75×75 piksel dengan 150 *epoch*, sedangkan *MobileNetV2* memperoleh akurasi hingga 87,23% pada *image size* 448×448 piksel dengan 50 dan 100 *epoch*. Temuan ini membuktikan bahwa optimasi *hyperparameter* dapat meningkatkan kinerja model secara substansial. Penelitian ini memberikan kontribusi pada pengembangan sistem klasifikasi tanaman berbasis *deep learning* yang efisien dan akurat, serta berpotensi diimplementasikan pada perangkat *mobile* untuk mendukung pertanian presisi.

**Kata kunci :** *Hyperparameter, Klasifikasi, ResNet50, MobileNetV2*

### 1. PENDAHULUAN

Perkembangan teknologi komputer dan informasi yang pesat telah memengaruhi berbagai bidang pekerjaan, meskipun pemanfaatannya masih menghadapi kendala baik dari sisi perangkat keras maupun perangkat lunak [1]. Salah satu perkembangan penting dalam ranah teknologi informasi adalah hadirnya *Convolutional Neural Network (CNN)*, ini adalah algoritma *deep learning* yang digunakan untuk mengenali citra digital. Sebagai pengenalan citra digital algoritma ini sangat efektif untuk klasifikasi dan memiliki banyak model [2]. Pengenalan citra digital sangat berpotensi pada pengenalan wajah [3], identifikasi pola, dan tentunya klasifikasi. Penelitian lain bahkan menunjukkan bahwa pengolahan citra digital dengan pendekatan berbeda, seperti *Histogram of Gradient (HoG)* dan *Bag of Visual Movement*, juga efektif dalam mendeteksi pola visual pada objek kompleks seperti tarian tradisional Bali [4]. Struktur *CNN* terdiri atas banyak *layer* diantaranya *convolution layers*, *pooling layers* dan *fully connected layers*. *CNN* bekerja dengan mengekstrak fitur penting pada data *input*, mengurangi dimensi, dan mengklasifikasikan data.

Pada penelitian sebelumnya, algoritma *CNN* telah digunakan untuk klasifikasi empat jenis tanaman, yakni Padi, Jagung, Singkong, dan Tebu, dengan tingkat akurasi yang masih dapat ditingkatkan. Hal ini membuka peluang untuk mengeksplorasi model *CNN* lain yang lebih dalam dan efisien, khususnya untuk implementasi pada perangkat *mobile*.

Meskipun *CNN* telah terbukti efektif untuk klasifikasi citra, model yang digunakan pada penelitian sebelumnya hanya mencapai akurasi 74% dalam klasifikasi empat jenis tanaman. Akurasi tersebut masih tergolong rendah untuk aplikasi praktis, terutama jika model akan diimplementasikan pada perangkat *mobile* yang memerlukan efisiensi dan presisi tinggi. Selain itu, pengaturan *hyperparameter* yang belum optimal turut menjadi kendala yang membatasi kinerja model.

Algoritma *mobile* yang dapat mengakomodasi kebutuhan ini, yaitu *MobileNetV2* dan *ResNet50* [5]. Dalam *CNN*, *Resnet50* termasuk model yang memiliki akurasi lebih tinggi dalam pengenalan gambar dibandingkan model lain seperti *VGG16* dan *VGG19* [2], dan model yang dapat secara efektif memecahkan masalah hilangnya gradien dan degradasi jaringan dengan menggunakan koneksi lewati dalam model *CNN* mendalam dengan menggunakan struktur residual [6], [7].

*MobileNet* adalah model *CNN* yang efektif digunakan sebagai model klasifikasi yang penggunaan modelnya ditujukan pada perangkat *mobile*, terutama model *MobileNetV2*. Hasil pengujian gambar dengan menggunakan *MobileNetV2* memiliki tingkat akurasi yang lebih tinggi dan waktu training lebih singkat dibandingkan model *MobileNetV1* [8]. Model *MobileNetV2* ideal untuk diimplementasikan pada perangkat *mobile* dengan sumber daya terbatas.

Dalam konteks klasifikasi jenis tanaman, pemilihan model *CNN* yang tepat dan optimalisasi

hyperparameter sangat penting untuk meningkatkan akurasi dan efisiensi [9]. *Hyperparameter* seperti *learning rate*, *image size*, dan jumlah *epoch* memiliki pengaruh signifikan terhadap performa model. Dengan penyetelan *hyperparameter* yang tepat dapat meningkatkan akurasi [10]. Penelitian ini bertujuan untuk menganalisis *hyperparameter* pada klasifikasi jenis tanaman menggunakan dua model CNN yang terkenal, yaitu *ResNet50* dan *MobileNetV2*.

Tujuan utama penelitian ini adalah untuk menjawab pertanyaan tentang bagaimana pengaturan *hyperparameter* yang optimal pada kedua model ini dapat meningkatkan akurasi klasifikasi jenis tanaman. Pertanyaan ini penting karena klasifikasi yang akurat memiliki aplikasi luas dalam pertanian presisi, monitoring tanaman, dan sistem pengelolaan pertanian berbasis teknologi. Beberapa studi menunjukkan bahwa teknologi informasi dan komunikasi banyak digunakan dalam pertanian, penelitian yang memanfaatkan kecerdasan buatan untuk pertanian juga telah dilakukan [11]. Dengan meningkatnya kebutuhan akan solusi *mobile* yang efisien dan akurat, penelitian ini juga mengeksplorasi keunggulan masing-masing model dalam implementasi pada perangkat *mobile*.

Untuk mencapai tujuan tersebut, penelitian ini dirancang dengan membandingkan kinerja dua arsitektur CNN populer, yaitu *ResNet50* dan *MobileNetV2*, dalam klasifikasi citra tanaman. Langkah-langkah yang dilakukan meliputi pengumpulan dan pengolahan dataset citra tanaman, penerapan teknik *preprocessing*, pelatihan model menggunakan variasi *hyperparameter*, evaluasi performa model menggunakan metrik akurasi dan *confusion matrix*, serta analisis perbandingan untuk menentukan model dan pengaturan *hyperparameter* yang optimal.

Penelitian ini diharapkan dapat memberikan kontribusi signifikan pada bidang pengenalan citra digital dan klasifikasi jenis tanaman, dengan menyediakan analisis mendalam tentang pengaruh *hyperparameter* pada performa model *ResNet50* dan *MobileNetV2*. Penelitian ini akan membantu dalam mengembangkan sistem klasifikasi yang lebih efektif dan efisien, yang pada akhirnya akan mendukung inovasi dalam bidang teknologi pertanian.

## 2. TINJAUAN PUSTAKA

### 2.1. Tanaman Pertanian

Tanaman pertanian seperti padi, jagung, singkong, dan tebu merupakan komoditas utama yang berperan penting dalam ketahanan pangan nasional. Digitalisasi informasi pertanian telah mulai diterapkan di beberapa wilayah, contohnya pada sistem informasi berbasis *web* [12] dan aplikasi *mobile* untuk produk pertanian Kabupaten Buleleng [13].

Penggunaan teknologi *deep learning* dalam klasifikasi tanaman pertanian mulai berkembang, namun penelitian-penelitian sebelumnya masih

cenderung terbatas pada objek seperti tanaman obat, bunga, daun dan [14], [15], [16], [17].

### 2.2. Arsitektur ResNet50

*ResNet50* diperkenalkan oleh *Microsoft Research* pada tahun 2015 dan memenangkan kompetisi pengenalan gambar *ImageNet*, ini menunjukkan keunggulan *ResNet* dalam pengenalan gambar [5], [18].

Beberapa studi menerapkan *ResNet50* untuk klasifikasi tanaman obat dan penyakit daun. Misalnya, dalam klasifikasi daun tanaman obat, *ResNet50* berhasil mencapai akurasi 99,84% berkat kedalaman jaringan dan penggunaan *transfer learning* [18]. Namun, model ini hanya menggunakan gambar daun tunggal, sehingga memiliki keterbatasan dalam mengenali struktur tanaman secara keseluruhan.

Dalam klasifikasi penyakit daun gandum, penambahan *layer* pada arsitektur *ResNet50* meningkatkan akurasi hingga 98,44% [14]. Kombinasi *ResNet50* dengan metode lain seperti SVM dan *softmax* juga menunjukkan performa tinggi dengan akurasi masing-masing 99% dan 98,8% [19]. Model ini juga telah digunakan dalam klasifikasi buah busuk dengan akurasi validasi mencapai 98,89% pada latar belakang sederhana, meskipun turun hingga 85% pada latar kompleks [20].

### 2.3. Arsitektur MobileNetV2

*MobileNetV2* merupakan model CNN ringan yang dirancang untuk efisiensi pada perangkat dengan keterbatasan komputasi, seperti *smartphone*. Model ini menggunakan pendekatan *inverted residual blocks* dan *depthwise separable convolution*, membuatnya sangat efisien dari sisi waktu dan memori [21]. *MobileNetV2* banyak digunakan dalam klasifikasi objek berbasis citra pertanian. Dalam klasifikasi tanaman teratai, model ini mampu mencapai akurasi hingga 99,5% [15]. Pada klasifikasi buah, *MobileNetV2* menunjukkan stabilitas akurasi masing-masing 95,75%, 96,74%, dan 96,23% pada beberapa dataset [16].

Dalam beberapa studi, performa *MobileNetV2* ditingkatkan dengan penambahan layer khusus atau penggabungan dengan modul atensi seperti *CBAM*, yang meningkatkan kemampuan model dalam mengekstraksi fitur penting. *CBAM-MobileNetV2* mampu mencapai akurasi hingga 98,75% pada klasifikasi penyakit citrus [22]. Namun, model ini juga mengalami peningkatan kompleksitas dan risiko *overfitting* [22].

Studi lain menggunakan kombinasi *MobileNetV2* dan *UNet* untuk segmentasi daun tanaman jambu biji, kentang, dan jambang dengan akurasi 96,38% [23]. *MobileNetV2* juga digunakan untuk klasifikasi bunga obat tradisional India dengan akurasi mencapai 98,23% [17]. Model ini tetap menunjukkan keunggulan pada data citra tanaman dengan latar berbeda tanpa *preprocessing* yang kompleks [17].

## 2.4. Hyperparameter

Pengaturan *hyperparameter* berperan penting dalam menentukan performa model *CNN*. Sebuah penelitian terhadap performa model berbasis *CNN* dalam deteksi landmark 3D menunjukkan bahwa penyesuaian *hyperparameter*, seperti *learning rate*, jumlah *epoch*, dan *batch size*, berpengaruh signifikan [24]. Parameter seperti ukuran citra dan jumlah *epoch* harus disesuaikan dengan karakteristik data agar model dapat belajar secara efektif. Studi menunjukkan bahwa ukuran citra yang optimal bergantung pada kompleksitas objek, objek dengan detail rumit memerlukan resolusi lebih tinggi [25].

## 2.5. Confusion Matrix

*Confusion matrix* merupakan tabel evaluasi untuk klasifikasi multi-kelas yang menunjukkan prediksi benar dan salah antar kelas (TP, TN, FP, FN). Matriks ini menjadi dasar perhitungan metrik seperti akurasi, presisi, *recall*, dan *F1-score* yang memberikan gambaran performa model lebih lengkap dibandingkan hanya menggunakan akurasi [26]. Dalam konteks klasifikasi penyakit tanaman, matriks ini penting untuk mengevaluasi kemampuan model dalam mengenali tiap kelas tanpa bias terhadap kelas mayoritas [27].

## 2.6. Penelitian Terdahulu

Penelitian yang membandingkan *VGG16*, *VGG19*, dan *ResNet50* pada klasifikasi citra dengan variasi *epoch*, menemukan *ResNet50* unggul pada *epoch* ke-20, sehingga model ini dipilih sebagai salah satu pembandingan dalam penelitian ini [28]. Penelitian lain menggunakan *ResNet50* untuk deteksi buah busuk dengan variasi *batch size* dan *epoch*, mencapai akurasi 98,89% pada *batch size* 10 dan *epoch* 6, menguatkan pentingnya tuning *hyperparameter* [20]. Pada studi lain *MobileNetV2* digunakan untuk klasifikasi bunga obat dengan akurasi tertinggi hingga 98,23% [17]. Sementara itu, studi lain mengungkap ukuran citra optimal 256×256 hingga 448×448 piksel untuk meningkatkan akurasi tanpa membebani komputasi, yang menjadi acuan dalam penentuan *image size* penelitian ini [29].

## 3. METODE PENELITIAN

### 3.1. Dataset



Gambar 1. Tanaman Padi, Jagung, Singkong, dan Tebu

Data yang digunakan dalam penelitian ini terdiri atas citra tanaman Padi, Jagung, Singkong, dan Tebu yang diperoleh dari sumber daring (internet). Seluruh citra berformat *.jpg*, dengan total sebanyak 245 gambar. Sesuai dengan fokus klasifikasi pada empat jenis tanaman, data uji terdiri atas empat kategori citra, yakni Padi, Jagung, Singkong, dan Tebu. Contoh representasi visual dari masing-masing kategori tanaman dapat dilihat pada Gambar 1.


### 3.2. Data Preprocessing

Data *preprocessing* adalah tahap awal dalam pelatihan model yang bertujuan menyiapkan data agar sesuai dengan kebutuhan arsitektur *deep learning*. Penelitian ini menggunakan 245 gambar tanaman (padi, jagung, singkong, dan tebu) dalam format *JPG* yang diperoleh dari internet. Data dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian.

*Preprocessing* ini dilakukan untuk menguji pengaruh resolusi terhadap performa model, serta memastikan data dalam format yang seragam agar bisa diterima oleh model *ResNet50* dan *MobileNetV2*.

### 3.3. Perancangan Model ResNet50

Model *ResNet* ini terdiri dari beberapa blok *Residual* yang mengatasi masalah degradasi pada jaringan dalam dengan menggunakan *shortcut connections*.



Gambar 2. Arsitektur *ResNet50*


Pada Gambar 2. dapat dilihat model menerima input gambar dengan beberapa ukuran dalam piksel, yang melalui beberapa tahap konvolusi, normalisasi *batch*, dan aktivasi *ReLU*. Blok *Residual* mencakup *identity block* dan *convolutional block* dengan filter bertingkat (64, 128, 256). *Shortcut connections* menjumlahkan *input* asli dengan *output* konvolusi, membantu mempertahankan informasi. Setelah melalui lapisan *pooling* dan *flattening*, model menggunakan lapisan *Dense* dan *Dropout* sebelum menghasilkan *output* dengan fungsi aktivasi *softmax* untuk klasifikasi multi-kelas.

Model dikompilasi dengan *optimizer Adam* dan *loss categorical crossentropy*, lalu dilatih selama 150 *epoch*. Data *testing* digunakan untuk evaluasi, mengukur akurasi, presisi, *recall*, *f1 score*, dan membuat *confusion matrix*. Hasil pelatihan dan evaluasi disimpan dalam file teks, sementara grafik akurasi dan *loss* divisualisasikan untuk pemantauan performa model.

### 3.4. Perancangan Model MobileNetV2

Model *MobileNetV2* ini menggunakan *layer* tambahan untuk klasifikasi, seperti *GlobalAveragePooling2D*, *Dropout*, dan *Dense*, yang diakhiri dengan *layer softmax* untuk prediksi kelas.

Gambar arsitektur *MobileNetV2* dapat dilihat pada Gambar 3.



Gambar 2. Arsitektur *MobileNetV2*

Lapisan dasar *MobileNetV2* dibekukan untuk mencegah pembaruan selama pelatihan, sementara lapisan tambahan dilatih menggunakan data pelatihan. Model dikompilasi dengan *optimizer Adam* dan *loss sparse categorical crossentropy*. Proses pelatihan dilakukan selama 150 *epoch* dengan *batch size* 32. Data pelatihan dan pengujian di-normalisasi ke rentang [0, 1] sebelum digunakan. Setelah pelatihan, model dievaluasi menggunakan data pengujian untuk menghitung metrik seperti akurasi, presisi, *recall*, dan *F1-score*. Hasil pelatihan dan evaluasi disimpan dalam file teks, sementara grafik akurasi dan *loss* divisualisasikan untuk memantau performa model.

### 3.5. Pelatihan Model

Model dilatih menggunakan data yang telah dinormalisasi ke rentang [0, 1], kemudian dikompilasi menggunakan *optimizer Adam* dengan fungsi *loss* yang berbeda yakni *Categorical Crossentropy* untuk *ResNet50* dan *Sparse Categorical Crossentropy* untuk *MobileNetV2*. Proses pelatihan dilakukan selama 50, 100, dan 150 *epoch* dengan *batch size* 32, dan hasil pelatihan berupa akurasi dan *loss* disimpan dalam file teks serta divisualisasikan dalam bentuk grafik untuk pemantauan performa selama *training*.

Dalam penelitian ini, digunakan dua jenis *hyperparameter* yaitu ukuran gambar (*image size*) dan jumlah *epoch*. Ukuran gambar yang diuji mencakup 32x32, 50x50, 75x75, 100x100, 224x224, dan 448x448 piksel, sedangkan *epoch* yang digunakan adalah 50, 100, dan 150 *epoch*. Setiap kombinasi diuji untuk mengetahui pengaruhnya terhadap performa model menggunakan metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-score*. Hasil terbaik dari masing-masing kombinasi digunakan untuk menentukan pengaturan *hyperparameter* yang optimal dan efisien.

### 3.6. Evaluasi Model

Analisis *confusion matrix* ini dilakukan untuk *MobileNetV2* dan *ResNet50* berdasarkan konfigurasi terbaik masing-masing. Pada *confusion matrix* terdapat empat nilai kunci yakni *True Positive (TP)*, *False Positive (FP)*, *False Negative (FN)*, dan *True Negative (TN)*. Tujuan evaluasi dalam penelitian ini adalah untuk mengukur kinerja dua model arsitektur berbeda, *ResNet50* dan *MobileNetV2*, dalam klasifikasi gambar tanaman dengan memvariasikan parameter ukuran gambar (32x32, 50x50, 75x75,

100x100, 224x224, dan 448x448 piksel) serta jumlah *epoch* (50, 100, dan 150). Pengujian ini memantau akurasi, presisi, *recall*, dan *F1-score* menggunakan rumus berikut.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$


$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

$$F1\ score = \frac{2 \times Recall \times Precision}{Recall + Precision}$$


## 4. HASIL DAN PEMBAHASAN

Berdasarkan hasil pengujian, dapat disimpulkan bahwa resolusi citra berpengaruh signifikan terhadap kinerja kedua model. Secara umum, citra berukuran lebih besar cenderung menghasilkan akurasi yang lebih tinggi. Hal ini terlihat pada *MobileNetV2* dengan resolusi 448x448 piksel, yang mencapai akurasi tertinggi sebesar 87,23% pada pelatihan dengan 50 dan 100 *epoch*.



Gambar 4. Akurasi *MobileNetV2* untuk citra resolusi 448x448 piksel, 50 *epoch*

Gambar 4 menampilkan grafik *training accuracy* dan *validation accuracy* *MobileNet* pada citra berukuran 448x448 piksel. *Training accuracy* (garis biru) naik cepat dan hampir mencapai 100%, menunjukkan kemampuan model mengenali pola dengan efisien. *Validation accuracy* (garis oranye) juga meningkat tajam di awal, meski kemudian fluktuatif dan bertahan di kisaran 50–70%. Ini menunjukkan generalisasi model cukup baik, meskipun tidak setinggi akurasi pelatihan. Fluktuasi kemungkinan disebabkan oleh kompleksitas data atau ukuran *batch* kecil. Secara keseluruhan, resolusi citra yang lebih besar membantu *MobileNet* menangkap fitur yang lebih kompleks.




Gambar 5. *Loss* *MobileNetV2* untuk citra resolusi 448x448 piksel

Gambar 5 menunjukkan *training loss* (garis biru) turun cepat dan stabil mendekati nol, menandakan pembelajaran yang konsisten. *Validation loss* (garis oranye) juga menurun di awal dan stabil di kisaran 0.8–1.2, dengan fluktuasi ringan. Meski ada gap, pola ini menunjukkan *MobileNet* mampu melakukan generalisasi dengan cukup baik dan tidak mengalami *overfitting* yang parah.

Tabel 1. Hasil pengujian dengan MobileNetV2


| No | Size Image (Pixel) | Epoch | Accuracy (%) | Precision (%) | Recall (%) | F1 Score (%) |
|----|--------------------|-------|--------------|---------------|------------|--------------|
| 1  | 32 x 32            | 50    | 42.55        | 55.45         | 41.36      | 38.36        |
| 2  |                    | 100   | 53.19        | 63.14         | 52.00      | 49.90        |
| 3  |                    | 150   | 53.19        | 63.89         | 52.00      | 50.26        |
| 4  | 50 x 50            | 50    | 59.57        | 70.06         | 58.62      | 53.86        |
| 5  |                    | 100   | 57.45        | 69.28         | 56.70      | 52.38        |
| 6  |                    | 150   | 59.57        | 70.83         | 58.62      | 54.30        |
| 7  | 75 x 75            | 50    | 59.57        | 61.42         | 58.25      | 54.53        |
| 8  |                    | 100   | 59.57        | 58.35         | 58.60      | 53.95        |
| 9  |                    | 150   | 51.06        | 41.12         | 50.64      | 41.80        |
| 10 | 100 x 100          | 50    | 61.70        | 74.79         | 61.38      | 56.40        |
| 11 |                    | 100   | 63.83        | 76.39         | 62.82      | 59.05        |
| 12 |                    | 150   | 61.70        | 75.10         | 61.22      | 56.68        |
| 13 | 224x224            | 50    | 78.72        | 85.20         | 77.81      | 75.48        |
| 14 |                    | 100   | 76.60        | 84.47         | 75.54      | 71.86        |
| 15 |                    | 150   | 78.72        | 85.90         | 77.81      | 75.68        |
| 16 | 448 x 448          | 50    | 87.23        | 89.29         | 87.09      | 87.61        |
| 17 |                    | 100   | 87.23        | 88.85         | 87.09      | 87.27        |
| 18 |                    | 150   | 82.98        | 84.58         | 82.93      | 83.06        |

Berdasarkan Tabel 1, performa *MobileNetV2* menunjukkan peningkatan seiring bertambahnya ukuran citra. Ukuran terkecil (32×32 piksel) menghasilkan akurasi dan *F1-score* yang rendah, bahkan setelah 150 *epoch*. Kinerja mulai stabil dan meningkat signifikan pada ukuran 100×100 ke atas. Hasil terbaik diperoleh pada ukuran 448×448 piksel dengan *F1-score* mencapai 87.61% dan akurasi 87.23% pada 50 *epoch*. Namun, peningkatan *epoch* hingga 150 tidak selalu meningkatkan performa, yang terlihat dari penurunan skor pada ukuran citra terbesar. Hal ini menunjukkan bahwa kombinasi ukuran citra dan jumlah *epoch* yang tepat sangat memengaruhi efektivitas model.

Gambar 6. Akurasi *ResNet50* untuk citra resolusi 75x75 piksel, 150 *epoch*

Gambar 6 menunjukkan grafik *training accuracy* (garis biru) meningkat tajam dan stabil mendekati

100%, menandakan model sangat baik dalam mempelajari data pelatihan. Sebaliknya, *validation accuracy* (garis oranye) tetap rendah dan fluktuatif tanpa peningkatan berarti. Perbedaan mencolok ini menunjukkan model mengalami *overfitting* dan gagal melakukan generalisasi terhadap data baru.

Gambar 7. Loss *ResNet50* untuk citra resolusi 75x75 piksel, 150 *epoch*

Gambar 7 memperlihatkan grafik *training* dan *validation loss* model *ResNet50*. *Training loss* (garis biru) menurun tajam dan stabil di angka sangat rendah, mendekati nol. Sebaliknya, *validation loss* (garis oranye) tetap tinggi dan fluktuatif. Pola ini menegaskan terjadinya *overfitting*, di mana model terlalu menghafal data pelatihan namun gagal menggeneralisasi ke data baru. Perbedaan tajam ini menunjukkan perlunya perbaikan seperti regularisasi, data *augmentation*, atau arsitektur yang lebih ringan.

Tabel 2. Hasil pengujian dengan ResNet50

| No | Size Image (Pixel) | Epoch | Accuracy (%) | Precision (%) | Recall (%) | F1 Score (%) |
|----|--------------------|-------|--------------|---------------|------------|--------------|
| 1  | 32 x 32            | 50    | 25.53        | 6.38          | 25.00      | 19.17        |
| 2  |                    | 100   | 23.40        | 5.85          | 25.00      | 9.48         |
| 3  |                    | 150   | 31.91        | 16.97         | 33.14      | 21.11        |
| 4  | 50 x 50            | 50    | 25.53        | 6.38          | 25.00      | 10.17        |
| 5  |                    | 100   | 59.57        | 69.26         | 57.74      | 54.66        |
| 6  |                    | 150   | 61.70        | 69.79         | 60.90      | 59.44        |
| 7  | 75 x 75            | 50    | 55.32        | 71.55         | 55.07      | 53.16        |
| 8  |                    | 100   | 61.70        | 68.58         | 60.17      | 58.25        |
| 9  |                    | 150   | 63.83        | 64.29         | 62.44      | 59.24        |
| 10 | 100 x 100          | 50    | 51.06        | 41.19         | 49.16      | 42.10        |
| 11 |                    | 100   | 51.06        | 41.19         | 49.16      | 42.10        |
| 12 |                    | 150   | 53.19        | 63.59         | 51.84      | 50.70        |

Berdasarkan Tabel 2, performa model *ResNet50* menunjukkan variasi yang cukup besar terhadap perubahan ukuran citra. Pada ukuran terkecil (32×32 dan 50×50 piksel), performa sangat rendah dengan *F1-score* di bawah 22%, bahkan setelah 150 *epoch*. Performa mulai meningkat secara signifikan pada ukuran 75×75 piksel ke atas, dengan hasil terbaik dicapai pada ukuran 150×150 piksel yang menghasilkan akurasi 63.83% dan *F1-score* sebesar 59.24%. Menariknya, ukuran 100×100 justru menunjukkan penurunan performa dibanding ukuran sebelumnya, mengindikasikan bahwa peningkatan resolusi tidak selalu linier terhadap peningkatan performa. Hal ini menunjukkan bahwa *ResNet50*

membutuhkan resolusi citra yang cukup, namun juga sensitif terhadap ukuran tertentu, sehingga pemilihan ukuran input yang tepat sangat krusial untuk performa optimal.

#### 4.1. Pengaruh *Size Image* terhadap Performa Model

Pada *ResNet50*, ukuran citra yang lebih kecil (32x32, 50x50) menunjukkan performa yang lebih rendah, dengan akurasi hanya mencapai sekitar 25-31%. Ukuran citra 75x75 memberikan hasil terbaik, dengan akurasi mencapai 63.83% pada 150 *epoch*. Namun, saat ukuran citra ditingkatkan ke 100x100, akurasi justru menurun ke 53.19%. Ukuran citra yang terlalu kecil (32x32, 50x50) tidak menyediakan detail yang cukup untuk model yang dalam seperti *ResNet50*, sehingga model gagal mengenali pola dengan baik. Namun, peningkatan ukuran citra secara berlebihan (100x100) justru menambah kompleksitas, yang menyebabkan model *overfitting* atau tidak bisa mengelola informasi yang terlalu banyak, terutama pada dataset kecil.

Sedangkan *MobileNetV2* lebih stabil dalam menangani ukuran citra yang lebih besar. Pada ukuran 224x224, akurasi meningkat menjadi 78.72%, dan pada ukuran 448x448, akurasi mencapai 87.23%. *MobileNetV2* menunjukkan bahwa semakin besar ukuran citra, model ini semakin mampu menangkap detail penting dan meningkatkan performa, dengan presisi, *recall*, dan *F1-score* yang juga tinggi. Dengan ini diketahui *MobileNetV2* memiliki arsitektur yang lebih ringan dan efisien, sehingga mampu memanfaatkan ukuran citra yang lebih besar tanpa mengalami penurunan performa seperti *ResNet50*. Ukuran citra yang lebih besar memungkinkan model menangkap lebih banyak informasi visual yang relevan untuk klasifikasi yang lebih akurat.

#### 4.2. Pengaruh Jumlah *Epoch* terhadap Performa Model

Jumlah *epoch* juga memiliki pengaruh yang signifikan terhadap performa model. Pada umumnya, peningkatan jumlah *epoch* cenderung meningkatkan akurasi model hingga titik tertentu, setelah itu akurasi bisa menurun atau stabil. Misalnya, pada *MobileNetV2* dengan ukuran gambar 224x224, akurasi tertinggi dicapai pada 50 *epoch* (78.72%) dan cenderung stabil pada 100 dan 150 *epoch*.

Pada *ResNet50*, peningkatan jumlah *epoch* dari 50 ke 100 dan 150 menunjukkan peningkatan akurasi secara umum, namun hasil terbaik tetap pada ukuran gambar 75x75 dengan 150 *epoch*.

#### 4.3. Pengaruh Ukuran Gambar dan Jumlah *Epoch* terhadap *Precision*, *Recall*, dan *F1-Score*

Selain akurasi, *precision*, *recall*, dan *F1-score* juga memberikan wawasan penting mengenai performa model. *Precision* menunjukkan proporsi prediksi positif yang benar-benar positif. *MobileNetV2*

mencapai *precision* tertinggi sebesar 89.29% pada ukuran gambar 448x448 dengan 50 *epoch*, sementara *ResNet50* mencapai *precision* tertinggi sebesar 71.55% pada ukuran gambar 75x75 dengan 50 *epoch*. *Precision* yang lebih tinggi pada *MobileNetV2* menunjukkan bahwa model ini lebih efektif dalam mengurangi prediksi positif yang salah.

*Recall* mengukur proporsi total data positif yang benar-benar terdeteksi oleh model. *MobileNetV2* mencapai *recall* tertinggi sebesar 87.09% pada ukuran gambar 448x448 dengan 50 *epoch*, sedangkan *ResNet50* mencapai *recall* tertinggi sebesar 64.29% pada ukuran gambar 75x75 dengan 150 *epoch*. *Recall* yang lebih tinggi pada *MobileNetV2* menunjukkan bahwa model ini lebih baik dalam mendeteksi semua data positif dalam dataset.

*F1-Score* adalah *harmonic mean* dari *precision* dan *recall*, yang memberikan gambaran menyeluruh tentang keseimbangan antara *precision* dan *recall*. *MobileNetV2* mencapai *F1-score* tertinggi sebesar 87.61% pada ukuran gambar 448x448 dengan 50 *epoch*, sementara *ResNet50* mencapai *F1-score* tertinggi sebesar 59.44% pada ukuran gambar 75x75 dengan 150 *epoch*. *F1-score* yang lebih tinggi pada *MobileNetV2* menunjukkan bahwa model ini memiliki keseimbangan yang lebih baik antara *precision* dan *recall*.

#### 4.4. Perbandingan antara *MobileNetV2* dan *ResNet50*

Secara keseluruhan, *MobileNetV* menunjukkan performa yang lebih baik dibandingkan *ResNet50* dalam tugas klasifikasi gambar pada dataset ini. Selain akurasi, *MobileNetV2* juga unggul dalam hal *precision*, *recall*, dan *F1-score*. *MobileNetV2* mencapai akurasi tertinggi sebesar 87.23%, *precision* tertinggi sebesar 89.29%, *recall* tertinggi sebesar 87.09%, dan *F1-score* tertinggi sebesar 87.61% pada gambar berukuran 448x448 dengan 50 *epoch*. Sedangkan *ResNet50* mencapai akurasi tertinggi sebesar 63.83%, *precision* tertinggi sebesar 71.55%, *recall* tertinggi sebesar 64.29%, dan *F1-score* tertinggi sebesar 59.44% pada gambar berukuran 75x75 dengan 150 *epoch*. *MobileNetV2* juga menunjukkan stabilitas performa yang lebih baik pada ukuran gambar yang lebih besar dan jumlah *epoch* yang lebih tinggi, dibandingkan dengan *ResNet50* yang cenderung menunjukkan fluktuasi performa.

#### 4.5. Evaluasi

Evaluasi menggunakan *Confusion matrix* memberikan gambaran rinci tentang performa klasifikasi model dengan menunjukkan jumlah prediksi benar dan salah yang dibuat untuk setiap kelas. Berikut adalah analisis *confusion matrix* untuk *MobileNetV2* dan *ResNet50* berdasarkan konfigurasi terbaik masing-masing yang ditunjukkan pada Gambar 8 dan 9.

Perbandingan kinerja antara *MobileNetV2* dan *ResNet50* menunjukkan bahwa *MobileNetV2*

memiliki keunggulan dalam ketepatan serta keseimbangan antara *precision* dan *recall*. Ukuran gambar yang lebih besar dan jumlah *epoch* yang optimal pada *MobileNetV2* memberikan hasil yang lebih baik dibandingkan dengan *ResNet50*.

|        |           | Predict |      |      |           |
|--------|-----------|---------|------|------|-----------|
|        |           | Cassava | Corn | Rice | Sugarcane |
| Actual | Cassava   | 12      | 1    | 0    | 0         |
|        | Corn      | 2       | 10   | 0    | 0         |
|        | Rice      | 0       | 0    | 11   | 0         |
|        | Sugarcane | 0       | 3    | 0    | 8         |

Gambar 8. Confusion matrix *MobileNetV2* 448x448 50 epoch

|        |           | Predict |      |      |           |
|--------|-----------|---------|------|------|-----------|
|        |           | Cassava | Corn | Rice | Sugarcane |
| Actual | Cassava   | 11      | 2    | 0    | 0         |
|        | Corn      | 2       | 10   | 0    | 0         |
|        | Rice      | 1       | 2    | 7    | 1         |
|        | Sugarcane | 1       | 3    | 5    | 2         |

Gambar 9. Confusion matrix *ResNet50* 75x75 150 epoch

Hasil penelitian ini menegaskan bahwa *MobileNetV2* merupakan pilihan yang lebih baik untuk tugas klasifikasi gambar pada dataset ini. Untuk implementasi praktis, disarankan untuk menggunakan *MobileNetV2* dengan ukuran gambar yang lebih besar dan jumlah *epoch* yang cukup guna mencapai akurasi dan keseimbangan yang optimal. Kesimpulan dari evaluasi menggunakan *confusion matrix* menunjukkan bahwa *MobileNetV2* tidak hanya mencapai akurasi yang lebih tinggi tetapi juga menunjukkan performa yang lebih baik dalam hal *precision*, *recall*, dan *F1-score*, memberikan panduan penting dalam pemilihan model dan pengaturan *hyperparameter* untuk tugas klasifikasi gambar serupa di masa depan.

## 5. KESIMPULAN DAN SARAN

Hasil eksperimen menunjukkan bahwa *MobileNetV2* memiliki performa klasifikasi yang lebih baik dibandingkan *ResNet50* dan *CNN*, khususnya pada citra berukuran besar. *MobileNetV2* mencapai akurasi tertinggi 87,23% pada ukuran 448x448 piksel dengan 50 *epoch*, sedangkan *ResNet50* hanya mencapai 63,83% pada ukuran 75x75 piksel dengan 150 *epoch*. Oleh karena itu, *MobileNetV2* direkomendasikan untuk klasifikasi citra pertanian dengan resolusi tinggi dan *epoch* yang optimal.

Penelitian selanjutnya perlu mengeksplorasi *hyperparameter* seperti *learning rate* dan *batch size*, serta menerapkan augmentasi data untuk meningkatkan generalisasi. Augmentasi dapat dilakukan melalui rotasi, refleksi, *zooming*, atau metode *deep learning* seperti *Generative Adversarial Networks (GANs)* [30]. Pengujian pada dataset yang lebih besar dan evaluasi model lain seperti *EfficientNet* dan *DenseNet* juga disarankan. Hal ini sejalan dengan temuan pada sektor lain, misalnya perikanan, di mana jumlah data yang sangat besar dan beragam membutuhkan teknologi cerdas untuk diekstraksi dan dianalisis sehingga menghasilkan solusi inovatif bagi pengelolaan sumber daya [31].

## DAFTAR PUSTAKA

- [1] P. H. Suputra, "Penggunaan Perangkat Lunak Berlisensi Publik Sebagai Tradisi Sehat Berbudaya," *Jurnal Pendidikan Teknologi dan Kejuruan*, vol. 7, no. 2, pp. 29–38, 2010.
- [2] S. L. and K. P. Lakshmi, "An Analysis of Convolution Neural Network for Image Classification using Different Models," *International Journal of Engineering Research & Technology (IJERT)*, vol. 9, no. 10, pp. 629–637, Oct. 2020, [Online]. Available: [www.ijert.org](http://www.ijert.org)
- [3] A. Budiman, Fabian, R. A. Yaputera, S. Achmad, and A. Kurniawan, "Student attendance with face recognition (LBPH or CNN): Systematic literature review," in *Procedia Computer Science*, Elsevier B.V., 2022, pp. 31–38. doi: 10.1016/j.procs.2022.12.108.
- [4] M. W. A. Kesiman, I. M. D. Maysanjaya, I. M. A. Pradnyana, I. M. G. Sunarya, and P. H. Suputra, "Profiling Balinese Dances with Silhouette Sequence Pattern Analysis," in *CENIM 2020 - Proceeding: International Conference on Computer Engineering, Network, and Intelligent Multimedia 2020*, Institute of Electrical and Electronics Engineers Inc., Nov. 2020, pp. 423–428. doi: 10.1109/CENIM51130.2020.9297893.
- [5] A. Fikri and A. Murni, "New Generation Indonesian Endemic Cattle Classification: MobileNetV2 and ResNet50," *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika*, vol. 9, no. 4, pp. 941–950, Oct. 2023, doi: 10.26555/jiteki.v9i4.26659.
- [6] Z. Bai, R. Zhu, D. He, S. Wang, and Z. Huang, "Adulteration Detection of Pork in Mutton Using Smart Phone with the CBAM-Invert-ResNet and Multiple Parts Feature Fusion," *Foods*, vol. 12, no. 19, Oct. 2023, doi: 10.3390/foods12193594.
- [7] J. Mantik, H. Fachri, and S. Simbolon, "Classification bootstrap resnet50 for potato diseases datasets," Online, 2024.
- [8] K. Dong, C. Zhou, Y. Ruan, and Y. Li, "MobileNetV2 Model for Image Classification," in *Proceedings - 2020 2nd International Conference on Information Technology and Computer Application, ITCA 2020*, Institute of Electrical and Electronics Engineers Inc., Dec. 2020, pp. 476–480. doi: 10.1109/ITCA52113.2020.00106.
- [9] Md. S. I. Prottasha, A. B. M. K. Hossain, Md. Z. Rahman, S. M. S. Reza, and D. A. Hossain, "Identification of Various Rice Plant Diseases Using Optimized Convolutional Neural Network,"

- International Journal of Computing and Digital Systems*, vol. 12, no. 7, pp. 1539–1551, Dec. 2022, doi: 10.12785/ijcds/1201124.
- [10] M. A. K. Raiaan *et al.*, “A systematic review of hyperparameter optimization techniques in Convolutional Neural Networks,” Jun. 01, 2024, Elsevier Inc. doi: 10.1016/j.dajour.2024.100470.
  - [11] L. J. E. Dewi, I. K. A. Seputra, N. K. Kertiasih, A. A. G. Y. Paramartha, and N. P. N. P. Dewi, “Pelatihan Sistem Informasi Produk Pertanian Berbasis Web Untuk Penyuluh Pertanian Lapangan Dinas Pertanian Buleleng,” in *Proceeding Senadimas Undiksha*, 2021.
  - [12] L. J. E. Dewi, I. N. S. W. Wijaya, and K. A. Seputra, “Web-based Buleleng regency agriculture product information system development,” *J Phys Conf Ser*, vol. 1810, no. 1, p. 012029, Mar. 2021, doi: 10.1088/1742-6596/1810/1/012029.
  - [13] L. J. E. Dewi, K. A. Seputra, and I. N. S. W. Wijaya, “PENGEMBANGAN APLIKASI MOBILE SISTEM INFORMASI PRODUK PERTANIAN KABUPATEN BULELENG,” *SINTECH (Science and Information Technology) Journal*, vol. 5, no. 1, pp. 66–74, Apr. 2022, doi: 10.31598/sintechjournal.v5i1.999.
  - [14] A. Usha Ruby, J. George Chellin Chandran, B. N. Chaithanya, T. J. Swasthika Jain, and P. Renuka, “Wheat Leaf Disease classification using modified ResNet50 Convolutional Neural Network model,” Oct. 11, 2022, doi: 10.21203/rs.3.rs-2130789/v1.
  - [15] N. Rachburee and W. Punlunjeak, “Lotus species classification using transfer learning based on VGG16, ResNet152V2, and MobileNetV2,” *IAES International Journal of Artificial Intelligence*, vol. 11, no. 4, pp. 1344–1352, 2022, doi: 10.11591/ijai.v11.i4.pp1344-1352.
  - [16] T. B. Shahi, C. Sitaula, A. Neupane, and W. Guo, “Fruit classification using attention-based MobileNetV2 for industrial applications,” *PLoS One*, vol. 17, no. 2 February, Feb. 2022, doi: 10.1371/journal.pone.0264586.
  - [17] B. J. Bipin Nair, B. Arjun, S. Abhishek, N. M. Abhinav, and V. Madhavan, “Classification of Indian Medicinal Flowers using MobileNetV2,” in *11th International Conference on Computing for Sustainable Global Development (INDIACom, IEEE)*, 2024.
  - [18] B. Sridhar *et al.*, “A Robust Approach to Medicinal Plant Classification through the ResNet50 Model,” vol. 14, no. 4, pp. 27–31, [Online]. Available: <https://open-instruction.com/dl-algorithms/overview-of-residual->
  - [19] D. S. Alwan and Mohammed. H. Naji, “Rice Diseases Classification by Residual Network 50 (RESNET50) and Support Vector Machine (SVM) Modeling,” *Journal of Kufa for Mathematics and Computer*, vol. 10, no. 1, pp. 96–101, Mar. 2023, doi: 10.31642/jokmc/2018/100114.
  - [20] C. C. Foong, G. K. Meng, and L. L. Tze, “Convolutional Neural Network based Rotten Fruit Detection using ResNet50,” in *2021 IEEE 12th Control and System Graduate Research Colloquium, ICSGRC 2021 - Proceedings*, Institute of Electrical and Electronics Engineers Inc., Aug. 2021, pp. 75–80. doi: 10.1109/ICSGRC53186.2021.9515280.
  - [21] R. Indraswari, R. Rokhana, and W. Herulambang, “Melanoma image classification based on MobileNetV2 network,” in *Procedia Computer Science*, Elsevier B.V., 2021, pp. 198–207. doi: 10.1016/j.procs.2021.12.132.
  - [22] S. Dou, L. Wang, D. Fan, L. Miao, J. Yan, and H. He, “Classification of Citrus Huanglongbing Degree Based on CBAM-MobileNetV2 and Transfer Learning,” *Sensors*, vol. 23, no. 12, Jun. 2023, doi: 10.3390/s23125587.
  - [23] J. Rashid, I. Khan, I. A. Abbasi, M. R. Saeed, M. Saddique, and M. Abbas, “A Hybrid Deep Learning Approach to Classify the Plant Leaf Species,” *Computers, Materials and Continua*, vol. 76, no. 3, pp. 3897–3920, 2023, doi: 10.32604/cmc.2023.040356.
  - [24] P. H. Suputra, A. D. Sensusiaty, M. D. Artaria, G. J. Verkerke, E. M. Yuniarno, and I. K. E. Purnama, “Automatic 3D Cranial Landmark Positioning based on Surface Curvature Feature using Machine Learning,” *Knowledge Engineering and Data Science*, vol. 5, no. 1, p. 27, Jun. 2022, doi: 10.17977/um018v5i12022p27-40.
  - [25] X. Du, Y. Sun, Y. Song, W. Chi, L. Dong, and X. Zhao, “Impact of Input Image Resolution on Deep Learning Performance for Side-Scan Sonar Classification: An Accuracy–Efficiency Analysis,” *Remote Sens (Basel)*, vol. 17, no. 14, p. 2431, Jul. 2025, doi: 10.3390/rs17142431.
  - [26] M. Alkanan and Y. Gulzar, “Enhanced corn seed disease classification: leveraging MobileNetV2 with feature augmentation and transfer learning,” *Front Appl Math Stat*, vol. 9, Jan. 2024, doi: 10.3389/fams.2023.1320177.
  - [27] S. Savaş, “Application of deep ensemble learning for palm disease detection in smart agriculture,” *Heliyon*, vol. 10, no. 17, p. e37141, Sep. 2024, doi: 10.1016/j.heliyon.2024.e37141.
  - [28] S. Mascarenhas and M. Agarwal, “A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for Image Classification,” in *Proceedings of IEEE International Conference on Disruptive Technologies for Multi-Disciplinary Research and Applications, CENTCON 2021*, Institute of Electrical and Electronics Engineers Inc., 2021, pp. 96–99. doi: 10.1109/CENTCON52345.2021.9687944.
  - [29] J. J. Luke, R. Joseph, and M. Balaji, “Impact of Image Size On Accuracy and Generalization of Convolutional Neural Networks,” *IJRAR19SP012 International Journal of Research and Analytical Reviews*, 2019, [Online]. Available: [www.ijrar.org](http://www.ijrar.org)
  - [30] F. B. Pasaribu, L. J. E. Dewi, K. Y. E. Aryanto, K. A. Seputra, P. Varnakovida, and N. K. Kertiasih, “Generating synthetic data on agricultural crops with DCGAN,” in *2024 11th International Conference on Advanced Informatics: Concept, Theory and Application (ICAICTA)*, IEEE, Sep. 2024, pp. 1–6. doi: 10.1109/ICAICTA63815.2024.10763158.
  - [31] N. P. N. P. Dewi and I. P. B. D. Purwanta, “Big Data for Indonesian Marine Fisheries A Preliminary Research Plan,” 2021