

# Analisis Penggunaan Pra-proses pada Metode *Transfer Learning* untuk Mendeteksi Penyakit Daun Singkong

## *Analysis of Pre-processing Use of Transfer Learning Methods for Cassava Leaves Diseases Detection*

Amelia Devi Putri A<sup>1</sup>, Salsabiil Hasanah<sup>2</sup>, M. Bahrul Subkhi<sup>3</sup>, Nanik Suciati<sup>4</sup>

<sup>1,2,3,4</sup>Departemen Teknik Informatika, Fakultas Teknologi Elektro dan Informatika Cerdas, Institut Teknologi Sepuluh Nopember, Surabaya

<sup>1</sup>Program Studi Sistem dan Teknologi Informasi, Fakultas Keperawatan, Bisnis dan Teknologi, Universitas Widy Husada, Semarang

E-mail: <sup>1</sup>ameliadev26@gmail.com, <sup>2</sup>salsabiilhasanah5@gmail.com, <sup>3</sup>bahruls27@gmail.com, <sup>4</sup>nanik@if.its.ac.id

### Abstrak

Singkong menjadi salah satu tanaman penting pada bidang agronomi dan banyak dikonsumsi oleh masyarakat. Namun, terdapat salah satu kendala dalam menjaga kelestarian tanaman singkong yaitu pendeteksian penyakit. Jika penyakit pada tanaman singkong dapat terdeteksi lebih dahulu melalui citra daunnya, maka penyakit tersebut dapat segera diobati. Proses klasifikasi dapat dilakukan untuk mendeteksi penyakit pada tanaman secara otomatis. Pada penelitian ini dilakukan klasifikasi tanaman singkong dengan menggunakan beberapa tahap pra-proses yaitu pra-proses dengan augmentasi, tanpa augmentasi dan pra-proses dengan rotasi, pada beberapa metode *transfer learning* seperti ResNet50 dan MobileNetV2. Penggunaan beberapa metode tersebut bertujuan untuk mencari metode mana yang memiliki hasil akurasi tertinggi. Penelitian menunjukkan bahwa MobileNetV2 dengan pra-proses rotasi memberikan akurasi tertinggi sebesar 92.50% dalam mendeteksi penyakit tanaman singkong. Hal ini dapat menjadi referensi bagi peneliti selanjutnya dalam menentukan tahap pra-proses terbaik dalam metode transfer learning.

Kata kunci: *Transfer learning*, Augmentasi, Rotasi, ResNet, MobileNet

### Abstract

*Cassava becomes one of the important crops in the agronomy field and is widely consumed by the community. However, there is one obstacle in maintaining the sustainability of cassava plants, namely plant disease detection. If the disease in cassava plants can be detected first through the image of the leaves, then the disease can be treated immediately. The classification process can be carried out to detect diseases in plants automatically. In this study, the classification of cassava plants was carried out using several pre-processing stages, namely pre-processing with augmentation, without augmentation and pre-processing with rotation, on several transfer learning methods such as ResNet50 and MobileNetV2. The use of several methods, aims to find which method has the highest accuracy results. Research shows that MobileNetV2 without augmentation provides the highest accuracy of 92.50% in detecting cassava plant diseases. This paper can be a reference for future researchers in determining the best pre-processing stage in the transfer learning method.*

Keywords: *Transfer learning*, Augmentation, Rotation, ResNet, MobileNet

## 1. PENDAHULUAN

Singkong (*Manihotesculenta Crantz*) merupakan salah satu tanaman yang penting pada bidang agronomi. Singkong juga merupakan sumber utama pangan yang sering dikonsumsi. Di Afrika, sebagian besar pertanian di Sub-Sahara menanam singkong. Hal tersebut dikarenakan

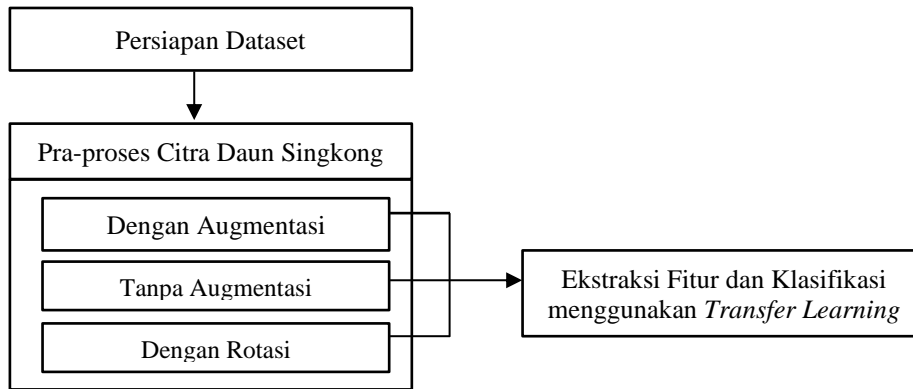
singkong menjadi tanaman pangan sebagai penyedia karbohidrat terbesar kedua di Afrika yang ditanam oleh para petani dan dapat bertahan dalam berbagai macam kondisi lingkungan [1]. Namun, adanya penyakit yang disebabkan oleh virus menjadikan hasil panen singkong yang buruk. Metode deteksi penyakit yang ada mengharuskan petani meminta bantuan ahli pertanian untuk memeriksa dan mendiagnosis tanaman secara visual. Permasalahan tersebut menjadi kendala bagi para petani karena membutuhkan tenaga tambahan dan biaya yang mahal [2]. Oleh karena itu, diperlukan pendekatan otomatis untuk mengidentifikasi penyakit umum pada tanaman singkong dengan mudah sehingga dapat diobati. Dalam hal ini, proses klasifikasi daun singkong sangat diperlukan untuk mengenali jenis daun yang memiliki penyakit dan jenis daun yang sehat. Klasifikasi tersebut dilakukan dengan tujuan agar daun yang memiliki penyakit dapat segera diobati dan tidak menimbulkan kerusakan lebih parah pada keseluruhan tanaman singkong yang dapat mempengaruhi hasil panen [3][4].

Penelitian sebelumnya menunjukkan bahwa klasifikasi daun merupakan topik yang penting untuk dibahas. Penelitian yang dilakukan oleh Sangbamrung et al. [5] melakukan klasifikasi penyakit tanaman dengan menggunakan metode *deep learning Faster R-CNN* dan memperoleh akurasi sebesar 91%. Pada penelitian Islam et al. [6] menggunakan proses rotasi untuk menyamakan posisi arah dari citra daun yang digunakan sebagai *input* program, kemudian dilanjutkan ke proses HOG dan LBP yang digunakan sebagai metode untuk ekstraksi fitur pada proses klasifikasi. Algoritma klasifikasi yang digunakan adalah SVM. Hasil akurasi dari penelitian tersebut yaitu sebesar 91.25%. Kemudian, penelitian yang dilakukan oleh Francis dan Deisy [7] menggunakan model *Convolutional Neural Network* untuk memprediksi apakah tanaman apel dan tomat terinfeksi penyakit atau tidak dengan menggunakan citra daun dari tanaman tersebut untuk diidentifikasi. Hasil akurasi dari penelitian tersebut adalah 87%. Pada penelitian Chen et al. [8] melakukan kombinasi metode *transfer learning Inception* dan DenseNet untuk mendeteksi penyakit tanaman padi dengan memperoleh akurasi sebesar 94.07%, sedangkan pada penelitian yang dilakukan oleh Ayu et al. [9] menggunakan MobileNetV2 untuk mendeteksi penyakit tanaman singkong dan diperoleh akurasi sebesar 65,6%. Berdasarkan beberapa penelitian yang sudah ada tersebut, sejauh ini belum ada yang membahas mengenai analisis performa penggunaan pra-proses pada metode *transfer learning*.


Oleh karena itu, penelitian ini akan membandingkan beberapa tahap pra-proses dengan menggunakan metode *transfer learning* yang berbeda, guna mendeteksi penyakit yang menyerang tanaman singkong dengan menggunakan citra daun untuk diidentifikasi. Beberapa tahap pra-proses yang akan dibandingkan adalah proses augmentasi, proses tanpa augmentasi dan proses rotasi, sedangkan pada tahap klasifikasi menggunakan metode ResNet50 dan MobileNetV2. Pada setiap tahap pra-proses yang berbeda, akan diproses menggunakan metode klasifikasi yang berbeda. Proses tersebut bertujuan untuk membandingkan hasil akurasi dari setiap metode yang digunakan, sehingga mampu membantu para peneliti selanjutnya dalam menentukan tahap pra-proses yang terbaik pada metode *transfer learning* dalam mendeteksi penyakit pada tanaman.

## 2. METODE PENELITIAN

Metode untuk mendeteksi penyakit pada tanaman singkong terdiri dari beberapa tahap seperti yang terlihat pada Gambar 1. Tahap pertama adalah persiapan dataset yang menjelaskan bagaimana data yang digunakan dalam penelitian ini diperoleh. Kemudian, dari data yang sudah didapatkan, dilanjutkan ke tahap pra-proses. Dikarenakan tujuan dari penelitian ini adalah memberikan analisis performa penggunaan pra-proses pada metode *transfer learning*, maka pada tahap pra-proses akan digunakan beberapa pra-proses yang berbeda, yaitu pra-proses dengan augmentasi, pra-proses tanpa augmentasi dan pra-proses dengan rotasi. Selanjutnya, dari beberapa tahap pra-proses tersebut akan dilanjutkan pada ekstraksi fitur dan sekaligus klasifikasi menggunakan metode *transfer learning* ResNet50 dan MobileNetV2. Penjelasan lebih detail tentang metode penelitian akan disampaikan pada beberapa sub bab selanjutnya.



Gambar 1 Alur metode penelitian yang digunakan



Gambar 2 Beberapa citra daun singkong dari masing-masing label dalam dataset: (a) CBB, (b)CBSD, (c) CGM, (d) CMD dan (e) sehat / *healthy*

## 2.1 Persiapan Dataset

Dataset diambil dari kompetisi Kaggle yang dibuat oleh *Makerere University Artificial Intelligence Lab*. Dataset tersebut berjumlah 21.367 citra daun singkong yang sudah berlabel dan dikumpulkan pada survei reguler di Uganda. Label yang terdapat dalam dataset tersebut, yaitu daun singkong yang memiliki penyakit *Cassava Bacterial Blight* (CBB), *Cassava Brown Streak Disease* (CBSD), *Cassava Green Mottle* (CGM), *Cassava Mosaic Disease* (CMD) dan yang terakhir adalah daun singkong yang sehat / *Healthy* [10].

Daun singkong yang memiliki penyakit CBB disebabkan oleh bakteri *Xanthomonas manihotis* dengan gejala kematian jaringan di tempat infeksi hingga kematian pada tunas. Penyakit CBSD disebabkan oleh virus *Bemisia tabaci*, yang menimbulkan bercak pada klorosis dan perkembangan sepia kering menjadi coklat, berbusa dan luka nekrotik pada jaringan umbi. CGM disebabkan oleh hama *Mononychellus tanajoa* yang memakan bagian bawah daun muda dan mengakibatkan daun menjadi belang-belang atau mati. Penyakit CMD diakibatkan oleh virus yang termasuk ke dalam genus *Begomovirus* yang menyebabkan daun memiliki campuran bercak klorosis berwarna kuning dan putih sehingga mempengaruhi proses fotosintesis dan menghambat pertumbuhan tanaman [11]. Gambar 2 menampilkan citra daun singkong dari berbagai label dalam dataset yang digunakan dalam penelitian ini.

## 2.2 Pra-proses

Melalui proses konversi citra original ke bentuk yang sesuai pada tahap pra-proses, klasifikasi citra dapat dioptimalkan dan performanya dapat ditingkatkan untuk langkah selanjutnya [12][13][14]. Dalam hal ini, dilakukan tiga percobaan pra-proses. Percobaan yang dilakukan pada penelitian ini yaitu pra-proses dengan augmentasi, pra-proses tanpa augmentasi dan pra-proses dengan rotasi.

### 2.2.1 Pra-proses dengan Augmentasi

Tahap ini bertujuan meningkatkan jumlah citra dalam *training set* supaya terhindar dari masalah *overfitting* dan dapat menghasilkan pembelajaran model yang lebih baik. Augmentasi citra dilakukan dengan memperkenalkan berbagai variasi tertentu pada citra daun singkong seperti *width shift*, *height shift*, *shear*, *zoom* dan *horizontal flip*.

### 2.2.2 Pra-proses Tanpa Augmentasi

Setelah dataset citra daun singkong didapatkan, citra langsung digunakan untuk klasifikasi penyakit tanaman singkong. Pada tahap ini, tidak dilakukan proses augmentasi, seperti *width shift*, *height shift*, *shear*, *zoom* dan *horizontal flip*, terlebih dahulu. Hal tersebut bertujuan untuk mengetahui bagaimana performa pra-proses tanpa maupun dengan augmentasi citra terhadap metode klasifikasi menggunakan *transfer learning*. Selain itu, memungkinkan tanpa adanya augmentasi dapat memberikan performa yang lebih baik, karena penambahan variasi atau augmentasi dapat memperlambat performa klasifikasi citra daun.

### 2.2.3 Pra-proses dengan Rotasi

Pra-proses dengan rotasi dilakukan tanpa menambahkan data baru, dimana data yang sudah ada langsung dilakukan rotasi. Tahapan rotasi ini bertujuan untuk menyamakan posisi dan arah dari citra daun yang digunakan sebagai *input* program. Selain itu, sudut rotasi yang digunakan juga bergantung pada posisi awal dari citra daun. Perhitungan dilakukan dengan mengukur jarak antara daun dan bingkai citra. Rumus yang digunakan dalam proses ini dapat dilihat pada persamaan (1).

$$[x \ y] = [\cos\theta \ -\sin\theta \ \sin\theta \ \cos\theta][X \ Y] + [t_x \ t_y] \quad (1)$$

Proses rotasi citra dilakukan tanpa perlu memberikan input sudut tertentu yang ditentukan sebelumnya. Dengan menggunakan metode yang telah ditentukan, kita dapat memperkirakan sudut rotasi daun dengan tepat pada citra yang diambil [15]. Terdapat beberapa tahapan yang harus dilakukan, yang pertama adalah mengubah *input* citra original ke bentuk *binary*. Proses tersebut dilakukan untuk mendeteksi keakuratan *contour* dari citra daun. Selanjutnya, masuk ke proses pendeteksian *contour* untuk mendapatkan perkiraan *contour* terbesar pada citra. Kemudian dilanjutkan dengan menghitung perkiraan sudut yang digunakan untuk merotasi citra daun. Penentuan sudut tersebut dilakukan dengan menemukan titik batas cembung citra dengan menggunakan *convex hull*, dimana terdapat sudut antara satu titik dengan dua titik disekitarnya dalam *contour* daun. Dari titik-titik tersebut akan dicari nilai minimal, yang nantinya akan digunakan sebagai nilai sudut dari rotasi citra daun yang digunakan.

## 2.3 Ekstraksi Fitur dan Klasifikasi

Untuk memecahkan permasalahan klasifikasi yang sedang dihadapi, diperlukan ekstraksi fitur yang relevan terlebih dahulu, seperti fitur pada citra yang berupa warna, bentuk maupun tekstur. Sebagian besar penelitian untuk mendeteksi penyakit tanaman yang menggunakan citra daun untuk diidentifikasi, cenderung fokus pada penggunaan fitur tekstur seperti metode *Grey-Level Co-occurrence Matrix* ataupun Transformasi Gabor [16]. Namun, dikarenakan *transfer learning* mampu menangani ekstraksi fitur secara otomatis, maka tidak perlu menggunakan metode ekstraksi fitur yang terpisah saat akan melakukan klasifikasi citra. Pada penelitian ini

digunakan metode *transfer learning* ResNet50 dan MobileNetV2 untuk ekstraksi fitur. Penggunaan kedua metode tersebut juga sekaligus dapat digunakan dalam proses klasifikasi citra daun singkong untuk mendeteksi penyakit yang menyerang pada tanaman singkong tersebut.

### 2.3.1 ResNet50

*Residual Networks* atau ResNet termasuk ke dalam *deep convolution networks* yang ide dasarnya adalah melewati blok pada *convolutional layers* dengan menggunakan *shortcut connections* [17]. Jadi, jaringan arsitektur pada ResNet50 bekerja berdasarkan pada banyaknya unit residu yang tertumpuk [18]. Unit tersebut terdiri dari *convolution layer*. Kemudian, *down sampling* dilakukan oleh *convolutional layers* yang memiliki *stride 2* dan *batch normalization* dilakukan tepat setelah setiap *convolution* dan sebelum *Rectified Linears Units (ReLU) activation*. Ketika *input* dan *output* memiliki dimensi yang sama maka *identity shortcut* digunakan. Namun, saat dimensi bertambah maka *projection shortcut* digunakan untuk mencocokkan dimensi melalui *1x1 convolution* atau disebut dengan *pointwise convolution*. Selanjutnya, jaringan/network pada ResNet berakhir pada 1000 *fully connected layers* dengan *softmax activation*. Jumlah total dari *weighted layers* adalah 50 dengan 23.534.592 parameter yang dapat dilatih (*trainable parameter*).

### 2.3.2 MobileNetV2

MobileNetV2 merupakan *convolution neural network* yang dikembangkan sebagai peningkatan dari MobileNetV1. Tujuan dari dilakukannya pengembangan tersebut adalah untuk menghindari hilangnya informasi dan meningkatkan kemampuan model [19]. Gambar 3 menunjukkan perubahan struktural dari MobileNetV1 ke MobileNetV2. Baik pada MobileNetV1 maupun MobileNetV2 masih mempertahankan *convolution* yang dapat dipisahkan sebagai lapisan inti dan parameter yang digunakan juga lebih sedikit daripada *full convolutional* [4].

Arsitektur jaringan MobileNetV2 yang digunakan pada penelitian ini terdiri dari *contracting path* (sisi kiri) dan *classifier head* (sisi kanan), seperti yang terlihat pada Gambar 4. *Contracting path* menggunakan *convolutional network* secara berulang yang terdiri dari dua *3x3 convolution*, diikuti dengan *Rectified Linear Unit (ReLU)*, dan operasi *2x2 max pooling* dengan *stride 2* untuk *down sampling*. *Convolution layers* akan mendapatkan jumlah bobot lokal (biasa disebut dengan *feature map*) disetiap *layers* dengan menghitung filter yang digunakan secara berulang kali, diseluruh kumpulan dataset citra daun singkong. Proses *3x3 convolution*, ReLU dan operasi *2x2 max pooling* biasa disebut dengan “*blocks*” akan dilakukan berulang kali hingga membuat suatu jaringan yang dalam dan menghasilkan satu set *fully connected layers* untuk tahap klasifikasi [20]. Block terakhir dari tahap MobileNetV2, berupa *feature map matrix*, akan dilakukan *flattened* (diratakan) menjadi bentuk vektor dan dimasukkan ke dalam *fully connected layers*. Selanjutnya, *activation function* berupa *softmax* digunakan untuk mengklasifikasikan citra daun singkong menjadi 5 label, yaitu penyakit CBB, CBSD, CGM, CMD atau kategori daun singkong yang sehat.

### 2.4 Evaluasi Performa

Perhitungan akurasi dilakukan untuk mengetahui hasil dari setiap metode yang digunakan. Hasil akhir yang akan ditampilkan yaitu berupa nilai akurasi dan nilai *loss*. Rumus yang digunakan untuk perhitungan akurasi dapat dilihat pada persamaan (2) dan perhitungan *loss* dapat dilihat pada persamaan (3). *Loss function* yang digunakan adalah *sparse categorical cross entropy* karena penelitian ini melakukan klasifikasi *multi-class* pada citra daun singkong [21]. Dari persamaan tersebut, nilai *n* merepresentasikan jumlah citra yang diklasifikasikan dengan benar dan *N* adalah jumlah total citra daun singkong. Nilai  $y_i$  adalah label yang benar,  $\hat{y}_i$  sebagai label prediksi, dan *w* adalah model parameter. Dari perhitungan akurasi ini, akan diketahui metode mana yang terbaik dalam proses klasifikasi daun singkong.

$$Akurasi = \frac{n}{N} \quad (2)$$

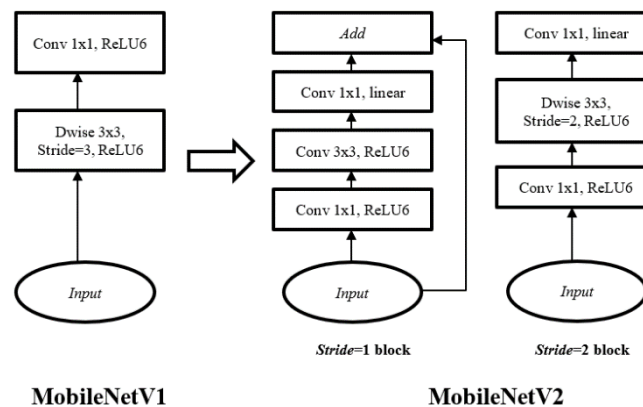
$$Loss(w) = -\frac{1}{n} \sum_{i=1}^n [y_i \log(y_i) + (1 - y_i) \log(\hat{y}_i)] \quad (3)$$

### 3. HASIL DAN PEMBAHASAN

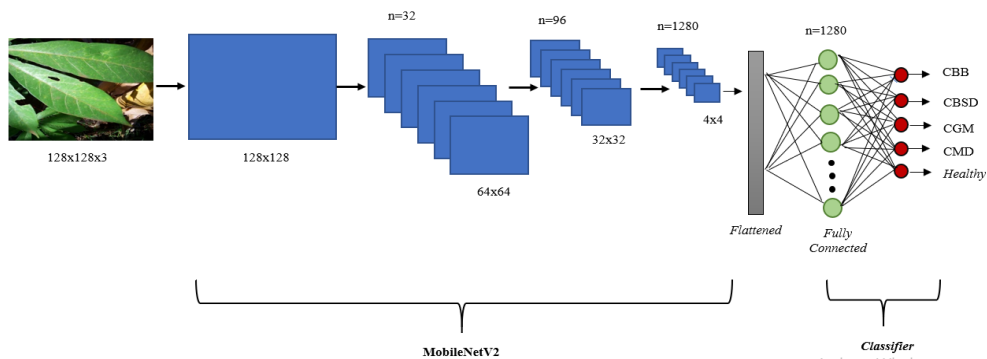
Hasil seluruh percobaan yang telah dilakukan akan dijelaskan pada bagian ini. Hasil uji coba proses klasifikasi digambarkan dalam bentuk grafik, dengan menunjukkan hasil akurasi dan hasil *loss* yang didapatkan. Jumlah dataset yang digunakan pada penelitian ini yaitu sebanyak 21.367 citra daun singkong. Dari seluruh dataset tersebut, citra akan dibagi menjadi 80% untuk *training set* dan 20% untuk *validation set*. Pembagian tersebut berguna untuk menggeneralisasi model yang sudah dibuat selama fase *training* berlangsung.

#### 3.1 Hasil Penggunaan Pra-proses

Pada percobaan dalam penelitian ini, citra daun singkong tersebut dinormalisasi terlebih dahulu untuk didapatkan citra daun berukuran sama semua pada keseluruhan dataset. Setelah didapatkan citra daun yang memiliki ukuran sama, kemudian diteruskan ke tahap pra-proses sesuai dengan skenario yang sudah dijelaskan pada metode penelitian. Beberapa tahap pra-proses yang dilakukan yaitu pra-proses dengan augmentasi, pra-proses tanpa augmentasi dan pra-proses dengan rotasi. Gambar 5 menunjukkan hasil percobaan dari pra-proses dengan rotasi. Gambar 5(a) merupakan citra original dari daun singkong, sedangkan Gambar 5(b) merupakan hasil dari pra-proses dengan rotasi. Dari hasil percobaan yang telah dilakukan, dapat terlihat bahwa posisi dari citra daun mengalami rotasi. Besarnya sudut rotasi pada citra daun tersebut didapatkan dari posisi awal dari daun singkong. Dengan adanya pra-proses tersebut, posisi seluruh data citra daun singkong yang digunakan menjadi sama. Gambar 6 menunjukkan hasil pra-proses dengan augmentasi maupun hasil pra-proses tanpa augmentasi.



Gambar 3 Perubahan struktural dari MobileNetV1 ke MobileNetV2



Gambar 4 Arsitektur jaringan MobileNetV2 yang digunakan



(a) (b)

Gambar 5 Percobaan pra-proses dengan rotasi: (a) Gambar asli (b) Hasil pra-proses dengan rotasi



(a) (b)

Gambar 6 Hasil percobaan: (a) Pra-proses tanpa augmentasi (b) Pra-proses dengan augmentasi

### 3.2 Hasil *Transfer Learning*

Proses selanjutnya yaitu melakukan *training* pada *convolutional neural network* menggunakan metode *transfer learning* ResNet50 dan MobileNetV2. *Batch size* dengan ukuran 16, *epoch* sebanyak 10, *softmax activation* dan Adam *optimizer* digunakan dalam penelitian ini. Kemudian, nilai akurasi dan *loss rate* yang didapatkan dicatat. Hasil nilai akurasi *training*, akurasi *validation*, waktu yang dibutuhkan per *step* selama fase *training* dan *loss rate* untuk setiap kombinasi metode pra-proses dan *transfer learning* ditunjukkan pada Tabel 1.

Tabel 1 Perbandingan Performa Penggunaan Pra-Proses Berbeda Pada Beberapa Metode *Transfer Learning*


Pra-proses	<i>Transfer Learning</i> Model	Akurasi <i>Training</i>	Akurasi <i>Validation</i>	Waktu yang dibutuhkan	<i>loss</i>
Dengan Augmentasi	ResNet50	0.7710	0.7856	699s 653ms/step	0.6515
	MobileNetV2	0.8641	0.8590	644s 602ms/step	0.3977
Tanpa Augmentasi	ResNet50	0.7871	0.7756	271s 253ms/step	0.5868
	MobileNetV2	0.9864	0.8403	292s 273ms/step	0.0595
Dengan Rotasi	ResNet50	0.8250	0.8000	767s 722ms/step	0.2032
	MobileNetV2	0.9750	0.9250	686s 622ms/step	0.4955

Berdasarkan Tabel 1 terlihat bahwa penggunaan metode MobileNetV2 pada beberapa

tahap pra-proses yang berbeda mampu menghasilkan nilai akurasi yang lebih tinggi dibandingkan dengan menggunakan metode ResNet50. Pada percobaan yang telah dilakukan, pra-proses dengan rotasi mampu menghasilkan nilai akurasi sebesar 97.5%. Namun, hasil tersebut bukan hasil tertinggi yang didapatkan pada fase *training*. Dengan menggunakan metode MobileNetV2 tanpa augmentasi mampu mendapatkan nilai akurasi yang paling tinggi diantara metode ResNet50 maupun metode MobileNetV2 dengan augmentasi atau dengan rotasi. Hasil akurasi yang didapatkan yaitu sebesar 98.64%. Selain itu, dengan menggunakan MobileNetV2 tanpa augmentasi juga mampu memperoleh *loss rate* yang kecil yaitu 0.0595. Waktu yang dibutuhkan per *step* selama fase *training* juga lebih sedikit daripada MobileNetV2 dengan augmentasi, yang mana hanya memakan waktu 292s. Hal ini disebabkan pada tahap pra-proses tanpa augmentasi tidak terjadi penambahan jumlah citra daun singkong dalam *training set* akibat adanya variasi tertentu pada citra tersebut oleh proses augmentasi itu sendiri seperti *width shift*, *height shift*, *shear*, *zoom* dan *horizontal flip*.


Selanjutnya, hasil metode MobileNetV2 tanpa augmentasi ini dibandingkan dengan hasil percobaan dari penelitian lain, seperti pada penelitian yang dilakukan oleh Ayu et al. [11] dan Ramcharan et al. [22]. Pada penelitian oleh Ayu et al. [11] melakukan deteksi penyakit pada tanaman singkong menggunakan metode *transfer learning* MobileNetV2. Dalam penelitian tersebut, menghasilkan akurasi sebesar 65.6%. Kemudian, pada penelitian yang dilakukan oleh Ramcharan et al. [22] menggunakan model *Convolutional Neural Network* untuk mendeteksi penyakit tanaman singkong. Pada penelitian tersebut, juga digunakan citra daun singkong dengan tingkat keparahan penyakit yang ringan, namun hanya mendapatkan akurasi 43.2% saja. Dari beberapa penelitian yang sudah ada tersebut, dapat membuktikan bahwa hasil percobaan yang telah dilakukan, dengan menggunakan metode MobileNetV2 tanpa augmentasi mampu memperoleh akurasi yang lebih tinggi yaitu sebesar 98.64%. Namun, terlihat bahwa nilai akurasi *training* yang diperoleh lebih tinggi daripada nilai akurasi *validation* sehingga terjadi perbedaan antara nilai akurasi *training* dengan nilai akurasi *validation* yang sangat jauh. Hal tersebut dikarenakan adanya kecenderungan *overfitting*. Berbeda dengan menggunakan tahap pra-proses augmentasi pada MobileNetV2, yang menunjukkan bahwa perbedaan antara nilai akurasi *training* dengan nilai akurasi *validation* menjadi cukup dekat, meskipun masih ada kecenderungan *overfitting*. Selain itu, dengan menggunakan pra-proses rotasi pada MobileNetV2 mampu memberikan nilai akurasi yang tinggi namun tetap masih ada kecenderungan *overfitting*. Oleh karena itu, akan lebih baik jika menambah jumlah epoch untuk mengatasi permasalahan *overfitting* tersebut pada pekerjaan selanjutnya.

### ResNet50




(a)





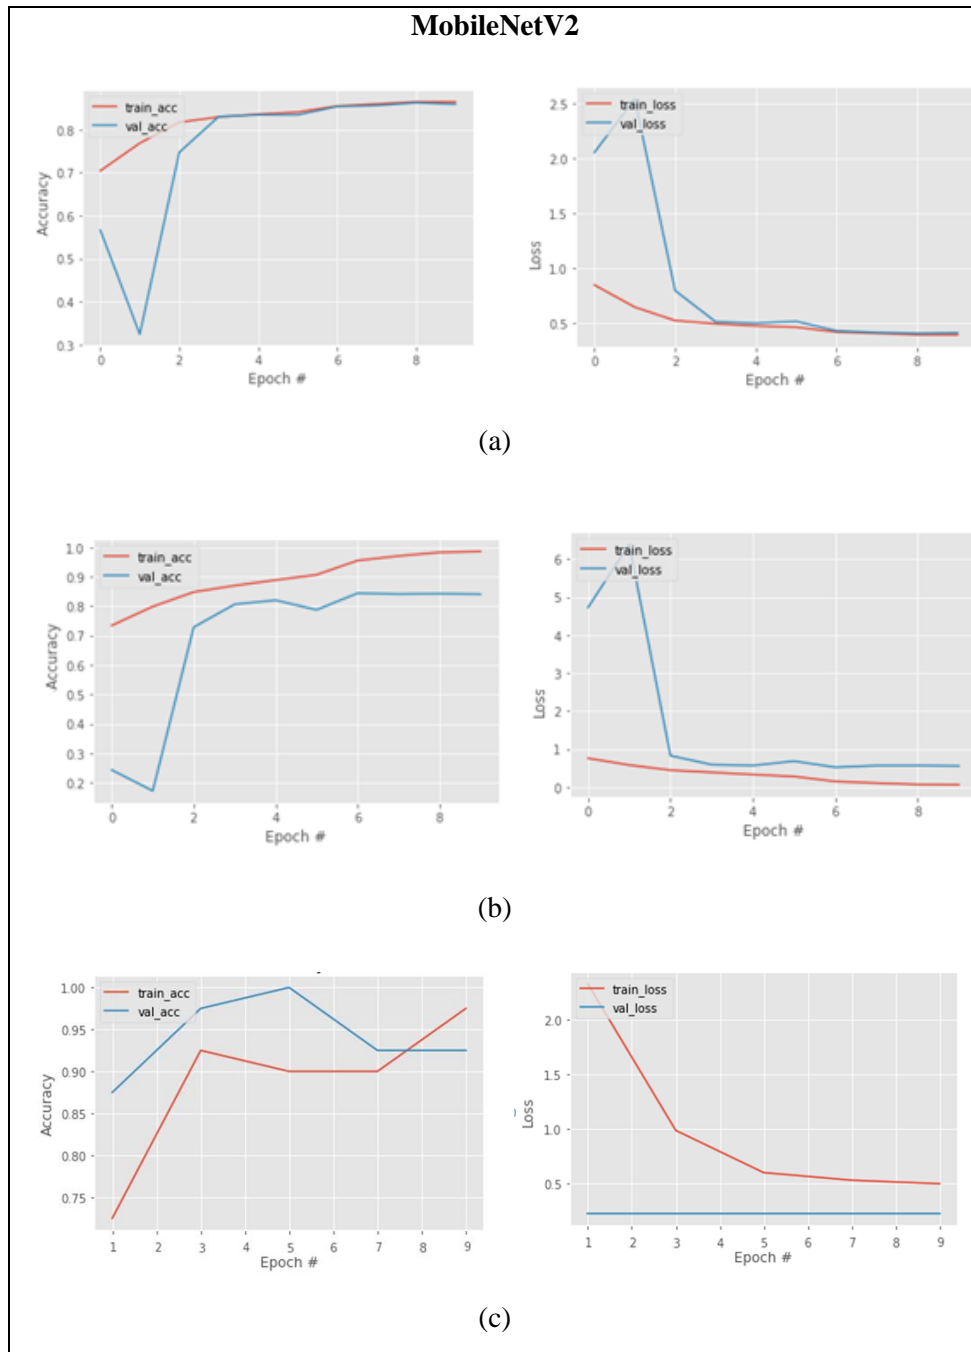
(b)



(c)

Gambar 7 Grafik perubahan akurasi dan *loss rate* dari ResNet50 menggunakan: (a) Pra-proses dengan augmentasi, (b) Pra-proses tanpa augmentasi, (c) Pra-proses dengan rotasi

Gambar 7 dan Gambar 8 menunjukkan perubahan akurasi dan *loss rate* dari ResNet50 dan MobileNetV2 selama fase *training*. Pada Gambar 8 terlihat bahwa metode MobileNetV2 tanpa augmentasi mampu mencapai tingkat keberhasilan tertinggi. *Loss rate* dan waktu konvergensi yang didapatkan juga lebih rendah jika dibandingkan dengan metode *transfer learning* maupun metode MobileNetV2 dengan tahap pra-proses lainnya. Pada percobaan dengan menggunakan ResNet50 menghasilkan nilai *loss rate* dan waktu konvergensi yang lebih tinggi. Namun, pada percobaan menggunakan metode ResNet50 dengan pra-proses augmentasi tidak terjadi *overfitting* karena terjadi peningkatan antara nilai akurasi *training* dengan nilai akurasi *validation*. Dengan demikian, berdasarkan uji coba dan analisis yang telah dilakukan, dapat memberikan kesimpulan dan pertimbangan, bahwa dengan menggunakan pra-proses augmentasi dan metode ResNet50 dapat mengurangi kecenderungan *overfitting*. Namun, hal tersebut juga memberikan *loss rate* yang tinggi dan membutuhkan waktu konvergensi yang cukup lama, sehingga perlu menjadi bahan pertimbangan untuk penelitian selanjutnya.



Gambar 8 Grafik perubahan akurasi dan *loss rate* dari MobileNetV2 menggunakan: (a) Pra-proses dengan augmentasi, (b) Pra-proses tanpa augmentasi, (c) Pra-proses dengan rotasi

#### 4. KESIMPULAN DAN SARAN

Penelitian ini berhasil membandingkan beberapa tahap pra-proses dengan menggunakan metode *transfer learning* yang berbeda guna mendeteksi penyakit yang menyerang tanaman singkong dengan menggunakan citra daun untuk diidentifikasi. Beberapa tahap pra-proses yang telah dilakukan adalah proses augmentasi, proses tanpa augmentasi dan proses rotasi. Kemudian dilanjutkan dengan tahap klasifikasi yang menggunakan dua metode yang berbeda yaitu metode ResNet50 dan MobileNetV2. Pada tahap pra-proses dengan augmentasi, diterapkan berbagai variasi tertentu pada citra seperti *width shift*, *height shift*, *shear*, *zoom* dan *horizontal flip*. Selain itu, pada pra-proses dengan rotasi telah dilakukan perubahan arah citra daun agar memiliki

posisi yang sama. Nilai sudut yang digunakan untuk mengubah arah akan berbeda-beda pada tiap citra, tergantung bagaimana posisi asli dari citra tersebut diambil. Selanjutnya, hasil dari beberapa pra-proses tersebut juga telah diteruskan ke proses klasifikasi dengan menggunakan metode ResNet50 dan MobileNetV2, serta sudah dibandingkan hasil akurasi, waktu yang dibutuhkan per *step* selama fase *training* dan *loss rate*.

Berdasarkan hasil percobaan menunjukkan bahwa selama fase *validation*, metode MobileNetV2 dengan pra-proses rotasi memiliki performa terbaik dengan memperoleh akurasi tertinggi yaitu sebesar 92.50%. Selama fase *training*, metode MobileNetV2 tanpa augmentasi menghasilkan *loss rate* yang kecil sebesar 0.0595 dan waktu konvergensi yang rendah juga didapatkan pada percobaan dalam penelitian ini. *Loss rate* dan waktu konvergensi yang rendah didapatkan karena pada tahap pra-proses tanpa augmentasi tidak terjadi penambahan jumlah citra daun singkong dalam *training set* akibat adanya variasi tertentu pada citra oleh proses augmentasi itu sendiri. Walaupun nilai akurasi dengan menggunakan pra-proses augmentasi dan metode ResNet50 lebih rendah, namun metode tersebut dapat mengurangi kecenderungan *overfitting*. Untuk lebih meningkatkan perfoma dari tugas klasifikasi citra, dapat dilakukan dengan menganalisis penggunaan *hybrid deep transfer learning* menggunakan *ensemble learning*. Percobaan tersebut dapat dilakukan pada penelitian yang akan dilakukan selanjutnya.

#### DAFTAR PUSTAKA

- [1] G. Sambasivam and G. D. Opiyo, "A predictive machine learning application in agriculture: Cassava disease detection and classification with imbalanced dataset using convolutional neural networks," *Egyptian Informatics Journal*, vol. 22, no. 1, pp. 27–34, 2021, doi: 10.1016/j.eij.2020.02.007.
- [2] K. P. Ferentinos, "Deep learning models for plant disease detection and diagnosis," *Comput Electron Agric*, vol. 145, no. January, pp. 311–318, 2018, doi: 10.1016/j.compag.2018.01.009.
- [3] A. Ramcharan, K. Baranowski, P. McCloskey, B. Ahmed, J. Legg, and D. P. Hughes, "Deep learning for image-based cassava disease detection," *Front Plant Sci*, vol. 8, no. October, pp. 1–7, 2017, doi: 10.3389/fpls.2017.01852.
- [4] 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: 10.1016/j.ecoinf.2020.101182.
- [5] I. Sangbamrung, P. Praneetpholkrang, and S. Kanjanawattana, "A novel automatic method for cassava disease classification using deep learning," *Journal of Advances in Information Technology*, vol. 11, no. 4, pp. 241–248, 2020, doi: 10.12720/jait.11.4.241-248.
- [6] M. A. Islam, M. Billah, and S. I. Yousuf, "Automatic Plant Detection Using HOG and LBP Features With SVM," *International Journal of Computer (IJC)*, vol. 33, no. 1, pp. 26–38, 2019.
- [7] M. Francis and C. Deisy, "Disease Detection and Classification in Agricultural Plants Using Convolutional Neural Networks - A Visual Understanding," *2019 6th International Conference on Signal Processing and Integrated Networks, SPIN 2019*, pp. 1063–1068, 2019, doi: 10.1109/SPIN.2019.8711701.
- [8] J. Chen, D. Zhang, Y. A. Nanekaran, and D. Li, "Detection of rice plant diseases based on deep transfer learning," *J Sci Food Agric*, vol. 100, no. 7, pp. 3246–3256, 2020, doi: 10.1002/jsfa.10365.
- [9] H. R. Ayu, A. Surtono, and D. K. Apriyanto, "Deep learning for detection cassava leaf disease," *J Phys Conf Ser*, vol. 1751, no. 1, 2021, doi: 10.1088/1742-6596/1751/1/012072.
- [10] Makerere University AI Lab, "Cassava Leaf Disease Classification," *Kaggle*, 2021. <https://www.kaggle.com/c/cassava-leaf-disease-classification> (accessed Apr. 27, 2023).
- [11] H. R. Ayu, A. Surtono, and D. K. Apriyanto, "Deep learning for detection cassava leaf disease," *J Phys Conf Ser*, vol. 1751, no. 1, 2021, doi: 10.1088/1742-6596/1751/1/012072.
- [12] I. Z. Mukti and D. Biswas, "Transfer Learning Based Plant Diseases Detection Using ResNet50," *2019 4th International Conference on Electrical Information and Communication Technology, EICT 2019*, no. December, pp. 1–6, 2019, doi: 10.1109/EICT48899.2019.9068805.

- [13] V. Kumar, H. Arora, Harsh, and J. Sisodia, "ResNet-based approach for Detection and Classification of Plant Leaf Diseases," *Proceedings of the International Conference on Electronics and Sustainable Communication Systems, ICESC 2020*, no. Icesc, pp. 495–502, 2020, doi: 10.1109/ICESC48915.2020.9155585.
- [14] K. P. Panigrahi, H. Das, A. K. Sahoo, and S. C. Moharana, "Maize Leaf Disease Detection and Classification Using Machine Learning Algorithms BT - Progress in Computing, Analytics and Networking," H. Das, P. K. Pattnaik, S. S. Rautaray, and K.-C. Li, Eds., Singapore: Springer Singapore, 2020, pp. 659–669.
- [15] X. Yin, X. Liu, J. Chen, and D. M. Kramer, "Multi-leaf alignment from fluorescence plant images," in *2014 IEEE Winter Conference on Applications of Computer Vision, WACV 2014*, 2014. doi: 10.1109/WACV.2014.6836067.
- [16] V. Kumar, H. Arora, Harsh, and J. Sisodia, "ResNet-based approach for Detection and Classification of Plant Leaf Diseases," *Proceedings of the International Conference on Electronics and Sustainable Communication Systems, ICESC 2020*, no. Icesc, pp. 495–502, 2020, doi: 10.1109/ICESC48915.2020.9155585.
- [17] E. Rezende, G. Ruppert, T. Carvalho, F. Ramos, and P. De Geus, "Malicious software classification using transfer learning of ResNet-50 deep neural network," *Proceedings - 16th IEEE International Conference on Machine Learning and Applications, ICMLA 2017*, vol. 2017-Decem, pp. 1011–1014, 2017, doi: 10.1109/ICMLA.2017.00-19.
- [18] S. Z. M. Zaki, M. A. Zulkifley, M. Mohd Stofa, N. A. M. Kamari, and N. A. Mohamed, "Classification of tomato leaf diseases using mobilenet v2," *IAES International Journal of Artificial Intelligence*, 2020, doi: 10.11591/ijai.v9.i2.pp290-296.
- [19] X. Liu, Z. Jia, X. Hou, M. Fu, L. Ma, and Q. Sun, "Real-time Marine Animal Images Classification by Embedded System Based on Mobilenet and Transfer Learning," *OCEANS 2019 - Marseille, OCEANS Marseille 2019*, vol. 2019-June, no. 61401244, 2019, doi: 10.1109/OCEANSE.2019.8867190.
- [20] M. Akay *et al.*, "Deep Learning Classification of Systemic Sclerosis Skin Using the MobileNetV2 Model," *IEEE Open J Eng Med Biol*, vol. 2, pp. 104–110, 2021, doi: 10.1109/OJEMB.2021.3066097.
- [21] M. K. Bayu, A. L. Prasasti, and D. Maryopi, "Analisis Performa Federated Learning Untuk Klasifikasi Gambar Yang Sensitif Terhadap Privasi Data," *e-Proceeding of Engineering*, vol. 9, 2022.
- [22] A. Ramcharan *et al.*, "A mobile-based deep learning model for cassava disease diagnosis," *Front Plant Sci*, vol. 10, no. March, pp. 1–8, 2019, doi: 10.3389/fpls.2019.00272.