

# Sistem Deteksi Penyakit Daun Singkong Menggunakan Deep Learning dengan Arsitektur MobilenetV3 berbasis Android

Diash Firdaus<sup>1</sup>, Idi Sumardi<sup>2</sup>, Rifky Rifatul Aziz<sup>3</sup>

[Diashfirdaus@gmail.com](mailto:Diashfirdaus@gmail.com)<sup>1</sup>, [idis@stmikjabar.ac.id](mailto:idis@stmikjabar.ac.id), [rifkyrifatulaziz@gmail.com](mailto:rifkyrifatulaziz@gmail.com)

<sup>1</sup>Institut Teknologi Nasional Bandung, <sup>2,3</sup>Universitas Al-Ghifari Bandung

---

## Abstract

*Cassava is a source of carbohydrates that is used as the main food in several regions such as Africa. The quality of Cassava can be seen from its leaves. So this study is based on 4 diseases that affect cassava yields, including Cassava Bacterial Blight (CBB), Cassava Brown Streak Disease (CBSD), Cassava Mosaic Disease (CMD), and Cassava Green Mottle (CGM). The algorithm used is CNN with Mobilenetv3 Architecture. MobilenetV3 is an Architecture from CNN that is good enough for the disease detection process in cassava leaves by having an accuracy of 88.78% and Validation with a score of 88.62% accuracy with MobilenetV3 has better accuracy compared to the EfficientNet-B7 architecture with an accuracy of 71.57% while with ConvNext small has an accuracy of 81.90%. This application for detecting diseases in cassava leaves is based on Android where the application can detect diseases in cassava leaves in real time. The method applied uses Deep Learning, which is a subfield of machine learning where the research stages used are dataset, preprocessing, model evaluation, embedding to Android App and testing.*

**Keywords:** CNN, Deep Learning, Mobilenetv3

## Abstrak

Singkong merupakan sumber karbohidrat yang dijadikan makanan utama di beberapa daerah seperti Afrika. Kualitas Singkong dapat dilihat dari daunnya sehingga penelitian ini didasarkan pada 4 penyakit yang mempengaruhi hasil singkong diantaranya, *Cassava Bacterial Blight (CBB)*, *Cassava Brown Streak Disease (CBSD)*, *Cassava Mosaic Disease (CMD)*, dan *Cassava Green Mottle (CGM)*. Algoritma yang digunakan adalah CNN dengan Arsitektur Mobilenetv3. MobilenetV3 merupakan Arsitektur dari CNN yang cukup baik untuk proses deteksi penyakit pada daun singkong dengan memiliki akurasi 88.78% dan Validasi dengan skor 88.62%, akurasi dengan MobilenetV3 memiliki akurasi yang lebih baik dibandingkan dengan arsitektur EfficientNet-B7 dengan akurasi 71.57% sedangkan dengan ConvNext small memiliki akurasi 81.90%. Aplikasi deteksi penyakit pada daun singkong ini berbasis android dimana aplikasi ini dapat mendeteksi penyakit pada daun singkong secara *realtime*. Metode yang diterapkan menggunakan *deep learning* yang merupakan subbidang dari *machine learning* dimana tahapan penelitian yang dipakai adalah dataset, *preprocessing*, evaluasi model, *embed to Android App* dan pengujian.

**Kata Kunci:** CNN, Deep Learning, Mobilenetv3

## Pendahuluan

Beberapa Tahun lalu, Algoritma CNN menjadi Algoritma yang banyak dikembangkan (Bougezzi et al., 2021). Algoritma CNN banyak dikembangkan untuk menyelesaikan masalah yang kompleks yang biasanya tidak bisa diselesaikan oleh Machine Learning (Suyanto et al., 2019).

Pada penelitian sebelumnya proses deteksi dan klasifikasi dapat dilakukan dengan menggunakan Decision Tree (Sahith et al., 2019), Support Vector Machine (Dandawate & Kokare, 2015) Naïve Bayes (Mohanapriya & Balasubramani, 2019) dan CNN (Manumpil et al., 2015) (Dan et al., 2019). CNN merupakan algoritma Deep Learning yang dapat menyelesaikan masalah deteksi dan klasifikasi dengan tingkat kompleksitas tinggi. Beberapa tahun akhir ini CNN mendapatkan penambahan performansi yang awalnya hanya bisa dilakukan pada dataset yang kecil saat ini CNN baik ketika digunakan pada dataset yang besar (Yoon et al., 2021).

Object detection merupakan bagian dari teknologi computer yang erat kaitannya dengan computer vision dan image processing. Dimana Komputer dapat melihat dan memproses Gambar atau video sehingga dapat mengenali barang yang dilihatnya (Dewi et al., 2019). Object detection menggunakan CNN banyak dilakukan di berbagai bidang, seperti deteksi jenis buah-buahan (Maulana & Rochmawati, 2020), deteksi penyakit kulit muka (Nurkhasanah & Murinto, 2021), deteksi penyakit daun teh (Ramdan et al., 2020), deteksi penyakit pada Tomat (Gunarathna & Rathnayaka, 2020), dan lain sebagainya. Sistem Deteksi Penyakit berbasis Deep learning dilakukan untuk mempermudah manusia dalam melakukan identifikasi dan monitoring terhadap objek (Dandawate & Kokare, 2015). Peningkatan CNN terjadi pada awal tahun 2012 dengan arsitektur Alexnet, dilanjutkan dengan VGG (Rani et al., 2022), GoogleNet, ResNet (Budhiman et al., 2019), Yolo (Li & Wang, 2020), dsb.

Singkong merupakan sumber karbohidrat yang dijadikan makanan utama dibeberapa daerah seperti afrika (Vijayalata Y et al., 2022) dan Indonesia (Muntoha et al., 2015). Kualitas Singkong dapat dilihat dari daunnya. Sehingga penelitian ini didasarkan pada 4 penyakit yang mempengaruhi hasil singkong diantaranya Cassava Bacterial Blight (CBB), Cassava Brown Streak Disease (CBSD), Cassava Mosaic Disease (CMD), dan Cassava Green Mottle (CGM).

Sistem Deteksi penyakit daun singkong ini dibangun berbasis mobile dengan algoritma MobileNetv3 (Qian, S., Ning, C., & Hu, 2021) untuk mempermudah user sehingga dapat dilakukan dimanapun dan kapanpun.

## Metode Penelitian

Metode penelitian ini membahas mengenai *Deep Learning*, *Convolutional Neural Network (CNN)*, *MobileNetv3*, dataset serta tahapan penelitian yang dilakukan peneliti.

### 1. *Deep Learning*

*Deep Learning* adalah subbidang dari *Machine Learning*. *Deep Learning* juga merupakan bagian dari *Artificial Intelligent* yang biasanya digunakan untuk

masalah masalah yang kompleks sebelumnya masalah komputasi sering diselesaikan oleh *machine learning* akan tetapi pada tahun 2012 mulai beralih kepada model *deep learning* (Suyanto et al., 2019).

## 2. *Convolutional Neural Network*

*Convolutional Neural Network* adalah algoritma dari *deep learning* yang terinspirasi dari proses biologi (Ilahiyah & Nilogiri, 2018). CNN dapat digunakan untuk melakukan klasifikasi atau sering disebut dengan *supervised learning*. CNN memiliki arsitektur dengan 3 dimensi, yaitu lebar, tinggi dan dalam (Zainab et al., 2022).

*Convolutional Neural Network (CNN)* adalah jenis arsitektur jaringan saraf yang biasa digunakan dalam pemrosesan gambar dan video. CNN dapat secara otomatis melakukan ekstraksi fitur dan mempelajari representasi dari input data. Arsitektur ini terdiri dari beberapa lapisan, masing-masing dengan tugas khusus dalam pembelajaran mesin.

Menurut (Yanagisawa et al., 2018) CNN memiliki tiga jenis layer yang umum digunakan yaitu *convolutional layer*, *pooling layer* dan *fully connected layer*. Tugas lapisan konvolusi adalah mengekstraksi fitur dari citra input menggunakan operasi konvolusi, sedangkan lapisan gabungan digunakan untuk memperkecil ukuran fitur yang dihasilkan oleh lapisan konvolusi. Terakhir, *fully connected layer* menggabungkan hasil ekstraksi fitur dari layer sebelumnya dengan *result layer*.

Selain itu, (Duvvuri et al., 2022) CNN telah banyak digunakan di beberapa bidang pemrosesan gambar dan video seperti deteksi objek, deteksi wajah, deteksi orang, segmentasi gambar dan banyak lainnya. Keuntungan dari arsitektur ini adalah kemampuan untuk mengekstrak fitur secara otomatis tanpa ekstraksi manual, memfasilitasi pemrosesan gambar dan video yang masif.

## 3. *MobileNetv3*

MobileNet merupakan sebuah arsitektur CNN yang didesain dengan 2 set *hyper-parameters* untuk membangun model yang kecil dan latensi rendah untuk kebutuhan efisiensi. MobileNet digunakan untuk kebutuhan *mobile* dan *embedded application* (Santoso & Ariyanto, 2018). MobileNetV3 merupakan pengembangan dari MobileNet dan MobileNetv2. MobileNetV3 memiliki 2 jenis model yaitu MobileNetv3 *Small* dan MobileNetv3 *Large* kedua model tersebut bisa dimanfaatkan untuk penggunaan sumber daya yang rendah ataupun sumberdaya tinggi. Untuk arsitektur dari MobileNetV3 small bisa dilihat pada Gambar 1 (Howard et al., 2019).

Input	Operator	exp size	#out	SE	NL	s
$224^2 \times 3$	conv2d, 3x3	-	16	-	HS	2
$112^2 \times 16$	bneck, 3x3	16	16	✓	RE	2
$56^2 \times 16$	bneck, 3x3	72	24	-	RE	2
$28^2 \times 24$	bneck, 3x3	88	24	-	RE	1
$28^2 \times 24$	bneck, 5x5	96	40	✓	HS	2
$14^2 \times 40$	bneck, 5x5	240	40	✓	HS	1
$14^2 \times 40$	bneck, 5x5	240	40	✓	HS	1
$14^2 \times 40$	bneck, 5x5	120	48	✓	HS	1
$14^2 \times 48$	bneck, 5x5	144	48	✓	HS	1
$14^2 \times 48$	bneck, 5x5	288	96	✓	HS	2
$7^2 \times 96$	bneck, 5x5	576	96	✓	HS	1
$7^2 \times 96$	bneck, 5x5	576	96	✓	HS	1
$7^2 \times 96$	conv2d, 1x1	-	576	✓	HS	1
$7^2 \times 576$	pool, 7x7	-	-	-	-	1
$1^2 \times 576$	conv2d 1x1, NBN	-	1280	-	HS	1
$1^2 \times 1280$	conv2d 1x1, NBN	-	k	-	-	1

Gambar 1. Arsitektur MobileNetV3 *Small*

MobileNetV3 juga memperkenalkan teknik baru, seperti penggunaan fungsi aktivasi *Swish* yang diketahui memiliki sifat non-linear yang lebih baik daripada fungsi aktivasi ReLU yang umum digunakan dalam model CNN. Selain itu, MobileNetV3 juga menggabungkan teknik optimasi lanjutan, seperti penggunaan algoritma pencarian arsitektur neural (*Neural Architecture Search* atau NAS), untuk mencari arsitektur model yang lebih optimal.

MobileNetV3 telah digunakan dalam berbagai aplikasi pengolahan gambar di perangkat *mobile*, seperti deteksi objek, pengenalan wajah, klasifikasi gambar, dan sebagainya. Model ini telah menjadi populer dalam komunitas penelitian dan industri karena kemampuannya dalam menyediakan solusi yang efisien dan akurat untuk pengolahan gambar di perangkat *mobile* dengan sumber daya terbatas. (Qian, S., Ning, C., & Hu, 2021).

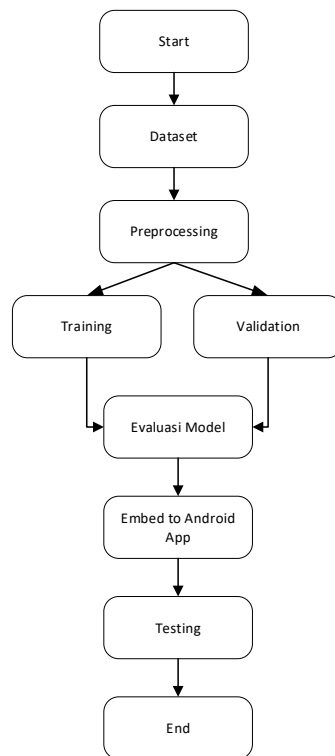
#### 4. Dataset

Dataset adalah sekumpulan data yang diorganisir sedemikian rupa sehingga memungkinkan pengolahan dan analisis menggunakan metode tertentu. Data dalam dataset dapat berupa data mentah atau data yang telah diolah sebelumnya. Beberapa contoh dataset yang sering digunakan adalah data survei, data medis, data keuangan, data penjualan, dan data citra. Setiap dataset biasanya terdiri dari beberapa variabel atau kolom yang mewakili aspek tertentu dari data tersebut, dengan setiap baris merepresentasikan observasi atau entitas yang berbeda.

Dataset yang digunakan untuk deteksi penyakit pada daun singkong adalah sebagai data yang bersumber dari (Kaggle, 2021).

#### 5. Tahapan Penelitian

Tahapan penelitian dimulai dari pencarian dataset. Dataset yang digunakan berasal dari (Kaggle, 2021). Tahapan penelitian bisa dilihat pada Gambar 2.



Gambar 2. Tahapan Penelitian

Proses selanjutnya adalah preprocessing, pada tahap ini *dilakukan Coverting image* dari 0-255 menjadi 0-1 menggunakan *tensorflow*. Selanjutnya membuat *tuples* dari gambar dan memberikan label. Setelah proses *preprocessing* selesai maka akan dilakukan *splitting*, proses ini membagi dataset menjadi data train dan data *validation*. Proses validasi akan menghasilkan evaluasi model berupa akurasi dengan perhitungan sebagai berikut:

$$Accuracy = ((TP+TN))/((TP+FP+FN+TN))$$

Selanjutnya Model akan disimpan dengan ekstensi *tflite*. *Tflite* merupakan alat yang dapat membantu *developer* dalam menjalankan model *machine learning* atau *deep learning* pada perangkat *IoT*, *Mobile* dan *embedded* (TensorFlow, 2022). Implementasi aplikasi android pada penelitian ini menggunakan *framework flutter* dengan Bahasa pemrograman *dart*. *Flutter* adalah *framework* pengembangan seluler *open source* yang dikembangkan oleh Google. *Flutter* menggunakan bahasa pemrograman *Dart* untuk membuat antarmuka pengguna yang indah, responsif, dan dikompilasi secara native untuk platform Android dan iOS. (Flutter, 2023). Pada tahap terakhir aplikasi akan ditest menggunakan Balckbox testing.


### Hasil dan Pembahasan

Pada hasil dan pembahasan, sistem deteksi penyakit pada daun singkong menggunakan MobileNetV3 akan dibandingkan dengan algoritma lain seperti ConvNext\_Small dan EfficientNet\_b7. Perbandingan akurasi dari ketiga algoritma bisa dilihat pada Tabel 1.

Table 1. Perbandingan Akurasi


Model	Akurasi	Validasi
ConvNext_Small	81.90%	82.28%
EfficientNet_b7	71.57%	71.70%
MobilenetV3	88.78%	88.62%

Sedangkan untuk Grafik dari Akurasi dan *Loss* dengan menggunakan MobilenetV3 bisa dilihat pada Gambar 3.



Gambar 3. Akurasi dan Loss Mobilenetv3

Selanjutnya untuk antarmuka dari aplikasi deteksi penyakit singkong berbasis Android bisa dilihat pada Gambar 3-5. Gambar 3 merupakan antarmuka *welcome screen*, Gambar 4. merupakan aplikasi android dapat mendeteksi penyakit pada daun singkong dan Gambar 5. merupakan aplikasi android dapat mendeteksi bahwa daun singkong sehat.



Gambar 4. Welcome Screen



Gambar 5. Deteksi Penyakit daun Singkong



Gambar 6. Deteksi Daun Singkong (Sehat)

## Kesimpulan

MobilenetV3 merupakan Arsitektur dari CNN yang cukup baik untuk proses deteksi penyakit pada daun singkong dengan memiliki akurasi 88.78% dan Validasi dengan skor 88.62%. akurasi dengan MobilenetV3 memiliki akurasi yang lebih baik dibandingkan dengan arsitektur EfficientNet-B7 dengan akurasi 71.57% sedangkan dengan ConvNext\_small memiliki akurasi 81.90%.

Deteksi Penyakit pada daun singkong menggunakan Mobilenetv3 memiliki akurasi yang cukup baik akan tetapi bisa penelitian selanjutnya bisa menggunakan arsitektur yang lebih terbaru seperti Yolov8 dan Yolo-nas.

## Daftar Pustaka

- Bouguezzi, S., Faiedh, H., & Souani, C. (2021). Slim MobileNet: An Enhanced Deep Convolutional Neural Network. *18th IEEE International Multi-Conference on Systems, Signals and Devices, SSD 2021*, 12–16. <https://doi.org/10.1109/SSD52085.2021.9429519>
- Budhiman, A., Suyanto, S., & Arifianto, A. (2019). Melanoma Cancer Classification Using ResNet with Data Augmentation. *2019 2nd International Seminar on Research of Information Technology and Intelligent Systems, ISRITI 2019*, 17–20. <https://doi.org/10.1109/ISRITI48646.2019.9034624>
- Dan, B., Sun, X., & Liu, L. (2019). Diseases and Pests Identification of Lycium Barbarum Using SE-MobileNet V2 Algorithm. *Proceedings - 2019 12th International Symposium on Computational Intelligence and Design, ISCID 2019, 1*, 121–125. <https://doi.org/10.1109/ISCID.2019.00034>
- Dandawate, Y., & Kokare, R. (2015). An automated approach for classification of plant diseases towards development of futuristic Decision Support System in Indian perspective. *2015 International Conference on Advances in Computing, Communications and Informatics, ICACCI 2015*, 794–799. <https://doi.org/10.1109/ICACCI.2015.7275707>
- Dewi, C., Chen, R. C., Hendry, & Liu, Y. T. (2019). Similar Music Instrument Detection via Deep Convolution YOLO-Generative Adversarial Network. *2019 IEEE 10th International Conference on Awareness Science and Technology, ICAST 2019 - Proceedings*, 1–6. <https://doi.org/10.1109/ICAwST.2019.8923404>
- Duvvuri, K., Kanisettypalli, H., & Jayan, S. (2022). Detection of Brain Tumor Using CNN and CNN-SVMNo Title. *2022 3rd International Conference for Emerging Technology (INCET)*.
- Flutter. (2023). *Flutter*. 18 April 2023
- Gunarathna, M. M., & Rathnayaka, R. M. K. T. (2020). Experimental determination of CNN hyper-parameters for tomato disease detection using leaf images. *ICAC 2020 - 2nd International Conference on Advancements in Computing*,

- Proceedings*, 464–469. <https://doi.org/10.1109/ICAC51239.2020.9357284>
- Howard, A., Sandler, M., Chen, B., Wang, W., Chen, L. C., Tan, M., Chu, G., Vasudevan, V., Zhu, Y., Pang, R., Le, Q., & Adam, H. (2019). Searching for mobileNetV3. *Proceedings of the IEEE International Conference on Computer Vision, 2019-October*, 1314–1324. <https://doi.org/10.1109/ICCV.2019.00140>
- Ilahiyah, S., & Nilogiri, A. (2018). Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network. *JUSTINDO (Jurnal Sistem Dan Teknologi Informasi Indonesia)*, 3(2), 49–56.
- Kaggle. (2021). *Cassava Dataset*. <https://www.kaggle.com/c/cassava-leaf-disease-classification/data>
- Li, Z., & Wang, J. (2020). An improved algorithm for deep learning YOLO network based on Xilinx ZYNQ FPGA. *Proceedings - 2020 International Conference on Culture-Oriented Science and Technology, ICCST 2020*, 447–451. <https://doi.org/10.1109/ICCST50977.2020.00092>
- Manumpil, B., Ismanto, Y., & Onibala, F. (2015). *hubungan penggunaan KB*. 3(April), 1–6.
- Maulana, F. F., & Rochmawati, N. (2020). Klasifikasi Citra Buah Menggunakan Convolutional Neural Network. *Journal of Informatics and Computer Science (JINACS)*, 1(02), 104–108. <https://doi.org/10.26740/jinacs.v1n02.p104-108>
- Mohanapriya, K., & Balasubramani, M. (2019). Recognition of Unhealthy Plant Leaves Using Naive Bayes Classifier. *IOP Conference Series: Materials Science and Engineering*, 561(1). <https://doi.org/10.1088/1757-899X/561/1/012094>
- Muntoha, Jamroni, & Ummayah, R. U. (2015). Pelatihan Pemanfaatan Dan Pengolahan Singkong Menjadi Makanan Ringan Tela Rasa. *Jurnal Inovasi Dan Kewirausahaan*, 4(3), 188–193.
- Nurkhasanah, & Murinto. (2021). Klasifikasi Penyakit Kulit Wajah Menggunakan Metode Convolutional Neural Network Classification of Facial Skin Diseases Using the Method of the Convolutional Neural Network. *Sainteks*, 18(2), 183–190. <https://www.kaggle.com/datasets>
- Qian, S., Ning, C., & Hu, Y. (2021). *MobileNetV3 for Image Classification*. *Icbaie*, 490–497.
- Ramdan, A., Heryana, A., Arisal, A., Kusumo, R. B. S., & Pardede, H. F. (2020). Transfer Learning and Fine-Tuning for Deep Learning-Based Tea Diseases Detection on Small Datasets. *Proceeding - 2020 International Conference on Radar, Antenna, Microwave, Electronics and Telecommunications, ICRAMET 2020*, 206–211. <https://doi.org/10.1109/ICRAMET51080.2020.9298575>

- Rani, S. J., Eswaran, S. U., Mukund, A. V. V., & Vidul, M. (2022). Driver Assistant System using YOLO V3 and VGGNET. *2022 International Conference on Inventive Computation Technologies (ICICT)*.
- Sahith, R., Reddy, P. V. P., & Nimmala, S. (2019). Decision Tree-based Machine Learning Algorithms to Classify Rice Plant Diseases. *International Journal of Innovative Technology and Exploring Engineering*, 9(1), 5365–5368. <https://doi.org/10.35940/ijitee.a4753.119119>
- Santoso, A., & Ariyanto, G. (2018). Implementasi Deep Learning berbasis Keras untuk Pengenalan Wajah. *Emitor: Jurnal Teknik Elektro*, 18(1), 15–21. <https://doi.org/10.23917/emitor.v18i01.6235>
- Suyanto, Ramadhani, K. N., & Mandala, S. (2019). *Deep Learning: Modernisasi Machine Learning untuk Big Data*. Informatika.
- TensorFlow. (2022). *TfLite*. <https://www.tensorflow.org/lite/guide>
- Vijayalata Y, Billakanti, N., Veeravalli, K., N, A. D. R., & Kota, L. (2022). Early Detection of Casava Plant Leaf Diseases using EfficientNet-B0. *2022 IEEE Delhi Section Conference (DELCON)*. <https://doi.org/10.1109/delcon54057.2022.9753210>
- Yanagisawa, H., Yamashita, T., & Watanabe, H. (2018). A study on object detection method from manga images using CNN. *2018 International Workshop on Advanced Image Technology, IWAIT 2018*, 1–4. <https://doi.org/10.1109/IWAIT.2018.8369633>
- Yoon, J., Hong, S., & Choi, M. K. (2021). Semi-Supervised Object Detection With Sparsely Annotated Dataset. *Proceedings - International Conference on Image Processing, ICIP, 2021-Septe*, 719–723. <https://doi.org/10.1109/ICIP42928.2021.9506790>
- Zainab, A. S. N., Soesanti, I., & Utomo, D. R. (2022). Detection of COVID-19 using CNN's Deep Learning Method: Review. *2022 4th International Conference on Biomedical Engineering (IBIOMED)*.