

# Penerapan Algoritma Convolutional Neural Network Dan Arsitektur MobileNet Pada Aplikasi Deteksi Penyakit Daun Padi

Rizal Amegia Saputra<sup>1</sup>, Sri Wasyanti<sup>2</sup>, Adi Supriyatna<sup>3</sup>, Dede Firmansyah Saefudin<sup>4</sup>

<sup>1,2,3,4</sup>Universitas Bina Sarana Informatika

e-mail: [rizal.rga@bsi.ac.id](mailto:rizal.rga@bsi.ac.id), [sri.siw@bsi.ac.id](mailto:sri.siw@bsi.ac.id), [adi.asp@bsi.ac.id](mailto:adi.asp@bsi.ac.id), [dede.dfs@bsi.ac.id](mailto:dede.dfs@bsi.ac.id)

## Abstract

Padi merupakan tanaman pangan penghasil beras, dan Indonesia merupakan negara yang mayoritas penduduknya menjadikan beras sebagai makanan utama, jumlah penduduk yang semakin meningkat, perlu menjaga kualitas padi agar resiko gagal panen dapat dihindari. Banyak faktor yang dapat menimbulkan resiko gagal panen salahsatunya itu penyakit daun padi, Pada penelitian ini diusulkan Algoritma Convolutional Neural Network untuk klasifikasi penyakit daun padi yang berdasarkan citra. Arsitektur yang digunakan pada penelitian ini menggunakan *MobileNetV1* dengan menggunakan ekstraksi fitur. Dataset berasal dari UCI Repository sebanyak 120 yang terdiri dari 3 penyakit daun padi yaitu Bacterial leaf blight, Brown spot, Leaf smut. Berdasarkan hasil pelatihan dan pengujian menggunakan citra penyakit daun padi yang berukuran 224x224 piksel didapat hasil nilai akurasi pelatihan mencapai 1.0 dan nilai akurasi validasi mencapai 0.8333. Nilai akurasi pada *Confusion Matrix* yaitu sebesar 92%, hasil ini menjadi bukti bahwa dengan penerapan algoritma CNN dan *MobileNetV1* dengan ekstraksi ciri memiliki akurasi yang baik sekali. Percobaan pada aplikasi yang dibangun hasil proses pengujian berbasis android terbukti dapat mengklasifikasikan jenis penyakit daun padi.

**Keywords:** CNN, Feature Extraction, Penyakit Daun Padi

## Abstract

*Rice is a rice-producing food crop, and Indonesia is a country where the majority of the population makes rice as the main food, the population is increasing, it is necessary to maintain the quality of rice so that the risk of crop failure can be avoided. Many factors that can pose a risk of crop failure one of them is rice leaf disease, in this study proposed Convolutional Neural Network Algorithm for the classification of rice leaf disease based on imagery. The architecture used in this study uses MobileNetV1 using feature extraction. Dataset comes from UCI Repository as many as 120 consisting of 3 rice leaf diseases namely Bacterial leaf blight, Brown spot, Leaf smut. Based on the results of training and testing using rice leaf disease imagery measuring 224x224 pixels, the results of training accuracy value reached 1.0 and validation accuracy value reached 0.8333. The accuracy value in the Confusion Matrix is 92%, this result is proof that with the penetration of CNN and MobileNetV1 algorithm with characteristic extraction has excellent accuracy. Experiments on applications built on the results of the android-based testing process proved to classify the type of rice leaf disease.*

**Keywords:** CNN, Feature Extraction, Rice Leaf Disease

## 1. Pendahuluan

Sektor pertanian merupakan sektor penting bagi pertumbuhan suatu negara (Isbah & Iyan, 2016). Pertanian padi merupakan tanaman pangan penghasil beras, dan beras salah satu komoditas utama bagi penduduk Asia dan negara tropis lainnya khususnya Indonesia. Oleh karena itu aspek kualitas dan kesehatan tanaman padi menjadi hal yang paling penting untuk menjaga hasil produktivitas tanaman padi.

Banyak faktor yang dapat menyebabkan gagal panen dalam produktivitas tanaman padi, salah satunya

yaitu hama dan penyakit daun padi (Soleh, 2020). Sebanyak 25% gagal panen padi disebabkan oleh penyakit daun padi (Nuryanto, 2018), untuk itu perlu upaya mengurangi resiko gagal panen dengan cara mendeteksi citra daun padi secara dini (Saputra et al., 2020).

Sebagian besar penyakit daun padi disebabkan oleh patogen/parasit, penyakit daun busuk, bakteri hawar daun dan bercak coklat merupakan penyakit yang paling banyak menyerang daun padi (Pothen & Pai, 2020). Penyakit padi yang paling umum adalah blas daun, bercak coklat, hawar

daun(Chawathe, 2020). Proses klasifikasi dalam mendeteksi citra penyakit daun padi perlu dibangun dalam sebuah aplikasi yang menerapkan metode *deep learning*, agar dengan mudah para petani pemula dapat dengan cepat mengetahui jenis penyakit daun padi tersebut. Banyak metode *deep learning* mampu menyeleksi fitur yang kompleks dan cepat namun algoritma *convolutional neural network (CNN)* merupakan algoritma yang paling efisien dalam mengekstraksi fitur(Rahman et al., 2020).

Penelitian terkait mengenai penyakit daun padi sudah banyak dilakukan sebelumnya, seperti penelitian (Saputra et al., 2020) klasifikasi penyakit daun padi menggunakan KNN dan ekstraksi fitur GLCM didapat akurasi 65.83% dan kappa 0.485, Penelitian (Jani & Noor, 2018) melakukan klasifikasi penyakit daun padi dengan ekstraksi fitur GLCM dan algoritma backpropagation didapat akurasi 80%. Penelitian (Phadikar & Sil, 2008) melakukan identifikasi penyakit daun padi menggunakan algoritma zooming dalam ekstrak gambar dan algoritma neural network menghasilkan klasifikasi penyakit daun padi dengan baik. Penelitian (Phadikar, Sil, & Das, 2013) klasifikasi penyakit daun padi dengan membandingkan dua algoritma yaitu Naive Bayes dan Support Vector Machine didapat akurasi sebesar 79,5% dan 68.1%, Penelitian (Minarni & Warman, 2017) membuat aplikasi sistem pakar identifikasi penyakit daun padi menggunakan algoritma CBR menghasilkan akurasi 82,69%. Penelitian (Yang et al., 2008) melakukan ekstrak fitur penyakit daun padi dengan algoritma Neural Network, penelitian ini menunjukkan bawah algoritma Neural Network dapat digunakan dalam klasifikasi penyakit daun padi.

Kebaharuan dalam penelitian ini akan membahas sebuah pengembangan dengan algoritma CNN dan arsitektur *MobileNet* dengan *feature extraction* dan *feature map*, *feature map* akan dapat indikasi klasifikasi beberapa penyakit daun padi yang dapat menyebabkan penurunan nilai makanan.

## 2. Metode Penelitian

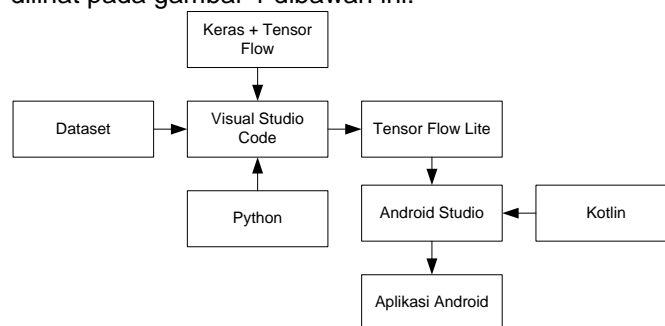
Pada metode penelitian ini dilaksanakan melalui beberapa tahapan yaitu:

- a. Proses Penyiapan dan Pre Proses Dataset

Pada tahap ini penyiapan dan pre-proses dataset dilakukan dengan mengambil gambar dari UCI repository <https://archive.ics.uci.edu/ml/datasets/Rice+Leaf+Diseases>, obyek data terdiri dari tiga macam jenis penyakit yaitu Bacterial leaf blight, Brown Spot, Leaf Smut.

- b. Desain Arsitektur

Dan berikut desain arsitektur dapat dilihat pada gambar 1 dibawah ini:



Gambar 1 Desain Arsitektur Sistem

Proses awal tahap desain arsitektur sistem ini yaitu menyiapkan dataset, dan membuat kode sumber untuk aplikasi menggunakan CNN dan mengimport framework keras dan *tensorflow* pada aplikasi visual studio code disimpan dengan format *.ipynb*, sistem yang dibangun menggunakan model CNN ini menggunakan arsitektur *mobileNetV1*, kemudian metode *transfer learning* dengan mengambil file keras *.h5* dimana sebelumnya sudah dilatih, setelah itu melakukan *feature extraction* pada file tersebut, dan sebagai tambahan untuk klasifikasi luaran pada aplikasi yang akan dibangun ditambah *feature map*.

- c. Pengujian

Pada tahap terakhir yaitu pengujian, seluruh dataset pelatihan dilatih pada arsitektur jaringan CNN yang digunakan dengan *epochs* yang diuji yaitu nilai 100. Kemudian dataset pengujian diekstrak dan dibandingkan hasilnya dengan data pengujian untuk melakukan prediksi pada klasifikasi jenis penyakit daun padi.

Setelah pengujian selesai maka hasil pelatihan dikonversi ke dalam format *TensorFlow Lite* dengan *extension .tflite*. Kemudian membangun program pada Android Studio dan memasukan file *.tflite* kedalam folder assets pada direktori project Android Studio tersebut. Setelah program di-build menjadi file *.apk*, maka aplikasi Android klasifikasi tiga jenis penyakit daun padi tersebut pada smartphone Android.

### 3. Hasil dan Pembahasan

#### 3.1. Hasil pelatihan dan pengujian

Pelatihan dan pengujian pada *Software Visual Studio Code* berfungsi untuk melatih dataset dan memperoleh modelnya serta melakukan pengujian dari hasil pelatihan tersebut.

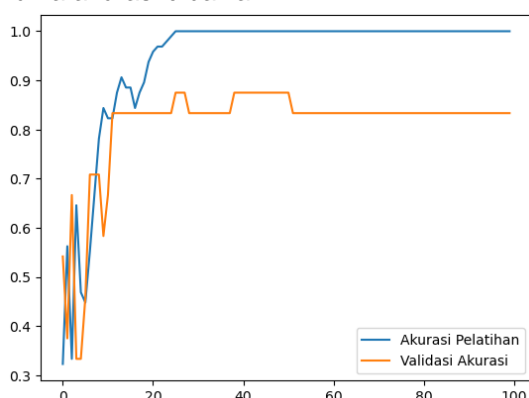
Pada penelitian ini proses pelatihan menggunakan 100 *Epochs* dan hasilnya dapat dilihat dibawah ini:

```
Epoch 1/100
1/1 [-----] - 14s 15s/step - loss: 1.7020 - acc: 0.3229 - val_loss: 4.4719 - val_acc: 0.5417
Epoch 2/100
1/1 [-----] - 10s 10s/step - loss: 4.7723 - acc: 0.5625 - val_loss: 7.4200 - val_acc: 0.3750
Epoch 3/100
1/1 [-----] - 10s 10s/step - loss: 6.8314 - acc: 0.3333 - val_loss: 2.9137 - val_acc: 0.6667
Epoch 4/100
1/1 [-----] - 10s 10s/step - loss: 2.6874 - acc: 0.6458 - val_loss: 2.2630 - val_acc: 0.3333
Epoch 5/100
1/1 [-----] - 9s 9s/step - loss: 2.4124 - acc: 0.4688 - val_loss: 1.6385 - val_acc: 0.3333
Epoch 6/100
1/1 [-----] - 9s 9s/step - loss: 1.6626 - acc: 0.4479 - val_loss: 0.8248 - val_acc: 0.4583
Epoch 7/100
1/1 [-----] - 9s 9s/step - loss: 0.8292 - acc: 0.5521 - val_loss: 0.6911 - val_acc: 0.7883
Epoch 8/100
1/1 [-----] - 9s 9s/step - loss: 0.6221 - acc: 0.6667 - val_loss: 0.7514 - val_acc: 0.7883
Epoch 9/100
1/1 [-----] - 10s 10s/step - loss: 0.6530 - acc: 0.7812 - val_loss: 0.7753 - val_acc: 0.7883
Epoch 10/100
1/1 [-----] - 11s 11s/step - loss: 0.6848 - acc: 0.8438 - val_loss: 0.7610 - val_acc: 0.5833
Epoch 11/100
1/1 [-----] - 11s 11s/step - loss: 0.6784 - acc: 0.8229 - val_loss: 0.7275 - val_acc: 0.6667
Epoch 12/100
1/1 [-----] - 10s 10s/step - loss: 0.6327 - acc: 0.8229 - val_loss: 0.6875 - val_acc: 0.8333
Epoch 13/100
1/1 [-----] - 12s 12s/step - loss: 0.6011 - acc: 1.0000 - val_loss: 0.5983 - val_acc: 0.8333
Epoch 99/100
1/1 [-----] - 11s 11s/step - loss: 0.6010 - acc: 1.0000 - val_loss: 0.6007 - val_acc: 0.8333
Epoch 100/100
1/1 [-----] - 10s 10s/step - loss: 0.6010 - acc: 1.0000 - val_loss: 0.6030 - val_acc: 0.8333
```

Gambar 2 Hasil Proses *Epochs*

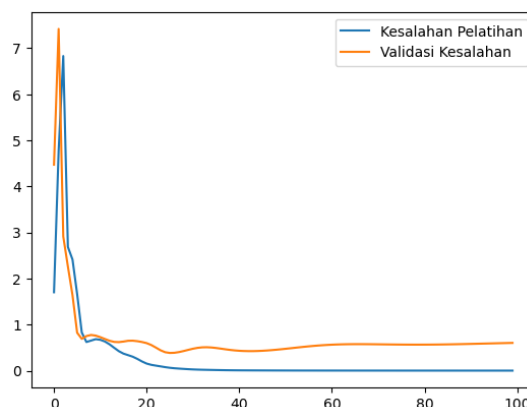
Berdasarkan hasil pelatihan dengan 100 *epochs* dapat dilihat bahwa hasil pelatihan dan validasinya semakin meningkat mendekati nilai 1.0 seiring bertambahnya *epochs*. Pada nilai *epochs* 100 nilai akurasi pelatihan mencapai 1.0 dan nilai akurasi validasi mencapai 0.8333. Dan nilai kesalahan pada saat proses pelatihan yaitu 0.0010, sedangkan nilai validasi kesalahan yaitu sebesar 0.6030. Sehingga nilai validasi kesalahan lebih tinggi dibandingkan nilai kesalahan proses pelatihan, hal ini akan terjadi *overfitting*.

Pada hasil pelatihan dan pengujian pada arsitektur *mobilenetV1* didapat hasil kurva akurasi dibawah ini:



Gambar 3 Kurva akurasi hasil pelatihan

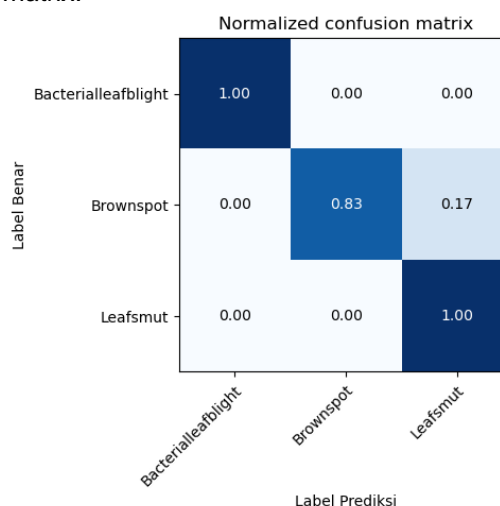
Dan kurva kesalahan selama proses pelatihan dapat dilihat pada gambar 4 dibawah ini:



Gambar 4 Kurva tingkat kesalahan hasil pelatihan

#### 3.2. Hasil Validasi *Confusion Matrix*

Hasil pelatihan *confusion matrix* yang digunakan untuk mengetahui tingkat keberhasilan dan kegagalan pada pengujian yang dilakukan. Berikut hasil *confusion matrix*:




Gambar 5 *Confusion Matrix* Hasil Pengujian

Berdasarkan *confusion matrix* dari hasil pengujian tersebut dapat disimpulkan bahwa hasil prediksi berlabel benar dari jenis penyakit daun *Bacterial leaf blight* memiliki nilai 1.0 hasil prediksi berlabel benar pada jenis penyakit *Brown Spot* bernilai 0.83 dan hasil prediksi berlabel benar pada jenis penyakit *Leaf Smut* yaitu dengan nilai 1.0. Dan terdapat 0.17 terjadi kesalahan prediksi yaitu pada jenis penyakit *Brown Spot*.

#### 3.3. Hasil Pengujian Pada Aplikasi Berbasis Android

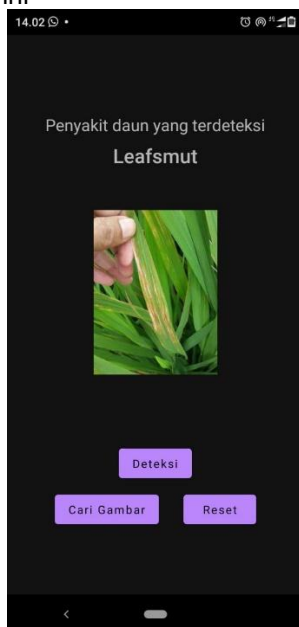
Aplikasi yang dibangun yaitu aplikasi berbasis android dengan menerapkan

algoritma CNN dan arsitektur *MobileNetV1* dapat dilihat pada gambar dibawah ini:



Gambar 6 Aplikasi Andorid Deteksi Penyakit Daun Padi

Penggunaan aplikasi yang sudah dibangun ketika dijalankan, pertamakali akan muncul seperti gambar 6, klasifikasi gambar pertama dimasukan dengan menekan tombol cari gambar, ketika di pilih gambar penyakit daun padi maka akan muncul jenis penyakit daun padi, seperti gambar 7 dibawah ini



Gambar 7 Hasil Klasifikasi Penyakit Daun Padi

#### 4. Kesimpulan

Klasifikasi gambar jenis penyakit daun padi menggunakan algoritma CNN dengan arsitektur *MobileNetV1* dan *Feature*

*Extraction* memiliki akurasi yang baik sekali yaitu sebesar 92% namun dengan jumlah data cukup kecil dan penggunaan *epochs* yaitu 100, mengakibatkan nilai validasi kesalahan lebih tinggi dibandingkan nilai kesalahan pada proses pelatihan, sehingga akan terjadi *overfitting*.

Saran pada penelitian selanjutnya yaitu perlu adanya optimasi agar tidak terjadi *overfitting* dan aplikasi yang dibangun berbasis android perlu dikembangkan agar dapat mendeteksi secara *realtime*, sehingga pengguna aplikasi tidak perlu menekan tombol deteksi.

#### Referensi

- Chawathe, S. S. (2020). Rice Disease Detection by Image Analysis. *2020 10th Annual Computing and Communication Workshop and Conference, CCWC 2020*, 524–530. <https://doi.org/10.1109/CCWC47524.2020.9031140>
- Isbah, U., & Iyan, R. Y. (2016). Analisis Peran Sektor Pertanian Dalam Perekonomian Dan Kesempatan Kerja Di Provinsi Riau. *Jurnal Sosial Ekonomi Pembangunan*, (19), 45–54.
- Jani, K., & Noor, A. H. (2018). Klasifikasi Penyakit Daun Padi Berdasarkan Hasil Ekstraksi Fitur GLCM Interval 4 Sudut. *Jurnal Teknologi Informasi Dan Komunikasi (JTik) STMIK ProVisi Semarang*, 03(01), 1–6. Retrieved from <https://ejournal.poltektegal.ac.id/index.php/informatika/article/view/669/632>
- Minarni, & Warman, I. (2017). Sistem Pakar Identifikasi Penyakit Tanaman Padi Menggunakan Case-Based Reasoning. *Seminar Nasional Aplikasi Teknologi Informasi*, (5 Agustus 2017 ISSN: 1907 – 5022), 28–32.
- Nuryanto, B. (2018). Pengendalian Penyakit Tanaman Padi Berwawasan Lingkungan Melalui Pengelolaan Komponen Epidemik. *Jurnal Penelitian Dan Pengembangan Pertanian*, 37(1), 1. <https://doi.org/10.21082/jp3.v37n1.2018.p1-8>
- Phadikar, S., & Sil, J. (2008). Rice disease identification using pattern recognition techniques. *Proceedings of 11th International Conference on Computer and Information Technology, ICCIT 2008*, (Iccit), 420–423. <https://doi.org/10.1109/ICCITECHN.2008.420>

- 08.4803079  
Phadikar, S., Sil, J., & Das, A. K. (2013). Rice diseases classification using feature selection and rule generation techniques. *Computers and Electronics in Agriculture*, *90*, 76–85. <https://doi.org/10.1016/j.compag.2012.11.001>
- Pothen, M. E., & Pai, D. M. L. (2020). Detection of Rice Leaf Diseases Using Image Processing. *Proceedings of the 4th International Conference on Computing Methodologies and Communication, ICCMC 2020*, (Iccmc), 424–430. <https://doi.org/10.1109/ICCMC48092.2020.ICCMC-00080>
- Rahman, C. R., Arko, P. S., Ali, M. E., Iqbal Khan, M. A., Apon, S. H., Nowrin, F., & Wasif, A. (2020). Identification and recognition of rice diseases and pests using convolutional neural networks. *Biosystems Engineering*, *194*(August 2019), 112–120. <https://doi.org/10.1016/j.biosystemsen>
- g.2020.03.020  
Saputra, R. A., Suharyanto, Wasianti, S., Saefudin, D. F., Supriyatna, A., & Wibowo, A. (2020). Rice Leaf Disease Image Classifications Using KNN Based on GLCM Feature Extraction. *Journal of Physics: Conference Series*, *1641*(1). <https://doi.org/10.1088/1742-6596/1641/1/012080>
- Soleh, M. I. (2020). Penggunaan Pestisida Dalam Perspektif Produksi dan Keamanan Pangan. Retrieved from Kementrian Pertanian website: <http://tanamanpangan.pertanian.go.id/index.php/iptek/16>
- Yang, J. H., Liu, H. X., Zhu, G. M., Pan, Y. L., Xu, L. P., & Guo, J. H. (2008). Diversity analysis of antagonists from rice-associated bacteria and their application in biocontrol of rice diseases. *Journal of Applied Microbiology*, *104*(1), 91–104. <https://doi.org/10.1111/j.1365-2672.2007.03534.x>