

---

## **KLASIFIKASI PENYAKIT TANAMAN PADA DAUN KENTANG DENGAN METODE CONVOLUTIONAL NEURAL NETWORK ARSITEKTUR MOBILENET**

**Putri Teresia Ompusunggu**

Fakultas Teknik Elektro, Universitas Telkom

Email: [putriteresiaompusunggu@gmail.com](mailto:putriteresiaompusunggu@gmail.com)

### **Abstract**

*Agriculture is very important for humans because it directly affects food production. One of the food products that is consumed by the community is Potato. Potatoes are not only consumed as a staple food but can also be used as a basic ingredient for making snacks. With the current production of potatoes, it is increasingly difficult for farmers to check the quality and quantity of potatoes. Potato leaf disease is one of the factors that affect potato quality. The rapid growth of technology today makes humans create Artificial Intelligence (AI). AI can also be referred to as artificial intelligence in machine technology that implements human intelligence. AI-based on Deep Learning for the classification process of image processing using the Convolutional Neural Network method has superior performance. Using one of the architectures, namely MobileNet, has the advantages of low cost, stability, and high precision. This study will classify the disease on potato leaves, namely early blight, late blight and healthy. By using the CNN method of the MobileNet architecture, there are four test scenarios to get the best results. The best results from each scenario using the RMSprop optimizer, learning rate 0.0001, epochs 50 and batch size 32 obtained 97,90% accuracy and 0.0390 loss.*

**Keyword:** *Classification of potato leaves, Convolutional Neural Network, Mobilenet*

### **Abstrak**

Pertanian merupakan hal yang sangat penting bagi manusia karena secara langsung berhubungan dengan produksi pangan. Salah satu produksi pangan yang dikonsumsi masyarakat adalah kentang. Kentang tidak hanya dikonsumsi sebagai makanan pokok tetapi dapat juga dijadikan bahan dasar untuk membuat cemilan. Dengan banyaknya yang produksi kentang saat ini maka semakin sulit untuk petani dalam memeriksa kualitas dan kuantitas kentang. Penyakit pada daun kentang merupakan salah satu faktor yang mempengaruhi kualitas kentang. Pertumbuhan pesat teknologi saat ini membuat manusia menciptakan Artificial Intelligence (AI). AI juga dapat disebut sebagai kecerdasan buatan pada teknologi mesin yang mengimplementasikan kecerdasan manusia. AI yang didasari oleh Deep Learning untuk proses klasifikasi pengolahan citra menggunakan metode Convolutional Neural Network memiliki kinerja yang lebih unggul. Dengan menggunakan salah satu arsitektur yaitu MobileNet yang memiliki kelebihan low cost, stable dan high precision. Penelitian ini akan melakukan klasifikasi penyakit pada daun kentang yaitu early blight, late blight dan healthy. Dengan menggunakan metode CNN arsitektur MobileNet terdapat empat skenario pengujian untuk mendapatkan hasil terbaik. Hasil terbaik

dari setiap skenario menggunakan optimizer RMSprop, learning rate 0,0001, epochs 50 dan batch size 32 memperoleh akurasi 97,90% dan loss 0,0390.

**Kata Kunci:** Klasifikasi daun kentang, Convolutional Neural Network, MobileNet

Diserahkan: 20-08-2022

Diterima: 05-09-2022

Diterbitkan: 14-09-2022

## PENDAHULUAN

Kentang (*Solanum Tuberosum* L.) adalah salah satu tanaman yang sangat diminati dalam sektor pertanian dunia. Setelah jagung, gandum dan beras, kentang merupakan salah satu sumber pangan utama terpenting keempat di dunia (Muhibuddin, 2016). Kentang dapat didefinisikan sebagai tanaman yang krusial karena dapat digunakan sebagai sumber karbohidrat untuk makanan pokok dan produk industri dalam membuat keripik kentang (potato chips) (Hidayah, Izzati, & Parman, 2017). Selain itu, kentang juga memiliki nilai gizi yang tinggi karena mengandung mineral, protein, lemak dan vitamin yang dapat dijadikan sebagai sumber energi (Koch, Naumann, Pawelzik, Gransee, & Thiel, 2020). Di pertanian dunia kentang telah ditanam lebih dari 18,9 juta hektar sehingga pada tahun 2020 kentang dipromosikan sebagai makanan pokok di negara Cina (Wang & Xiao, 2021).

Untuk menjamin kualitas kentang sebagai salah satu sumber pangan yang penting pencegahan dan pengendalian penyakit tanaman efektif untuk dilakukan. Terjadinya penyakit tanaman akan berdampak buruk pada produksi pertanian. Apabila penyakit tanaman kentang tidak dideteksi tepat waktu maka akan terjadi peningkatan kerawanan pada tanaman kentang. Secara umum, daun tanaman merupakan sumber informasi pertama untuk mengidentifikasi penyakit tanaman dan sebagian besar gejala penyakit dapat muncul pada daun (Ebrahimi, Khoshtaghaza, Minaei, & Jamshidi, 2017). Salah satu faktor yang mempengaruhi kualitas baik atau buruk kentang yaitu bercak hitam pada daun (early blight), terdapat warna kecoklatan pada daun atau pembusukan (late blight), dan daun yang sehat (healthy). Beragamnya penyakit yang dapat terjadi pada kentang tentunya membuat para petani kesulitan untuk mengidentifikasi penyakit yang menyerang tanaman kentang. Hal ini karena penyakit pada kentang memiliki gejala dan pengobatan berbeda dari tanaman lainnya. Identifikasi penyakit tanaman kentang merupakan topik penelitian yang penting, karena dapat membuktikan manfaat dalam mengklasifikasikan gejala penyakit segera setelah muncul pada daun tanaman.

Perkembangan teknologi dalam bidang Artificial Intelligence (AI) atau kecerdasan buatan berdampak besar dalam bidang medis, peternakan, pertanian dan masih banyak lagi. Salah satu penelitian yang paling berpengaruh adalah Deep Learning (DL) yang telah mencapai kemajuan yang sangat pesat dalam banyak aspek contohnya representasi data, ekstraksi fitur dan interaksi fitur (Chen, 2021). DL sendiri memiliki salah satu arsitektur yang paling populer dalam bidang citra visual yaitu Convolutional Neural Network (CNN). Metode DL berbasis CNN ini juga memiliki performansi yang baik dalam bidang pertanian untuk deteksi, klasifikasi dan identifikasi penyakit tanaman (Lu, Tan, & Jiang, 2021). Dalam kompetisi ImageNet Large Scale Visual Recognition

Competition (ILSVRC) pada tahun 2012 CNN mendapatkan popularitas sebagai metode yang paling efisien untuk klasifikasi citra (Naranjo-Torres et al., 2020).

Penelitian yang dilakukan oleh Puji Utami Rakhmawati, Yuliana Melita Pranoto, Endang Setyati pada tahun 2018 yang mengusulkan Klasifikasi Penyakit Daun Kentang Berdasarkan Fitur Tekstur dan Fitur Warna Menggunakan Support Vector Machine. Pada penelitian ini, klasifikasi pada daun kentang menggunakan metode SVM) dengan ciri GLCM (Grey Level Co-occurrence Matrix). Penelitian ini menggunakan 100 gambar data latih dan 30 data uji dengan tiga kelas yaitu late blight, early blight, dan healthy yang menghasilkan nilai akurasi 87%. Saat mengidentifikasi penyakit tanaman pada daun kentang nilai akurasi penyakit early blight dan late blight mencapai 90% sedangkan saat mengidentifikasi daun kentang healthy performa menurun dengan akurasi 83,33% (Rakhmawati, Pranoto, & Setyati, 2018).

Penelitian sebelumnya, juga dilakukan oleh Rizqi Amaliatus Sholihati, Indra Adji Sulistijono, Anhar Risnumawan, Eny Kusumawati yang mengusulkan Potato Leaf Disease Classification Using Deep Learning Approach. Pada eksperimen ini mengklasifikasikan lima jenis penyakit tanaman kentang berdasarkan kondisi daun. Dataset yang digunakan pada eksperimen ini menggunakan citra input tidak lebih dari 224x224 piksel. Kondisi daun yang digunakan pada penelitian ini yaitu alter-naria solan, insect, virus, phytophthora infestans, dan healthy. Dengan memanfaatkan metode CNN dengan arsitektur VGG (VGG16 dan VGG19), eksperimen ini telah mencapai akurasi rata-rata 91% (Sholihati, Sulistijono, Risnumawan, & Kusumawati, 2020).

Berdasarkan penjelasan yang telah dipaparkan, penulis akan mencari metode yang cepat, otomatis, lebih murah dan akurat dan membuat sistem yang akan mengenali penyakit tanaman pada daun kentang yaitu early blight, late blight, dan healthy. Untuk memudahkan pengklasifikasian penyakit tanaman pada daun kentang penelitian ini menggunakan teknologi berbasis Artificial Intelligence. Penelitian ini akan menerapkan deep learning dengan metode yang sedang berkembang Convolutional Neural Network dengan arsitektur MobileNet yang diharapkan dapat memiliki nilai akurasi yang lebih tinggi.

## **METODE PENELITIAN**

Dalam penelitian ini terdapat banyak permasalahan yang harus diselesaikan. Dalam menyelesaikan suatu masalah, dibutuhkan suatu metode yang logis dan sistematis. Penelitian ini terbagi menjadi beberapa tahap yaitu:

1. Studi Literatur

Studi literatur bertujuan untuk mempelajari dasar teori dan teori pendukung tentang klasifikasi, penyakit pada daun kentang, CNN, dan MobileNet. Dasar teori berupa referensi seperti buku, jurnal, skripsi, website dan sumber lainnya.

2. Pengumpulan Dataset

Pada tahap pengumpulan dataset, data yang dikumpulkan berupa citra gambar yang telah dibagi menjadi training, validation, dan testing.

3. Perancangan Sistem

Tahap perancangan sistem akan menggunakan Google Colaboratory sebagai coding environment bahasa pemrograman Python. Perancangan sistem bertujuan untuk membuat sistem yang mampu mengklasifikasikan penyakit tanaman pada daun kentang berdasarkan metode yang dipilih.

4. Implementasi Sistem

Pada tahap implementasi sistem, data citra akan dilatih dan diimplementasikan sesuai dengan perancangan sistem yang telah dibuat.

5. Pengujian dan Analisis

Pada tahap pengujian akan didapatkan hasil performansi sistem yang telah diimplementasikan. Kemudian hasil performansi yang sudah didapat akan dianalisis untuk mengetahui apakah sistem dibuat telah sesuai standart atau tidak.

### HASIL DAN PEMBAHASAN

Analisis pada penelitian pengujian sistem pada klasifikasi citra daun menggunakan CNN arsitektur MobileNet. Pengujian sistem ini dilakukan dengan tujuan mendapatkan hasil performansi terbaik pada klasifikasi citra daun kentang dengan melihat nilai parameter akurasi, loss, recall presisi dan F1-score. Penelitian dilakukan dengan menggunakan dataset sebanyak 3000 citra daun yang terdiri dari tiga kelas yaitu, Early Blight, Late Blight dan Healthy. Dataset tersebut akan dibagi menjadi data train, data validation dan data test yang dapat dilihat pada Tabel 4.1

**Tabel 4.1.** Pembagian Dataset

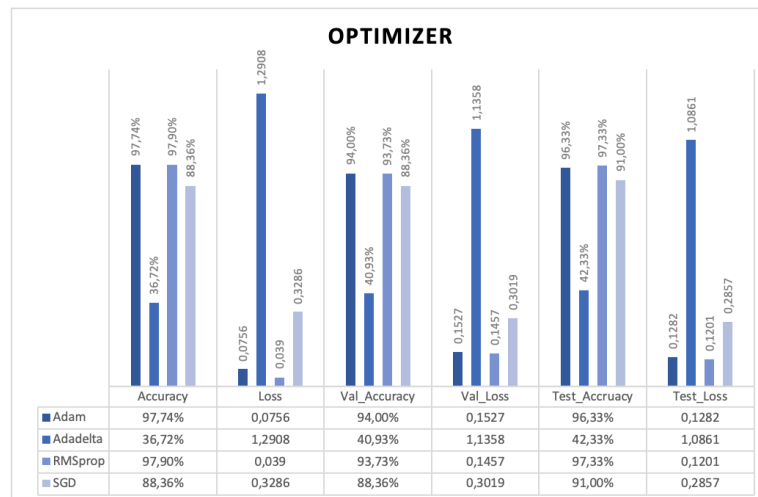
Jumlah Dataset	Data Train	Data Validation	Data Test
3000 data	65% (1950 data)	25% (750 data)	10% (300 data)

### Skenario Pengujian Sistem

Sistem akan diuji dengan menggunakan empat skenario yaitu perbandingan terhadap optimizer, perbandingan terhadap learning rate, perbandingan terhadap epoch dan perbandingan terhadap batch size.

### Skenario 1 : Pengujian Terhadap Optimizer

Pemilihan optimizer sangat penting untuk proses training, karena dapat pelatihan model secara signifikan. Skenario pertama adalah melakukan pengujian terhadap optimizer. Pengujian ini dilakukan bertujuan untuk menemukan optimizer yang paling efisien dalam mengklasifikasi citra daun kentang. Optimizer yang digunakan yaitu Adam, AdaDelta, RMSprop dan SGD. Diketahui ketentuan hyperparameter adalah learning rate 0,0001, jumlah epochs 100 dan batch size 32. Hasil pengujian terhadap optimizer diilustrasikan pada Gambar 4.1




**Gambar 4.1.** Hasil Pengujian Terhadap Optimizer

Berdasarkan Gambar 4.1 mendapatkan hasil yang efisien pada optimizer RMSprop dengan nilai akurasi 97,90% dan nilai loss 0,0390. Optimizer RMSprop (Root Mean Square Propagation) adalah metode optimasi untuk mempertahankan nilai learning rate dengan rata-rata dari gradien. Selanjutnya, optimizer RMSprop akan digunakan untuk melakukan perbandingan terhadap learning rate, epoch dan batch size.

### Skenario 2 : Pengujian Terhadap Learning Rate

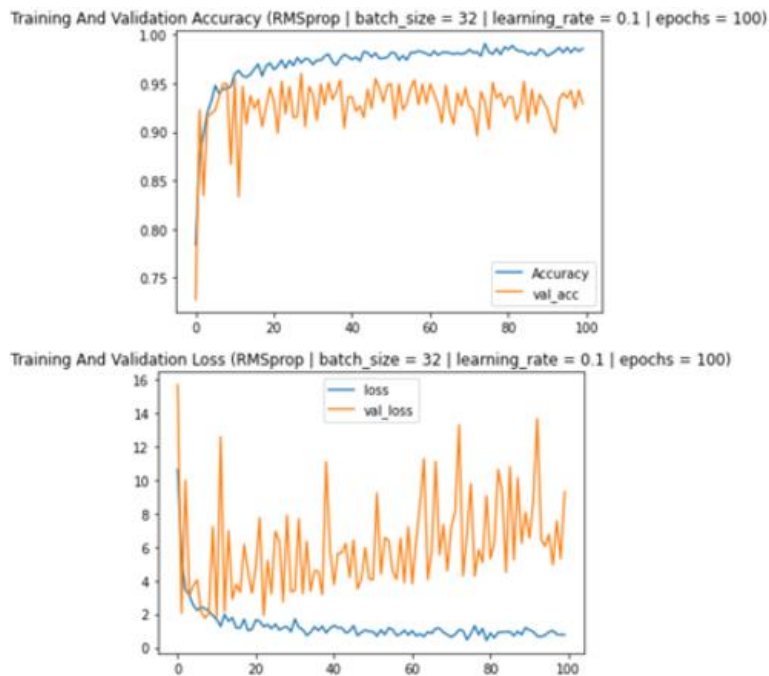
Skenario kedua adalah melakukan pengujian terhadap nilai learning rate dengan menggunakan hasil analisis terbaik pada skenario pertama. Nilai learning rate yang digunakan dalam skenario ini yaitu 0,1; 0,01; 0,001; 0,0001 dengan ketentuan optimizer RMSprop, jumlah epochs 100 dan batch size 32. Hasil pengujian terhadap learning rate diilustrasikan pada Gambar 4.2



**Gambar 4.2.** Hasil Pengujian Terhadap Learning Rate

*Learning Rate 0,1*

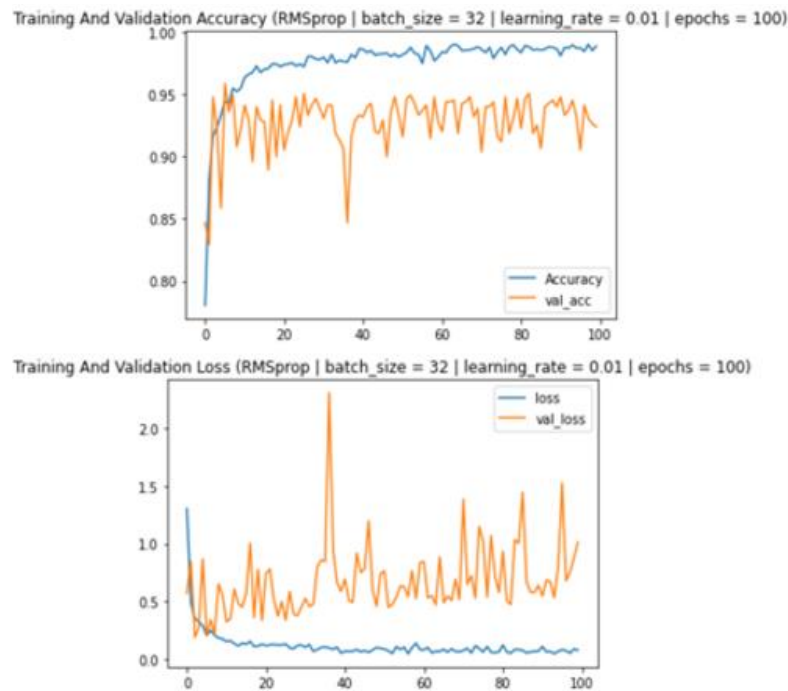
Berdasarkan pengujian terhadap learning rate 0,1 didapatkan hasil akurasi yang cukup tinggi yaitu 98,56% tetapi nilai loss 0,7702. Berdasarkan hasil tersebut model dapat dinilai cukup baik karena akurasi semakin tinggi dan loss semakin rendah tetapi pada garis akurasi dan garis validation akurasi se- dikit berjauhan. Grafik yang dihasilkan menunjukkan bahwa hasil validation akurasi dan validation loss memberikan nilai yang berubah-ubah sangat dras- tis sehingga model dapat dikatakan underfitting. Hasil pengujian learning rate 0,1 diilustrasikan pada **Gambar 4.3**



**Gambar 4.3.** Grafik Pengujian Learning Rate 0,1

*Learning Rate 0,01*

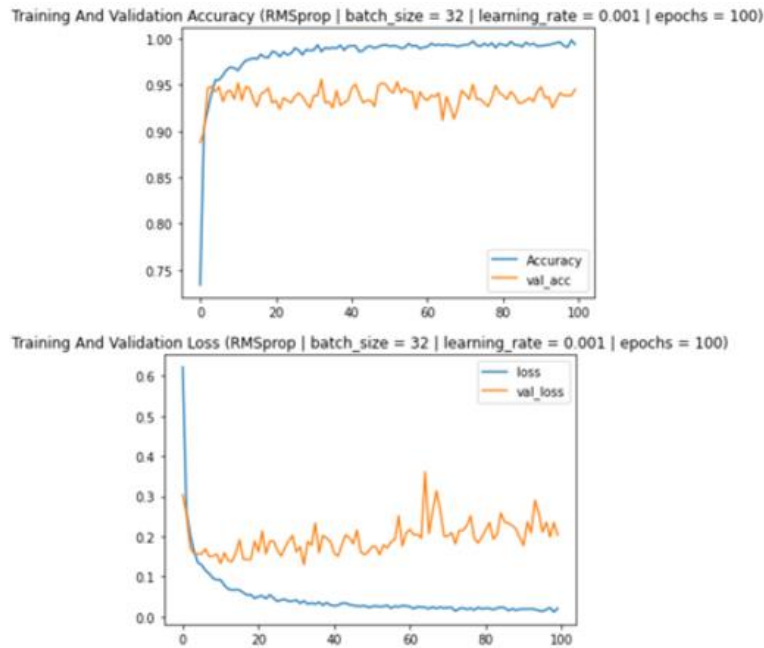
Berdasarkan pengujian terhadap learning rate 0,01 didapatkan hasil akurasi yang cukup tinggi yaitu 98,87% tetapi nilai loss 0,0796. Berdasarkan hasil tersebut model dapat dinilai cukup baik karena akurasi semakin tinggi dan loss semakin rendah tetapi pada garis akurasi dan garis validation akurasi se- dikit berjauhan. Grafik yang dihasilkan menunjukkan bahwa hasil validation akurasi dan validation loss memberikan nilai yang berubah-ubah sehingga model dapat dikatakan underfitting. Hasil pengujian learning rate 0,01 diilustrasikan pada **Gambar 4.4**



**Gambar 4.4.** Grafik Pengujian Learning Rate 0,01

#### ***Learning rate 0,001***

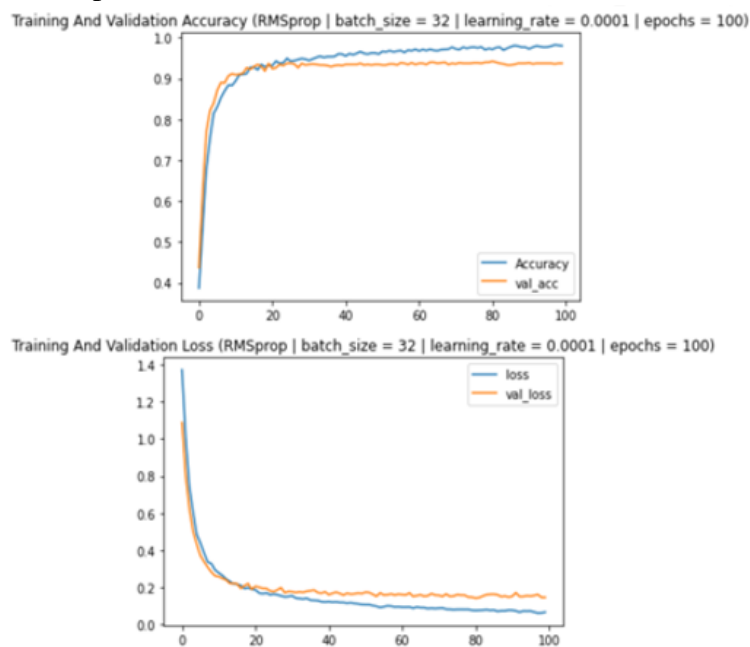
Berdasarkan pengujian terhadap learning rate 0,001 didapatkan hasil akurasi yang cukup tinggi yaitu 99,38% tetapi nilai loss 0,0213. Berdasarkan hasil tersebut model dapat dinilai cukup baik karena akurasi semakin tinggi dan loss semakin rendah tetapi pada garis akurasi dan garis validation akurasi se- dikit berjauhan sehingga model dapat dikatakan underfitting. Hasil pengujian learning rate 0,001 diilustrasikan pada Gambar 4.5



Gambar 4.5. Grafik Pengujian Learning Rate 0,001

**Learning Rate 0,0001**

Nilai learning rate 0,0001 merupakan nilai yang paling efisien pada peneliti- an ini Berdasarkan pengujian terhadap learning rate 0,0001 didapatkan hasil akurasi yang cukup tinggi yaitu 97,90% tetapi nilai loss 0,039. Berdasarkan- an hasil tersebut model dapat dinilai cukup baik karena menghasilkan model yang fitting. Hasil pengujian learning rate 0,0001 diilustrasikan pada **Gambar 4.6**




Gambar 4.6. Grafik Pengujian Learning Rate 0,0001

**Skenario 3 : Pengujian Terhadap Epoch**

Epoch merupakan sebuah proses training yang dilakukan secara berulang-ulang untuk mencapai nilai akurasi yang optimum. Skenario ketiga adalah melakukan pe-



ngujian terhadap jumlah epoch dengan menggunakan hasil parameter terbaik pada skenario sebelumnya. Jumlah epoch yang akan diuji adalah 25, 50, 75 dan 100 dengan ketentuan optimizer RMS prop, nilai learning rate 0,0001 dan batch size 32. Hasil pengujian terhadap jumlah epochs diilustrasikan pada **Gambar 4.7**

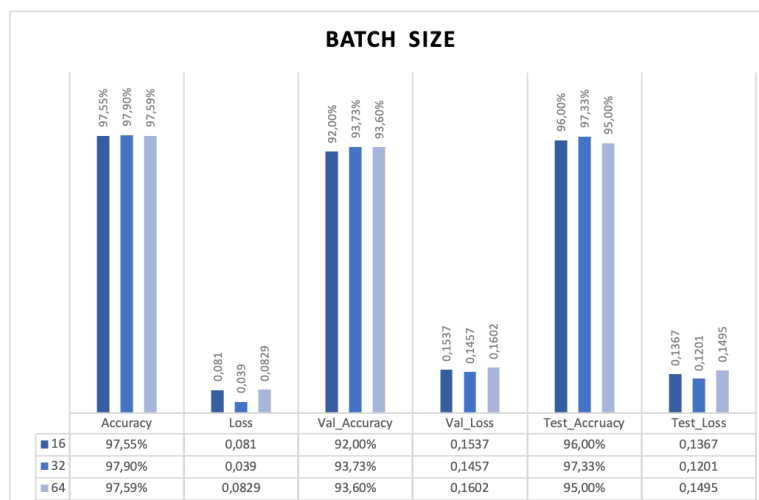


Gambar 4.7. Hasil Pengujian Terhadap Epoch

Berdasarkan Gambar 4.7 mendapatkan hasil yang paling efisien pada pengujian ini jumlah epoch 100. Pada pengujian ini jumlah epoch 100 dengan memiliki nilai akurasi 97,90% dan nilai loss 0,0390. Dari nilai tersebut dilihat bahwa jumlah epoch 100 lebih baik dibandingkan dengan jumlah epochs 25, 50 dan 100, karena semakin banyak nilai epoch semakin banyak proses belajar pada model.

**Skenario 4 : Pengujian Terhadap Batch Size**

Batch Size adalah pembagian dataset per-batch pada epochs untuk mempercepat proses training. Skenario terakhir adalah melakukan pengujian terhadap batch size dengan menggunakan hasil parameter terbaik pada skenario sebelumnya. Batch size yang akan diuji adalah 16, 32, 64 dengan ketentuan optimizer RMSprop, nilai learning rate 0,0001 dan jumlah epochs 100. Hasil pengujian terhadap batch size diilustrasikan pada **Gambar 4.8**



Gambar 4.8. Hasil pengujian terhadap Batch Size

Berdasarkan Gambar 4.8 didapatkan hasil yang paling efisien pada pengujian batch size adalah 32. Batch Size 32 menghasilkan nilai akurasi 97,90% dan nilai loss 0,0390. Proses pembagian dataset dengan sebanyak 32 per-batch memberikan hasil efisien bagi model untuk proses belajarnya.

**Analisa Hasil Pengujian**


Setelah melakukan pengujian terhadap empat skenario yaitu optimizer, learning rate, epochs dan batch size hasil yang paling berpengaruh terjadi pada learning rate. Pada penelitian ini didapatkan bahwa semakin besar nilai learning rate, maka semakin bagus hasil pengujiannya yang dapat ditunjukkan pada grafik yang tidak mengalami overfitting atau underfitting. Analisa hasil pengujian terbaik tiap skenario pada **Tabel 4.2**

Terdapat parameter lain untuk menentukan kinerja model terbaik adalah nilai performansi sistem berupa Recall, Precision dan F1-Score dengan menggunakan Confussion Matrix. Nilai performansi sistem diilustrasikan pada **Gambar 4.3**

Tabel 4.2. Hasil Pengujian Terbaik

Parameter	Nilai
Optimizer	RMSprop
Learning rate	0,0001
Epochs	100
Batch size	32
Akurasi Training	97,90%
Loss Training	0,0390
Akurasi Validation	99,38%
Loss Validation	0,2034

Confussion Matrix diilustrasikan pada Gambar 4.9



Gambar 4.9. Hasil Confussion Matrix

Tabel 4.3. Nilai Performansi Sistem

Akurasi	Loss	Presisi	Recall	F1-Score
97,90%	0,0390	97%	97%	97%

Pada penelitian ini dengan menggunakan hasil pengujian terbaik akan dilakukan pelatihan ulang. Tujuan dilakukan pelatihan ulang adalah untuk melihat apakah model yang dibuat

## Klasifikasi Penyakit Tanaman Pada Daun Kentang Dengan Metode Convolutional Neural Network Arsitektur Mobilenet

bekerja dengan baik sesuai dengan akurasi yang telah didapat. Pada penelitian ini didapatkan akurasi testing adalah 97,33% dan nilai loss testing adalah 0,1142, ini menunjukkan bahwa model dapat bekerja dengan baik selama pelatihan.

### **KESIMPULAN**

Sistem yang dirancang dengan menggunakan metode CNN arsitektur Mobile-Net dalam mengklasifikasi tiga jenis penyakit pada daun kentang, yaitu Early Blight, Late Blight dan Healthy mendapatkan nilai akurasi yang lebih unggul dari penelitian sebelumnya. Setelah melakukan percobaan dengan empat skenario didapatkan hasil yang paling efisien yaitu pada optimizer RMSprop, learning rate 0,0001; epochs 100 dan batch size 32 dengan akurasi 97,90% dan loss 0,0390. Performansi sistem pada penelitian ini mendapatkan nilai rata-rata 97%.

## BIBLIOGRAFI

- Chen, Lei. (2021). *Deep Learning and Practice with MindSpore*. Springer Nature.
- Ebrahimi, M. A., Khoshtaghaza, Mohammad Hadi, Minaei, Saeid, & Jamshidi, Bahareh. (2017). Vision-based pest detection based on SVM classification method. *Computers and Electronics in Agriculture*, 137, 52–58.
- Hidayah, Partiyani, Izzati, Munifatul, & Parman, Sarjana. (2017). Pertumbuhan dan produksi tanaman Kentang (*Solanum tuberosum* L. var. Granola) pada sistem budidaya yang berbeda. *Buletin Anatomi Dan Fisiologi (Bulletin Anatomy and Physiology)*, 2(2), 218–225.
- Koch, Mirjam, Naumann, Marcel, Pawelzik, Elke, Gransee, Andreas, & Thiel, Heike. (2020). The importance of nutrient management for potato production Part I: Plant nutrition and yield. *Potato Research*, 63(1), 97–119.
- Lu, Jinzhu, Tan, Lijuan, & Jiang, Huanyu. (2021). Review on convolutional neural network (CNN) applied to plant leaf disease classification. *Agriculture*, 11(8), 707.
- Muhibuddin, Ir A. (2016). *INOVASI TEKNOLOGI PENGEMBANGAN KENTANG DI DATARAN MEDIUM (Teori dan Pengalaman Empiris (Vol. 1))*. SAH MEDIA.
- Naranjo-Torres, José, Mora, Marco, Hernández-García, Ruber, Barrientos, Ricardo J., Fredes, Claudio, & Valenzuela, Andres. (2020). A review of convolutional neural network applied to fruit image processing. *Applied Sciences*, 10(10), 3443.
- Rakhmawati, Puji Utami, Pranoto, Yuliana Melita, & Setyati, Endang. (2018). Klasifikasi Penyakit Daun Kentang Berdasarkan Fitur Tekstur Dan Fitur Warna Menggunakan Support Vector Machine. *Semin. Nas. Teknol. Dan Rekayasa, 2018*, 1–8.
- Sholihati, Rizqi Amaliatus, Sulistijono, Indra Adji, Risnumawan, Anhar, & Kusumawati, Eny. (2020). Potato leaf disease classification using deep learning approach. *2020 International Electronics Symposium (IES)*, 392–397. IEEE.
- Wang, Chenglong, & Xiao, Zhifeng. (2021). Potato Surface Defect Detection Based on Deep Transfer Learning. *Agriculture*, 11(9), 863.

---

**First publication right:**

[Jurnal Syntax Fusion: Jurnal Nasional Indonesia](#)

**This article is licensed under:**

