

# Analisis Performa CNN Arsitektur MobileNet Untuk Pengenalan Penyakit Pada Tanaman Bawang Merah

**<sup>1\*</sup>Hadi Rizky Dwi Via Prahesta, <sup>2</sup>Danar Putra Pamungkas, <sup>3</sup>Patmi Kasih**

<sup>1,2,3</sup> Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: [\\*1hadirizky300603@gmail.com](mailto:*1hadirizky300603@gmail.com), [2danar@unpkediri.ac.id](mailto:2danar@unpkediri.ac.id), [3fatkasih@gmail.com](mailto:3fatkasih@gmail.com)

**Penulis Korespondens : Hadi Rizky Dwi Via Prahesta**

**Abstrak**— Penyakit pada tanaman bawang merah, seperti busuk bawah, jamur daun, dan serangan ulat, dapat menyebabkan penurunan kualitas dan kuantitas hasil panen. Deteksi dini penyakit sangat penting untuk mencegah kerugian lebih lanjut. Penelitian ini mengembangkan sistem klasifikasi penyakit pada tanaman bawang merah otomatis berbasis citra menggunakan Convolutional Neural Network (CNN) dengan arsitektur MobileNetV1. Dataset terdiri dari 250 citra daun bawang merah yang dikategorikan ke dalam empat kelas: normal, busuk bawah, jamur daun, dan ulat. Proses pelatihan menggunakan teknik augmentasi citra dan callbacks EarlyStopping serta ModelCheckpoint untuk mencegah overfitting. Model berhenti pada epoch ke-16 dan mencapai akurasi 92,00%, presisi 92,31%, recall 92,00%, serta F1-score 91,90%. Hasil ini menunjukkan bahwa arsitektur MobileNetV1 efektif dalam mengklasifikasikan penyakit pada tanaman bawang merah secara otomatis.

**Kata Kunci**— bawang merah, CNN, klasifikasi citra, MobileNetV1, penyakit tanaman.

**Abstract**— Diseases in shallot plants, such as bottom rot, leaf fungus, and caterpillar attacks, can cause a decrease in the quality and quantity of the harvest. Early detection of diseases is very important to prevent further losses. This study develops an automatic image-based disease classification system in shallot plants using Convolutional Neural Network (CNN) with MobileNetV1 architecture. The dataset consists of 250 images of shallot leaves categorized into four classes: normal, bottom rot, leaf fungus, and caterpillars. The training process uses image augmentation techniques and EarlyStopping callbacks and ModelCheckpoint to prevent overfitting. The model stops at the 16th epoch and achieves an accuracy of 92.00%, a precision of 92.31%, a recall of 92.00%, and an F1-score of 91.90%. These results indicate that the MobileNetV1 architecture is effective in automatically classifying diseases in shallot plants.

**Keywords**— CNN, image classification, MobileNetV1, plant disease, shallot.

This is an open access article under the CC BY-SA License.



## I. PENDAHULUAN

Bawang merah (*Allium cepa L.*) merupakan salah satu komoditas hortikultura penting yang banyak dibudidayakan di Indonesia. Selain memiliki nilai ekonomi tinggi, tanaman ini juga menjadi bahan utama dalam kebutuhan rumah tangga dan industri kuliner. Namun, produktivitas bawang merah sering mengalami penurunan akibat serangan penyakit seperti bercak ungu (*Alternaria porri*), busuk umbi, dan hama ulat grayak (*Spodoptera exigua*)[1].

Dalam praktik di lapangan, deteksi penyakit pada tanaman bawang merah umumnya masih dilakukan secara manual oleh petani melalui pengamatan visual. Cara ini bersifat subjektif dan berisiko menimbulkan kesalahan klasifikasi, terutama jika gejala antar penyakit memiliki kemiripan visual[2]. Keterbatasan ini menunjukkan pentingnya dukungan teknologi dalam proses identifikasi penyakit tanaman.

Seiring berkembangnya teknologi kecerdasan buatan, metode berbasis *deep learning* mulai dimanfaatkan dalam sistem pengolahan citra digital di bidang pertanian [3]. Salah satu pendekatan yang paling banyak digunakan adalah *Convolutional Neural Network* (CNN), karena kemampuannya dalam mengenali pola visual secara otomatis. CNN telah terbukti efektif dalam mengklasifikasikan berbagai jenis penyakit tanaman dari gambar daun tanpa memerlukan proses segmentasi manual[4] .

CNN telah terbukti efektif dalam mengklasifikasikan berbagai jenis penyakit tanaman dari gambar daun tanpa memerlukan proses segmentasi manual [5]. Untuk mendukung efisiensi komputasi, arsitektur MobileNet banyak dipilih karena dirancang khusus untuk perangkat dengan keterbatasan sumber daya [6]. MobileNet menggunakan teknik *depthwise separable convolution* yang membuat jumlah parameter dalam model menjadi jauh lebih ringan dibandingkan CNN konvensional. Arsitektur ini telah diterapkan pada berbagai penelitian klasifikasi penyakit tanaman dan memberikan hasil yang akurat [7].

Dengan mempertimbangkan keunggulan tersebut, penelitian ini bertujuan untuk menganalisis performa MobileNet dalam mengklasifikasikan penyakit pada tanaman bawang merah menggunakan pendekatan CNN berbasis citra digital.

## II. METODE

### A. Persiapan Data

Penelitian ini menggunakan data berupa 250 gambar daun bawang merah yang diklasifikasikan ke dalam empat kelas, yaitu normal, jamur daun, busuk bawah, dan ulat. Seluruh gambar diperoleh melalui pengambilan langsung menggunakan kamera smartphone. Setelah dikumpulkan, gambar-gambar tersebut diproses melalui beberapa tahap prapemrosesan. Ukuran gambar diubah menjadi  $224 \times 224$  piksel agar sesuai dengan dimensi input model MobileNet. Selanjutnya dilakukan normalisasi nilai piksel ke dalam rentang 0 hingga 1 agar model dapat belajar secara lebih stabil. Untuk memperkaya variasi data dan meningkatkan generalisasi model, dilakukan augmentasi citra seperti rotasi, zoom, dan flipping horizontal.

Proses augmentasi seperti ini telah terbukti mampu meningkatkan performa model CNN dalam mendeteksi objek atau fitur penting pada citra, khususnya pada data tanaman yang memiliki variasi bentuk dan posisi daun yang beragam [8]. Setelah proses ini, data dibagi menjadi dua bagian: 80% untuk data latih dan 20% untuk data validasi.

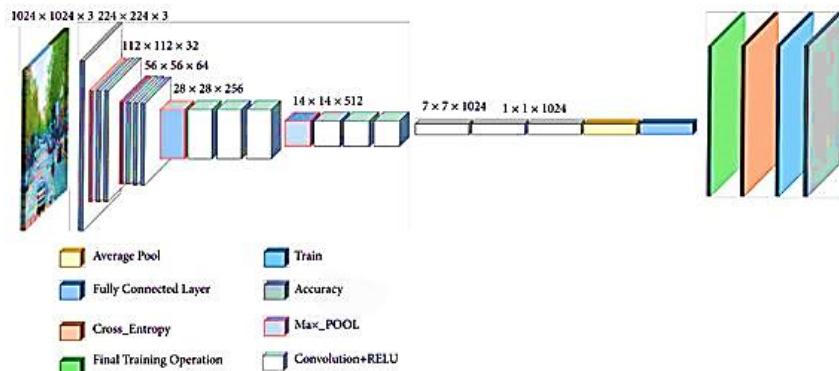
### B. Arsitektur Model

Model yang digunakan dalam penelitian ini adalah MobileNet, yaitu salah satu arsitektur *Convolutional Neural Network* yang dirancang untuk memberikan akurasi tinggi dengan jumlah parameter yang lebih sedikit. MobileNet menggunakan teknik *depthwise separable convolution* untuk mengefisienkan proses pelatihan dan pengujian.

Ramcharan et al. (2019) mengembangkan model deteksi objek berbasis CNN menggunakan arsitektur MobileNet yang dioptimalkan untuk perangkat mobile. Model ini dilatih untuk mengidentifikasi gejala penyakit pada daun singkong dan diuji di lapangan menggunakan aplikasi seluler. Hasilnya menunjukkan bahwa pendekatan ini efektif untuk diagnosis penyakit tanaman secara real-time di kondisi dunia nyata [9].

Dalam implementasinya, model ini menggunakan bobot pralatih dari ImageNet. Bagian dasar model dibekukan (freeze) untuk mempertahankan fitur umum yang telah dipelajari sebelumnya. Di atasnya ditambahkan beberapa lapisan tambahan, seperti *Global Average*

*Pooling*, dropout sebesar 20% untuk mengurangi overfitting, lapisan dense sebanyak 1024 neuron dengan fungsi aktivasi ReLU, dan satu lapisan output berisi empat neuron dengan aktivasi softmax.



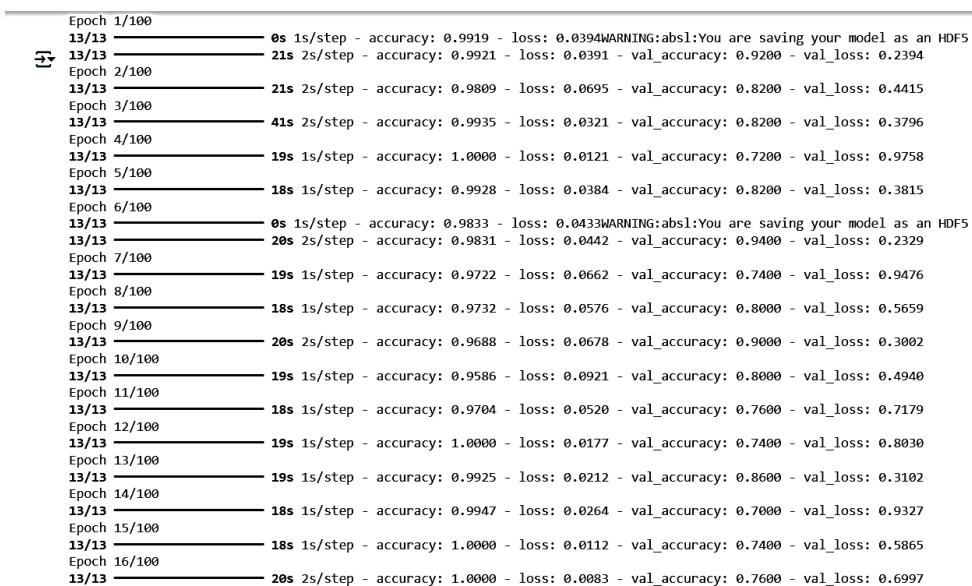
Gambar 1. Arsitektur MobileNet

### C. Pelatihan Model

Model dikompilasi menggunakan algoritma optimasi Adam dengan *learning rate* sebesar 0,0001 dan fungsi *loss* categorical crossentropy karena tugas klasifikasi ini bersifat multi-kelas. Proses pelatihan dilakukan selama maksimal 100 epoch dengan ukuran batch 16.

Untuk menghindari overfitting, digunakan dua mekanisme *callback*, yaitu *EarlyStopping* dan *ModelCheckpoint*. *EarlyStopping* berfungsi untuk menghentikan pelatihan secara otomatis jika akurasi validasi tidak mengalami peningkatan selama beberapa epoch, sedangkan *ModelCheckpoint* menyimpan bobot model terbaik selama proses pelatihan berlangsung.

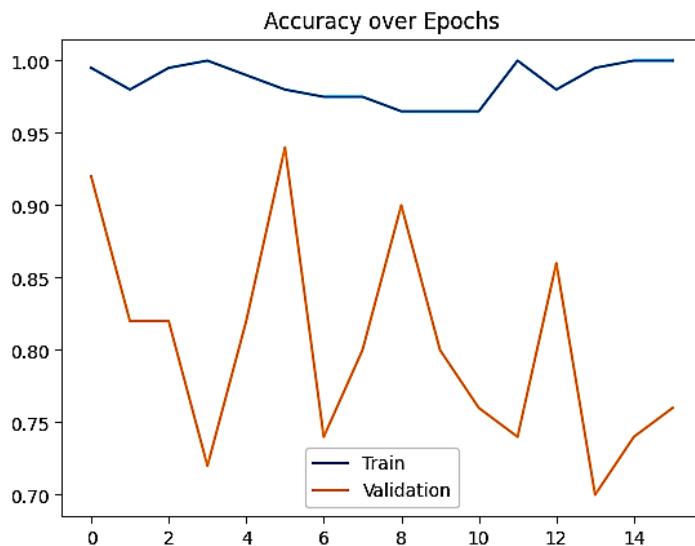
Menurut Julianto et al. (2022), penggunaan teknik optimasi hyperparameter pada CNN secara tepat dapat meningkatkan akurasi dan mencegah overfitting dalam klasifikasi penyakit tanaman padi [10]. Oleh karena itu, pendekatan serupa juga diterapkan dalam penelitian ini guna menjaga kualitas hasil pelatihan dan efisiensi proses pembelajaran model.



Gambar 2. Pelatihan Model

### III. HASIL DAN PEMBAHASAN

#### A. Analisis Hasil Pelatihan Berdasarkan Epoch



Gambar 3. Pelatihan Berdasarkan Epoch

Pada gambar 3 proses pelatihan model dilakukan selama 16 epoch dari total 100 epoch yang direncanakan. Namun, pelatihan dihentikan lebih awal oleh mekanisme *early stopping* karena akurasi validasi tidak mengalami peningkatan yang signifikan. Model menunjukkan akurasi pelatihan yang sangat tinggi sejak awal pelatihan, bahkan mencapai 100% mulai dari epoch keempat hingga akhir. Hal ini menandakan bahwa model mampu mempelajari pola dari data pelatihan dengan sangat baik. Namun demikian, akurasi validasi menunjukkan fluktuasi yang cukup tajam antar epoch. Misalnya, pada epoch pertama akurasi validasi berada di angka 92,00%, kemudian menurun drastis menjadi 72,00% pada epoch keempat. Meski sempat meningkat kembali hingga 94,00% pada epoch keenam, akurasi ini terus mengalami naik-turun pada epoch-epoch berikutnya. Fenomena ini menunjukkan bahwa model mengalami overfitting, yaitu kondisi di mana model terlalu menyesuaikan diri dengan data pelatihan tetapi kurang mampu menggeneralisasi pada data baru.

Gejala overfitting ini juga didukung oleh nilai *loss* yang sangat rendah pada data pelatihan, tetapi tetap tinggi dan tidak stabil pada data validasi. Contohnya, *training loss* terus menurun hingga mencapai 0,0083 pada epoch ke-16, sementara *validation loss* sempat mencapai 0,9758 pada epoch keempat dan 0,9327 pada epoch keempat belas. Faktor penyebab overfitting ini kemungkinan adalah jumlah dataset yang terbatas, distribusi kelas yang tidak merata, dan kemiripan visual antar kelas yang menyulitkan model dalam membedakan fitur-fitur spesifik.

#### B. Evaluasi Kinerja Model

Pada gambar 4 evaluasi terhadap model dilakukan dengan menggunakan data uji yang terpisah dari data pelatihan dan validasi. Berdasarkan hasil evaluasi, diperoleh nilai akurasi sebesar 92,00%, presisi 92,31%, recall 92,00%, dan F1-score sebesar 91,90%. Nilai-nilai ini

menunjukkan bahwa model memiliki kemampuan klasifikasi yang baik, dengan tingkat kesalahan yang relatif rendah.

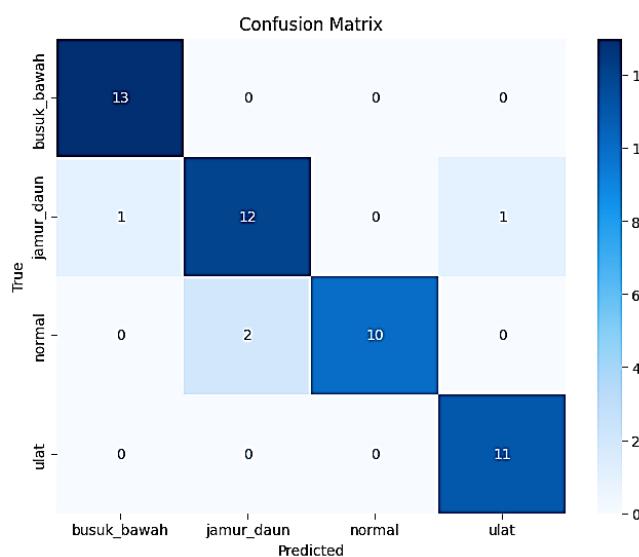
```
Akurasi : 0.9200
Presisi : 0.9231
Recall  : 0.9200
F1-score : 0.9190
```

Gambar 4. Hasil Kinerja Model

Akurasi menunjukkan persentase prediksi yang benar secara keseluruhan, sedangkan presisi dan recall masing-masing mengukur ketepatan dan kelengkapan model dalam mengenali setiap kelas. Nilai F1-score yang tinggi menunjukkan bahwa model mampu menjaga keseimbangan antara presisi dan recall. Dengan demikian, model MobileNet dalam penelitian ini cukup andal untuk digunakan sebagai dasar pengembangan sistem klasifikasi penyakit bawang merah secara otomatis.

### C. Analisis Confusion Matrik

Pada gambar 5 untuk mengetahui detail prediksi pada setiap kelas, digunakan confusion matrix. Matriks ini menunjukkan jumlah prediksi benar dan salah yang dilakukan model terhadap masing-masing kelas. Hasilnya menunjukkan bahwa kelas *busuk\_bawah* diprediksi dengan sangat baik, yaitu 13 dari 13 gambar diklasifikasikan dengan benar. Kelas *jamur\_daun* memiliki dua kesalahan: satu gambar diklasifikasikan sebagai *busuk\_bawah* dan satu lagi sebagai *ulat*. Untuk kelas *normal*, dua gambar salah diklasifikasikan sebagai *jamur\_daun*, sementara sisanya benar. Kelas *ulat* diklasifikasikan dengan sempurna sebanyak 11 gambar.

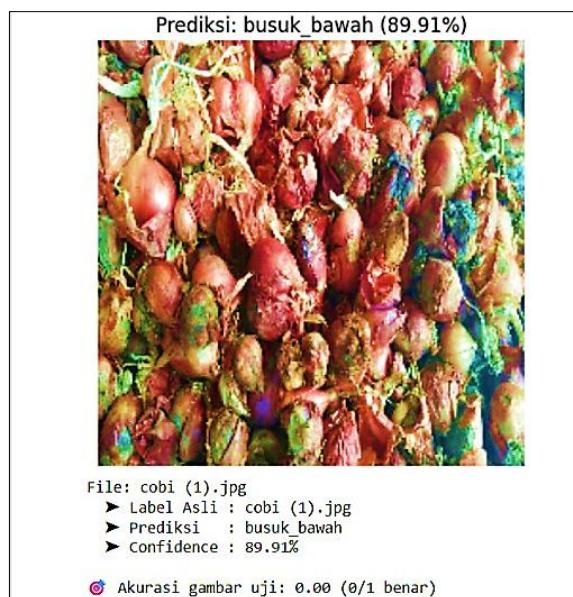


Gambar 5. Confussion Matrik

Meskipun terdapat sedikit kesalahan pada kelas *jamur\_daun* dan *normal*, secara keseluruhan model menunjukkan distribusi prediksi yang sangat baik. Kesalahan ini kemungkinan disebabkan oleh kemiripan ciri visual antar kelas, sehingga menyebabkan overlap dalam fitur yang dikenali oleh model.

#### D. Contoh Prediksi Gambar Uji

Pada gambar 6 untuk melihat bagaimana model bekerja pada tingkat individu, ditampilkan salah satu hasil prediksi gambar uji.



Gambar 6. Prediksi Gambar Uji

Gambar tersebut memiliki nama file "cobi (1).jpg". Model memprediksi gambar tersebut sebagai kelas *busuk bawah* dengan tingkat kepercayaan (confidence) sebesar 89,91%. Namun, berdasarkan label aslinya, gambar ini tidak termasuk kelas tersebut, sehingga prediksi dinyatakan salah. Kesalahan ini menandakan bahwa model belum sepenuhnya akurat dalam mengenali fitur penyakit tertentu pada gambar tertentu, yang mungkin dipengaruhi oleh pencahayaan, kondisi fisik umbi, atau latar belakang gambar.

### IV. KESIMPULAN

Penelitian ini bertujuan untuk menganalisis performa arsitektur MobileNet dalam mengenali penyakit pada daun bawang merah menggunakan pendekatan *Convolutional Neural Network* (CNN). Berdasarkan hasil pengujian, model MobileNet yang dilatih dengan 250 gambar dan empat kelas penyakit menunjukkan performa yang cukup baik. Model berhasil mencapai akurasi sebesar 92,00%, dengan nilai presisi sebesar 92,31%, recall sebesar 92,00%, dan F1-score sebesar 91,90%. Nilai-nilai tersebut menunjukkan bahwa model mampu melakukan klasifikasi citra daun bawang merah secara akurat dan seimbang pada masing-masing kelas.

Meskipun model menunjukkan akurasi pelatihan yang sangat tinggi, evaluasi terhadap akurasi validasi memperlihatkan adanya fluktuasi yang menandakan kemungkinan overfitting. Hal ini dapat disebabkan oleh jumlah data yang terbatas serta kemiripan visual antara kelas-kelas tertentu. Namun, penggunaan strategi pelatihan seperti *early stopping*, *data augmentation*, dan *transfer learning* dari MobileNet terbukti mampu meningkatkan performa secara keseluruhan.

Dengan demikian, dapat disimpulkan bahwa arsitektur MobileNet efektif digunakan dalam sistem klasifikasi penyakit daun bawang merah, terutama untuk keperluan deteksi cepat berbasis citra digital. Untuk penelitian selanjutnya, disarankan agar jumlah dataset ditambah dan distribusi kelas diseimbangkan guna memperoleh hasil yang lebih optimal dan stabil.

## DAFTAR PUSTAKA

- [1] M. Y. Kim, J. W. Han, Q. Le Dang, J. C. Kim, H. Kim, and G. J. Choi, “Characterization of Alternaria porri causing onion purple blotch and its antifungal compound magnolol identified from Caryodaphnopsis baviensis,” *PLoS One*, vol. 17, no. 1 January, pp. 1–17, 2022, doi: 10.1371/journal.pone.0262836.
- [2] T. Turahman, E. Hasmin, and K. Aryasa, “Analisis Perbandingan Metode Convolutional Neural Network (CNN) dan MobileNet dalam Klasifikasi Penyakit Daun Padi,” *J. JTIK (Jurnal Teknol. Inf. dan Komunikasi)*, vol. 9, no. 1, pp. 368–377, Nov. 2024, doi: 10.35870/jtik.v9i1.3218.
- [3] F. Habib Hawari, F. Fadillah, M. Rifqi Alviandi, and T. Arifin, “KLASIFIKASI PENYAKIT PADI MENGGUNAKAN ALGORITMA CNN (CONVOLUTIONAL NEURAL NETWORK),” *J. RESPONSIF*, vol. 4, no. 2, pp. 184–189, 2022, doi: 10.51977/jti.v4i2.856.
- [4] J. Lu, L. Tan, and H. Jiang, “Review on convolutional neural network (CNN) applied to plant leaf disease classification,” *Agric.*, vol. 11, no. 8, pp. 1–18, 2021, doi: 10.3390/agriculture11080707.
- [5] P. Arsitektur *et al.*, “Prosiding SEMNAS INOTEK (Seminar Nasional Inovasi Teknologi) 1626,” Online, 2024. doi: 10.29407/5m496763.
- [6] A. Nada Nafisa, E. Nia Devina Br Purba, F. Aulia Alfarisi Harahap, N. Adawiyah Putri, I. Komputer, and F. Matematika dan Ilmu Pengetahuan Alam, “Implementasi Algoritma Convolutional Neural Network Arsitektur Model MobileNetV2 dalam Klasifikasi Penyakit Tumor Otak Glioma, Pituitary dan Meningioma.” doi: 10.29303/jtika.v5i1.234.
- [7] M. G. Somoal and A. R. Dzikrillah, “Komparasi MobileNETV2 dengan Kustomisasi Transfer Learning dan Hyperparameter untuk Identifikasi Tumor Otak,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 12, no. 1, pp. 229–240, Feb. 2025, doi: 10.25126/jtiik.2025129582.
- [8] A. Dickyu Septian and A. Suhendar, “IMPLEMENTASI ALGORTIMA CONVOLUTIONAL NEURAL NETWORK UNTUK DETEksi PENYAKIT DAUN KENTANG MENGGUNAKAN CITRA DIGITAL,” *J. Inform. Teknol. dan Sains*, 2024, doi: 10.51401/jinteks.v6i4.4880.
- [9] A. Ramcharan *et al.*, “A mobile-based deep learning model for cassava disease diagnosis,” *Front. Plant Sci.*, vol. 10, Mar. 2019, doi: 10.3389/fpls.2019.00272.
- [10] A. Julianto, A. Sunyoto, D. Ferry, and W. Wibowo, “OPTIMASI HYPERPARAMETER CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI PENYAKIT TANAMAN PADI (OPTIMIZATION OF CONVOLUTIONAL NEURAL NETWORK HYPERPARAMETERS FOR CLASSIFICATION OF RICE PLANT DISEASES).” doi: 10.46764/teknimedia.v3i2.77.