

Pengenalan Pola Penyakit Pada Gambar Daun Tanaman Kentang Memanfaatkan Metode *Convolution Neural Network*

*Dafauzan Bilal Syaifulloh, Nauval Maulana Rizky Irawan, Faisal Wildan Habibi,
Farrel Aprillian, Fetty Tri Anggraeny

Universitas Pembangunan Nasional Veteran Jawa Timur, Indonesia

Artikel Histori:

Disubmit: Januari 2024

Diterima: Maret 2024

Diterbitkan: Juni 2024

DOI

[10.33005/jifti.v6i1.167](https://doi.org/10.33005/jifti.v6i1.167)



ABSTRAK

Kentang (*Solanum tuberosum*) merupakan komoditas pertanian penting yang rentan terhadap penyakit seperti late blight dan early blight. Metode deteksi penyakit secara tradisional seringkali kurang akurat dan efisien, sehingga diperlukan teknik komputasi lanjutan. Penelitian ini mengimplementasikan Convolutional Neural Network (CNN) untuk mendeteksi penyakit daun kentang dengan klasifikasi tiga kategori: sehat, late blight, dan early blight. Menggunakan dataset PlantVillage dengan total 2152 citra, model CNN dilatih dan diuji. Proses preprocessing meliputi perubahan ukuran citra menjadi 150 x 150 piksel dan normalisasi nilai piksel. Hasil menunjukkan akurasi model sebesar 94,88%. Metrik evaluasi seperti precision, recall, dan F1-score menunjukkan keandalan model yang tinggi. Penelitian ini menunjukkan potensi CNN dalam mengotomatisasi deteksi penyakit tanaman, sehingga dapat meningkatkan produktivitas dan mengurangi kerugian.

Kata Kunci: CNN, Deteksi penyakit, daun kentang, Identifikasi, Late blight, Early Blight

PENDAHULUAN

Tanaman kentang (*Solanum tuberosum*) merupakan salah satu tanaman yang dimanfaatkan umbinya sebagai makanan pokok dan termasuk dalam 4 besar komoditas pangan yang penting di dunia (Rahmi dkk., 2021). Kentang termasuk dalam 4 besar komoditas pangan karena memiliki kandungan karbohidrat yang cukup banyaknya di dalamnya sehingga dapat menjadikannya makanan utama selain beras (Lestari & Naufal, 2021). Dalam pembudidayaan tanaman kentang terdapat tantangan yang harus dihadapi, salah satunya adalah tantangan dalam menghadapi penyakit yang menjangkiti tanaman kentang. Terdapat 2 penyakit yang sangat rentan menjangkiti area daun kentang yaitu hawar daun (*late blight*) dan bercak kering (*early blight*) yang seringkali ditemukan pada tanaman kentang berusia 5 sampai 6 minggu (Amatullah dkk., 2021).

Identifikasi penyakit diperlukan untuk mendeteksi penyakit apa yang sedang menyerang daun kentang. namun, sejauh ini umumnya proses identifikasi dilakukan secara tradisional atau manual oleh para petani yang dimana membuat hasil identifikasi menjadi tidak efektif karena manusia memiliki kelemahan (Lestari & Naufal, 2021).

How to Cite:

Rachmawati, L. N., Octaviana, M. E. A., Agussalim. (2024). Monitoring Jaringan Menggunakan PRTG (Studi Kasus: Fakultas Ekonomi Bisnis UPN "Veteran" Jatim). *Jurnal Ilmiah Teknologi Informasi dan Robotika*, 6(1), 54-63. <https://doi.org/10.33005/jifti.v6i1.167>.

*Corresponding Author:

Email : 23082010052@student.upnjatim.ac.id

Alamat : Jl. Rungkut Madya, Gn. Anyar, Kec. Gn. anyar,
Surabaya, Jawa Timur, 60294



This article is published under a Creative Commons Attribution 4.0 International License.

Penyakit pada tanaman kentang dapat diidentifikasi berdasarkan perbedaan warna dan tekstur daun. Oleh karena itu, diperlukan metode komputerisasi yang mampu mendeteksi jenis penyakit melalui pengolahan citra daun. Teknologi pengolahan citra digital telah banyak digunakan untuk menyelesaikan berbagai masalah dalam *image processing*, termasuk meningkatkan akurasi klasifikasi (Sekar dkk., 2020). Pengolahan citra adalah proses manipulasi dan analisis gambar menggunakan computer (Saputra, 2019). Kemajuan teknologi yang pesat juga telah memodernisasi berbagai sektor, termasuk pertanian, di mana teknologi kini digunakan untuk mendukung penelitian, khususnya dalam pendeteksian penyakit tanaman (Ratnawati & Sulityaningrum, 2019).

Penelitian ini ditujukan untuk mengembangkan sistem yang mempermudah pekerjaan petani dalam mendeteksi penyakit gejala penyakit pada daun kentang lewat citra daun kentang. Proses identifikasi terbagi menjadi tiga kategori, yaitu *daun sehat*, *late blight* (hawar daun), dan *early blight* (bercak kering). Dalam melakukan identifikasi terhadap penyakit pada daun tanaman kentang, penelitian ini menerapkan algoritma *Convolutional Neural Network* (CNN), yang termasuk ke dalam salah satu metode dalam *Deep Learning*. Data yang dipergunakan pada penelitian ini diperoleh dari dataset *PlantVillage* yang tersedia di situs *Kaggle* (Emmanuel, 2020).

METODE PENELITIAN

Penelitian yang dilakukan ini memiliki beberapa tahapan yang perlu dijalankan bagi peneliti untuk mengklasifikasi penyakit pada daun tanaman kentang yang ditampilkan pada Gambar 1 berupa flowchart tahapan penelitian.

Gambar 1 menggambarkan alur metode penelitian yang dilakukan untuk mengidentifikasi jenis dari penyakit yang ada pada daun tanaman kentang. Proses ini terdiri dari lima tahapan utama, diawali dengan pengumpulan data (*dataset collection*), yang berfokus pada pengumpulan gambar daun kentang. Tahap kedua adalah praproses data (*data preprocessing*), di mana data dipersiapkan sebelum masuk ke proses selanjutnya. Selanjutnya adalah klasifikasi (*classification*), di mana citra daun kentang diklasifikasikan menggunakan algoritma tertentu. Tahap keempat adalah evaluasi (*evaluation*), yang bertujuan menilai keefektifan metode klasifikasi yang digunakan. Terakhir, terdapat tahap pengujian (*testing*), di mana model diuji dengan gambar input untuk memastikan akurasi deteksi yang dihasilkan sudah sesuai. Penjelasan rinci dari setiap tahap dalam alur penelitian ini akan dijabarkan lebih lanjut.

Pengumpulan Dataset

Data yang digunakan adalah "*PlantVillage Dataset*" dari situs *Kaggle*. Dataset tersebut memiliki beberapa macam jenis daun tanaman, sedangkan untuk tanaman daun kentang terdapat 3 kelas yakni *Early Blight*, dan *Late Blight*, serta *Healthy* dengan total dataset berjumlah 2152 gambar yang terdiri dari 1000 *Early Blight*, dan 1000 *Late Blight*, serta 152 *Healthy*.

Preprocessing Data

Dalam tahap ini, data yang telah didapat diolah agar dapat memaksimalkan hasil dengan cara melakukan pengubahan ukuran menjadi 150 x 150 untuk mempercepat pemrosesan. Pembagian data dilakukan dengan cara membagi dua data yakni data train serta data test. Pembagiannya untuk data train kelas *Early Blight* dan *Late Blight* menggunakan masing-

masing 400 file gambar sedangkan pada kelas Healthy terdapat 100 file gambar. Pada data testing pembagian dilakukan untuk kelas penyakit *Early Blight* serta *Late Blight* menggunakan masing-masing 200 file gambar, sedangkan daun sehat dalam kategori *Healthy* 50 file gambar. Pada data uji kelas *Early Blight* dan *Late Blight* masing-masing 10 gambar, dan untuk kelas *Healthy* ada 2 file gambar.

Proses Klasifikasi CNN

Proses klasifikasi Citra dengan menggunakan metode CNN dilalui dalam beberapa tahap yaitu :

Normalisasi Citra

Normalisasi citra dilakukan untuk memastikan setiap piksel dalam gambar berada dalam rentang nilai tertentu, biasanya antara 0 hingga 1, yang bertujuan untuk meningkatkan efisiensi pelatihan model CNN. Citra daun kentang yang diambil dari dataset PlantVillage pada awalnya memiliki nilai piksel dalam rentang nilai dari 0 hingga 255, di mana nilai 0 merupakan piksel berwarna hitam (tanpa intensitas cahaya) dan 255 merupakan piksel berwarna putih (intensitas maksimum).

Dalam jurnal ini, setiap piksel dalam gambar daun kentang diubah dengan membaginya dengan nilai maksimal, yaitu 255, sehingga semua nilai piksel menjadi angka desimal dalam rentang 0 hingga 1.

Lapisan Konvolusi (*Convolutional Layer*)

Lapisan konvolusi bertugas mengekstraksi fitur dari citra input melalui proses konvolusi menggunakan kernel atau filter. Filter ini adalah matriks kecil yang bergeser melintasi gambar dan melakukan operasi elemen-per-elemen. Setiap filter berfungsi mendeteksi pola tertentu, seperti tepi, tekstur, atau bentuk objek.

Rumus:

$$Z = (X \otimes K) + b$$

X : Input gambar (dimensi tinggi x lebar x saluran warna).

K : Filter/Kernel (matriks kecil, misalnya 3x3 atau 5x5).

b : Bias, nilai skalar yang ditambahkan untuk setiap filter.

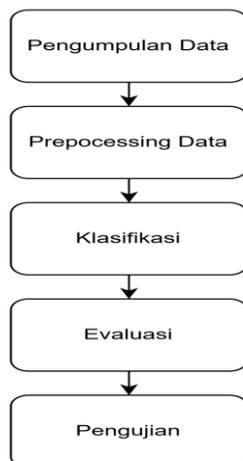
\otimes : Operasi konvolusi (pengalian elemen-matriks dan penjumlahan).

Z : Output yang dikenal sebagai *feature map*.

Setelah operasi konvolusi dilakukan, selanjutnya fungsi aktivasi ReLU (Rectified Linear Unit) digunakan untuk mengenalkan non-linearitas:

$$A = ReLU(Z) = \max(0, Z)$$

Fungsi ReLU menetapkan semua nilai negatif menjadi nol untuk meningkatkan efisiensi komputasi dan mempercepat konvergensi.



Gambar 1. Metode Alur Penelitian

Sumber: Data Diolah

Max Pooling

Max pooling bertujuan untuk mengurangi sebuah dimensi dari feature map yang dihasilkan dari lapisan konvolusi sebelumnya, namun tetap mempertahankan fitur yang paling penting. Proses ini mengambil nilai maksimum dari sekelompok piksel dalam jendela filter kecil. Jika filter pooling adalah 2×2 , maka pooling dilakukan dengan:

$$Z_{pool}(i, j) = \max(Z[i: i + 2, j: j + 2])$$

i dan j adalah indeks posisi piksel, dan pooling mengambil nilai maksimum dari tiap jendela ukuran 2×2 piksel.

Fully Connected Layer

Setelah melalui beberapa lapisan sebelumnya seperti konvolusi dan pooling, outputnya dipipihkan menjadi vektor 1D dan dimasukkan ke lapisan terhubung penuh (fully connected) untuk membuat prediksi akhir. Lapisan ini mirip dengan jaringan saraf biasa, di mana output dari lapisan pooling dikalikan dengan bobot dan ditambahkan dengan bias, lalu melewati fungsi aktivasi.

$$Y = W \cdot A_{pool} + b$$

Keterangan:

W : Matriks bobot *fully connected*

A_{pool} : Output dari lapisan pooling terakhir yang telah dipipihkan

b : Bias

Lapisan *Output* dan Fungsi *Softmax*

Lapisan *output* menggunakan fungsi aktivasi *Softmax* untuk mengubah hasil menjadi probabilitas bagi setiap kelas. Fungsi ini memastikan nilai output berada dalam rentang $[0,1]$ dan jumlah total probabilitas sama dengan 1.

$$P(y_i) = \frac{e^{z_i}}{\sum_{j=1}^n e^{z_j}}$$

Keterangan:

$P(y_i)$: Probabilitas kelas i .

z_i : Skor yang diberikan oleh model untuk kelas i .

n : Jumlah total kelas

e : Bilangan konstan Euler (2, 71828....)

Hasil akhir berupa kelas dengan probabilitas tertinggi yang diprediksi sebagai label citra.

Evaluasi Model

Evaluasi pada model digunakan untuk menilai performa model yang digunakan untuk mengklasifikasikan citra daun kentang ke dalam tiga kategori: *Early Blight*, *Late Blight*, dan *Healthy*. Beberapa metrik yang digunakan dalam evaluasi ini meliputi:

Akurasi

Akurasi adalah metrik dasar yang mengukur persentase prediksi yang benar dari keseluruhan data uji. Akurasi memberikan gambaran umum tentang seberapa baik model dalam memprediksi kelas secara keseluruhan.

Rumus:

$$\text{Akurasi} = \frac{\text{Jumlah prediksi benar}}{\text{Total data}}$$

Precision

Precision mengukur seberapa banyak dari prediksi positif yang benar-benar sesuai dengan kelas target. *Precision* sangat penting ketika kesalahan positif palsu (false positive) harus diminimalkan.

Rumus:

$$\text{Precision} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Positives}}$$

Recall (Sensitivity)

Recall mengukur kemampuan model dalam mendeteksi semua instance yang benar-benar termasuk dalam kelas target. *Recall* penting ketika kesalahan negatif palsu (false negative) harus diminimalkan.

Rumus:

$$\text{Recall} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Negatives}}$$

F1-Score

F1-Score adalah nilai rata-rata yang bersifat harmonik antara *precision* dan *recall*. Metrik ini dapat dimanfaatkan ketika terdapat ketidakseimbangan antara kelas positif dan negatif.

Rumus:

$$F1 - \text{Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Grafik Akurasi dan Loss

Sewaktu berlangsungnya proses pelatihan, grafik akurasi serta loss digunakan buat memantau kinerja model. Grafik ini menunjukkan perkembangan akurasi dan penurunan loss seiring bertambahnya *epoch*. Korelasi positif antara data pelatihan dan data validasi menjadi indikator bahwa model berjalan dengan baik dan tidak mengalami *overfitting*.

Pengujian

Pengujian Dengan Data Uji

Data uji yang digunakan meliputi citra yang dibagi berdasarkan kategori *Early Blight*, *Late Blight*, dan *Healthy*. Model menghasilkan prediksi untuk setiap citra, yang kemudian dibandingkan dengan label sebenarnya.

Confusion Matrix

Confusion matrix diterapkan untuk memvisualisasikan performa model dengan memberikan rincian jumlah *True Positives* (TP), *True Negatives* (TN), *False Positives* (FP), dan *False Negatives* (FN).

Visualisasi Prediksi

Model menghasilkan visualisasi dari citra uji dengan label prediksi yang ditampilkan di atas citra. Hal ini memberikan gambaran langsung tentang akurasi prediksi model pada setiap gambar dan membantu dalam identifikasi potensi kesalahan.

HASIL DAN PEMBAHASAN

Epoch adalah tahap dalam pelatihan neural network di mana seluruh dataset diproses dalam satu siklus penuh. Jika hanya menggunakan satu epoch, proses pelatihan akan terlalu berat dan memakan waktu karena banyaknya data yang digunakan. Oleh karena itu, data dibagi menjadi batch dengan ukuran tertentu untuk mempercepat proses pelatihan. Dalam penelitian ini, digunakan ukuran batch sebanyak 20. Untuk menentukan jumlah epoch, peneliti menyesuaikan ukuran batch dengan jumlah sampel yang digunakan.

Proses klasifikasi menggunakan dataset yang terdiri dari 1152 sampel, yang dibagi dengan proporsi 80% untuk pelatihan dan 20% untuk pengujian. Secara rinci, terdapat 900 gambar daun kentang untuk pelatihan dan 450 gambar untuk pengujian. Model dilatih dengan batch size sebanyak 20, serta melibatkan 20 steps per epoch untuk data pelatihan dan 45 steps per epoch untuk data pengujian.

Selanjutnya, pelatihan dilakukan dengan menggunakan citra daun kentang yang telah dibagi, dan model dilatih menggunakan metode fit. Table menunjukkan hasil dari proses fit model, yang memperlihatkan bahwa nilai akurasi untuk data pelatihan dan data pengujian meningkat dari epoch 1 hingga epoch 10.

Pada Tabel 1, terlihat bahwa pada epoch pertama, nilai akurasi untuk data pelatihan adalah 0,4210 dengan nilai loss 1.0644. Pada epoch kedua, nilai akurasi meningkat menjadi 0,6549 dengan loss yang turun menjadi 0,8585. Pada *epoch* ketiga, akurasi mencapai 0,6838 dengan loss 0,7308, dan terus meningkat hingga mencapai akurasi 0,9870 pada epoch ke-10, dengan nilai loss 0.0392. Secara keseluruhan, akurasi pada data pelatihan terus menunjukkan peningkatan seiring bertambahnya epoch, sementara loss terus berkurang, mencerminkan perbaikan dalam model.

Tabel 1
Hasil Akurasi setiap Epoch

Epoch	Training Accuracy	Training loss	Validation Accuracy	Validation Loss	Test Accuracy
1	0.4210	1.0644	0.6674	0.8941	
2	0.6549	0.8585	0.5884	0.9345	
3	0.6549	0.8585	0.5884	0.9345	
4	0.7988	0.4629	0.9163	0.2164	
5	0.7988	0.4629	0.9163	0.2164	
6	0.7988	0.4629	0.9163	0.2164	
7	0.7988	0.4629	0.9163	0.2164	
8	0.7988	0.4629	0.9163	0.2164	
9	0.9625	0.0971	0.9488	0.1205	
10	0.9870	0.0392	0.9558	0.1380	
11	0.9898	0.0334	0.9558	0.1554	
12	0.9932	0.0255	0.9419	0.1860	
13	0.9723	0.0648	0.9279	0.2568	
14	0.9841	0.0390	0.9279	0.2024	
15	0.9954	0.0085	0.9558	0.1395	
16	1.0000	0.0033	0.9558	0.1755	
17	1.0000	0.0010	0.9558	0.1801	
18	1.0000	5.3941e-04	0.9558	0.1854	
19	1.0000	5.1044e-04	0.9558	0.1881	
Optimal Epoch	9				94.88%

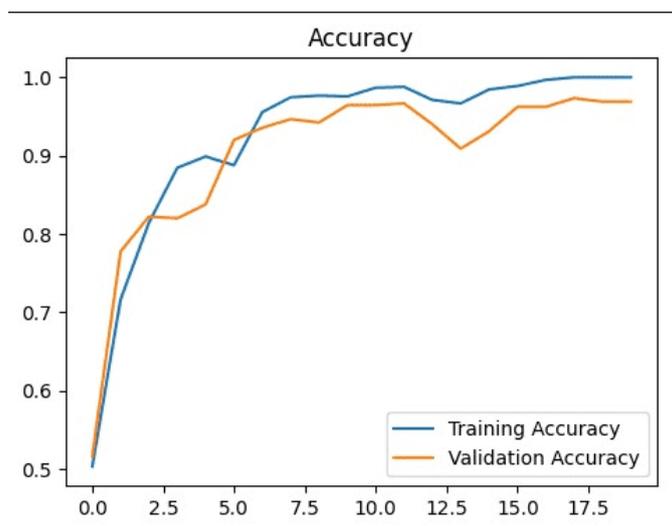
Sumber: Data Diolah

Sementara itu, pada data pengujian, nilai akurasi pada epoch pertama adalah 0,6674 dengan loss 0,8941. Pada epoch kedua, akurasi meningkat menjadi 0,5884 dengan loss yang sedikit naik menjadi 0,9345. Pada epoch ketiga, akurasi pada data pengujian mencapai 0,7791 dengan loss 0,5930, dan terus meningkat hingga mencapai akurasi 0,9558 pada epoch ke-10, dengan nilai loss 0.1380. Seiring berjalannya epoch, nilai akurasi pada data pengujian juga menunjukkan peningkatan signifikan, diikuti dengan penurunan nilai loss, yang menunjukkan kinerja model yang semakin optimal.

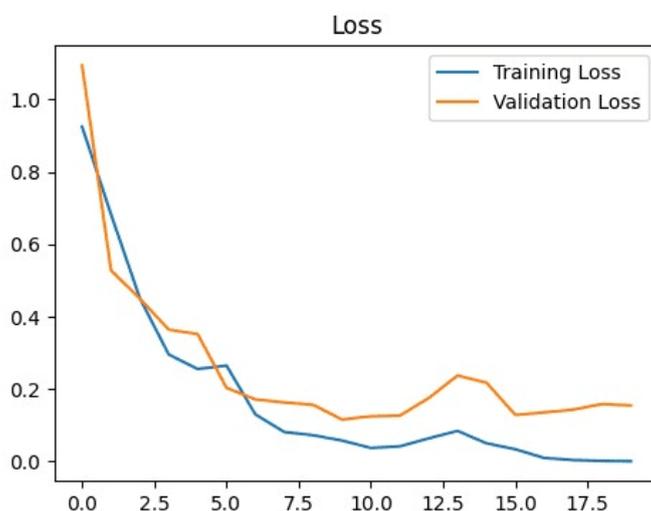
Pada Gambar 2 & 3, ditampilkan grafik yang menunjukkan perkembangan akurasi dan juga loss pada klasifikasi daun tanaman kentang menggunakan arsitektur CNN yang diusulkan. Dapat dilihat garis pertama pada Gambar dan Gambar mewakili data pengujian, sementara garis kedua mewakili data pelatihan.

Terlihat Gambar 2, terlihat bahwa nilai akurasi untuk data pelatihan dan pengujian terus meningkat. Begitu pula, pada Gambar 3, nilai loss untuk kedua jenis data, pelatihan dan pengujian, terus mengalami penurunan. Grafik akurasi dan loss ini menunjukkan adanya korelasi positif antara data pelatihan dan pengujian, yang terlihat dari peningkatan akurasi yang diikuti dengan penurunan loss secara seiring, menunjukkan hubungan yang searah.

Pada Gambar 4, 5, dan 6 yang diunggah sebagai data uji dianalisis menggunakan metode deteksi gambar dengan tingkat akurasi yang tinggi. Proses ini mencakup pengolahan sejumlah file gambar secara otomatis, dengan hasil berupa informasi detail seperti nomor file, lokasi folder penyimpanan, dan hasil deteksi dari setiap gambar. Selain itu, gambar yang telah melalui proses deteksi akan ditampilkan beserta hasil identifikasinya. Berdasarkan hasil analisis, dapat disimpulkan bahwa metode deteksi yang digunakan mampu mendeteksi setiap gambar dengan akurasi yang baik.

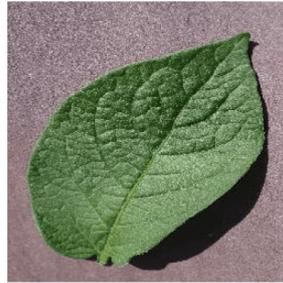


Gambar 2. Grafik nilai akurasi data *training* dan *testing*
Sumber: Data Diolah



Gambar 3. Grafik nilai *loss* data *training* dan *testing*
Sumber: Data Diolah

Filename: 1
Folder: data_uji_ph
Prediction: Healthy



Gambar 4. Hasil identifikasi daun sehat (*healty*)

Sumber: Data Diolah

Filename: 3
Folder: data_uji_peb
Prediction: Early Blight



Gambar 5. Hasil identifikasi daun *early blight*

Sumber: Data Diolah

Filename: 8
Folder: data_uji_plb
Prediction: Late Blight



Gambar 6. Hasil identifikasi daun *late blight*

Sumber: Data Diolah

SIMPULAN

Penelitian ini berhasil mengimplementasikan metode *Convolutional Neural Network* (CNN) untuk melakukan deteksi jenis penyakit pada daun kentang, khususnya *late blight*, *early blight*, dan daun sehat. Berdasarkan hasil pelatihan, model mencapai akurasi sebesar 98.7% pada data pelatihan dan 95.58% pada data pengujian. Proses preprocessing seperti normalisasi citra dan pembagian dataset menjadi train dan test terbukti efektif dalam meningkatkan efisiensi dan performa model. Hasil evaluasi menggunakan metrik seperti precision, recall, dan F1-score menunjukkan kemampuan model untuk mengklasifikasikan citra secara akurat. Visualisasi prediksi juga mengindikasikan bahwa model mampu mengenali pola penyakit dengan baik. Penelitian ini memberikan solusi instan yang dapat membantu petani kentang dalam mendeteksi penyakit tanaman secara otomatis dan lebih akurat, akan tetapi ada beberapa hal yang masih perlu ditingkatkan, seperti hal nya menambah jumlah data daun sehat untuk meningkatkan keseimbangan dataset dan mempertimbangkan variasi kondisi lingkungan dalam pengumpulan data.

DAFTAR PUSTAKA

- Amatullah, L., Ein, I., & Santoni, M. M. (2021). Identifikasi Penyakit Daun Kentang Berdasarkan Fitur Tekstur Dan Warna Dengan Menggunakan Metode K-Nearest Neighbor. *Prosiding Seminar Nasional Mahasiswa Bidang Ilmu Komputer dan Aplikasinya*, 2(1), 783-791.
- Emmanuel, T. O., Plant Village Dataset, *Kaggle*, <https://www.kaggle.com/emmarex/plantdisease>, diakses pada 24 Juli 2020.
- Lestari, S., & Nauval, K. I. (2021). Implementasi Deteksi Objek Penyakit Daun Kentang Dengan Metode Convolutional Neural Network. *Jurnal Teknologi dan Informatika Multimedika*, 6(2), 87-95.
- Rahmi, H., Nurhafisah, Andriani, I., & Fitriawaty. (2021). Petunjuk Teknis Budidaya Tanaman Kentang. *BPTP Balitbangtan: Sulawesi Barat*.
- Ratnawati, L., & Sulistyningrum, D. R. (2019). Penerapan Random Forest Untuk Mengukur Tingkat Keparahan Penyakit Pada Daun Apel. *Jurnal Sains dan Seni ITS*, 8(2), 71-77.
- Sekar, D. P., Nugroho, P., & Santoso, R. (2020). Penerapan Teknologi Pengolahan Citra Untuk Deteksi Penyakit Daun. *Jurnal Teknologi Terapan*, 9(2), 112-118.
- Saputra, R., & Ibadillah, M. (2019). Modernisasi Pertanian Dengan Teknologi Citra. *Jurnal Teknologi Pertanian*, 10(4), 33-41.