

Terbit : 12 Oktober 2024

Klasifikasi Penyakit Daun Tomat dengan Perbandingan Fungsi Aktivasi Multi Layer Perceptron

Masri Wahyuni

Akademi Manajemen Informatika dan Komputer Polibisnis

masriwahyuni997@gmail.com

ABSTRAK

Penelitian ini bertujuan untuk meningkatkan akurasi pendeteksian penyakit daun tomat melalui kombinasi arsitektur Convolutional Neural Network (CNN) VGG-16 dan Multi-Layer Perceptron (MLP) dengan berbagai fungsi aktivasi. Dataset yang digunakan terdiri dari 1.000 gambar daun tomat, terbagi menjadi 10 kategori penyakit, termasuk Tomato Bacterial Spot, Early Blight, Late Blight, dan Tomato Mosaic Virus. Tiga model klasifikasi MLP diuji, masing-masing dengan fungsi aktivasi sigmoid, tanh, dan ReLU, menggunakan aplikasi Orange 3. Evaluasi dilakukan dengan metrik akurasi, presisi, dan recall melalui proses validasi silang 10-fold. Hasil menunjukkan bahwa fungsi aktivasi tanh (MLP-2) memberikan performa terbaik dengan akurasi, presisi, dan recall sebesar 0,797, diikuti oleh ReLU (MLP-3) dengan nilai 0,78, sedangkan sigmoid (MLP-1) mencatatkan performa terendah dengan akurasi 0,721. Analisis confusion matrix mengungkapkan bahwa kesalahan klasifikasi sering terjadi pada kelas dengan kemiripan visual, seperti Early Blight dan Late Blight. Model MLP-2 menunjukkan keunggulan dalam menangkap pola non-linear antar fitur, sementara MLP-3 menawarkan keseimbangan antara efisiensi dan akurasi. Kesimpulan menunjukkan bahwa kombinasi VGG-16 dan MLP dengan fungsi aktivasi tanh adalah pendekatan optimal untuk pendeteksian penyakit daun tomat. Penelitian ini memberikan kontribusi signifikan terhadap pengembangan sistem deteksi dini penyakit tanaman, yang berpotensi membantu peningkatan kualitas dan kuantitas produksi tomat. Teknik augmentasi data, optimasi parameter, dan pembobotan ulang kelas direkomendasikan untuk peningkatan performa lebih lanjut.

Kata kunci: VGG-16, MLP, Sigmoid, Tanh, ReLU, Penyakit Daun Tomat

ABSTRACT

This study aims to improve the accuracy of tomato leaf disease detection through the combination of the VGG-16 Convolutional Neural Network (CNN) architecture and Multi-Layer Perceptron (MLP) with various activation functions. The dataset used consists of 1,000 images of tomato leaves, categorized into 10 disease classes, including Tomato Bacterial Spot, Early Blight, Late Blight, and Tomato Mosaic Virus. Three MLP classification models were tested, each with sigmoid, tanh, and ReLU activation functions, using the Orange 3 application. The evaluation was conducted using accuracy, precision, and recall metrics through a 10-fold cross-validation process. The results show that the tanh activation function (MLP-2) provided the best performance with accuracy, precision, and recall of 0.797, followed by ReLU (MLP-3) with a score of 0.78, while sigmoid (MLP-1) recorded the lowest performance with an accuracy of 0.721. The confusion matrix analysis revealed that misclassification often occurred in classes with visual similarities, such as Early Blight and Late Blight. The MLP-2 model demonstrated superiority in capturing non-linear patterns among features, while MLP-3 offered a balance between efficiency and accuracy. The conclusion indicates that the combination of VGG-16 and MLP with the tanh activation function is an optimal approach for detecting tomato leaf diseases. This study contributes significantly to the development of early plant disease detection systems, potentially aiding in the improvement of tomato production quality and

quantity. Data augmentation techniques, parameter optimization, and class reweighting are recommended for further performance enhancement.

Keywords: VGG-16, MLP, Sigmoid, Tanh, ReLU, Tomato Leaf Diseases

PENDAHULUAN

Tomat (*Solanum lycopersicum*) adalah tanaman hortikultura yang dikenal dengan buahnya yang kaya akan nutrisi seperti vitamin C dan likopen [1]. Buah tomat merupakan salah satu komoditi ekspor yang memiliki potensi besar, terutama mengingat tingginya permintaan global [2]. Namun, ekspor tomat dari Indonesia masih tergolong rendah jika dibandingkan dengan negara seperti Taiwan atau India [2]. Hal ini disebabkan oleh kurangnya penanganan yang serius terhadap tanaman tomat, baik dari segi kualitas hasil panen maupun kuantitas produksi [3]. Upaya perbaikan dalam teknik budidaya, pengelolaan pasca-panen, dan akses pasar yang lebih luas sangat diperlukan untuk meningkatkan daya saing tomat Indonesia di pasar internasional [4]

Salah satu tantangan dalam penanganan tanaman tomat di Indonesia adalah sulitnya mendeteksi dan mencegah penyakit yang menyerang tanaman ini. Penyakit seperti Tomato Bacterial Spot, Tomato Early Blight, Tomato Late Blight, Tomato Leaf Mold, Tomato Septoria Leaf Spot, Tomato Spider Mites (Two-Spotted Spider Mite), Tomato Target Spot, Tomato Mosaic Virus, dan Tomato Yellow Leaf Curl Virus merupakan beberapa jenis penyakit yang sering menyerang daun tanaman tomat. Kemiripan gejala serta kerusakan yang diakibatkan penyakit-penyakit ini menjadi alasan utama sulitnya pendeteksian dan penanganan yang efektif [5]. Untuk mengatasi masalah ini, diperlukan sebuah sistem pendeteksian dini yang mampu mengidentifikasi jenis penyakit daun secara akurat. Teknologi computer vision dapat menjadi solusi alternatif, dengan memanfaatkan pengambilan gambar daun tanaman tomat yang kemudian diproses untuk mengidentifikasi apakah daun tersebut terkena penyakit tertentu atau dalam kondisi normal .

Beberapa penelitian sebelumnya telah melakukan pendeteksian penyakit daun tomat dengan menggunakan ekstraksi fitur tradisional, seperti Histogram of Oriented Gradients (HOG), Local Binary Patterns (LBP), dan Gray Level Co-occurrence Matrix (GLCM), kemudian mengolah hasilnya dalam bentuk klasifikasi [6], [7], [8]. Namun, model berbasis ekstraksi fitur tradisional ini memiliki kekurangan, salah satunya adalah kebutuhan untuk melakukan pre-processing terpisah, seperti mengubah struktur gambar menjadi bentuk grayscale, melakukan resizing, dan rotating sebelum proses analisis [9]. Dalam penelitian ini, penulis ingin memanfaatkan arsitektur Convolutional Neural Network (CNN) yaitu VGG-16, yang terkenal efektif dan efisien dalam mengekstrak fitur langsung dari gambar, terutama pada gambar dengan skala besar, sehingga dapat mengurangi kebutuhan pre-processing yang rumit [10].

Pemilihan arsitektur CNN sebagai media ekstraksi fitur dibandingkan metode tradisional didasarkan pada kemampuannya untuk secara otomatis mengekstraksi fitur dari gambar tanpa memerlukan pre-processing yang kompleks [11], sehingga lebih adaptif terhadap variasi data seperti warna, tekstur, dan bentuk. VGG-16 dianggap efektif dan efisien dalam mengekstrak fitur dari gambar daun tomat karena memiliki arsitektur yang dalam dengan susunan lapisan konvolusi yang terorganisir, memungkinkan deteksi pola visual yang kompleks sekaligus menjaga kesederhanaan desain model. Beberapa penelitian yang telah memanfaatkan VGG-16 dalam pendeteksian penyakit tanaman termasuk deteksi penyakit pada daun padi menggunakan gambar leaf blast [10], klasifikasi penyakit daun anggur seperti powdery mildew [12], dan identifikasi jenis daun tanaman obat menggunakan CNN dengan model VGG-16 [13] . Hal ini menunjukkan bahwa VGG-16 memiliki keunggulan dalam menganalisis penyakit pada berbagai jenis tanaman secara akurat.

Salah satu kelebihan lain dari arsitektur CNN, khususnya VGG-16, adalah kemampuannya untuk dikombinasikan dengan algoritma klasifikasi populer seperti Multi-Layer Perceptron (MLP). Dengan memanfaatkan hasil ekstraksi fitur dari VGG-16 sebagai dataset, dapat dibentuk model analisis deteksi penyakit daun tomat yang lebih akurat menggunakan algoritma tersebut. Contoh penelitian yang memanfaatkan kombinasi VGG-16 dan MLP termasuk analisis penyakit daun kapas (cotton leaf disease detection) [14], klasifikasi penyakit black rot pada daun anggur [15], dan identifikasi penyakit blight pada daun kentang [16].

Penelitian ini bertujuan untuk mengkombinasikan VGG-16 dengan Multi-Layer Perceptron (MLP) dengan variasi fungsi aktivasi seperti Sigmoid, ReLU, dan Tanh, guna membangun model pendeteksian jenis penyakit daun tomat [17]. Dengan memanfaatkan 1.000 gambar daun tomat yang terbagi ke dalam 10 kategori penyakit berbeda, kombinasi model dengan varian fungsi aktivasi ini diuji dan dibandingkan untuk menentukan model yang paling optimal. Evaluasi dilakukan menggunakan metrik akurasi, presisi, dan recall untuk mengukur kinerja masing-masing model. Hasil penelitian diharapkan dapat memberikan kesimpulan mengenai model terbaik sebagai alternatif untuk pendeteksian dini penyakit daun tomat, sehingga dapat membantu mencegah serangan penyakit secara lebih efektif pada tanaman tomat.

METODOLOGI PENELITIAN

Multi Layer Perceptron (MLP) salah satu algoritma deep learning, sudah banyak digunakan dalam penelitian masalah klasifikasi karena memiliki kelebihan dibandingkan metode klasifikasi konvensional lain. MLP memiliki kelebihan seperti mampu mengadaptasikan dirinya dengan data, dapat memperkirakan hubungan antar keanggotaan kelas dengan atribut dari objek, lebih reliabel terhadap noise dalam data, dan mampu menghitung nilai probabilitas posterior, yang merupakan dasar untuk membangun aturan klasifikasi dan analisis statistika [17]. Multilayer perceptron (MLP) merupakan salah satu algoritma berbasis neural network yang terdiri dari input layer, dua atau lebih hidden layer, dan output layer, dimana algoritma ini memiliki kelebihan dalam hal kemampuannya beradaptasi terhadap noise pada data [18].

Confusion matrix adalah matriks untuk mengukur kinerja suatu klasifikasi yang memiliki 4 variabel yaitu TP (True Positive) berarti ketika sistem memprediksi positif dan hasilnya benar, TN (True Negative) berarti ketika sistem memprediksi negatif dan hasilnya benar, FP (False Positive) berarti ketika sistem memprediksi positif dan hasilnya salah, FN (False Negative) berarti ketika sistem memprediksi negatif dan hasilnya salah.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

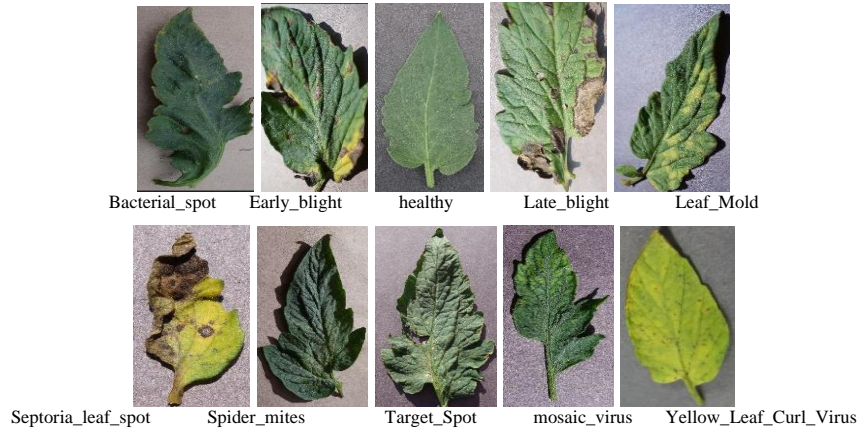
$$Precision = \frac{TP}{TP+FP}$$

$$Recall = \frac{TP}{TP+FN}$$

Data set yang digunakan dalam penelitian ini diambil dari Repository Kaggle yaitu data set leaf Tomato. Jumlah data set yang digunakan sebanyak 1000 data citra penyakit daun tomat yang dibagi menjadi 10 kelas dengan masing-masing kelas sebanyak 100 data citra.

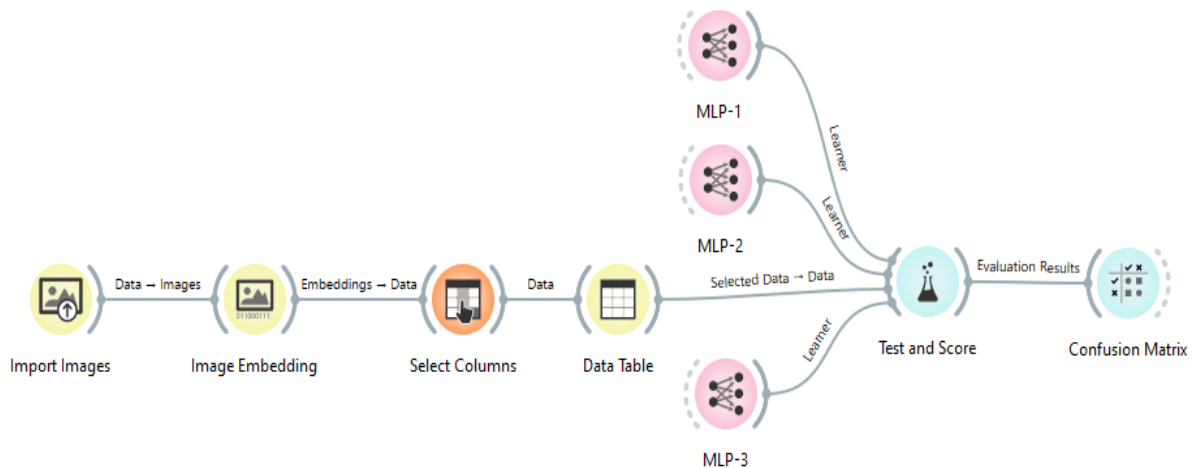
Tabel 1. Data Set Penyakit Daun Tomat

| No | Label | Jumlah Gambar |
|-----|---|---------------|
| 1. | Tomato Bacterial_spot | 100 |
| 2. | Tomato Early_blight | 100 |
| 3. | Tomato healthy | 100 |
| 4. | Tomato Late_blight | 100 |
| 5. | Tomato Leaf_Mold | 100 |
| 6. | Tomato Septoria_leaf_spot | 100 |
| 7. | Tomato Spider_mites Two-spotted_spider_mite | 100 |
| 8. | Tomato Target_Spot | 100 |
| 9. | Tomato Mosaic_virus | 100 |
| 10. | Tomato_Yellow_Leaf_Curl_Virus | 100 |



Gambar 1. Data penyakit daun tomat

Penelitian ini diuji menggunakan aplikasi data mining Orange 3, dibentuk model klasifikasi berdasarkan variasi kombinasi fungsi aktivasi dan fungsi optimasi seperti terlihat pada Gambar 2.

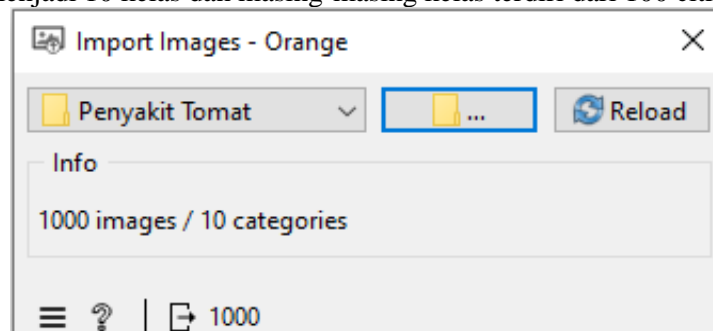


Gambar 2. Model Klasifikasi

Berikut adalah penjelasan mengenai widget yang digunakan dalam model klasifikasi diatas:

a. Import Image


Data set akan dibaca pada widget ini, data set yang digunakan sebanyak 1000 citra data daun tomat yang dibagi menjadi 10 kelas dan masing-masing kelas terdiri dari 100 citra data.



Gambar 3. Import Image

b. Image Embedding

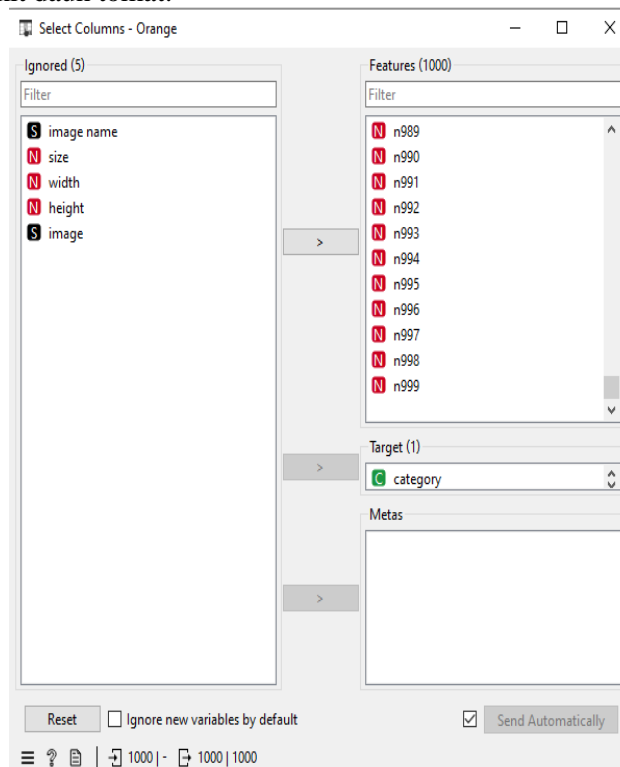
Widget ini untuk memilih model VGG 16 yang akan digunakan sebagai model pre-trained dalam proses transfer learning pada algoritma MLP.



Gambar 4. Image Embedding

c. Select columns

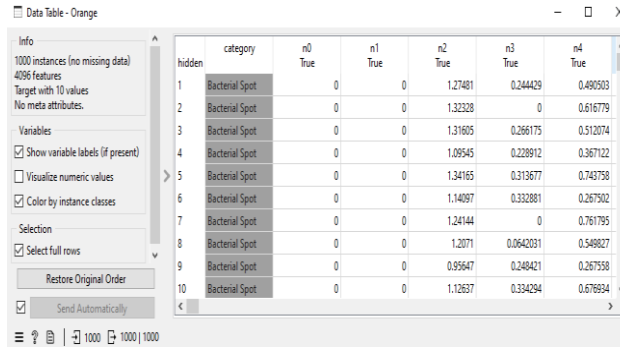
Widget ini digunakan untuk memilih fitur-fitur dan kategori kelas target yang akan digunakan di dalam klasifikasi penyakit daun tomat.



Gambar 5. Select Columns

d. Data Tabel

Widget ini digunakan untuk menampilkan data hasil ekstraksi fitur yang dipilih berdasarkan fitur-fitur dan kelas target dari widget Select Columns.

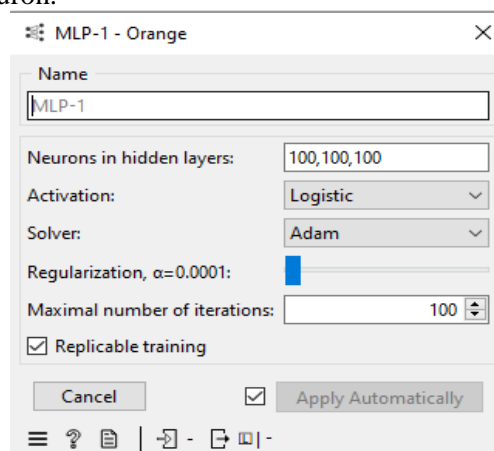


| hidden | category | n0 | n1 | n2 | n3 | n4 |
|--------|----------------|------|----|---------|-----------|----------|
| 1 | Bacterial Spot | True | 0 | 0 | 1.27481 | 0.244429 |
| 2 | Bacterial Spot | 0 | 0 | 1.32328 | 0 | 0.616779 |
| 3 | Bacterial Spot | 0 | 0 | 1.31605 | 0.286175 | 0.512074 |
| 4 | Bacterial Spot | 0 | 0 | 1.09545 | 0.228912 | 0.367122 |
| 5 | Bacterial Spot | 0 | 0 | 1.34165 | 0.313677 | 0.749758 |
| 6 | Bacterial Spot | 0 | 0 | 1.14097 | 0.332881 | 0.267502 |
| 7 | Bacterial Spot | 0 | 0 | 1.24144 | 0 | 0.761795 |
| 8 | Bacterial Spot | 0 | 0 | 1.2071 | 0.0642031 | 0.548827 |
| 9 | Bacterial Spot | 0 | 0 | 0.95647 | 0.248421 | 0.267558 |
| 10 | Bacterial Spot | 0 | 0 | 1.12637 | 0.334294 | 0.676934 |

Gambar 6. Data Tabel

e. Widget MLP-1

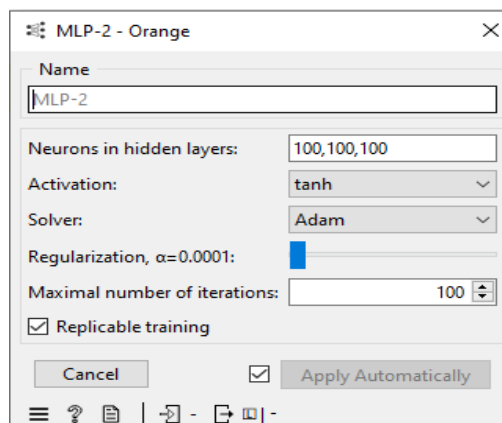
Widget yang digunakan sebagai learner proses klasifikasi. Pada MLP-1, digunakan kombinasi fungsi aktivasi sigmoid dan fungsi optimasi Adam, dengan tiga hidden layer dan masing-masing hidden layer memiliki 100 neuron.



Gambar 7. Widget MLP-1

f. Widget MLP-2

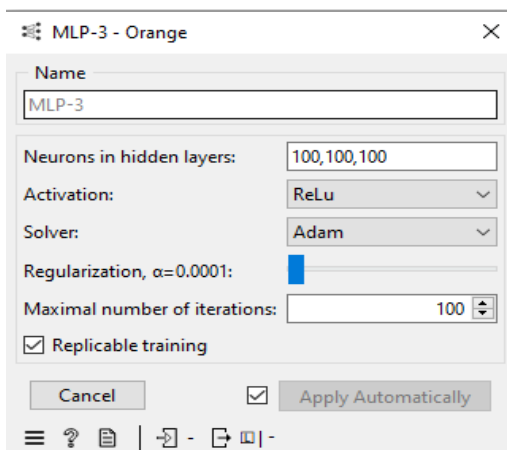
Widget yang digunakan sebagai learner proses klasifikasi. Pada MLP-2, digunakan kombinasi fungsi aktivasi ReLu dan fungsi optimasi Adam, dengan tiga hidden layer dan masing-masing hidden layer memiliki 100 neuron.



Gambar 8. Widget MLP-2

g. Widget MLP-3

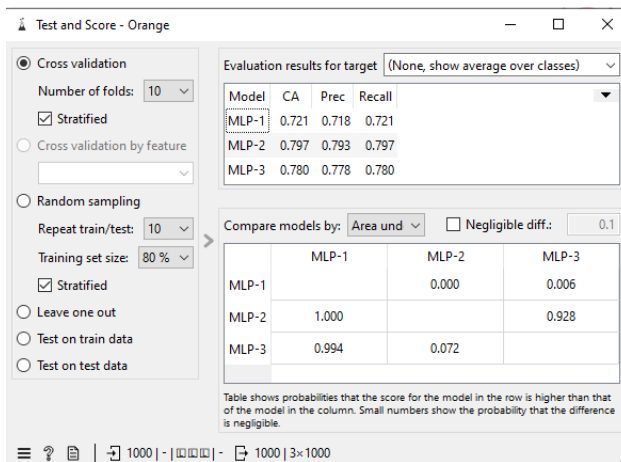
Widget yang digunakan sebagai learner proses klasifikasi. Pada MLP-3, digunakan kombinasi fungsi aktivasi Tanh dan fungsi optimasi Adam, dengan tiga hidden layer dan masing-masing hidden layer memiliki 100 neuron.



Gambar 9. Widget MLP-3

h. Test and Score

Pada widget test and score akan dapat mengetahui hasil dari klasifikasi penyakit daun tomat yang telah dilakukan melalui evaluation results. Pada widget ini, digunakan metrik evaluasi akurasi, presisi, dan recall untuk membandingkan kinerja model yang dihasilkan. Nilai metrik ini diperoleh dari proses 10-fold cross validation.



Gambar 10. Widget Test & Score

HASIL DAN PEMBAHASAN

Klasifikasi data menggunakan metode Multi Layer Perceptron (MLP) menghasilkan tabel confusion matrix, untuk masing-masing fungsi aktivasi. Gambar 11 menunjukkan confusion matrix dari hasil klasifikasi data menggunakan kombinasi VGG-16 dan MLP dengan fungsi aktivasi sigmoid.

| | | Predicted | | | | | | | | | | |
|--------|--------------------|----------------|--------------|---------|-------------|-----------|--------------------|-------------|-------------------|-------------------|---------------|------|
| | | Bacterial Spot | Early Blight | Healthy | Late Blight | Leaf Mold | Septoria Leaf Spot | Target Spot | Tomato Mosaic ... | Tomato Yellow ... | Two-Spotte... | Σ |
| Actual | Bacterial Spot | 80 | 10 | 0 | 1 | 0 | 4 | 4 | 0 | 1 | 0 | 100 |
| | Early Blight | 11 | 43 | 1 | 15 | 4 | 8 | 7 | 3 | 3 | 5 | 100 |
| | Healthy | 0 | 1 | 88 | 0 | 0 | 0 | 7 | 1 | 0 | 3 | 100 |
| | Late Blight | 3 | 14 | 2 | 58 | 13 | 5 | 1 | 1 | 3 | 0 | 100 |
| | Leaf Mold | 0 | 4 | 1 | 11 | 72 | 2 | 0 | 2 | 4 | 4 | 100 |
| | Septoria Leaf Spot | 10 | 5 | 0 | 4 | 8 | 64 | 4 | 2 | 2 | 1 | 100 |
| | Target Spot | 5 | 6 | 9 | 0 | 0 | 0 | 69 | 0 | 0 | 11 | 100 |
| | Tomato Mosaic ... | 0 | 0 | 2 | 0 | 4 | 1 | 0 | 89 | 0 | 4 | 100 |
| | Tomato Yellow ... | 3 | 4 | 0 | 2 | 0 | 1 | 0 | 0 | 83 | 7 | 100 |
| | Two-Spotte... | 2 | 2 | 3 | 0 | 2 | 1 | 9 | 5 | 1 | 75 | 100 |
| | Σ | 114 | 89 | 106 | 91 | 103 | 86 | 101 | 103 | 97 | 110 | 1000 |

Gambar 11. Confusion Matrix Model MLP-1

Gambar 11 di atas menunjukkan hasil klasifikasi menggunakan kombinasi model VGG-16 dan MLP dengan fungsi aktivasi sigmoid dalam 10-fold cross-validation untuk mendeteksi 10 jenis kelas. Prediksi yang benar terlihat di diagonal utama, seperti "Bacterial Spot" (80), "Healthy" (88), dan "Tomato Mosaic Virus" (89), menunjukkan performa yang baik pada beberapa kelas. Namun, kesalahan klasifikasi masih sering terjadi, terutama pada kelas dengan kemiripan visual, seperti "Early Blight" yang sering diklasifikasikan sebagai "Late Blight" (15 kali) dan "Leaf Mold" yang sering salah sebagai "Early Blight" (41 kali). Model ini bekerja sangat baik untuk kelas dengan pola visual yang lebih jelas, seperti "Healthy" dan "Tomato Mosaic Virus," tetapi kesulitan membedakan kelas dengan fitur yang tumpang tindih, seperti "Early Blight" dan "Late Blight." Secara keseluruhan, meskipun model menunjukkan hasil yang cukup baik, terdapat ruang untuk peningkatan melalui teknik augmentasi data, pembobotan ulang kelas, atau optimasi parameter lebih lanjut.

Gambar 12 menunjukkan confusion matrix dari hasil klasifikasi data menggunakan kombinasi VGG-16 dan MLP dengan fungsi aktivasi tanh.

| | | Predicted | | | | | | | | | | |
|--------|--------------------|----------------|--------------|---------|-------------|-----------|--------------------|-------------|-------------------|-------------------|---------------|-----|
| | | Bacterial Spot | Early Blight | Healthy | Late Blight | Leaf Mold | Septoria Leaf Spot | Target Spot | Tomato Mosaic ... | Tomato Yellow ... | Two-Spotte... | Σ |
| Actual | Bacterial Spot | 87 | 6 | 0 | 0 | 1 | 3 | 2 | 0 | 1 | 0 | 100 |
| | Early Blight | 8 | 55 | 1 | 7 | 6 | 7 | 5 | 3 | 6 | 2 | 100 |
| | Healthy | 0 | 0 | 93 | 0 | 1 | 0 | 4 | 0 | 0 | 2 | 100 |
| | Late Blight | 0 | 9 | 0 | 70 | 6 | 4 | 7 | 0 | 3 | 1 | 100 |
| | Leaf Mold | 2 | 3 | 1 | 3 | 79 | 3 | 2 | 1 | 2 | 4 | 100 |
| | Septoria Leaf Spot | 5 | 5 | 0 | 6 | 4 | 71 | 4 | 2 | 2 | 1 | 100 |
| | Target Spot | 0 | 1 | 5 | 1 | 2 | 3 | 77 | 0 | 1 | 10 | 100 |
| | Tomato Mosaic ... | 0 | 0 | 0 | 0 | 2 | 1 | 0 | 97 | 0 | 0 | 100 |
| | Tomato Yellow ... | 3 | 2 | 0 | 0 | 1 | 2 | 0 | 2 | 87 | 3 | 100 |
| | Two-Spotte... | 1 | 1 | 5 | 0 | 1 | 0 | 4 | 5 | 2 | 81 | 100 |
| Σ | 106 | 82 | 105 | 87 | 103 | 94 | 105 | 110 | 104 | 104 | 1000 | |

Gambar 12. Confusion Matrix Model MLP-2

Gambar 12 di atas menunjukkan hasil klasifikasi menggunakan kombinasi VGG-16 dan MLP dengan fungsi aktivasi tanh dalam 10-fold cross-validation untuk mendeteksi 10 kelas penyakit atau kondisi tanaman. Hasilnya menunjukkan performa tinggi pada beberapa kelas, seperti "Bacterial Spot" (87), "Healthy" (93), "Tomato Mosaic Virus" (97), dan "Two-Spotted Spider Mite" (81), dengan jumlah prediksi benar yang dominan. Namun, terdapat kesalahan klasifikasi signifikan pada kelas seperti "Early Blight", yang sering diklasifikasikan sebagai "Late Blight" (7 kali) dan "Leaf Mold" (6 kali), serta "Late Blight" yang salah diprediksi sebagai "Early Blight" (9 kali). Selain itu, "Targe Spot" memiliki 77 prediksi benar tetapi beberapa kali diklasifikasikan sebagai "Two-Spotted Spider Mite" (10 kali). Sementara itu, kelas seperti "Leaf Mold" dan "Septoria Leaf Spot" masih mengalami distribusi kesalahan ke beberapa kelas lainnya. Secara keseluruhan, fungsi aktivasi tanh menunjukkan peningkatan performa dengan prediksi yang lebih akurat untuk sebagian besar kelas, namun masih memerlukan perbaikan pada kelas-kelas dengan ciri visual yang mirip, seperti "Early Blight" dan "Late Blight", agar model dapat membedakan pola dengan lebih baik.

Gambar 13 menunjukkan confusion matrix dari hasil klasifikasi data menggunakan kombinasi VGG-16 dan MLP dengan fungsi aktivasi ReLU.

| | | Predicted | | | | | | | | | | |
|--------|--------------------|----------------|--------------|---------|-------------|-----------|--------------------|-------------|-------------------|-------------------|---------------|-----|
| | | Bacterial Spot | Early Blight | Healthy | Late Blight | Leaf Mold | Septoria Leaf Spot | Target Spot | Tomato Mosaic ... | Tomato Yellow ... | Two-Spotte... | Σ |
| Actual | Bacterial Spot | 85 | 5 | 0 | 0 | 0 | 5 | 3 | 0 | 2 | 0 | 100 |
| | Early Blight | 11 | 53 | 0 | 11 | 5 | 6 | 5 | 1 | 5 | 3 | 100 |
| | Healthy | 0 | 1 | 92 | 0 | 0 | 0 | 3 | 1 | 0 | 3 | 100 |
| | Late Blight | 0 | 8 | 0 | 65 | 12 | 5 | 5 | 2 | 0 | 3 | 100 |
| | Leaf Mold | 3 | 2 | 0 | 3 | 75 | 1 | 4 | 2 | 2 | 8 | 100 |
| | Septoria Leaf Spot | 6 | 4 | 0 | 2 | 5 | 77 | 4 | 2 | 0 | 0 | 100 |
| | Target Spot | 1 | 4 | 4 | 3 | 0 | 2 | 75 | 0 | 1 | 10 | 100 |
| | Tomato Mosaic ... | 0 | 0 | 0 | 0 | 2 | 1 | 1 | 96 | 0 | 0 | 100 |
| | Tomato Yellow ... | 2 | 4 | 0 | 1 | 1 | 1 | 1 | 2 | 84 | 4 | 100 |
| | Two-Spotte... | 2 | 3 | 4 | 0 | 4 | 0 | 5 | 4 | 0 | 78 | 100 |
| Σ | 110 | 84 | 100 | 85 | 104 | 98 | 106 | 110 | 94 | 109 | 1000 | |

Gambar 13. Confusion Matrix Model MLP-3

Gambar 13 di atas menunjukkan hasil klasifikasi menggunakan kombinasi VGG-16 dan MLP dengan fungsi aktivasi ReLU dalam 10-fold cross-validation untuk mendeteksi 10 kelas penyakit atau kondisi tanaman. Model menunjukkan performa yang baik pada beberapa kelas, seperti "Bacterial Spot" (85), "Healthy" (92), dan "Tomato Mosaic Virus" (96), dengan jumlah prediksi benar yang tinggi. Namun, kesalahan masih terjadi, terutama pada kelas dengan kemiripan visual, seperti "Early Blight" yang sering diklasifikasikan sebagai "Late Blight" (11 kali) dan "Late Blight" yang salah diprediksi sebagai "Leaf Mold" (12 kali). Selain itu, "Targe Spot" sering salah diklasifikasikan sebagai "Two-Spotted Spider Mite" (10 kali), sementara "Leaf Mold" dan "Tomato Yellow Leaf Curl Virus" masing-masing mengalami beberapa kesalahan ke kelas lain. Secara keseluruhan, fungsi aktivasi ReLU menghasilkan performa yang baik pada kelas dengan pola yang jelas, tetapi masih memerlukan peningkatan pada kelas-kelas dengan ciri visual yang tumpang tindih, misalnya melalui optimasi model atau augmentasi data untuk meningkatkan akurasi klasifikasi.

Berdasarkan hasil confusion matrix dari masing-masing variasi fungsi aktivasi, diperoleh nilai akurasi, presisi, dan recall masing-masing model, seperti terlihat pada Tabel 2.

Tabel 2. Metrik Evaluasi Model

| Model | Akurasi | Presisi | Recall |
|-------|---------|---------|--------|
| MLP-1 | 0.721 | 0.718 | 0.721 |
| MLP-2 | 0.797 | 0.793 | 0.797 |
| MLP-3 | 0.78 | 0.778 | 0.78 |

Tabel 2 di atas menunjukkan performa tiga model kombinasi VGG-16 dan MLP dengan fungsi aktivasi berbeda (sigmoid, tanh, dan ReLU) berdasarkan akurasi, presisi, dan recall. MLP-1 (fungsi aktivasi sigmoid) memiliki akurasi, presisi, dan recall sebesar 0.721, yang menunjukkan performa paling rendah dibandingkan model lain. Hal ini mengindikasikan bahwa fungsi aktivasi sigmoid kurang efektif dalam membedakan kelas dengan karakteristik kompleks, karena cenderung mengalami saturasi gradien pada nilai ekstrim.

MLP-2 (fungsi aktivasi tanh) menunjukkan performa terbaik dengan akurasi, presisi, dan recall sebesar 0.797. Fungsi aktivasi tanh yang memiliki rentang nilai -1 hingga 1 tampaknya lebih baik dalam menangkap hubungan non-linear antar fitur, sehingga menghasilkan prediksi yang lebih akurat dan konsisten.

MLP-3 (fungsi aktivasi ReLU) memiliki akurasi, presisi, dan recall sebesar 0.78, yang sedikit lebih rendah dibandingkan MLP-2 tetapi tetap lebih baik daripada MLP-1. Fungsi aktivasi ReLU yang sederhana dan efisien mampu menangani kompleksitas data dengan baik, tetapi sedikit kalah dalam performa dibandingkan tanh, mungkin karena adanya kesalahan prediksi pada kelas dengan kemiripan visual.

Secara keseluruhan, fungsi aktivasi tanh pada MLP-2 memberikan hasil terbaik dalam evaluasi ini, sedangkan fungsi sigmoid pada MLP-1 memiliki performa yang paling rendah. Model dengan ReLU (MLP-3) berada di posisi tengah, menunjukkan keseimbangan antara efisiensi dan akurasi dalam klasifikasi data.

KESIMPULAN

Kombinasi VGG-16 dan Multi-Layer Perceptron (MLP) dengan berbagai fungsi aktivasi menunjukkan performa yang bervariasi dalam mendeteksi 10 jenis kelas penyakit atau kondisi tanaman. Dari evaluasi yang dilakukan, fungsi aktivasi tanh pada model MLP-2 memberikan performa terbaik dengan nilai akurasi, presisi, dan recall masing-masing sebesar 0.797, menunjukkan kemampuan yang unggul dalam menangkap pola kompleks dan hubungan non-linear antar fitur. Meskipun demikian, fungsi aktivasi ReLU pada MLP-3 tetap memberikan hasil yang kompetitif dengan akurasi 0.78, menunjukkan keseimbangan antara efisiensi komputasi dan akurasi. Sebaliknya, fungsi aktivasi sigmoid pada MLP-1 memiliki performa paling rendah dengan akurasi 0.721, yang

mengindikasikan keterbatasannya dalam membedakan kelas dengan karakteristik yang tumpang tindih. Kesalahan klasifikasi cenderung terjadi pada kelas dengan ciri visual serupa, seperti "Early Blight" dan "Late Blight." Untuk meningkatkan performa, teknik augmentasi data, optimasi parameter, atau pembobotan ulang kelas dapat diterapkan. Secara keseluruhan, fungsi aktivasi tanh adalah pilihan yang paling optimal untuk meningkatkan akurasi klasifikasi dalam skenario ini.

DAFTAR PUSTAKA

- M. J. Ahmed, I. R. Iya, and M. F. Dogara, "Proximate, Mineral and Vitamin Content of Flesh, Blanched and Dried Tomatoes (*Lycopersicon esculentum*)," *Asian Food Sci. J.*, vol. 18, no. 4, pp. 11–18, 2020, doi: 10.9734/afsj/2020/v18i430223.
- Saptana *et al.*, "Competitiveness analysis of fresh tomatoes in Indonesia: Turning comparative advantage into competitive advantage," *PLoS One*, vol. 18, no. 11 November, pp. 1–29, 2023, doi: 10.1371/journal.pone.0294980.
- L. Okdinawati, Y. Sunitiyoso, T. M. Simatupang, P. Hermawan, P. Noerhatini, and D. Sitadewi, "Interaction model of agribusiness: The case of tomato farming in West Java," *Int. J. Bus. Glob.*, vol. 26, no. 1–2, pp. 24–40, 2020, doi: 10.1504/IJBG.2020.109827.
- M. I. Wahid, S. A. Mustamin, and A. Lawi, "Identifikasi Dan Klasifikasi Citra Penyakit Daun Tomat Menggunakan Arsitektur Inception V4," no. 2019, pp. 257–264, 2021.
- C. R. Kotta, D. Paseru, and M. Sumampouw, "Implementasi Metode Convolutional Neural Network untuk Mendeteksi Penyakit pada Citra Daun Tomat Implementation of Convolutional Neural Network Method to Detect Diseases in Tomato Leaf Image," pp. 123–132, 2022.
- W. S. Admass, Y. Y. Munaye, and G. A. Bogale, "Convolutional neural networks and histogram-oriented gradients: a hybrid approach for automatic mango disease detection and classification," *Int. J. Inf. Technol.*, vol. 16, no. 2, pp. 817–829, 2024, doi: 10.1007/s41870-023-01605-z.
- R. Khan, N. Ud Din, A. Zaman, and B. Huang, "Automated Tomato Leaf Disease Detection Using Image Processing: An SVM-Based Approach with GLCM and SIFT Features," *J. Eng. (United Kingdom)*, vol. 2024, 2024, doi: 10.1155/2024/9918296.
- A. Rachmad, M. Syarief, S. Rifka, F. Sonata, W. Setiawan, and E. M. S. Rochman, "Corn Leaf Disease Classification Using Local Binary Patterns (LBP) Feature Extraction," *J. Phys. Conf. Ser.*, vol. 2406, no. 1, 2022, doi: 10.1088/1742-6596/2406/1/012020.
- R. Zebari, A. Abdulazeez, D. Zeebaree, D. Zebari, and J. Saeed, "A Comprehensive Review of Dimensionality Reduction Techniques for Feature Selection and Feature Extraction," *J. Appl. Sci. Technol. Trends*, vol. 1, no. 1, pp. 56–70, 2020, doi: 10.38094/jastt1224.
- M. Iqbal, F. Rozi, N. O. Adiwijaya, and D. I. Swasono, "Identifikasi Kinerja Arsitektur Transfer Learning VGG16, ResNet-50, dan Inception-V3 Dalam Pengklasifikasian Citra Penyakit Daun Tomat Identification of VGG16, ResNet-50, and Inception-V3 Transfer Architecture Performance in Image Classification of Tomato Leaf Diseases," vol. 5, no. 2, pp. 145–154, 2023.
- P. O. Sgd, D. Irfan, R. Rosnelly, M. Wahyuni, J. T. Samudra, and A. Rangga, "MENGGUNAKAN CNN," vol. 4307, no. June, pp. 244–253, 2022.
- Y. Riyanto, D. Riana, Y. Riyanto, and D. Riana, "Klasifikasi penyakit citra daun anggur menggunakan model CNN-VGG16 Grape leaf image disease classification using CNN-VGG16 model," vol. 9, no. July, pp. 218–223, 2021, doi: 10.14710/jtsiskom.2021.14013.
- S. Adiningsi and R. A. Saputra, "IDENTIFIKASI JENIS DAUN TANAMAN OBAT MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN) DENGAN MODEL VGG16," pp. 451–460, 2020.
- N. M. Awandi, B. Nugroho, and A. Akbar, "Klasifikasi Hama Dan Penyakit Daun Kapas Berdasarkan Fitur Tekstur Dan," vol. 10, no. 2, pp. 72–80, 2023.
- K. E. N. Ratri, R. Wardani, and L. Leonardi, "Klasifikasi Penyakit pada Daun Anggur menggunakan Metode Convolutional Neural Network," vol. 17, no. 2, pp. 112–126, 2023.
- A. J. Rozaqi, A. Sunyoto, R. Arief, M. T. Informatika, and U. A. Yogyakarta, "Deteksi Penyakit pada

Daun Kentang Menggunakan Pengolahan Citra dengan Metode Convolutional Neural Network,” pp. 22–31.

D. Pardede, B. H. Hayadi, and Iskandar, “Kajian Literatur Multi Layer Perceptron Seberapa Baik Performa Algoritma Ini,” *J. ICT Apl. Syst.*, vol. 1, no. 1, pp. 23–35, Jun. 2022, doi: 10.56313/jictas.v1i1.127.

R. H. Saputra, R. Cipta, and S. Hariyono, “Deteksi Penyakit Tomat Melalui Citra Daun menggunakan Metode Convolutional Neural Network,” vol. 5, no. 1, pp. 43–51, 2023.