Analisis Penyakit pada Daun Padi Menggunakan VGG-16 Transfer Learning dan Teknik Segmentasi K-Mean

Jose Julian Hidayat[1], Cindy Setyowati[2], Aditya Pratama Werdana[3]

[1,2,3]Department of Informatics Engineering, College of Pelita Bangsa Univercity, Bekasi, Indonesia
e-mail: josejulianhidayat@gmail.com1, cindyssetyo@gmail.com, adityapw2000@gmail.com

(Received: Nopember 2024, Revised: Februari 2025, Accepied: April 2025

Abstract— *Early diagnosis of leaf diseases is crucial to increasing crop yields since illnesses in rice plants can significantly affect agricultural production. Using Transfer Learning techniques on an enhanced VGG-16 model in conjunction with K-Means-based segmentation, this study suggests a deep learning-based approach for rice leaf disease diagnosis. Because of its exceptional ability to extract features from digital photos, VGG-16 was selected to capture crucial information about the leaf surface that might indicate disease. In order to separate contaminated regions from the background and enable more precise and effective identification, K-Means segmentation is employed as a preprocessing step. The dataset utilized in this experiment contains a wide range of photos from multiple disease categories on rice plants. According to experimental data, the approach can identify the type of sickness on the leaves with great accuracy—it can surpass 90%. By concentrating on key regions of the image, K-Means enhances detection performance. When compared to conventional methods, these results show how this combination strategy may increase the accuracy of rice leaf disease diagnosis. It is anticipated that this system's deployment would help agronomists and farmers efficiently monitor plant health, which will boost agricultural output.*

Keyword: Disease Detection, Rice Leaf, VGG-16, Transfer Learning, K-Means, Image Segmentation

***I**ntisari*— *Diagnosis dini penyakit daun sangat penting untuk meningkatkan hasil panen karena penyakit pada tanaman padi dapat secara signifikan mempengaruhi produksi pertanian. Dengan menggunakan teknik Transfer Learning pada model VGG-16 yang telah disempurnakan bersama dengan segmentasi berbasis K-Means, penelitian ini menyarankan pendekatan berbasis pembelajaran mendalam untuk diagnosis penyakit daun padi. Karena kemampuannya yang luar biasa dalam mengekstrak fitur dari foto digital, VGG-16 dipilih untuk menangkap informasi penting tentang permukaan daun yang mungkin mengindikasikan adanya penyakit. Untuk memisahkan daerah yang terkontaminasi dari latar belakang dan memungkinkan identifikasi yang lebih tepat dan efektif, segmentasi K-Means digunakan sebagai langkah prapemrosesan. Kumpulan data yang digunakan dalam percobaan ini berisi berbagai macam foto dari berbagai kategori penyakit pada tanaman padi. Menurut data percobaan, pendekatan ini dapat mengidentifikasi jenis penyakit pada daun dengan sangat akurat-akurasi dapat melampaui 90%. Dengan berkonsentrasi pada daerah-daerah kunci pada gambar, K-Means meningkatkan kinerja deteksi. Jika dibandingkan dengan metode konvensional, hasil ini menunjukkan bagaimana strategi kombinasi ini dapat meningkatkan akurasi diagnosis penyakit daun padi. Penggunaan sistem ini diharapkan dapat membantu para ahli agronomi dan petani untuk memantau kesehatan tanaman secara efisien, sehingga dapat meningkatkan hasil pertanian..*

Kata Kunci: Penyakit deteksi,Rice Leaf, VCG-16,Transfer pembelajaran,K-Means, Segmen gambar.

I. PENDAHULUAN

Dokumen Salah satu masalah utama yang memengaruhi produksi tanaman dan kualitas produk pertanian adalah penyakit daun. Agar dapat mengurangi kerugian keuangan, menjaga kualitas panen tanaman, dan mengendalikan penyakit dengan sukses, petani harus melakukan deteksi dini dan tepat penyakit daun. Namun, untuk mendeteksi penyakit daun secara manual, terutama di wilayah pertanian yang luas, diperlukan banyak waktu dan upaya bagi profesional.

Dalam beberapa tahun terakhir, kemajuan dalam teknologi kecerdasan buatan, terutama dalam bidang pembelajaran mendalam, telah membuka jalan baru untuk diagnosis penyakit tanaman secara otonom. Model pembelajaran transfer seperti VGG16, yang awalnya dilatih pada dataset ImageNet, dapat mendeteksi penyakit daun dengan akurasi yang tinggi dengan menyempurnakan dan menyesuaikan lapisan akhir model.

Selain itu, sebagai langkah awal pemrosesan gambar, segmentasi gambar menggunakan teknik K-Means biasanya digunakan untuk menemukan titik-titik yang tidak sehat pada daun. Dengan membagi gambar berdasarkan kesamaan warna dan tekstur, segmenasi ini menyederhanakan proses kategorisasi dan membantu mengidentifikasi area yang sakit. Oleh karena itu, sebelum gambar masuk ke fase klasifikasi, perubahan ruang warna merupakan langkah penting untuk meningkatkan hasil segmentasi.

Kemajuan teknologi informasi telah membantu industri pertanian menggunakan Internet of Things (IoT) untuk memantau dan menemukan penyakit tanaman secara real-time. Dengan menggunakan algoritme segmentasi seperti K-Means untuk mengumpulkan dan menganalisis data gambar daun yang sakit, Internet of Things dapat mengidentifikasi otomatis area yang terkena penyakit. Metode ini memiliki kelebihan dibandingkan metode manual tradisional, yaitu lebih akurat dan efisien dalam hal waktu.

K-Means telah digunakan secara luas sebagai alat segmentasi karena cepat dan efisien dalam mengklasifikasikan piksel berdasarkan warna dan intensitas. Menggabungkannya dengan metode klasifikasi berbasis jaringan syaraf seperti CNN dan VGG16

P-ISSN 1858-2680
E-ISSN 2723-4673

meningkatkan keakuratan deteksi penyakit daun. Studi sebelumnya telah menunjukkan bahwa proses segmentasi menggunakan ruang warna LAB lebih akurat karena saluran warna terpisah lebih jelas daripada ruang warna RGB.

Selain itu, fitur Transfer Learning model VGG16 memungkinkan penggunaan kembali bobot model yang telah dilatih pada dataset yang cukup besar, seperti ImageNet. Ini membuat proses pelatihan untuk dataset baru lebih cepat dan efisien. Hal ini sangat bermanfaat di bidang pertanian, di mana mendapatkan set data yang komprehensif dengan anotasi yang menyeluruh dapat menjadi tantangan. Dengan menggunakan teknik fine-tuning, model ini dapat disesuaikan dengan data lokal dan menghasilkan hasil klasifikasi yang lebih tepat untuk berbagai penyakit, seperti hawar daun bakteri, bercak coklat, dan daun busuk.

Tujuan utama proyek ini adalah untuk membuat sistem yang dapat mendeteksi penyakit daun yang menggunakan model VGG16 untuk klasifikasi dan menggunakan segmentasi K-Means. Diharapkan teknologi ini dapat digunakan secara luas untuk membantu petani memantau kesehatan tanaman secara lebih akurat dan cepat. Untuk mengetahui seberapa efektif dan bergantung model ini pada berbagai kondisi, beberapa penyakit tanaman, seperti Hawar Daun Bakteri dan Spot Hitam, akan diperiksa

II. METODOLOGI PENELITIAN

1. Dataser Collection and Construction

   Untuk mengembangkan model identifikasi penyakit daun padi yang komprehensif, kami memeriksa beberapa penyakit padi dan memilih tiga jenis penyakit daun padi yang lazim, untuk menyusun kumpulan data identifikasi. Koleksi ini memiliki 120 gambar mentah bersama dengan klasifikasi kategori penyakit yang sesuai. Bagian ini menjelaskan proses anotasi data dan penambahan data secara komprehensif. Ada beberapa kumpulan data yang dapat diakses publik tentang penyakit daun padi yang tersedia secara online. Data eksperimen untuk investigasi ini terutama bersumber dari Internet, kumpulan data publik Sampel Gambar Penyakit Daun Padi, dan foto serta label penyakit daun padi yang tersedia di Kaggle (www.kaggle.com). Dataset ini terdiri dari beberapa daun padi, dengan foto-foto yang diambil di bawah kondisi pencahayaan yang beragam dan dari berbagai sudut kameraKumpulan data terutama terdiri dari foto-foto yang menggambarkan satu jenis penyakit daun padi yang bermanifestasi pada dedaunan padi.

Gambar 1 Sample Foto Dataset

2. Transfer Learning VCG-16

   Algoritme yang digunakan dalam pembelajaran mesin dan pembelajaran mendalam secara tradisional telah dirancang untuk berfungsi pada distribusi geografis data tertentu. Model tersebut harus sepenuhnya direkonstruksi karena adanya pergeseran dalam distribusi ruang fitur, dan memperoleh data pelatihan yang diperlukan merupakan tantangan tambahan. Akibatnya, model deep learning membutuhkan data berlabel yang cukup untuk pelatihan [7].

   Dalam deep learning, transfer learning adalah metode yang digunakan untuk mengatasi tantangan dalam pelatihan dan pengoptimalan model, terutama yang membutuhkan dataset yang luas dan GPU yang kuat. Metode ini memungkinkan pemanfaatan model Convolutional Neural Network (CNN) yang telah dilatih sebelumnya pada tugas tertentu untuk menerapkan pengetahuan mereka pada tugas yang berbeda di berbagai set data. Model CNN yang digunakan dalam penelitian ini adalah VGG16, yang awalnya dilatih pada dataset besar seperti ImageNet [8]. Pengetahuan model yang telah dilatih ini digunakan untuk mengklasifikasikan penyakit daun pada berbagai tanaman melalui pendekatan pembelajaran transfer.

P-ISSN 1858-2680
E-ISSN 2723-4673

Lapisan residual model (ResNet) disesuaikan agar lebih efektif selaras dengan dataset gambar multi-tanaman 224 × 224 piksel yang digunakan. Model pembelajaran transfer meningkatkan kinerja kategorisasi tanpa memerlukan pelatihan awal. Dimensi gambar yang diperkecil dapat lebih mudah diakomodasi dalam jaringan dengan menggunakan lapisan penggabungan dan meminimalkan ukuran penggabungan. Penelitian ini menggambarkan bahwa model tersebut dapat mendeteksi penyakit tanaman dengan akurasi dan efisiensi yang lebih tinggi daripada metode konvensional dengan menggunakan VGG16 yang telah dilatih sebelumnya dan pembelajaran transfer [9].

Arsitektur utama untuk mendeteksi dan mengklasifikasikan penyakit tanaman adalah VGG-16. VGG-16 dipilih karena kinerjanya yang luar biasa dalam klasifikasi gambar dan keampuhannya sebagai model Jaringan Syaraf Tiruan (CNN). Pembelajaran transfer memungkinkan pemanfaatan model CNN yang dilatih pada kumpulan data yang luas, seperti ImageNet, untuk tugas-tugas tertentu, yang dicontohkan di sini dengan klasifikasi penyakit tanaman. Strategi ini menghemat waktu dan sumber daya karena tidak perlu melatih model dari awal. Model ini menawarkan manfaat lebih lanjut, dibuktikan dengan peran VGG-16 dalam klasifikasi gambar dan potensinya untuk lokalisasi penyakit di area daun tertentu [10].

3. Preprocessing Data

Diagnosis penyakit daun sangat penting untuk menentukan langkah-langkah yang dapat dilakukan petani. Teknologi meningkatkan efisiensi dan ketepatan proses identifikasi. Dataset lengkap yang terdiri dari 120 contoh dibagi menjadi tiga kategori data, menggunakan Convolutional Neural Network (CNN) berdasarkan model VGG yang telah dilatih sebelumnya [11]. Kualitas dan struktur data yang digunakan secara signifikan mempengaruhi kinerja model, membuat persiapan data gambar menjadi fase penting dalam proses kategorisasi deep learning. Gambar daun yang menunjukkan berbagai penyakit diproses dalam penelitian ini sebelum dimasukkan ke dalam model VGG16.

Untuk memastikan bahwa cetakan yang sudah jadi menunjukkan tingkat ketepatan warna yang tinggi, pemrosesan warna atau gambar sangat penting. Warna adalah elemen penting karena dapat memengaruhi persepsi manusia dan identitas merek. Oleh karena itu, pemilihan dan konversi warna yang cermat dapat meningkatkan nilai merek dan meningkatkan pengenalannya [12]. Python sekarang digunakan secara luas dalam pengembangan beberapa domain. Keuntungan lainnya adalah kemudahan instalasi, dan Python memiliki pustaka sederhana yang memudahkan pemahaman. Bentuk pemrograman ini memungkinkan komputer untuk memahami sifat dari suatu masalah dan mengambil kesimpulan atau membuat penilaian[13].

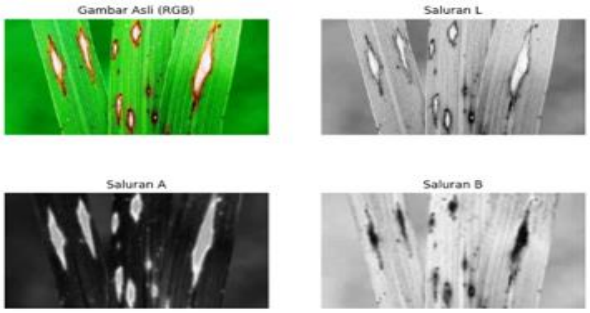

Gambar 2 Konversi Warna ke LAB

4. Augmentasi Citra

Model pembelajaran mendalam dengan arsitektur yang berbeda, seperti VGG16, ResNet50, dan Inception V3, memproses data gambar dengan dimensi tertentu pada lapisan awalnya. Model ini tidak mampu memproses data secara efektif jika gambar tidak memiliki keseragaman ukuran. Sebagai contoh, VGG16 dan Inception V3 membutuhkan resolusi input 224x224 piksel [15]. Struktur tensor jaringan akan bervariasi berdasarkan dimensi foto. Untuk memastikan pemrosesan yang bebas dari kesalahan dan distribusi bobot dan parameter model yang seragam, setiap gambar yang dimasukkan ke dalam model harus memiliki dimensi yang sama.

Komputasi foto resolusi tinggi, seperti 5000x3000 piksel, memerlukan memori dan sumber daya komputasi yang lebih besar. Komputasi dapat dipercepat tanpa mengorbankan kualitas prediksi secara signifikan dengan mengurangi dimensi ke ukuran yang

P-ISSN 1858-2680
E-ISSN 2723-4673

lebih kecil, seperti 224x224. Perbedaan dalam ukuran gambar relatif terhadap lapisan input akan menghasilkan kesalahan atau menghambat kemampuan model untuk mengevaluasi data secara akurat. Selain itu, penyelarasan ukuran ini sangat penting untuk memastikan ekstraksi fitur yang akurat, yang mempengaruhi kemampuan prediksi model [14].

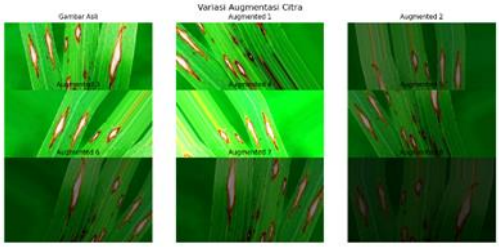

Gambar 3 Augmentasi Citra

Penambahan kecerahan dan beberapa modifikasi tambahan diimplementasikan selama prapemrosesan untuk meningkatkan kualitas dan keragaman set data. Hal ini penting agar model dapat belajar dari input secara lebih efisien dan menggeneralisasi pola di seluruh gambar tambahan. Untuk memastikan kinerja yang optimal selama fase pelatihan dan pengujian, gambar dataset harus sesuai dengan spesifikasi model. Hal ini akan mengoptimalkan proses pembelajaran dan prediksi model [14][15].

5. Segmentasi dengan K-Means

   Teknik yang umum digunakan untuk mengelompokkan penyakit daun adalah segmentasi gambar dengan algoritma K-Means. Teknik ini memfasilitasi identifikasi bagian daun yang sakit dengan mengelompokkan data gambar berdasarkan diferensiasi fitur data. Algoritma K-Means digunakan dalam proses segmentasi ini untuk menempatkan piksel gambar ke pusat-pusat tertentu. Pusat-pusat tersebut diperbarui secara iteratif sampai tidak ada perubahan signifikan yang diamati. Hal ini memungkinkan penggambaran yang efektif dari area yang terkena penyakit dengan area yang sehat, membantu petani dalam mendeteksi penyakit secara dini dan memfasilitasi tindakan pencegahan yang tepat [16].

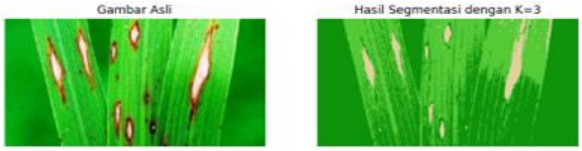

Gambar 4 Segmentasi K-Means

Pengelompokan K-Means telah terbukti menjadi metode segmentasi yang sangat baik untuk menemukan daerah daun yang rusak dalam pemrosesan gambar resolusi tinggi. Sistem ini unggul dalam mengelompokkan objek berdasarkan atribut warna dan tekstur sambil membedakan piksel dengan karakteristik yang sama. Untuk meningkatkan akurasi klasifikasi, elemen asing dan latar belakang yang rumit dihilangkan selama proses segmentasi. Akibatnya, dalam bidang identifikasi penyakit tanaman, segmentasi berbasis K-Means meningkatkan efisiensi pemrosesan data dan mengurangi kesalahan deteksi, sehingga menghasilkan akurasi klasifikasi yang lebih baik [16][2].

6. Deteksi Tepi

   Canny Edge Detection adalah salah satu algoritme yang paling umum dalam pemrosesan gambar karena kemampuannya menghasilkan deteksi tepi yang akurat dan halus. Menggunakan filter Gaussian untuk mengurangi noise, menghitung gradien untuk mendeteksi variasi intensitas pada tepi, dan menerapkan penekanan non-maksimum untuk mempertahankan hanya piksel pada puncak gradien adalah fase penting dalam prosedur [17]. Untuk memastikan bahwa hanya tepi yang relevan yang ditampilkan pada hasil akhir, algoritme ini menggunakan metode double thresholding dan pelacakan histeresis. Penelitian ini melampaui batasan tradisional algoritma Canny Edge dalam menangani noise, seperti salt-and-pepper, dengan mengintegrasikannya dengan filter median. Kombinasi ini meningkatkan pengenalan tepi pada gambar yang berisik dengan mempertahankan fitur gambar dan meminimalkan kontaminasi noise eksternal.

   Teknik pemrosesan gambar yang dikenal sebagai “Annotate with Circles” digunakan untuk menerapkan anotasi atau penandaan yang akurat ke bagian gambar yang signifikan. Untuk menyoroti komponen tertentu, seperti benda yang dikenali atau tempat yang memerlukan peningkatan fokus, anotasi terkadang ditampilkan sebagai lingkaran yang dilapiskan pada gambar. Elemen objek atau fitur tertentu dalam gambar, yang terdeteksi oleh teknik pemrosesan gambar,

P-ISSN 1858-2680
E-ISSN 2723-4673

digambarkan dengan lingkaran. Contohnya meliputi deteksi penyakit pada daun [19].

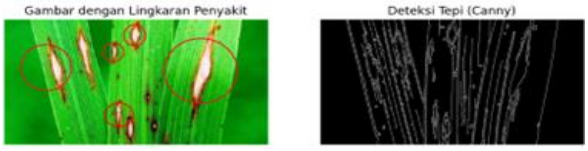

Gambar 5 Deteksi Tepi

III. HASIL DAN PEMBAHASAN

A. Akurasi Model

Hasil dari confusion matrix menunjukkan bahwa model VGG-16 cukup efektif dalam mendeteksi Bacterial leaf blight dan Leaf smut, namun kurang akurat dalam mendeteksi Brown spot.

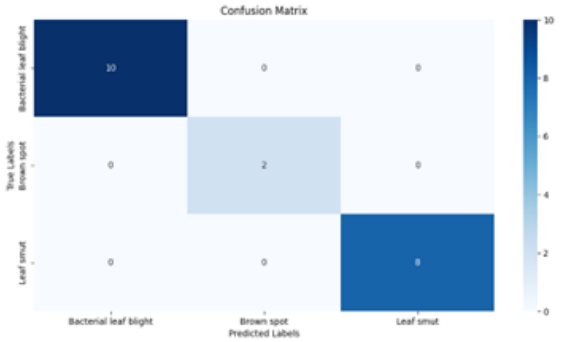

Gambar 6 Confusion Matrix

Brown spot dan Leaf smut pada daun padi mungkin memiliki pola bintik atau perubahan warna yang mirip, terutama dalam hal tekstur dan distribusi warna pada daun. Kedua penyakit ini bisa sama-sama terlihat sebagai bercak atau area yang lebih gelap di atas permukaan daun, yang membuat model sulit membedakannya. Untuk mengklasifikasikan penyakit, model VGG-16 biasanya melihat fitur tekstur dan warna. Jika kedua penyakit memiliki karakteristik tekstur atau warna yang serupa, model akan kesulitan membedakan keduanya dengan akurasi tinggi.

Faktor eksternal seperti usia tanaman, kondisi lingkungan, atau tahap perkembangan penyakit dapat menentukan gejala Brown spot dan Leaf smut. Misalnya, pada tahap awal infeksi, spot coklat mungkin terlihat sangat mirip dengan Leaf smut sebelum bercak menjadi lebih gelap atau lebih luas.

B. Visualisasi

Dalam penelitian ini, visualisasi proporsi penyakit menggunakan pie chart dan histogram membantu memahami distribusi dari ketiga jenis penyakit daun padi yang dideteksi oleh model: bacterial leaf blight, brown spot, dan leaf smut. Visualisasi ini juga memberikan wawasan yang lebih jelas tentang frekuensi masing-masing penyakit dalam dataset serta mengidentifikasi jenis penyakit yang paling umum terjadi.

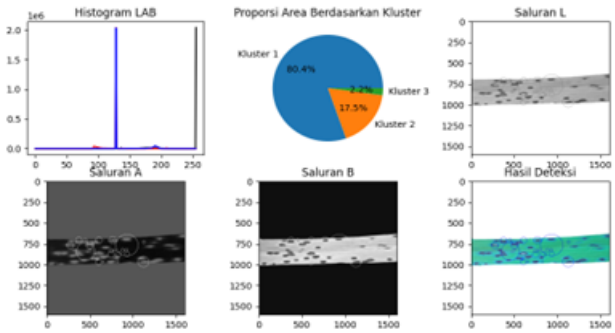

Gambar 7 Tampilan Aplikasi Analisa

Histogram menunjukkan jumlah kasus untuk setiap penyakit yang terdeteksi. Dari visualisasi ini, terlihat bahwa Bacterial leaf blight memiliki jumlah kasus tertinggi, diikuti oleh Leaf smut, sedangkan Brown spot memiliki jumlah kasus terendah.

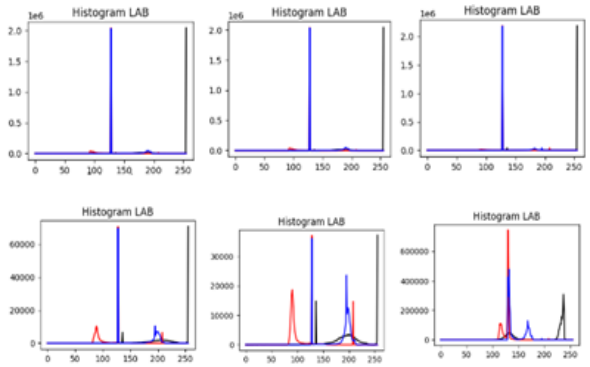

Gambar 8 Tampilan Histogram Beberapa Sample

Dalam penelitian ini, visualisasi proporsi penyakit menggunakan pie chart dan histogram membantu memahami distribusi dari ketiga jenis penyakit daun padi yang dideteksi oleh model: bacterial leaf blight, brown spot, dan leaf smut. Visualisasi ini juga memberikan wawasan yang lebih jelas tentang frekuensi masing-masing penyakit

P-ISSN 1858-2680
E-ISSN 2723-4673

dalam dataset serta mengidentifikasi jenis penyakit yang paling umum terjadi.

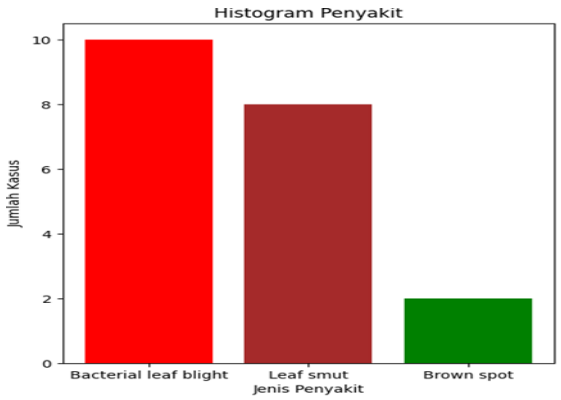

Gambar 9 Histogram Rata-Rata Kasus

Gambar pie chart memberikan representasi proporsi relatif dari setiap penyakit. Bakteri leaf blight mencakup sekitar 50% dari kasus yang dianalisis, leaf smut mencakup 40%, dan brown spot mencakup hanya 10%. Dengan mengetahui proporsi penyakit, petani dan praktisi agrikultur dapat mengalokasikan sumber daya dan strategi penanganan yang tepat untuk penyakit yang dominan pada tanaman padi. Misalnya, jika bakteri leaf blight mendominasi jumlah kasus, maka lebih banyak perhatian dapat diberikan pada pencegahan dan penanganan penyakit ini, misalnya dengan menggunakan fungisida atau varietas padi yang lebih tahan terhadap penyakit ini. Selain itu, pie chart membantu memahami tingkat prevalensi masing-masing penyakit. Sebaliknya, proporsi spot merah yang rendah mungkin disebabkan oleh kurangnya data atau kemiripan visual dengan leaf smut, sehingga penyakit ini sulit dibedakan dengan jelas oleh model. Dengan demikian, peningkatan proporsi bakteri lebah daun juga dapat menunjukkan bahwa penyakit ini memiliki ciri visual yang lebih mudah dikenali oleh model.

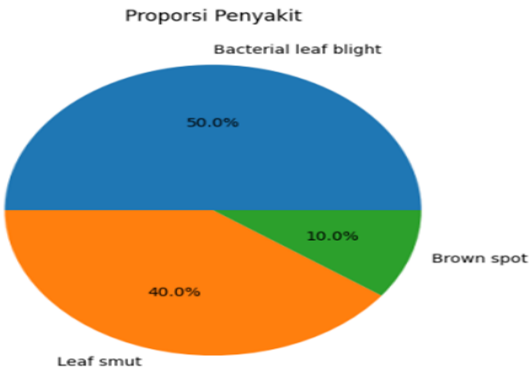

Gambar 10 Proporsi Penyakit

C. Implikasi Visualisasi Proporsi Penyakit

Visualisasi proporsi ini dapat membantu praktisi pertanian mendapatkan pemahaman yang lebih baik tentang penyakit yang paling umum di lahan pertanian. Seseorang dapat membuat rencana untuk memantau dan mengendalikan penyakit dengan lebih baik dengan mengetahui proporsi penyakit. Misalnya, jika data menunjukkan bahwa bakteri leaf blight adalah penyakit yang paling umum, maka strategi pengendalian penyakit yang lebih terfokus dapat diterapkan, termasuk pencegahan khusus untuk penyakit ini. Sebaliknya, proporsi spot Brown yang rendah tidak menunjukkan bahwa penyakit ini kurang penting. Sebaliknya, itu menunjukkan bahwa teknik untuk menemukan penyakit ini dan jumlah data yang diperlukan mungkin perlu ditingkatkan agar model dapat mengenalinya dengan lebih baik

IV. PENUTUP

Kesamaan visual antara Brown spot dan Leaf smut memang menjadi tantangan dalam klasifikasi otomatis menggunakan model deep learning. Mengakui tantangan ini dalam bagian pembahasan menunjukkan pemahaman yang mendalam tentang kendala yang dihadapi oleh penelitian. Pendekatan tambahan atau perbaikan, seperti dataset yang lebih besar dan lebih beragam atau metode segmentasi dan klasifikasi yang lebih maju, dapat membantu meningkatkan akurasi deteksi dan membuat model lebih dapat diandalkan dalam aplikasi nyata.

DAFTAR PUSTAKA

[1] Lu, Q.T. (2023). An Approach for Classification of Diseases on Leaves. International Journal of Advanced Computer Science and Applications (IJACSA), 14(10), pp.112–118. Available at: https://thesai.org/Downloads/Volume14No10/Paper_112-An_Approach_for_Classification_of_Diseases_on_Leaves.pdf [Accessed 25 Oct. 2024].

[2] Jamjoom, M., Elhadad, A., Abulkasim, H. dan Abbas, S. (2023). Plant Leaf Diseases Classification Using Improved K-Means Clustering and SVM Algorithm for Segmentation. Computers, Materials & Continua, 76(1), pp.367-382. DOI:10.32604/cmc.2023.037310. Available at: https://www.techscience.com/cmc/v76n1/53063/html [Accessed 25 Oct. 2024].

[3] Gayathri Devi, T., Neelamegam, P. dan Srinivasan, A. (2018). Plant Leaf Disease Detection using K-means Segmentation.

P-ISSN 1858-2680
E-ISSN 2723-4673

International Journal of Pure and Applied Mathematics, 119(15), pp. 3477-3483. Available at: http://www.acadpubl.eu/hub/2018-119-15/2/370.pdf [Accessed 25 Oct. 2024].

[4] Jadhav, S.B., Udupi, V.R., dan Patil, S.B. (2019). Convolutional neural networks for leaf image-based plant disease classification. IAES International Journal of Artificial Intelligence (IJ-AI), 8(4), pp.328-341. DOI: 10.11591/ijai.v8.i4.pp328-341. Available at: https://pdfs.semanticscholar.org/d7b3/c229b8c4654badc6f1f0750034e1032472c5.pdf [Accessed 25 Oct. 2024].

[5] Biradar, V.G., Sarojadevi, H., Shalini, J., Veena, R.S., dan Prashanth, V. (2022). Rice leaves disease classification using deep convolutional neural network. International Journal of Health Sciences, 6(S4), pp.1230-1244. DOI: 10.53730/ijhs.v6nS4.6067. Available at: https://media.neliti.com/media/publications/429393-rice-leaves-disease-classification-using-b28038e5.pdf [Accessed 25 Oct. 2024].

[6] Shi, Y., Wang, X. dan Zhang, S. (2023). Plant Disease Leaf Image Segmentation Using K-Means Clustering Based on Internet of Things. International Journal of Research in Agricultural Sciences, 3(2), pp.2348-3997. Available at: https://ijras.com/administrator/components/com_jresearch/files/publications/IJRAS_355_Final.pdf [Accessed 25 Oct. 2024].

[7] Tammina, S., 2019. Transfer learning using VGG-16 with deep convolutional neural network for classifying images. International Journal of Scientific and Research Publications (IJSRP), 9(10), pp.143-150. Available at: https://doi.org/10.29322/IJSRP.9.10.2019.p9420 [Accessed 26 Oct. 2024].

[8] Aversano, L., Bernardi, M.L., Cimitile, M., Iammarino, M., & Rondinella, S., 2020. Tomato diseases classification based on VGG and transfer learning. In: 2020 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor). IEEE, pp. 294-298. Available at: https://doi.org/10.1109/MetroAgriFor50201.2020.9277626 [Accessed 26 Oct. 2024].

[9] Paymode, A.S. and Malode, V.B., 2022. Transfer learning for multi-crop leaf disease image classification using convolutional neural network VGG. Artificial Intelligence in Agriculture, 6, pp.23-33. Available at: https://doi.org/10.1016/j.aiia.2021.12.003 [Accessed 26 Oct. 2024].

[10] Alatawi, A.A., Alomani, S.M., Alhawiti, N.I., and Ayaz, M., 2022. Plant disease detection using AI based VGG-16 model. International Journal of Advanced Computer Science and Applications (IJACSA), 13(4), pp.1-11. Available at: https://doi.org/10.14569/IJACSA.2022.0130401 [Accessed 26 Oct. 2024].

[11] Rayhan, Y. and Setyohadi, D.B., 2021. Classification of grape leaf disease using convolutional neural network (CNN) with pre-trained model VGG16. In: 2021 International Conference on Computer Science, Information Technology, and Engineering (ICoSITE). IEEE, pp. 1-5. Available at: https://doi.org/10.1109/ICoSITE53117.2021.9645862 [Accessed 26 Oct. 2024].

[12] Pratama, Y.P., Prastiwnarti, W., Ahmad, L., and Mahmuda, Z.S., 2023. Perancangan aplikasi konversi RGB CMYK berbasis Python. Journal of Applied Electrical Engineering, 7(2), pp.102-106. Available at: https://jurnal.polibatam.ac.id/index.php/JAEE/article/view/6360 [Accessed 26 Oct. 2024].

[13] Ratna, S., 2020. Pengolahan citra digital dan histogram dengan Python dan text editor PyCharm. Jurnal Ilmiah Technologia, 11(3), pp.181-186. Available at: https://ojs.uniska-bjm.ac.id/index.php/JIT/article/view/3294 [Accessed 26 Oct. 2024].

[14] Shah, S.R., Qadri, S., Bibi, H., Shah, S.M.W., Sharif, M.I. and Marinello, F., 2023. Comparing Inception V3, VGG 16, VGG 19, CNN, and ResNet 50: A Case Study on Early Detection of a Rice Disease. Agronomy, 13(6), p.1633. DOI: 10.3390/agronomy13061633. [Accessed 26 Oct. 2024].

[15] Roseno, M.T., Oktorina, S., Nearti, Y., Syaputra, H. and Jayanti, N., 2024. Comparing CNN Models for Rice Disease Detection: ResNet50, VGG16, and MobileNetV3-Small. Journal of Information Systems and Informatics, Vol. 6, No. 3, September. DOI: 10.51519/journalisi.v6i3.865. . [Accessed 26 Oct. 2024].

[16] Devi, T. G., Neelamegam, P., & Srinivasan, A. (2018). Plant Leaf Disease Detection using K-means Segmentation. International Journal of Pure and Applied Mathematics, 119(15), 3477-3483.

[17] Akbari Sekehravani, E., Babulak, E., & Masoodi, M. (2020) 'Implementing canny edge detection algorithm for noisy image', Bulletin of Electrical Engineering and Informatics, 9(4), pp. 1404-1410. Available at: https://doi.org/10.11591/eei.v9i4.1837.

[18] Faheem, Z.B., Ishaq, A., Rustam, F., de la Torre Díez, I., Gavilanes, D., Vergara, M.M., & Ashraf, I. (2023) 'Image Watermarking Using Least Significant Bit and Canny Edge Detection', Sensors, 23(3), p. 1210. Available at: https://doi.org/10.3390/s23031210.

[19} Kumar, A., Marks, T. K., Mou, W., Wang, Y., Jones, M., Cherian, A., Koike-Akino, T., Liu, X., & Feng, C. (2020) 'LUVLi Face Alignment: Estimating Landmarks' Location, Uncertainty, and Visibility Likelihood', Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), pp. 8236-8246. Available at: https://openaccess.thecvf.com/content_CVPR_2020/papers/Kumar_LUVLi_Face_Alignment_Estimating_Landmarks_Location_Uncertainty_and_Visibility_Likelihood_CVPR_2020_paper.pdf

P-ISSN 1858-2680
E-ISSN 2723-4673