

Pemanfaatan Citra Drone dan Neural Network untuk Mendeteksi Penyakit pada Daun

Utilization of Drone Imagery and Neural Network to Detect Diseases on Leaves

¹Rasna*, ²Moh. Rahmat Irjii Matdoan, ³Muhammad Taher Jufri ⁴Jusmawati

^{1,3,4}Sistem Informasi, Fakultas Teknik dan Sistem Informasi, Universitas Yapis Papua

²Teknik Informatika, Fakultas Ilmu Komputer dan Manajemen, Universitas Sains dan Teknologi Jayapura

e-mail: ¹razna.anwar@gmail.com, ²irjiimatdoan@gmail.com, ³jufri.conoras@gmail.com, ⁴juzmawati.nr@gmail.com

Abstrak

Pemantauan kondisi tanaman menjadi sangat penting. Hal ini disebabkan oleh banyaknya serangan penyakit dan kurangnya perawatan. Selain jarak yang cukup jauh untuk perawatan tanaman, struktur bagian tanaman yang terkena penyakit perlu diklasifikasi. Tingginya penyakit yang disebabkan oleh daun dapat mengakibatkan gagal panen. Sehingga keterlambatan proses diagnose penyakit menyebabkan penyakit yang ada pada tanaman menjadi parah. Penelitian ini bertujuan untuk memanfaatkan teknologi drone dan menampilkan dalam bentuk citra untuk mendeteksi penyakit pada daun tanaman. Kami menggunakan neural network untuk memproses hasil pada citra. Neural Network merupakan salah satu algoritma yang efektif dalam memodelkan hubungan antara data input dan output. Hasil dari penelitian yaitu akurasi pendeteksi penyakit pada daun pengambilan citra dari drone mencapai 99,63.

Kata kunci: neural network, deteksi penyakit, penyakit daun, drone

Abstract

Monitoring the condition of the plant becomes very important. This is caused by the large number of disease attacks and lack of treatment. In addition to the considerable distance for plant treatment, the structure of plant parts affected by the disease needs to be classified. High disease caused by leaves can result in panel failure. So that the delay in the process of diagnosing the disease causes the disease in plants to become severe. This study aims to utilize drone technology and display it in image form to detect disease on plant leaves. We use a neural network to process the results on the image. Neural Network is one of the most effective algorithms in modeling the relationship between input and output data. The results of the study, namely the accuracy of detecting diseases on leaves, taking images from drones reached 99.63.

Keywords: neural networks, disease detection, leaf diseases, drones

1 Pendahuluan

Pertanian memiliki peranan penting di Indonesia. Kerawanan pangan merupakan salah satu masalah serius dunia yang disebabkan oleh penyakit tanaman. Penyakit tanaman ini menyebabkan kerusakan tanaman dan sangat mempengaruhi hasil produksi tanaman secara keseluruhan. Pertanian memainkan peran penting dalam domestikasi tanaman pangan dan ternak utama saat ini ribuan tahun yang lalu. Kerawanan pangan merupakan salah satu masalah serius dunia yang dihadapi umat manusia saat ini, yang disebabkan oleh penyakit tanaman. Penyakit tanaman menyebabkan kerusakan tanaman dan sangat mempengaruhi hasil produksi tanaman secara keseluruhan, yang menyebabkan kekurangan pangan. Menurut perkiraan Organisasi Pangan dan Pertanian, hama dan penyakit tanaman bertanggung jawab atas 40% kehilangan produksi pertanian global [1]. Hal ini dapat mengakibatkan konsekuensi bencana, seperti jutaan orang tidak memiliki cukup makanan dan sangat merugikan sektor pertanian.

Selain itu, petani kecil menyediakan lebih dari 80% produksi pertanian di negara berkembang, yang merupakan sumber penghidupan utama mereka. Selain itu, mayoritas penduduk miskin sekitar 50% tinggal di keluarga petani kecil, membuat petani kecil sangat rentan terhadap gangguan pasokan makanan [2]. Oleh karena itu, menemukan cara baru untuk mengidentifikasi penyakit tanaman dapat meningkatkan hasil pangan secara signifikan dan mengubah kerugian menjadi keuntungan.

Pengelolaan produksi pertanian skala besar memerlukan berbagai tindakan tepat waktu, seperti mengawasi penyakit dan membatasinya pada barang-barang yang tidak diinginkan. Penyebab penyakit tanaman yang paling umum adalah hama serangga, bakteri, virus, alga, dan jamur. Penyakit tanaman tertentu tidak memiliki indikasi visual, oleh karena itu metode analitik lanjutan digunakan dalam kasus ini. Namun, sebagian besar tanaman yang terinfeksi memiliki tanda yang terlihat, dan ahli patologi tanaman yang berpengalaman mengidentifikasi penyakit tersebut dengan memeriksa daun tanaman yang terinfeksi menggunakan mikroskop optik. Diagnosis penyakit tanaman yang akurat membutuhkan keterampilan pengamatan dan pengetahuan yang baik untuk mengenali gejala penyakit tertentu secara tepat. Proses identifikasi penyakit tanaman secara manual ini memakan waktu dan tergantung pada ketersediaan ahli patologi tanaman yang berpengalaman. Selain itu, diperlukan pemantauan tanaman secara terus-menerus, yang sangat mahal jika berurusan dengan peternakan besar. Selain itu, variasi tanaman yang berlebihan dan variasi gejala dari waktu ke waktu karena perubahan iklim, bahkan ahli patologi yang berpengalaman mungkin tidak dapat mengidentifikasi penyakit tertentu secara akurat dan mungkin memakan waktu lama. Untuk pertanian yang berkelanjutan dan benar, serta untuk menghindari pemborosan keuangan dan sumber daya lainnya yang tidak perlu, identifikasi penyakit tanaman yang tepat waktu dan tepat sangat penting.

Dalam beberapa tahun terakhir, karena kemajuan teknologi, sistem kontrol proses otomatis berbasis citra diperkenalkan yang dapat mengidentifikasi tanaman penyakit secara otomatis dan menawarkan wawasan berharga bagi ahli agronomi. Teknik deteksi otomatis membantu petani dalam meningkatkan kualitas tanaman sekaligus mengurangi kejadian penyakit melalui identifikasi dini, tepat waktu, dan pengobatan yang tepat. Awalnya, model berbasis pembelajaran mesin (ML) diusulkan untuk identifikasi dan klasifikasi penyakit tanaman. Metode seperti Support Vector Machine (SVM) [3], Decision Tree (DT)[4], Random Forest (RF) [5], dan K-Nearest Neighbour (KNN) [6] telah digunakan untuk deteksi dini dan akurat penyakit tanaman. Teknik berbasis ML lebih mudah diterapkan dan tidak memerlukan data pelatihan yang besar; namun, mereka lambat karena pemrosesan awal yang rumit dan bergantung pada pengetahuan spesialis manusia yang berpengalaman untuk ekstraksi dan pemilihan fitur yang sesuai yang diperlukan untuk melakukan klasifikasi [7]. Selain itu, memilih kumpulan fitur yang besar meningkatkan kompleksitas komputasi, sementara menggunakan kumpulan fitur yang kecil menurunkan kinerja identifikasi. Oleh karena itu, kemandirian pendeteksian dari pendekatan ini bergantung pada kualitas dan representasi fitur yang diekstraksi dan rentan terhadap kesalahan saat bekerja dengan data dalam jumlah besar. Dengan demikian, teknik berbasis ML memiliki akurasi terbatas untuk identifikasi penyakit tanaman otomatis.

Identifikasi yang akurat dari beberapa penyakit tanaman masih menjadi tantangan karena bercak penyakit memiliki kenampakan yang bervariasi, seperti ukuran, bentuk, rona, dan posisi. Selain itu, adanya kebisingan latar belakang, perbedaan intra-kelas pada tahap pertumbuhan yang berbeda, dan beberapa bercak penyakit kecil dan padat pada daun yang sama mempengaruhi diagnosis penyakit daun tanaman. Selain itu, variasi dalam kondisi iluminasi dan kecerahan selama proses akuisisi citra daun berkontribusi terhadap hasil deteksi yang tidak memuaskan dari solusi desain berbantuan komputer (CAD). Untuk mengatasi tantangan tersebut di atas, penelitian ini mengusulkan metode berbasis drone yang efisien dan efektif

2 Tinjauan Literatur

Dalam penelitian, penyelidikan kritis terhadap penelitian deteksi dan klasifikasi berbagai penyakit tanaman dilakukan. Literatur terkini untuk kategorisasi daerah berpenyakit daun tanaman dibagi menjadi dua jenis, yaitu metode berbasis ML atau pendekatan berbasis DL.

Pendekatan berbasis ML untuk klasifikasi penyakit tanaman telah dilakukan [7]. Beberapa algoritma ekstraksi fitur, yaitu Local Binary Pattern (LBP), Gray Level Co-Occurrence Matrix (GLCM), Shift-Invariant Feature Transform (SIFT), dan Gabor diterapkan untuk ekstraksi fitur dari citra masukan. Kemudian, pengklasifikasi ML, yaitu, SVM, KNN, Artificial Neural Network (ANN), dan RF dilatih untuk menyelesaikan tugas kategorisasi penyakit tanaman. Hasil terbaik untuk fitur

Gabor dengan akurasi klasifikasi 90,23%. Namun, kinerja perlu perbaikan lebih lanjut [7]. Solusi untuk deteksi dan klasifikasi berbagai penyakit tanaman diusulkan [8]. Awalnya, 14 ruang warna digunakan untuk mengekstraksi 172 poin kunci dari sampel yang dicurigai. Kemudian, poin kunci yang dihitung digunakan untuk pelatihan SVM. Peningkatan kinerja kategorisasi daerah berpenyakit daun tanaman dengan akurasi 94,68%, namun, pendekatan ini tidak kuat untuk sampel dengan distorsi besar [8]. Le dkk menyajikan pendekatan untuk menemukan dan mengkategorikan tanaman dan penyakit berbasis gulma [9]. Pada langkah pertama, kebisingan dari sampel yang dicurigai dihilangkan dengan menggunakan operasi pembukaan dan penutupan morfologis. Pada langkah selanjutnya, model khusus, yaitu pendekatan LBP yang difilter bersama dengan topeng kontur dan koefisien k (k -FLBPCM) diperkenalkan untuk mengekstraksi poin-poin penting dari gambar yang disempurnakan. Terakhir, poin-poin penting yang dihitung digunakan untuk pelatihan SVM untuk mencapai kategorisasi daerah daun yang sakit. Teknik oleh Le et al. (2020) menunjukkan peningkatan daya pengenalan penyakit tanaman dengan akurasi 98,63%; namun, pendekatan ini tidak kuat untuk gambar yang mengandung distorsi perspektif [10]. Ahmad dkk mempresentasikan metode untuk mengidentifikasi dan mengenali area yang terkena dampak dari beberapa daun tanaman [11]. Awalnya, Directional Local Quinary Patterns (DLQPs) digunakan untuk ekstraksi fitur dari gambar masukan. Poin kunci yang dihitung digunakan untuk melatih pengklasifikasi SVM untuk mengklasifikasikan penyakit daun tanaman. Metode ini (Ahmad et al., 2020) bekerja dengan baik untuk klasifikasi penyakit tanaman dengan akurasi klasifikasi 96,50%; namun, kinerja pendeteksian dapat lebih ditingkatkan dengan menggunakan informasi berbasis bentuk dan warna dari gambar yang dicurigai. Pendekatan lain untuk mendeteksi dan mengklasifikasikan penyakit daun tanaman teh disajikan [12]. Awalnya, Simple Linear Iterative Cluster (SLIC) digunakan untuk membagi citra masukan menjadi beberapa blok, dari mana fitur dihitung melalui metode Harris. Kemudian, metode convex hull diterapkan untuk mendeteksi fuzzy salient area, dan teknik GLCM digunakan untuk menghitung vektor fitur. Terakhir, keypoint yang diekstraksi digunakan untuk melatih pengklasifikasi SVM. Framework menunjukkan kategorisasi penyakit daun tanaman yang lebih baik dengan akurasi 98,50%; Namun, metode ini rumit secara ekonomi. Pantazi dkk menyajikan metode untuk menemukan dan mengkategorikan beberapa penyakit tanaman [13]. Pada langkah pertama, pendekatan GrabCut digunakan pada citra yang dicurigai untuk melakukan segmentasi sampel. Pada langkah selanjutnya, transformasi Hue, Saturation, dan Value (HSV) diterapkan pada gambar tersegmentasi dari mana fitur dihitung menggunakan algoritma LBP. Akhirnya, poin kunci yang diekstraksi digunakan untuk melatih SVM. Teknik berbasis ML lainnya digunakan untuk mengklasifikasikan beberapa penyakit tanaman [14]. Awalnya, sampel input diproses terlebih dahulu dengan menerapkan pendekatan histogram equalization (HE) untuk meningkatkan informasi visual gambar. Pada langkah selanjutnya, metode K-means clustering diterapkan untuk melakukan segmentasi citra. Kemudian, GLCM bersama dengan deskriptor LBP digunakan untuk perhitungan titik kunci. Terakhir, algoritma SVM dilatih melalui fitur yang dihitung untuk mengklasifikasikan berbagai area yang terkena dampak daun tanaman. Hasil penelitian menunjukkan peningkatan kinerja klasifikasi daerah berpenyakit daun tanaman dengan akurasi 84,6. Namun, evaluasi dilakukan pada database dengan jumlah sampel yang sedikit. Ramesh dkk memperkenalkan teknik untuk mengkategorikan berbagai kelainan daun tanaman [15]. Pendekatan Histogram of Oriented Gradient (HOG) diterapkan untuk perhitungan keypoint, yang digunakan untuk pelatihan pengklasifikasi RF.

Kami telah meninjau beberapa teknik klasifikasi penyakit daun tanaman baik menggunakan metode berbasis ML konvensional atau pendekatan berbasis DL. Namun, ada kebutuhan untuk peningkatan kinerja baik untuk kategorisasi daerah penyakit daun tanaman yang berbeda dan kompleksitas waktu pemrosesan. Metode yang ada menggunakan langkah prapemrosesan yang ekstensif atau tidak dapat bekerja dengan baik pada sampel yang terdistorsi. Selain itu, metode tersebut mengalami masalah pemasangan model yang berlebihan dan tidak mencapai kinerja yang lebih baik dibandingkan sampel yang tidak terlihat. Oleh karena itu, identifikasi dan klasifikasi penyakit daun tanaman yang tepat diperlukan untuk mencegah kerusakan tanaman yang selanjutnya dapat membantu petani untuk mengambil tindakan pencegahan tepat waktu.

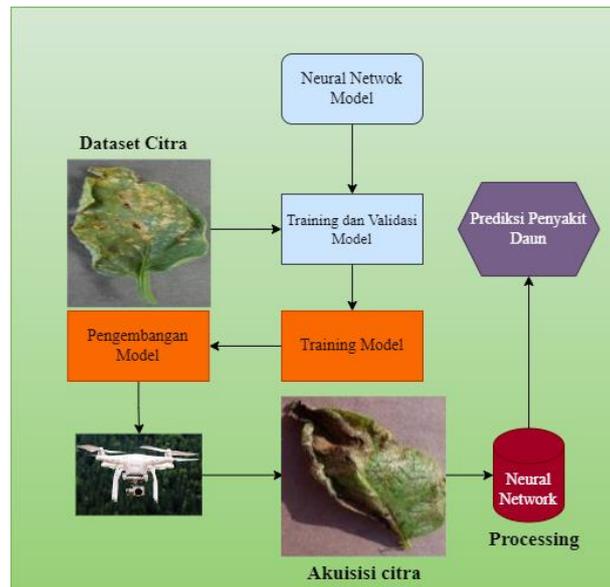
3 Metode Penelitian

Bagian ini menjelaskan dataset dan metodologi yang diadopsi untuk identifikasi penyakit tanaman. Selain itu, rincian metrik evaluasi yang digunakan juga dibahas. Untuk gambar input, tujuan utamanya adalah untuk secara otomatis mengidentifikasi dan menentukan kelas penyakit tanaman tertentu. Awalnya, sampel masukan yang terdiri dari berbagai spesies dan penyakit tanaman dikumpulkan dari kumpulan data yang tersedia untuk umum dan dari lingkungan dunia nyata melalui penggunaan kamera drone. Fitur mendalam digunakan untuk mengklasifikasikan penyakit tanaman dari beberapa jenis dengan benar menggunakan pengklasifikasi Softmax.

Untuk mengevaluasi kinerja deteksi dan klasifikasi penyakit tanaman dari pendekatan kami, kami menggunakan database PlantVillage [16]. Kumpulan data PlantVillage adalah database standar klasifikasi penyakit daun tanaman yang besar dan dapat diakses secara online, yang dieksplorasi secara ekstensif oleh beberapa teknik dari masa lalu untuk penilaian kinerja. Untuk memeriksa keakuratan klasifikasi dari metode yang disajikan, kami telah merancang beberapa percobaan pada dataset ini, yang berisi gambar dari beberapa jenis tumbuhan dan penyakitnya. Lebih khusus lagi, dataset PlantVillage terdiri dari 54.306 sampel dari 14 spesies tanaman yang berbeda dan berisi total 32 kelas, dimana 26 kelas berasal dari tanaman sakit sedangkan 12 kelas sisanya milik tanaman sehat (Gambar 1). Gambar dari semua kategori tanaman yang mengandung Tomat, Stroberi, Anggur, dan Jeruk diambil dari database PlantVillage. Dataset yang digunakan adalah database yang beragam dan menantang untuk deteksi dan kategorisasi daerah yang terkena daun tanaman karena berisi sampel yang bervariasi dalam hal ukuran bagian daun tanaman yang sakit, warna, dan cahaya, yang mengalami beberapa distorsi gambar seperti adanya noise.



Gambar 1. Contoh gambar dari dataset PlantVillage.



Gambar 2. Arsitektur model usulan untuk klasifikasi penyakit tumbuhan

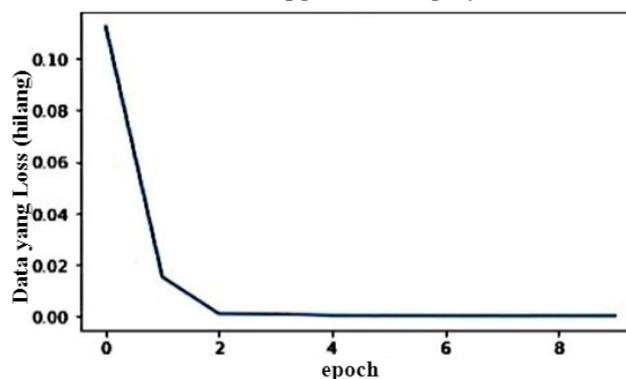
4 Hasil dan Pembahasan

Pada bagian ini, pembahasan dari model yang diperoleh untuk mengklasifikasikan beberapa penyakit pada daun tanaman. Selain itu, kami telah membahas kumpulan data yang digunakan bersama dengan metrik evaluasi kinerja. Untuk implementasi, kami telah membagi dataset yang digunakan menjadi 70–30% untuk pelatihan dan pengujian model masing-masing.

Untuk klasifikasi penyakit tanaman, kami telah meningkatkan model yang ada dan menerapkan pembelajaran transfer untuk memberikan pertukaran yang baik antara akurasi dan kompleksitas komputasi. Dalam model kami yang dimodifikasi, lapisan normalisasi Batch ditambahkan di awal jaringan untuk membakukan input. Arsitekturnya terdiri dari blok Fused-MBConv, dan lapisan selanjutnya menggunakan blok MBConv yang memiliki konvolusi kedalaman 3×3 dan 5×5 dengan blok squeeze-and-excitation (SE). Blok MBConv adalah blok residual terbalik yang menggunakan koneksi residual terbalik bersama dengan blok SE untuk lebih meningkatkan kinerja. Blok SE menggunakan mekanisme perhatian untuk meningkatkan representasi fitur yang memungkinkan model untuk memprioritaskan daerah yang terinfeksi pada daun tanaman melalui pembelajaran bobot secara mandiri.

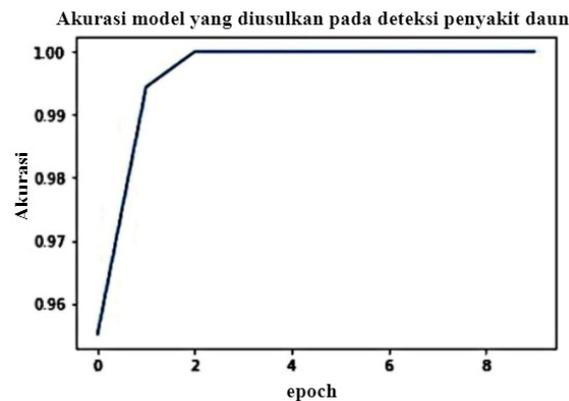
Untuk menunjukkan perilaku model pada waktu training, kami telah membahas akurasi klasifikasi penyakit tanaman waktu pelatihan dan kerugian pelatihan karena parameter ini membantu menunjukkan perilaku model selama prosedur pelatihan. Untuk pendekatan yang disajikan, kami telah menunjukkan representasi visual dari grafik kerugian pada Gambar 3.

Loss Training pada deteksi penyakit daun



Gambar 3. Grafik loss data training pada deteksi daun

Dari Gambar 4, menunjukkan perolehan nilai optimal 0,0012, yang menunjukkan pembelajaran yang efisien dari teknik yang diusulkan.



Gambar 4. Grafik akurasi data training pada deteksi daun

Solusi yang disajikan kuat untuk klasifikasi penyakit daun tanaman karena struktur jaringannya yang dangkal yang memungkinkan penggunaan informasi yang diperoleh dengan lebih baik dengan menghilangkan data yang berlebihan.

5 Kesimpulan

Dalam penelitian ini, kami memperkenalkan metode mendeteksi penyakit pada daun berbasis drone. Metode yang diusulkan dapat secara tepat mengenali dan mengkategorikan berbagai kelas kelainan daun tanaman dari database PlantVillage. Selain itu, teknik yang disajikan mampu mengkategorikan penyakit tanaman di bawah terjadinya beberapa distorsi gambar, yaitu perubahan kecerahan, kontras, warna, posisi, sudut, dan struktur penyakit daun tanaman. Analisis hasil yang dilakukan dengan jelas menunjukkan bahwa pendekatan kami mampu mendeteksi dengan akurasi perolehan nilai optimal 0,0012. Hasil dari penelitian yaitu akurasi pendeteksi penyakit pada daun pengambilan citra dari drone mencapai 99,63%.

6 Referensi

- [1] ákos Mesterházy, J. Oláh, and J. Popp, "Losses in the grain supply chain: Causes and solutions," *Sustain.*, vol. 12, no. 6, pp. 1–18, 2020, doi: 10.3390/su12062342.
- [2] F. Ceballos, S. Kannan, and B. Kramer, "Impacts of a national lockdown on smallholder farmers' income and food security: Empirical evidence from two states in India," *World Dev.*, vol. 136, p. 105069, 2020, doi: 10.1016/j.worlddev.2020.105069.
- [3] S. V. Militante, B. D. Gerardo, and R. P. Medina, "Sugarcane Disease Recognition using Deep Learning," *2019 IEEE Eurasia Conf. IOT, Commun. Eng. ECICE 2019*, no. October, pp. 575–578, 2019, doi: 10.1109/ECICE47484.2019.8942690.
- [4] A. Ahmim, L. Maglaras, M. A. Ferrag, M. Derdour, and H. Janicke, "A novel hierarchical intrusion detection system based on decision tree and rules-based models," *Proc. - 15th Annu. Int. Conf. Distrib. Comput. Sens. Syst. DCOSS 2019*, pp. 228–233, 2019, doi: 10.1109/DCOSS.2019.00059.
- [5] M. D. Chauhan, R. Walia, C. Singh, and M. Deivakani, "Detection of Maize Disease Using Random Forest Classification Algorithm," vol. 12, no. 9, pp. 715–720, 2021.
- [6] I. B. Suban, A. Paramartha, M. Fortwonatus, and A. J. Santoso, "Identification the Maturity Level of Carica Papaya Using the K-Nearest Neighbor," *J. Phys. Conf. Ser.*, vol. 1577, no. 1, 2020, doi: 10.1088/1742-6596/1577/1/012028.
- [7] S. Dargan, M. Kumar, M. R. Ayyagari, and G. Kumar, "A Survey of Deep Learning and Its Applications: A New Paradigm to Machine Learning," *Arch. Comput. Methods Eng.*, vol. 27, no. 4, pp. 1071–1092, 2020, doi: 10.1007/s11831-019-09344-w.
- [8] V. K. Shrivastava and M. K. Pradhan, "Rice plant disease classification using color features: a machine learning paradigm," *J. Plant Pathol.*, vol. 103, no. 1, pp. 17–26, 2021, doi: 10.1007/s42161-020-00683-3.
- [9] V. N. T. Le, S. Ahderom, B. Apopei, and K. Alameh, "A novel method for detecting morphologically similar crops and weeds based on the combination of contour masks and filtered Local Binary Pattern operators," *Gigascience*, vol. 9, no. 3, pp. 1–16, 2020, doi: 10.1093/gigascience/giaa017.

- [10] V. N. T. Le, S. Ahderom, and K. Alameh, “Performances of the lbp based algorithm over cnn models for detecting crops and weeds with similar morphologies,” *Sensors (Switzerland)*, vol. 20, no. 8, pp. 1–18, 2020, doi: 10.3390/s20082193.
- [11] W. Ahmad, S. M. A. Shah, and A. Irtaza, “Plants disease phenotyping using quinary patterns as texture descriptor,” *KSII Trans. Internet Inf. Syst.*, vol. 14, no. 8, pp. 3312–3327, 2020, doi: 10.3837/tiis.2020.08.009.
- [12] Y. Sun, Z. Jiang, L. Zhang, W. Dong, and Y. Rao, “SLIC_SVM based leaf diseases saliency map extraction of tea plant,” *Comput. Electron. Agric.*, vol. 157, no. December 2018, pp. 102–109, 2019, doi: 10.1016/j.compag.2018.12.042.
- [13] X. E. Pantazi, D. Moshou, and A. A. Tamouridou, “Automated leaf disease detection in different crop species through image features analysis and One Class Classifiers,” *Comput. Electron. Agric.*, vol. 156, no. November 2018, pp. 96–104, 2019, doi: 10.1016/j.compag.2018.11.005.
- [14] M. Sahana, H. Reshma, R. Pavithra, and B. S. Kavya, “Plant Leaf Disease Detection Using Image Processing,” *Lect. Notes Electr. Eng.*, vol. 789, no. 9, pp. 161–168, 2022, doi: 10.1007/978-981-16-1338-8_14.
- [15] S. R. Maniyath *et al.*, “Plant disease detection using machine learning,” *Proc. - 2018 Int. Conf. Des. Innov. 3Cs Comput. Commun. Control. ICDI3C 2018*, pp. 41–45, 2018, doi: 10.1109/ICDI3C.2018.00017.
- [16] W. Albattah, M. Masood, A. Javed, M. Nawaz, and S. Albahli, “Custom CornerNet: a drone-based improved deep learning technique for large-scale multiclass pest localization and classification,” *Complex Intell. Syst.*, no. MI, 2022, doi: 10.1007/s40747-022-00847-x.