

Tinjauan Sistematis Model Convolutional Neural Network untuk Deteksi Penyakit Daun Tomat

A Systematic Review of Convolutional Neural Network Models for Tomato Leaf Disease Detection

Fiki Sanora¹, Naufal Hafizh Mufafaq², Shofwatul Uyun^{3*}

^{1,2,3} Magister Informatika, Sains dan Teknologi, UIN Sunan Kalijaga, Yogyakarta, Indonesia

¹fiki.sano01@gmail.com, ²naufalhafizhmufafaq@gmail.com, ³shofwatul.uyun@uin-suka.ac.id

Abstract

Tomato leaf disease can cause a decline in productivity and crop failure, making early detection very important in precision farming practices. Manual detection methods, which are still commonly used in the field, have limitations in terms of speed and accuracy, requiring an automated image-based approach. Convolutional Neural Networks (CNNs) have become a leading technique in plant disease classification, but the diversity of architecture used requires systematic study to identify the most effective model. This study summarizes, compares, and evaluates CNN models for tomato leaf disease detection through a Systematic Literature Review (SLR) that adopts the PRISMA guidelines, covering the stages of identification, screening, feasibility assessment, and inclusion. A search in Scopus (2022–2025) using the query: (“Convolutional Neural Network” OR ‘CNN’) AND (‘tomato’ AND “leaf disease detection”) yielded 21 relevant articles. Analysis shows common preprocessing such as image resizing, data augmentation, and denoising. The best CNN architecture is InceptionV3 (most frequently used and high performing), followed by DenseNet201, MobileNetV2, and ResNet152V2. Architectures with optimal depth and high computational efficiency are preferred. This study provides a comprehensive map of CNN models to support architecture selection in tomato leaf disease detection. Future research directions include improving image quality, integrating attention mechanisms, semantic segmentation, and developing concise and efficient models for field applications.

Keywords: Convolutional Neural Network (CNN); Plant Disease Detection; Tomato; Deep Learning; Systematic Literature Review

Abstrak

Penyakit daun tomat dapat menyebabkan penurunan produktivitas dan kegagalan panen, sehingga deteksi dini menjadi sangat penting dalam praktik pertanian presisi. Metode deteksi manual yang masih umum digunakan di lapangan memiliki keterbatasan dari sisi kecepatan dan akurasi, sehingga dibutuhkan pendekatan otomatis berbasis citra. Convolutional Neural Network (CNN) telah menjadi teknik unggulan dalam klasifikasi penyakit tanaman, namun keragaman arsitektur yang digunakan menuntut adanya kajian sistematis untuk mengidentifikasi model yang paling efektif. Studi ini merangkum, membandingkan, dan mengevaluasi model CNN untuk deteksi penyakit daun tomat melalui Systematic Literature Review (SLR) yang mengadopsi pedoman PRISMA, mencakup tahap identifikasi, penyaringan, penilaian kelayakan, dan inklusi. Pencarian di Scopus (2022–2025) menggunakan kueri: (“Convolutional Neural Network” ATAU ‘CNN’) DAN (‘tomato’ DAN “leaf disease detection”) menghasilkan 21 artikel relevan. Analisis menunjukkan pra-pemrosesan umum seperti penyesuaian ukuran gambar, augmentasi data, dan denoising. Arsitektur CNN terbaik adalah InceptionV3 (paling sering digunakan dan berkinerja tinggi), diikuti DenseNet201, MobileNetV2, dan ResNet152V2. Arsitektur dengan kedalaman optimal dan efisiensi komputasi tinggi lebih disukai. Studi ini menyediakan peta komprehensif model CNN untuk mendukung pemilihan arsitektur dalam deteksi penyakit daun tomat. Arah penelitian masa depan meliputi peningkatan kualitas gambar, integrasi mekanisme perhatian, segmentasi semantik, serta pengembangan model ringkas dan efisien untuk aplikasi lapangan.

Kata kunci: Convolutional Neural Network (CNN); Deteksi Penyakit Tanaman; Tomat; Deep Learning; Systematic Literature Review

1. Pendahuluan

Tomat merupakan salah satu jenis tanaman yang memiliki kandungan gizi yang cukup tinggi, tanaman ini juga merupakan salah satu tanaman yang paling

banyak dibudidayakan dan dianggap sebagai salah satu sayuran konsumsi utama dunia. Beberapa permasalahan yang sering muncul pada tanaman tomat diantaranya yaitu penyakit pada daun tomat. Apabila

kondisi ini terus dibiarkan akan menyebabkan kegagalan panen yang nantinya bisa merugikan para petani dan bisa menyebabkan kekurangan stok untuk tomat itu sendiri. Adapun cara yang biasa petani lakukan dalam mengklasifikasikan penyakit pada daun tomat adalah dengan mengamati gejala fisik secara langsung seperti perubahan warna daun, bintik dan juga bentuk daun. Cara ini dinilai kurang efisien karena memakan waktu dan juga konsistensi dan akurasi yang dihasilkan dapat bervariasi dan bersifat subjektif. Berdasarkan permasalahan yang dihadapi perlu adanya sebuah metode atau model yang bisa mendeteksi penyakit pada daun tomat dengan efisien, akurasi dan konsistensi yang tinggi dengan hasil yg objektif [1].

Convolutional Neural Network (CNN) adalah salah satu jenis dari model *Deep Learning* yang dapat melatih kumpulan dataset yang besar, membuat representasi visual dua dimensi dan mengkombinasikannya dengan beberapa filter untuk mendapatkan hasil yang diinginkan [2], [3]. CNN juga dapat menganalisis gambar tanaman secara otomatis dan mengklasifikasikan apakah tanaman tersebut sehat atau tidak dengan cara mengekstraksi fitur-fitur pada gambar seperti warna, pola dan tekstur, kemudian membandingkannya dengan ribuan gambar penyakit. CNN memiliki kecepatan, akurasi dan konsistensi yang tinggi dalam mendeteksi penyakit tanaman.


Peneliti sebelumnya sudah banyak membahas tentang model-model dari CNN yang digunakan dalam mendeteksi penyakit pada tanaman salah daun pada tanaman salah satunya yaitu daun tanaman tomat. Model-model tersebut antara lain yaitu model *CNN VGG19*, *Resnet152V2*, *Inceptionv3*, *MobileNet*, *AlexNet*, *DenseNet201* dan beberapa juga ada yang menciptakan model baru dengan menggabungkan beberapa model seperti *ResNet50-CBAM* + *SVM* dan *DTomatoDNet*. Model-model tersebut mendapatkan performa atau akurasi yang bervariasi dari 90% sampai 100%.

Meskipun terdapat banyak penelitian yang mengembangkan model CNN untuk mendeteksi penyakit daun tomat, belum ada kajian sistematis yang membandingkan arsitektur, performa dan pendekatan praproses secara komprehensif. Hal ini penting untuk mengidentifikasi model paling efisien, serta tantangan yang masih tersisa untuk implementasi dunia nyata. Oleh karena itu penelitian ini akan menjawab tiga *Research Question (RQ)* yang ada yaitu: RQ1 Apa saja langkah prapemrosesan (*preprocessing*) citra yang paling umum dilakukan sebelum mengidentifikasi penyakit pada daun tomat? RQ2 Model CNN apa saja yang paling sering digunakan dalam mengidentifikasi penyakit pada daun tomat? RQ3 Apa saja arah penelitian masa depan terkait deteksi penyakit daun tomat berbasis CNN?

Penelitian ini memiliki peranan yang penting untuk memberikan wawasan yang lebih luas terkait model-model CNN yang digunakan dalam mengidentifikasi penyakit pada daun tanaman tomat. Dengan penerapan pertanian presisi yang didukung oleh *image-based detection* secara akurat tentunya dapat mengurangi angka penyakit pada tanaman dan akan memaksimalkan hasil panen.

2. Metodologi Penelitian

Metodologi yang diterapkan pada penelitian ini adalah SLR (*Systematic Literature Review*) yaitu metode yang digunakan untuk mengembangkan serangkaian indikator penilaian yang komprehensif dalam mengumpulkan, mengevaluasi dan mengidentifikasi penelitian yang ada terkait dengan topik yang diteliti [4]. Metode ini juga mengacu pada panduan PRISMA (*Preferred Reporting Items for Systematic reviews and Meta-Analyses*) yaitu panduan yang menyediakan kerangka kerja metodologis untuk memastikan proses tinjauan dilakukan secara lengkap, transparan, dan berkualitas [5]. Penelitian ini dilakukan secara bertahap, mulai dari mengidentifikasi artikel yang relevan dengan topik penelitian, *screening* berdasarkan dengan kriteria-kriteria yang sudah ditetapkan, menentukan kelayakan artikelnya, dan yang terakhir yaitu menetapkan jumlah artikel yang sudah disaring dan dianggap sudah memenuhi kriteria. Dibawah ini adalah gambar diagram alur PRISMA yang menggambarkan proses penyeleksian literatur dari penelitian ini.



Gambar 1. Diagram Alur PRISMA

2.1. Research Question (RQ)

Tahapan pertama yang dilakukan pada metode SLR (*Systematic Literature Review*) adalah membuat *Research Question (RQ)* atau pertanyaan penelitian yang jelas dan juga spesifik. Untuk menjawab kebutuhan tersebut, penelitian ini dirancang untuk

menjawab tiga pertanyaan penelitian utama (RQ) yaitu:

1. RQ1 Apa saja langkah prapemrosesan (*preprocessing*) citra yang paling umum dilakukan sebelum mengidentifikasi penyakit pada daun tomat?
2. RQ2 Model CNN apa saja yang paling sering digunakan dalam mengidentifikasi penyakit pada daun tomat?
3. RQ3 Apa saja arah penelitian masa depan terkait deteksi penyakit daun tomat berbasis CNN?

2.2. Pengumpulan Data

Pengumpulan data dalam studi ini dilakukan melalui pendekatan Ulasan Literatur Sistematis (SLR) dengan mengacu pada pedoman PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) untuk memastikan bahwa proses ulasan bersifat transparan, sistematis dan dapat direplikasi. Pencarian literatur difokuskan pada studi primer yang membahas deteksi atau klasifikasi penyakit daun tomat menggunakan metode *Convolutional Neural Network* (CNN). Database utama yang digunakan adalah Scopus, dipilih karena cakupan luasnya terhadap publikasi ilmiah yang terpercaya. Pencarian dilakukan pada 14 Oktober 2025, menggunakan string pencarian: ("*Convolutional Neural Network*" OR "*CNN*") AND ("*tomato*" AND "*leaf disease detection*"), sehingga semua studi relevan yang menerapkan CNN dalam deteksi penyakit daun tomat dapat diidentifikasi. Studi ini membatasi rentang tahun publikasi dari 2022 hingga 2025 untuk memperoleh model CNN terbaru yang relevan dengan perkembangan teknologi komputer modern. Penyaringan literatur dilakukan berdasarkan jenis dokumen (artikel), bahasa publikasi (Inggris), akses terbuka atau tertutup, dan bidang studi (Ilmu Komputer dan Teknik).

Selain itu, kriteria inklusi ditetapkan untuk memastikan bahwa hanya literatur yang relevan dan berkualitas tinggi yang dianalisis. Artikel-artikel yang termasuk dalam tinjauan ini adalah studi primer yang berfokus pada deteksi atau klasifikasi penyakit daun tomat berdasarkan gambar menggunakan CNN atau turunan-turunannya, serta menyajikan hasil kinerja model seperti akurasi. Sebaliknya, artikel-artikel yang dikecualikan adalah yang bukan makalah lengkap, berupa abstrak atau poster, merupakan studi tinjauan non-teknis, menggunakan metode non-visual seperti sensor kimia atau spektral, tidak berfokus pada tanaman tomat, atau tidak menggunakan CNN sebagai metode utama. Proses seleksi dilakukan melalui tahap-tahap PRISMA, yang meliputi identifikasi, penyaringan, kelayakan, dan inklusi. Pada tahap identifikasi, pencarian awal menghasilkan 536 catatan, di mana 79 catatan dieliminasi karena tidak masuk

dalam kriteria dalam 3 tahun terakhir yaitu tahun 2022-2025. Kemudian 314 catatan dikecualikan karena jenis dokumennya tidak termasuk dalam jenis artikel dan bahasa yang digunakan tidak menggunakan bahasa Inggris, sehingga meninggalkan 143 catatan untuk tahap penyaringan. Pada tahap penyaringan, 36 catatan dieliminasi berdasarkan selain kata kunci yaitu *Computer Sains* dan *Engineering*, dan 107 laporan diteruskan ke tahap penarikan untuk penilaian kelayakan. Pada tahap kelayakan, 76 laporan dieliminasi karena tidak memiliki akses penuh atau tidak relevan dengan bidang studi. Pada tahap akhir, 31 studi baru diperoleh, dan setelah proses seleksi lebih lanjut, 21 artikel ditemukan memenuhi semua kriteria dan digunakan sebagai dasar analisis dalam studi ini.

3. Hasil dan Pembahasan

3.1. Hasil

Berdasarkan pencarian artikel penelitian sebelumnya, ditemukan beberapa artikel yang berkaitan dengan CNN (*Convolutional Neural Network*) dan penyakit pada daun tanaman tomat. Dari tinjauan literatur yang dilakukan terdapat 21 artikel yang menurut penulis relevan dengan topik penelitian. Artikel-artikel ini kemudian dianalisis untuk membandingkan hasil dari masing-masing penelitian. Berikut ini adalah analisis perbandingan dari 21 artikel yang disajikan dalam bentuk Tabel 1.

Tabel 1. Analisis Perbandingan

No	Sumber Referensi	Prapemrosesan	Model	Performa
1.	Balaji, Banothu et al [6].	Konversi gambar ke format NumPy array, normalisasi ukuran ke 224x224, augmentasi data dan validasi.	VGG19, Resnet152 V2, Inceptionv3, dan MobileNet	VGG19 95%, Inceptionv3 92%, MobileNet 97%, ResNet152 V2 95%
2.	Altalak, Maha et al [1].	Mengubah ukuran ke 256x256x3, Konversi dari RGB ke BGR, Zero-centering, Augmentasi data dan kompilasi data.	ResNet50-CBAM + SVM	ResNet50-CBAM + SVM 97.2%.
3.	Mahakud, Rina et al [7].	Standarisasi ukuran 224X224 piksel, menerapkan filter median.	Hybrid + PGGAN	Hybrid + PGGAN 98.49%.

No	Sumber Referensi	Prapemrosesan	Model	Performa	No	Sumber Referensi	Prapemrosesan	Model	Performa
4.	Ullah, Naeem et al [8].	Normalisasi data, augmentasi data, penghapusan noise dan peningkatan kontras.	DTomatoD Net	DTomatoD Net 99.33%	12.	Siregar, Sandy Putra et al [2].	Balancing dataset, pembagian dataset dengan ukuran 256×256 piksel dan format JPG.	Optimized VGG16	Optimized VGG16 98.25%
5.	Batool, Amreen et al [9].	Normalisasi data, augmentasi data dan ubah ukuran menjadi 224x224 atau 256x256.	T-Net	T-Net 98.97%	13.	Poomima, S et al [16].	Penghapusan noise, normalisasi, augmentasi data, <i>remove</i> background dan konversi ke HSV.	RCNN-RFCN	RCNN-RFCN 98.88%
6.	Mengesh a, Alexander Takele et al [10].	Penghapusan latar belakang, normalisasi, pemotongan dan pengubahan ukuran ke 256x256.	MobileNet V3, Inceptionv3, DenseNet201	MobileNet V3 96.88%, Inceptionv3 98.44%, DenseNet201 100%	14.	Chen, Junzhi et al [17].	Kalibrasi radiometrik, penekanan kebisingan, dan standarisasi spasial.	SSDBRN	SSDBRN 96.2%
7.	Ulutaş, Hasan et al [11].	Menggunakan dataset gambar mentah, fine tuning model, augmentasi data, optimasi hyperparameter.	MobileNet V3Small, EfficientNetV2L, Inceptionv3, CNN1, CNN2	99,60%	15.	Zhou, Huaxin et al [18].	Pengelolaan aset, augmentasi dan pengujian rasio.	small ACGAN	small ACGAN pada MobileNet V3 97.9%
8.	Goyal, Praveen et al [12].	Meningkatkan kualitas gambar dan mengubah ukuran menjadi 224x224x3.	Convolutional Neural Network (CNN)	Convolutional Neural Network (CNN) 88%	16.	Bensaadi, Soumia et al [19].	Pemilihan gambar dan mengubah ukuran menjadi 256×256 piksel.	CNN	CNN 97.04%
9.	Hidayah, A. H.Nurul et al [13].	Transformasi data, menghilangkan rotasi dan mengubah ukuran menjadi 416x416.	YOLOv4, YOLOv5	YOLOv4 94.0%, YOLOv5 94.2%	17.	Wang, Guoying et al [20].	Augmentasi gambar dan disimpan dalam format PASCAL VOC.	TDGA	TDGA 91.40%
10.	Najim, Mohammed Hussein et al [14].	Mengubah ukuran menjadi 128×128 piksel.	Special Model (CNN)	Special Model (CNN) 96%	18.	Gatla, Anitha et al [21].	TensorFlow dan TensorFlow addons, dan augmentasi data.	MobileNet v2, Inceptionv3, ResNet50, VGG19	MobileNet V2 98,99%
11.	Saraf, Puja et al [15].	Konversi gambar dari RGB dan Grayscale dan mengurangi noise.	SVM, CNN, XGBoost, RF dan NB	SVM, CNN, XGBoost, RF dan NB 95.5%	19.	Patel, Sunil A et al [22].	Mengubah ukuran, cropping, segmentasi, normalisasi dan konversi	Parallel Custom	Parallel Custom 99.65%


No	Sumber Referensi	Prapemrosesan	Model	Performa
20.	Kumar, Tajinder et al [23].	<i>Scalling</i> , mengubah ukuran menjadi 224x224x3, perubahan ruang warna, pengurangan noise dan peningkatan citra.	CAE + CNN	CAE + CNN 98.35%
21.	Bakr, Mahmou d et al [24].	Peningkatan kualitas gambar dan mengubah ukuran gambar menjadi 224x224 piksel.	Based on DenseNet201	Based on DenseNet201 97.97%

3.2. Pembahasan

RQ1: Apa saja langkah prapemrosesan (*preprocessing*) citra yang paling umum dilakukan sebelum mengidentifikasi penyakit pada daun tomat?

Berdasarkan analisis perbandingan pada Tabel 1 bahwa langkah-langkah prapemrosesan setiap pengujian pada masing-masing penelitian itu berbeda-beda, tetapi secara umum langkah prapemrosesan yang dilakukan sebelum mengidentifikasi penyakit pada daun tanaman tomat adalah yang pertama, mengubah ukuran gambar menjadi 224x224 piksel atau 256x256 piksel supaya sesuai dengan input CNN dan mengurangi variasi ukuran gambar. Kedua augmentasi data, tujuannya adalah untuk memperluas variasi dataset dan mengurangi risiko *overfitting*. Ketiga menghilangkan noise, tujuannya adalah untuk memperjelas fitur penting dalam gambar daun, sehingga fitur tersebut lebih mudah dipelajari oleh jaringan.

RQ2: Model CNN apa saja yang paling sering digunakan dalam mengidentifikasi penyakit pada daun tomat?



VOSviewer

Gambar 2. Network Visualization Model CNN

Tabel 2. Keyword By Author

Rank	Keyword	Total Link Strength
1	Inceptionv3	32
2	Densenet201	10
3	Alexnet	9
4	Mobilenetv2	9
5	Resnet152v2	9
6	SVM	5

Berdasarkan gambar 2 yang menunjukkan visualisasi jaringan dan analisis data kata kunci dari VOSviewer, dapat disimpulkan bahwa model CNN yang paling sering digunakan dalam mengidentifikasi penyakit pada daun tanaman tomat adalah Inceptionv3, dengan total *link strenght* yaitu 32. Penelitian yang dilakukan oleh Balaji et al mendukung temuan ini dengan mengembangkan sistem deteksi dan klasifikasikan penyakit pada daun tomat menggunakan pendekatan *deep learning* [25]. Penelitian ini menunjukkan bahwa inceptionv3 berhasil mendeteksi penyakit pada daun tanaman tomat dengan performanya yaitu 92%.

Kata kunci Densenet201 muncul sebagai model CNN yang sering digunakan dengan total *link strenght* yaitu sebanyak 10. Penelitian yang dilakukan oleh Mengesha et al mendukung temuan ini dimana beliau melakukan penelitian untuk meningkatkan akurasi dan transparansi deteksi penyakit daun tomat melalui teknik *deep learning* [26]. Penelitian ini menunjukkan bahwa Densenet201 merupakan model terbaik dalam mendeteksi penyakit pada daun tanaman tomat dengan performanya yaitu 100%.

Selanjutnya, beberapa kata kunci lainnya yang menunjukkan bahwa model CNN yang paling sering digunakan dalam mendeteksi penyakit pada daun tanaman tomat adalah Alexnet, Mobilenetv2 dan Resnet152v2, dengan masing-masing total *link strenght* adalah 9. Penelitian yang dilakukan oleh Gatla et al mendukung temuan ini dimana beliau melakukan penelitian yaitu mengevaluasi berbagai model yang telah diuji seperti MobileNetV2, Inceptionv3, ResNet50, dan VGG19 terhadap CNN khusus, melatih dan memvalidasinya pada kumpulan data gambar daun tomat yang komprehensif [27]. Pada penelitian ini menunjukkan bahwa Mobilenetv2 memiliki akurasi tertinggi dengan performanya yaitu 98.99%.

Selain itu, kata kunci SVM muncul sebagai model CNN yang paling sering digunakan dengan masing-masing total *link strenght* yaitu 5. Penelitian yang dilakukan oleh Saraf et al mendukung temuan ini dimana beliau melakukan penelitian yaitu

Secara keseluruhan, hasil ini menunjukkan bahwa model CNN yang paling sering digunakan dalam mendeteksi penyakit pada daun tanaman tomat adalah model Inceptionv3, Densenet201, Alexnet, Mobilenetv2, Resnet152v2 dan SVM. Masing-masing model ini mampu mendeteksi penyakit pada daun tanaman tomat dengan akurasi diatas 90%. Analisis lebih mendalam menunjukkan bahwa variasi performa antar model tersebut sangat dipengaruhi oleh karakteristik arsitektur masing-masing. Keunggulan DenseNet201 yang mampu mencapai akurasi hingga 100% dikaitkan dengan mekanisme *dense connectivity*, yang memungkinkan penggunaan kembali fitur (*feature reuse*) secara *efisien* dan meminimalkan hilangnya informasi pada jaringan yang dalam. Sementara itu, popularitas InceptionV3 sebagai model yang paling sering digunakan didorong oleh kemampuannya menangkap fitur penyakit pada berbagai skala spasial melalui modul *Inception*, sehingga efektif mendeteksi gejala visual yang bervariasi ukurannya.

Penelitian lebih lanjut diperlukan sebuah model yang mampu mendeteksi penyakit tanaman dengan skala luas dan dataset yang banyak.

Berdasarkan hasil *overlay visualization* VOSviewer, penelitian terbaru mengenai deteksi penyakit daun tomat berbasis CNN menunjukkan kecenderungan kuat menuju teknologi yang lebih modern, cepat, dan akurat. Hal ini terlihat dari munculnya beberapa keyword berwarna hijau muda hingga kuning, seperti *Image Enhancement*, *Attention Mechanisms*,

Pertama, penelitian mengarah pada peningkatan gambar dan arsitektur seperti *Image Enhancement*, *Attention Mechanisms*, Densenet121, *Neural Network Models*. Peningkatan kualitas *input* data dan pengembangan arsitektur model yang canggih diprioritaskan karena penting untuk meningkatkan fokus model pada fitur penyakit yang kecil atau halus. Penelitian sebelumnya oleh Santoso et al dan Kim et al, membuktikan bahwa peningkatan kualitas gambar dan penggunaan arsitektur yang tepat dapat mempengaruhi tingkat akurasi dan keberhasilan pendeteksian penyakit pada daun tanaman [29], [30]. Oleh karena itu penelitian lebih lanjut terkait peningkatan kualitas input data atau gambar dan pengembangan arsitektur sangat diperlukan untuk mengoptimalkan dalam penentuan berbagai penyakit pada daun tanaman terutama tanaman tomat.

Ketiga, penelitian mengarah pada interpretasi dan segmentasi yang dibuktikan dengan munculnya beberapa keyword seperti *Semantic Segmentation* dan *Semantics*. Dengan munculnya keyword tersebut dapat diartikan bahwa para peneliti tidak hanya berfokus pada klasifikasi penyakit suatu gambar, tetapi juga ingin menentukan batas-batas yang tepat dari area yang terinfeksi untuk diagnosis dan memberikan informasi tentang pemahaman keparahan yang lebih akurat. Penelitian yang dilakukan oleh Ma et al menunjukkan bahwa segmentasi *organ-level* yang akurat sangat penting untuk analisis fenotipik dan pemantauan pertumbuhan tanaman [33]. Penelitian ini juga memberikan solusi yang efektif dan praktis untuk fenotipe tanaman tomat otomatis dengan throughput tinggi, berkontribusi pada kemajuan pertanian cerdas.

Keempat, aspek praktis dan komputasi. Pada arah penelitian masa depan ini para peneliti akan mengoptimalkan proses pelatihan dan membuat model yang lebih ringan, ini dibuktikan dengan munculnya beberapa keyword seperti *Optimizers* dan VGG16. VGG16 adalah salah satu *network* model yang memiliki 16 lapisan yang digunakan untuk mendeteksi penyakit pada tanaman. Menurut Borugadda et al dalam penelitiannya mengungkapkan bahwa model VGG16 dapat dikembangkan dengan menambahkan teknik pengurangan dimensi lainnya, seperti optimasi kawanan partikel (PSO), analisis kearifan linier (LDA), dan autoencoder untuk mengatasi masalah overfitting dan mengidentifikasi penyakit pada tanaman, dan sayuran berdasarkan gambar [34].

Terlepas dari tingginya akurasi yang didapatkan oleh masing-masing model CNN, masih terdapat beberapa keterbatasan mendasar yang masih menjadi tantangan besar yaitu, pertama adanya bias dataset yang cukup signifikan, dimana biasanya penelitian dilakukan ditempat-tempat tertentu yang lingkungannya sudah terkontrol seperti laboratorium. Hal ini tentu berbeda dengan kondisi dilapangan dan tidak mempresentasikan kondisi riil dilahan pertanian. Kedua, kondisi pencahayaan alami dilapangan termasuk pantulan sinar matahari, bayangan dan kondisi cuaca yang ekstrem seringkali mengaburkan fitur visual penyakit yang halus sehingga akan menurunkan performa model saat diimplementasikan secara nyata. Kondisi seperti ini tentu mempengaruhi generalisasi model, dimana algoritma yang memberikan hasil yang bagus pada suatu dataset yang spesifik seringkali gagal mempertahankan akurasi ketika dihadapkan pada variasi tomat yang berbeda atau lingkungan geografis yang tidak sama dengan sebelumnya. Tantangan ini menunjukkan bahwa *preprocessing* yang *robust* masih sangat diperlukan untuk menjembatani antara celah hasil riset dilaboratorium dengan kondisi riil dilapangan.

4. Kesimpulan

Studi tinjauan sistematis ini menyimpulkan bahwa

Convolutional Neural Network (CNN) telah mencapai tingkat kematangan yang tinggi dalam mendeteksi penyakit daun tomat, di mana arsitektur InceptionV3 dan DenseNet201 mendominasi *literatur* terkini dengan performa akurasi rata-rata melampaui 90%.

Berdasarkan sintesis hasil penelitian, keberhasilan model-model tersebut sangat bergantung pada tahapan prapemrosesan yang ketat, khususnya penyeragaman dimensi citra ke ukuran 224x224 atau 256x256 piksel serta augmentasi data untuk memitigasi risiko *overfitting* dan *sensitivitas* terhadap *noise visual*. Namun, tingginya akurasi pada model arsitektur dalam (*deep architectures*) ini membawa kelemahan *inherent* berupa kompleksitas komputasi yang tinggi, yang menjadi hambatan signifikan dalam penerapan praktis pada perangkat mobile atau sistem tertanam (*embedded systems*) di lahan pertanian yang memiliki sumber daya terbatas.

Mengacu pada kelemahan tersebut, fokus pengembangan masa depan tidak lagi cukup hanya dengan mengejar metrik akurasi klasifikasi semata, melainkan harus berorientasi pada efisiensi arsitektur dan presisi diagnostik. Solusi untuk tantangan komputasi terletak pada pengembangan model ringan (*lightweight models*) dan teknik optimasi model yang mampu mempertahankan performa tinggi tanpa membebani perangkat keras. Selain itu, keterbatasan model klasifikasi standar yang hanya memberikan label "sakit atau sehat" tanpa konteks lokasi perlu diatasi dengan integrasi *segmentasi semantik* dan mekanisme atensi (*attention mechanisms*).

Pendekatan ini memungkinkan sistem untuk tidak hanya mendeteksi keberadaan penyakit, tetapi juga memetakan area infeksi dan tingkat keparahannya secara presisi. Dengan demikian, arah riset selanjutnya adalah menciptakan keseimbangan ideal antara model yang robust terhadap variasi lapangan, efisien secara komputasi, serta informatif secara spasial untuk mendukung pertanian presisi yang berkelanjutan.

Reference

- [1] M. Altalak, M. A. Uddin, A. Alajmi, and A. Rizg, "A Hybrid Approach for the Detection and Classification of Tomato Leaf Diseases," *Applied Sciences* (Switzerland), vol. 12, no. 16, Aug. 2022, doi: 10.3390/app12168182.
- [2] S. P. Siregar, I. Akbari, Poningsih, A. Wanto, and Solikhun, "Enhancing Tomato Leaf Disease Detection via Optimized VGG16 and Transfer Learning Techniques," *Jurnal RESTI*, vol. 9, no. 3, pp. 570–580, Jun. 2025, doi: 10.29207/resti.v9i3.6410.
- [3] J. Kim, Y. Kim, D. E. Yoon, I. S. Lee, and Y. Chae, "Identification of auricular acupoints using a convolutional neural network," *Integr Med Res*, vol. 15, no. 1, Mar. 2026, doi: 10.1016/j.imr.2025.101226.
- [4] S. R. Ahmad, M. A. Wibowo, N. U. Handayani, D. B. Nugroho, Y. Latief, and R. Arifuddin, "Safety Knowledge Management in Construction Industry: A Systematic Literature Review of Performance Measurement Indicators," *International Journal of Engineering, Transactions B: Applications*, vol. 39, no. 7, pp. 1561–1577, Jun. 2026, doi: 10.5829/ije.2026.39.07a.03.

- [5] D. C. Rodríguez-Lira, D. M. Córdova-Esparza, J. M. Álvarez-Alvarado, J. Terven, J. A. Romero-González, and J. Rodríguez-Reséndiz, "Trends in Machine and Deep Learning Techniques for Plant Disease Identification: A Systematic Review," Dec. 01, 2024, Multidisciplinary Digital Publishing Institute (MDPI). doi: 10.3390/agriculture14122188.
- [6] B. Balaji, T. Satyanarayana Murthy, and R. Kuchipudi, "A Comparative Study on Plant Disease Detection and Classification Using Deep Learning Approaches," *International Journal of Image, Graphics and Signal Processing*, vol. 15, no. 3, pp. 48–59, Jun. 2023, doi: 10.5815/ijigsp.2023.03.04.
- [7] R. Mahakud, N. Mohanty, D. Kumar Behera, B. K. Pattanayak, K. Rautaray, and B. Mohanty, "on-line version) A Hybrid Vggnet-Vision Transformer Approach For Leaf Disease Classification Using Pggan-Augmentation (on-line version)," *Int J Appl Math (Sofia)*, vol. 38, no. 4s, p. 2025, 2025.
- [8] N. Ullah et al., "A Lightweight Deep Learning-Based Model for Tomato Leaf Disease Classification," *Computers, Materials and Continua*, vol. 77, no. 3, pp. 3969–3992, 2023, doi: 10.32604/cmc.2023.041819.
- [9] A. Batool, J. Kim, S. J. Lee, J. H. Yang, and Y. C. Byun, "An enhanced lightweight T-Net architecture based on convolutional neural network (CNN) for tomato plant leaf disease classification," *PeerJ Comput Sci*, vol. 10, 2024, doi: 10.7717/peerj-cs.2495.
- [10] A. T. Mengesha and M. A. Mengistie, "Applying transfer learning in CNN model architectures for detecting tomato leaf disease with explainable artificial intelligence," *Smart Agricultural Technology*, vol. 11, Aug. 2025, doi: 10.1016/j.atech.2025.101034.
- [11] H. Ulutaş and V. Aslantaş, "Design of Efficient Methods for the Detection of Tomato Leaf Disease Utilizing Proposed Ensemble CNN Model," *Electronics (Switzerland)*, vol. 12, no. 4, Feb. 2023, doi: 10.3390/electronics12040827.
- [12] P. Goyal, D. K. Verma, and S. Kumar, "Diagnosis Of Plant Leaf Diseases Using Image Based Detection And Prediction Using Machine Learning Approach," *Econ Comput Econ Cybern Stud Res*, vol. 57, no. 4, pp. 293–312, 2023, doi: 10.24818/18423264/57.4.23.18.
- [13] A. H. N. Hidayah, A. R. Syafeeza, N. A. Razak, W. H. M. Saad, Y. C. Wong, and A. A. Naja, "Disease Detection of Solanaceous Crops Using Deep Learning for Robot Vision," *Journal of Robotics and Control (JRC)*, vol. 3, no. 6, pp. 790–799, Nov. 2022, doi: 10.18196/jrc.v3i6.15948.
- [14] M. H. Najim, S. K. Abdulateef, and A. H. Alasadi, "Early detection of tomato leaf diseases based on deep learning techniques," *IAES International Journal of Artificial Intelligence*, vol. 13, no. 1, pp. 509–515, Mar. 2024, doi: 10.11591/ijai.v13.i1.pp509-515.
- [15] P. Saraf, J. Patil, and R. Wagh, "Enhancing Tomato Leaf Disease Detection Through Multimodal Feature Fusion," *Applied Computer Science*, vol. 20, no. 4, pp. 14–38, 2024, doi: 10.35784/acs-2024-38.
- [16] S. Poornima, N. Sripriya, A. F. Alrasheedi, S. S. Askar, and M. Abouhawwash, "Hybrid Convolutional Neural Network for Plant Diseases Prediction," *Intelligent Automation and Soft Computing*, vol. 36, no. 2, pp. 2393–2409, 2023, doi: 10.32604/iasc.2023.024820.
- [17] J. Chen et al., "Hyperspectral imaging-driven deep learning approach: Asymptomatic stage detection and severity grading of tomato yellow leaf curl disease," *Smart Agricultural Technology*, vol. 12, Dec. 2025, doi: 10.1016/j.atech.2025.101281.
- [18] H. Zhou, Z. Fang, Y. Wang, and M. Tong, "Image Generation of Tomato Leaf Disease Identification Based on Small-ACGAN," *Computers, Materials and Continua*, vol. 76, no. 1, pp. 175–194, 2023, doi: 10.32604/cmc.2023.037342.
- [19] S. Bensaadi and A. Louchene, "Low-cost convolutional neural network for tomato plant diseases classification," *IAES International Journal of Artificial Intelligence*, vol. 12, no. 1, pp. 162–170, Mar. 2023, doi: 10.11591/ijai.v12.i1.pp162-170.
- [20] G. Wang, R. Xie, L. Mo, F. Ye, X. Yi, and P. Wu, "Multifactorial Tomato Leaf Disease Detection Based on Improved YOLOV5," *Symmetry (Basel)*, vol. 16, no. 6, Jun. 2024, doi: 10.3390/sym16060723.
- [21] A. Gatla et al., "Optimizing Edge AI for Tomato Leaf Disease Identification," *Engineering, Technology and Applied Science Research*, vol. 14, no. 4, pp. 16061–16068, Aug. 2024, doi: 10.48084/etasr.7802.
- [22] S. A. Patel and P. A. Barot, "Parallel Custom Deep Learning Model for Classification of Plant Leaf Disease Using Fusion of Features," *International Journal of Intelligent Engineering and Systems*, vol. 17, no. 2, pp. 50–60, 2024, doi: 10.22266/ijies2024.0430.05.
- [23] T. Kumar et al., "Plant Disease Detection and Classification Using Hybrid Model Based on Convolutional Auto Encoder and Convolutional Neural Network," *Computers, Materials and Continua*, vol. 83, no. 3, pp. 5219–5234, 2025, doi: 10.32604/cmc.2025.062010.
- [24] M. Bakr, S. Abdel-Gaber, M. Nasr, and M. Hazman, "Tomato Disease Detection Model Based On Densenet And Transfer Learning," *Applied Computer Science*, vol. 18, no. 2, pp. 56–70, 2022, doi: 10.35784/acs-2022-13.
- [25] B. Balaji, T. Satyanarayana Murthy, and R. Kuchipudi, "A Comparative Study on Plant Disease Detection and Classification Using Deep Learning Approaches," *International Journal of Image, Graphics and Signal Processing*, vol. 15, no. 3, pp. 48–59, 2023, doi: 10.5815/ijigsp.2023.03.04.
- [26] A. T. Mengesha and M. A. Mengistie, "Applying transfer learning in CNN model architectures for detecting tomato leaf disease with explainable artificial intelligence," *Smart Agricultural Technology*, vol. 11, no. May, 2025, doi: 10.1016/j.atech.2025.101034.
- [27] A. Gatla et al., "Optimizing Edge AI for Tomato Leaf Disease Identification," *Engineering, Technology and Applied Science Research*, vol. 14, no. 4, pp. 16061–16068, 2024, doi: 10.48084/etasr.7802.
- [28] P. Saraf, J. Patil, and R. Wagh, "Enhancing Tomato Leaf Disease Detection Through Multimodal Feature Fusion," *Applied Computer Science*, vol. 20, no. 4, pp. 14–38, 2024, doi: 10.35784/acs-2024-38.
- [29] H. A. Santoso, B. Fandhi Safsalta, N. Febrianto, G. Wilujeng Saraswati, and S. C. Haw, "Comparative analysis of convolutional neural network and DenseNet121 transfer learning in agriculture focusing on crop leaf disease identification," *Applied Computing and Informatics*, 2024, doi: 10.1108/ACI-03-2024-0132.
- [30] T. Kim et al., "Enhancement for Greenhouse Sustainability Using Tomato Disease Image Classification System Based on Intelligent Complex Controller," *Sustainability (Switzerland)*, vol. 15, no. 23, 2023, doi: 10.3390/su152316220.
- [31] T. Uygun, S. Kiliçarslan, C. Közkurt, and M. M. Ozguven, "An Effective Feature Extraction Method for Tomato Leafminer - Tuta Absoluta (Meyrick) (Lepidoptera: Gelechiidae) Classification," *Brazilian Archives of Biology and Technology*, vol. 68, pp. 1–20, 2025, doi: 10.1590/1678-4324-2025240501.
- [32] H. Terzioğlu, A. Gölcük, A. M. A. Shakarji, and M. Y. Al-Bayati, "Comparative Analysis of Deep Learning-Based Feature Extraction and Traditional Classification Approaches for Tomato Disease Detection," *Agronomy*, vol. 15, no. 7, pp. 1–19, 2025, doi: 10.3390/agronomy15071509.
- [33] S. Ma, X. Lu, and L. Zhang, "TSINet: A Semantic and Instance Segmentation Network for 3D Tomato Plant Point Clouds," *Applied Sciences (Switzerland)*, vol. 15, no. 15, pp. 1–16, 2025, doi: 10.3390/app15158406.
- [34] P. Borugadda, R. Lakshmi, and S. Sahoo, "Transfer Learning VGG16 Model for Classification of Tomato Plant Leaf Diseases: A Novel Approach for Multi-Level Dimensional Reduction," *Pertanika J Sci Technol*, vol. 31, no. 2, pp. 813–841, 2023, doi: 10.47836/pjst.31.2.09.