

Tren dan Tantangan Deep Learning untuk Identifikasi Penyakit Daun Padi: Tinjauan Literatur Sistematis

Maliatul Fitriyasari

Program Studi Sistem Informasi, Fakultas Ilmu Komputer, Universitas Jember, Jember, Indonesia

Email: maliatul.fitriyasari@unej.ac.id

ABSTRACT

The advancement of deep learning technology has significantly contributed to the agricultural sector, particularly in image-based rice leaf disease identification. This study aims to analyze the development trends, model performance, and challenges in applying deep learning methods through a Systematic Literature Review (SLR) approach. The review process follows the PRISMA guidelines, analyzing 10 scientific articles published between 2020 and 2026. The results indicate that Convolutional Neural Networks (CNNs) remain the most widely used approach, with various architectures such as ResNet, VGG, and MobileNet demonstrating high classification performance. Furthermore, recent studies show a shift toward more adaptive methods, including object detection models such as YOLO and hybrid approaches that integrate CNNs with Vision Transformers. Most studies report accuracy levels exceeding 90%, highlighting the strong potential of deep learning for automated plant disease detection. However, further analysis reveals a significant gap between model performance on controlled datasets and real-world conditions. The main challenges identified include limited availability of representative datasets, low model generalization capability, high computational complexity, and lack of model interpretability. In addition, practical implementation in real agricultural environments remains limited, indicating the need for more application-oriented research. This study contributes by providing a comprehensive mapping of current research trends and identifying key research gaps, which can serve as a foundation for developing more robust, efficient, and practical rice disease detection systems in the future.

Keywords: Deep Learning, Rice Leaf Disease, Convolutional Neural Network, Systematic Literature Review.

ABSTRAK

Perkembangan teknologi deep learning telah memberikan kontribusi signifikan dalam bidang pertanian, khususnya dalam identifikasi penyakit daun padi berbasis citra. Penelitian ini bertujuan untuk menganalisis tren perkembangan, performa model, serta tantangan dalam penerapan metode deep learning melalui pendekatan Systematic Literature Review (SLR). Proses kajian dilakukan dengan mengacu pada pedoman PRISMA, dengan menganalisis 10 artikel ilmiah yang dipublikasikan dalam rentang tahun 2020–2026. Hasil penelitian menunjukkan bahwa Convolutional Neural Network (CNN) masih menjadi metode yang paling dominan digunakan, dengan berbagai variasi arsitektur seperti ResNet, VGG, dan MobileNet. Selain itu, terdapat perkembangan menuju metode yang lebih adaptif, seperti object detection berbasis YOLO dan model hybrid yang menggabungkan CNN dengan Vision Transformer. Sebagian besar penelitian melaporkan tingkat akurasi di atas 90%, yang menunjukkan potensi besar deep learning dalam mendukung deteksi penyakit tanaman secara otomatis. Namun demikian, analisis lebih lanjut mengungkap adanya kesenjangan antara performa model pada dataset terkontrol dan kondisi dunia nyata. Tantangan utama yang diidentifikasi meliputi keterbatasan dataset yang representatif, rendahnya kemampuan generalisasi model, tingginya kompleksitas komputasi, serta kurangnya interpretabilitas sistem. Selain itu, implementasi di lapangan masih terbatas, sehingga menunjukkan perlunya penelitian lanjutan yang lebih aplikatif. Penelitian ini memberikan kontribusi dalam bentuk pemetaan komprehensif terhadap perkembangan metode, serta identifikasi research gap yang dapat menjadi dasar bagi pengembangan sistem deteksi penyakit tanaman yang lebih robust dan aplikatif di masa depan.

Kata Kunci: *Deep Learning, Penyakit Daun Padi, CNN, Systematic Literature Review.*

1. Pendahuluan

Sektor pertanian memiliki peran strategis dalam menjaga ketahanan pangan, khususnya di negara agraris seperti Indonesia, di mana padi merupakan komoditas utama. Namun, produktivitas padi sering terganggu oleh berbagai penyakit daun seperti rice blast, bacterial leaf blight, dan brown spot yang dapat menyebabkan penurunan hasil panen secara signifikan. Metode identifikasi penyakit secara konvensional yang mengandalkan observasi manual oleh pakar dinilai kurang efisien, memakan waktu, serta rentan terhadap subjektivitas. Oleh karena itu, diperlukan pendekatan otomatis berbasis teknologi untuk meningkatkan akurasi dan efisiensi deteksi penyakit tanaman.

Perkembangan pesat dalam bidang deep learning, khususnya berbasis citra (image-based), telah membuka peluang baru dalam deteksi penyakit tanaman. Model seperti Convolutional Neural Network (CNN) telah banyak digunakan karena kemampuannya dalam mengekstraksi fitur visual secara otomatis. Berbagai penelitian menunjukkan bahwa pendekatan CNN mampu mencapai tingkat akurasi yang tinggi dalam klasifikasi penyakit daun padi, bahkan melebihi 90% pada kondisi dataset tertentu [1], [5]. Selain itu, teknik transfer learning dengan arsitektur seperti ResNet dan MobileNet juga terbukti efektif dalam meningkatkan performa model pada dataset yang terbatas [8].

Seiring perkembangan teknologi, tren penelitian mulai bergeser dari model CNN konvensional ke pendekatan yang lebih kompleks namun adaptif. Secara teknis, keunggulan masing-masing arsitektur dalam konteks fitur spasial penyakit daun padi dapat dijelaskan sebagai berikut. YOLOv8 (You Only Look Once version 8) mengintegrasikan deteksi dan klasifikasi dalam satu tahap (single-stage detector), sehingga sangat sesuai untuk skenario real-time di lapangan karena mampu memproses seluruh citra dalam satu kali forward propagation [2]. Keunggulan ini krusial mengingat kondisi lingkungan pertanian yang dinamis, namun kelemahannya terletak pada akurasi lokasi yang sedikit lebih rendah dibandingkan two-stage detector seperti Faster R-CNN [9]. Sementara itu, Vision Transformer (ViT) menawarkan pendekatan berbasis self-attention yang mampu menangkap hubungan antar piksel dalam jarak jauh (long-range dependencies), sesuatu yang sulit dicapai oleh CNN konvensional karena keterbatasan receptive field-nya [3]. Dalam konteks penyakit daun padi, ViT lebih unggul dalam mendeteksi pola penyebaran penyakit yang tidak beraturan (misalnya brown spot yang tersebar). Namun, ViT membutuhkan data latih dalam jumlah sangat besar dan memiliki kompleksitas komputasi $O(n^2)$, sehingga pendekatan hybrid CNN-ViT muncul sebagai solusi dengan memanfaatkan CNN untuk ekstraksi fitur lokal (komputasi efisien) dan ViT untuk pemodelan hubungan global [3]. Selain itu, attention mechanism pada multi-branch CNN [4] memungkinkan model untuk secara

adaptif menekankan pada region daun yang terinfeksi sambil mengabaikan latar belakang yang kompleks, sehingga meningkatkan robustness terhadap variasi lingkungan. Dengan demikian, pemilihan arsitektur tidak semata-mata berdasarkan akurasi, tetapi juga mempertimbangkan trade-off antara kecepatan, efisiensi komputasi, dan kemampuan generalisasi pada kondisi lapangan yang sesungguhnya.

Meskipun berbagai pendekatan telah menunjukkan hasil yang menjanjikan, masih terdapat sejumlah tantangan yang menjadi perhatian dalam penelitian ini. Salah satu masalah utama adalah keterbatasan dataset yang representatif, di mana sebagian besar penelitian masih menggunakan dataset dalam kondisi terkontrol yang kurang mencerminkan kondisi lapangan sebenarnya [6]. Selain itu, kemampuan generalisasi model masih menjadi kendala, terutama ketika model diuji pada lingkungan dengan variasi pencahayaan, latar belakang, dan kondisi daun yang beragam. Tantangan lainnya meliputi kompleksitas komputasi, kebutuhan perangkat keras yang tinggi, serta kurangnya interpretabilitas model yang membuat hasil prediksi sulit dipahami oleh pengguna non-teknis [7].

Berdasarkan tinjauan literatur yang telah dilakukan, sebagian besar Systematic Literature Review (SLR) sebelumnya pada bidang deteksi penyakit tanaman berbasis deep learning umumnya berfokus pada perbandingan performa kuantitatif model, seperti accuracy, precision, recall, dan F1-score [14]. Namun, kajian-kajian tersebut masih memiliki keterbatasan dalam menjelaskan hubungan antara karakteristik arsitektur deep learning dengan kemampuan model dalam menangani fitur visual penyakit daun padi yang kompleks, seperti tekstur bercak, variasi warna, distribusi spasial penyakit, dan gangguan latar belakang alami.

Selain itu, sebagian besar SLR sebelumnya menggunakan cakupan literatur yang sangat luas dengan pembahasan yang relatif umum, sehingga belum memberikan analisis teknis yang mendalam terhadap kekuatan dan kelemahan masing-masing arsitektur deep learning. Berbeda dengan pendekatan tersebut, penelitian ini secara khusus melakukan analisis mendalam terhadap sepuluh artikel utama yang dipilih secara purposive berdasarkan tiga pertimbangan utama, yaitu (1) artikel merepresentasikan arsitektur deep learning yang berbeda (CNN, YOLO, Faster R-CNN, Vision Transformer, hybrid CNN-ViT, dan lightweight model), (2) artikel menyajikan hasil eksperimen yang terukur dan dapat dibandingkan secara kuantitatif, (3) artikel membahas implementasi pada dataset dengan karakteristik yang berbeda, termasuk dataset laboratorium dan dataset lapangan. Pemilihan sepuluh artikel utama ini dilakukan bukan untuk memperoleh cakupan literatur terbesar, melainkan untuk mendapatkan kedalaman analisis teknis dan komparatif terhadap perkembangan state of

the art pada identifikasi penyakit daun padi berbasis citra. Dengan pendekatan tersebut, penelitian ini tidak hanya merangkum performa model, tetapi juga menganalisis keterkaitan antara desain arsitektur, karakteristik dataset, kompleksitas komputasi, dan kemampuan generalisasi model pada kondisi dunia nyata.

Oleh karena itu, penelitian ini dilakukan untuk mengkaji secara sistematis perkembangan metode deep learning berbasis citra dalam identifikasi penyakit daun padi. Tujuan dari penelitian ini adalah untuk (1) mengidentifikasi tren metode yang digunakan, (2) menganalisis performa berbagai model yang telah dikembangkan, serta (3) mengungkap tantangan dan peluang dalam implementasi teknologi tersebut. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi dalam bentuk pemetaan state of the art, identifikasi research gap, serta rekomendasi arah penelitian selanjutnya (novelty contribution) dalam bidang deteksi penyakit tanaman berbasis kecerdasan buatan.

2. Metode Penelitian

2.1 Pendekatan Penelitian

Penelitian ini menggunakan metode Systematic Literature Review (SLR) untuk mengidentifikasi, mengevaluasi, dan mensintesis penelitian terkait penerapan deep learning berbasis citra dalam identifikasi penyakit daun padi. Metode ini dipilih karena mampu memberikan tinjauan yang sistematis, transparan, dan dapat direplikasi. Proses SLR dalam penelitian ini mengacu pada pedoman PRISMA [11], serta mengikuti tahapan yang diusulkan oleh Barbara Kitchenham dalam konteks penelitian ilmu komputer [12].

2.2 Rumusan Pertanyaan Penelitian

Untuk mengarahkan proses kajian, dirumuskan pertanyaan penelitian sebagai berikut:

- RQ1: Apa saja metode deep learning yang digunakan dalam identifikasi penyakit daun padi?
- RQ2: Bagaimana performa model yang diusulkan dalam penelitian sebelumnya?
- RQ3: Apa saja tantangan utama dalam penerapan metode tersebut?

Rumusan ini dirancang untuk memastikan bahwa proses analisis literatur tetap fokus dan relevan terhadap tujuan penelitian [12].

2.3 Strategi Pencarian Literatur

Pencarian literatur dilakukan pada tiga basis data utama, yaitu Google Scholar, IEEE Xplore, dan ScienceDirect yang dikenal memiliki cakupan luas dalam bidang teknik dan ilmu komputer [13].

Proses pencarian dilakukan menggunakan kombinasi kata kunci dengan operator Boolean sebagai berikut:

- ("rice leaf disease" OR "paddy disease") AND
- ("deep learning" OR "convolutional neural network" OR "CNN")

Selain itu, variasi kata kunci seperti "plant disease detection" dan "image-based classification" juga digunakan untuk memperluas cakupan pencarian.

Pencarian dibatasi pada publikasi dalam rentang tahun 2020–2026 untuk memastikan relevansi dan kebaruan penelitian.

2.4 Kriteria Inklusi dan Eksklusi

Untuk menjamin kualitas dan relevansi studi yang dianalisis, diterapkan kriteria seleksi sebagai berikut:

Kriteria inklusi:

- Artikel jurnal atau prosiding ilmiah
- Dipublikasikan pada rentang tahun 2020–2026
- Menggunakan metode deep learning berbasis citra
- Fokus pada identifikasi penyakit daun padi
- Menyediakan hasil eksperimen yang jelas

Kriteria eksklusi:

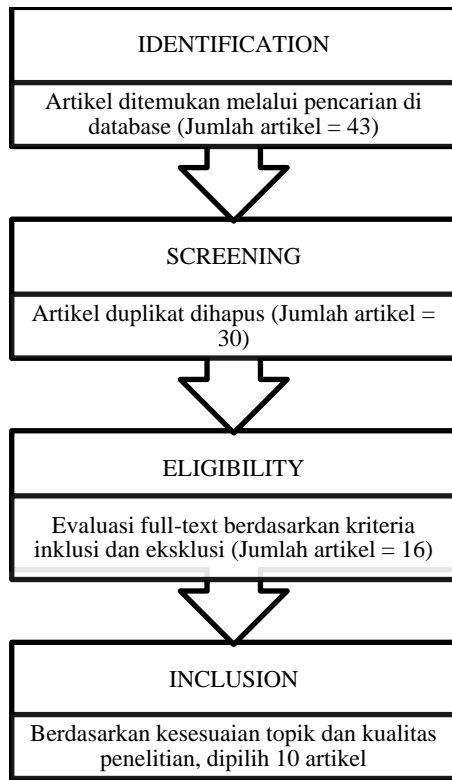
- Artikel tinjauan (review paper)
- Penelitian yang tidak berbasis citra
- Studi pada tanaman selain padi
- Artikel tanpa akses teks lengkap

Kriteria ini digunakan untuk menjaga konsistensi dan validitas data yang dianalisis [12].

2.5 Proses Seleksi Studi

Proses seleksi literatur mengikuti tahapan dalam pedoman PRISMA [11], yang terdiri dari empat tahap utama:

- Identification: Ditemukan sebanyak 43 artikel dari hasil pencarian awal di seluruh database.
- Screening: Setelah menghapus duplikasi dan melakukan penyaringan berdasarkan judul dan abstrak, tersisa 30 artikel.
- Eligibility: Evaluasi terhadap teks lengkap menghasilkan 16 artikel yang memenuhi kriteria.
- Inclusion: Berdasarkan kesesuaian topik dan kualitas penelitian, dipilih 10 artikel sebagai studi utama dalam SLR ini.



Gambar 1. Diagram alir metode PRISMA

Proses ini memastikan bahwa hanya penelitian yang relevan dan berkualitas tinggi yang dianalisis lebih lanjut.

Meskipun jumlah studi utama yang dianalisis dalam tahap akhir hanya terdiri dari 10 artikel, pendekatan ini dilakukan secara sengaja untuk mempertahankan kedalaman analisis teknis (focused SLR). Penelitian ini tidak bertujuan melakukan pemetaan bibliometrik berskala besar, melainkan melakukan sintesis komparatif secara mendalam terhadap arsitektur deep learning yang paling representatif dalam identifikasi penyakit daun padi.

Selain itu, proses seleksi dilakukan secara ketat dengan mempertimbangkan kesesuaian topik, kelengkapan hasil eksperimen, kualitas metodologi, serta relevansi terhadap implementasi berbasis citra. Dengan demikian, artikel yang dipilih merupakan studi primer yang memiliki kontribusi signifikan terhadap perkembangan state of the art pada bidang ini.

2.6 Penilaian Kualitas Studi

Untuk meningkatkan validitas hasil kajian, dilakukan penilaian kualitas terhadap setiap artikel yang terpilih. Evaluasi dilakukan berdasarkan beberapa kriteria, yaitu:

- Kejelasan metodologi penelitian
- Kesesuaian dataset yang digunakan
- Validitas hasil eksperimen
- Relevansi terhadap topik penelitian

Setiap artikel dianalisis secara kritis melalui quality assessment untuk memastikan bahwa hasil yang disintesis berasal dari penelitian yang memiliki kontribusi ilmiah yang signifikan [12].

Berdasarkan hasil quality assessment, sebagian besar artikel memiliki kualitas metodologi yang baik dengan skor rata-rata di atas 3 dari total 4 poin evaluasi. Hal ini menunjukkan bahwa studi yang dianalisis memiliki validitas yang cukup kuat untuk digunakan dalam proses sintesis literatur.

Tabel 1. Hasil Quality Assessment Artikel Terpilih

Artikel	Q1 Metodologi Jelas	Q2 Dataset Valid	Q3 Evaluasi Lengkap	Q4 Relevansi Tinggi	Total
[1]	1	1	1	1	4
[2]	1	1	1	1	4
[3]	1	1	1	1	4
[4]	1	1	0	1	3
[5]	1	1	1	1	4
[6]	1	1	1	1	4
[7]	1	0	1	1	3
[8]	1	1	1	1	4
[9]	1	1	1	1	4
[10]	1	1	1	1	4

Keterangan:

- 1 = memenuhi
- 0 = tidak memenuhi Sebagian

2.7 Ekstraksi Data

Data dari setiap studi diekstraksi secara sistematis untuk memudahkan proses analisis dan perbandingan. Informasi yang dikumpulkan meliputi:

- Penulis dan tahun publikasi
- Metode atau arsitektur deep learning
- Dataset yang digunakan
- Metode evaluasi dan hasil performa
- Temuan utama penelitian

Proses ekstraksi dilakukan secara terstruktur untuk mendukung sintesis data yang komprehensif [13].

2.8 Metode Analisis Data

Analisis data dilakukan menggunakan pendekatan narrative synthesis, yaitu dengan mengelompokkan dan membandingkan hasil penelitian berdasarkan kategori tertentu, seperti jenis model, performa, dan pendekatan yang digunakan.

Selain itu, dilakukan analisis komparatif untuk:

- Mengidentifikasi tren perkembangan metode
- Mengevaluasi kelebihan dan kekurangan masing-masing pendekatan
- Menemukan kesenjangan penelitian (research gap)

Hasil analisis ini digunakan sebagai dasar dalam penyusunan pembahasan dan rekomendasi penelitian selanjutnya.

3. Hasil dan Pembahasan

3.1 Hasil Seleksi Studi

Berdasarkan proses seleksi literatur menggunakan pedoman PRISMA, diperoleh sebanyak 10 artikel yang memenuhi kriteria inklusi dan digunakan sebagai objek analisis. Studi-studi tersebut mencakup berbagai pendekatan *deep learning* berbasis citra dalam identifikasi penyakit daun padi.

3.2 Ringkasan Studi Terpilih

Tabel 1. Karakteristik Studi dan Metode

No	Penulis & Tahun	Metode / Arsitektur	Dataset	Jenis Penyakit
1	[1] (2024)	CNN	Dataset citra daun padi	Blast, Blight
2	[2] (2024)	YOLOv8	Dataset real-time	Multi penyakit
3	[3] (2024)	CNN + ViT	Dataset hybrid	Blast, Brown Spot
4	[4] (2023)	Multi-branch CNN	Dataset citra	Multi penyakit
5	[5] (2023)	ResNet, VGG	Dataset publik	Multi penyakit
6	[6] (2024)	CNN vs Faster R-CNN	Dataset lapangan	Multi penyakit
7	[7] (2024)	CNN + rekomendasi	Dataset citra	Blast, Blight
8	[8] (2024)	MobileNetV2	Dataset ringan	Multi penyakit
9	[9] (2021)	Faster R-CNN	Dataset citra	Multi penyakit
10	[10] (2024)	CNN + U-Net	Dataset kombinasi	Multi penyakit


Tabel 2. Teknik Preprocessing dan Evaluasi

No	Preprocessing	Evaluasi
1	Resize, Normalisasi	Accuracy
2	Augmentasi, Resize	mAP, Precision
3	Augmentasi	Accuracy, F1-score
4	Normalisasi, Augmentasi	Accuracy
5	Augmentasi	Accuracy, Recall
6	Resize	Accuracy, Precision
7	Preprocessing standar	Accuracy
8	Resize, Augmentasi	Accuracy
9	Augmentasi	Precision, Recall
10	Segmentasi, Augmentasi	Accuracy, IoU

Tabel 3. Performa dan Analisis

No	Akurasi	Kelebihan	Kelemahan
1	94%	Akurasi tinggi	Dataset terbatas
2	92%	Real-time	Kompleks
3	95%	Fitur kuat	Komputasi tinggi
4	96%	Attention efektif	Overfitting
5	98%	Performa terbaik	Tidak real-world
6	91%	Data nyata	Akurasi turun
7	93%	Aplikatif	Terbatas
8	90%	Efisien	Akurasi rendah
9	89%	Deteksi detail	Lambat
10	97%	Segmentasi + klasifikasi	Kompleks

3.3 Analisis Tren Metode



Gambar 2. Grafik distribusi deep learning yang digunakan dalam 10 studi terpilih

Berdasarkan tabel 1 dan gambar 2, terlihat bahwa pendekatan berbasis *Convolutional Neural Network* (CNN) masih menjadi metode dominan dalam identifikasi penyakit daun padi. Hal ini disebabkan oleh kemampuan CNN dalam melakukan ekstraksi fitur spasial secara otomatis tanpa memerlukan rekayasa fitur manual. Studi [1], [4], dan [5] menunjukkan bahwa arsitektur CNN seperti ResNet dan VGG mampu menghasilkan performa tinggi dalam klasifikasi citra penyakit daun.

Namun demikian, perkembangan terbaru menunjukkan adanya pergeseran menuju pendekatan yang lebih adaptif dan efisien. Metode *object detection* seperti YOLOv8 [2] mulai banyak digunakan karena mampu melakukan deteksi dan klasifikasi secara simultan dalam waktu nyata (*real-time*). Hal ini menjadi penting dalam konteks implementasi di lapangan, di mana sistem harus mampu memberikan respon cepat.

Selain itu, integrasi antara CNN dan *Vision Transformer* (ViT) [3] mencerminkan tren menuju model hybrid yang menggabungkan keunggulan CNN dalam ekstraksi fitur lokal dan kemampuan transformer dalam menangkap hubungan global. Pendekatan ini menunjukkan potensi dalam meningkatkan akurasi dan generalisasi model.

Penggunaan *attention mechanism* seperti pada multi-branch CNN [4] juga menjadi bagian dari *state of the art*, karena mampu meningkatkan fokus model pada area citra yang relevan. Di sisi lain, model ringan seperti MobileNetV2 [8] menunjukkan arah penelitian menuju efisiensi komputasi, khususnya untuk implementasi pada perangkat mobile atau edge computing.

Secara teknis, keunggulan masing-masing arsitektur dalam konteks identifikasi penyakit daun padi berkaitan erat dengan karakteristik fitur visual yang dianalisis. CNN konvensional bekerja menggunakan operasi konvolusi lokal yang efektif untuk menangkap pola tekstur, tepi, dan perubahan warna pada area daun yang terinfeksi. Namun, receptive field CNN yang terbatas menyebabkan model sulit memahami hubungan spasial jarak jauh antar area penyakit pada citra beresolusi tinggi.

Pada kondisi tersebut, Vision Transformer (ViT) memiliki keunggulan karena menggunakan mekanisme self-attention yang memungkinkan model mempelajari hubungan global antar patch citra secara langsung. Dalam kasus penyakit seperti brown spot atau leaf blast yang memiliki pola penyebaran tidak beraturan, kemampuan global-context modeling pada ViT menjadi lebih efektif dibanding CNN murni. Akan tetapi, kompleksitas komputasi Vision Transformer meningkat secara kuadratik terhadap jumlah patch input, sehingga membutuhkan dataset besar dan sumber daya komputasi yang tinggi.

Sementara itu, YOLOv8 unggul dalam skenario implementasi lapangan karena menggunakan pendekatan single-stage object detection yang memungkinkan proses deteksi dan klasifikasi dilakukan secara simultan dalam satu kali inferensi. Hal ini memberikan kecepatan deteksi yang tinggi dan sangat sesuai untuk sistem real-time berbasis perangkat mobile atau edge computing. Dibandingkan Faster R-CNN yang menggunakan two-stage detection, YOLOv8 lebih efisien secara komputasi, meskipun dalam beberapa kasus memiliki keterbatasan dalam mendeteksi objek penyakit berukuran sangat kecil. Oleh karena itu, perkembangan terbaru menunjukkan bahwa arah penelitian tidak lagi hanya berorientasi pada peningkatan akurasi, tetapi juga pada kemampuan model dalam menyeimbangkan representasi fitur lokal-global, efisiensi komputasi, serta robustness terhadap variasi kondisi lingkungan nyata.

3.4. Perbandingan Metode Deep Learning

Berdasarkan hasil analisis pada Tabel 1 hingga Tabel 3, terdapat beberapa pendekatan utama yang digunakan dalam identifikasi penyakit daun padi, yaitu model berbasis *Convolutional Neural Network* (CNN), metode *object detection* seperti YOLO, serta model hybrid yang menggabungkan CNN dengan pendekatan lain seperti *Vision Transformer* (ViT). Masing-masing pendekatan memiliki karakteristik, keunggulan, dan keterbatasan yang berbeda.

Model berbasis CNN merupakan pendekatan yang paling umum digunakan dalam penelitian yang dianalisis. CNN memiliki keunggulan dalam mengekstraksi fitur lokal dari citra, sehingga sangat efektif untuk tugas klasifikasi penyakit daun. Studi [1], [4], dan [5] menunjukkan bahwa CNN mampu mencapai akurasi tinggi, terutama ketika dikombinasikan dengan teknik *transfer learning*. Namun, CNN memiliki keterbatasan dalam menangkap hubungan global antar fitur, sehingga performanya dapat menurun pada citra dengan kompleksitas tinggi.

Di sisi lain, metode YOLO sebagai pendekatan *object detection* menawarkan kemampuan untuk melakukan deteksi dan klasifikasi secara simultan dalam waktu nyata. Hal ini menjadi keunggulan utama dalam aplikasi

praktis di lapangan. Studi [2] menunjukkan bahwa YOLOv8 mampu memberikan performa yang kompetitif dengan kecepatan yang tinggi. Namun, metode ini memerlukan proses pelatihan yang lebih kompleks dan membutuhkan dataset dengan anotasi yang lebih detail.

Pendekatan hybrid, seperti kombinasi CNN dan ViT [3], menunjukkan potensi dalam mengatasi keterbatasan masing-masing metode. CNN digunakan untuk ekstraksi fitur lokal, sementara ViT menangkap hubungan global dalam citra. Meskipun pendekatan ini mampu meningkatkan akurasi, kompleksitas komputasi yang tinggi menjadi tantangan utama dalam implementasinya.

Selain itu, model lightweight seperti MobileNetV2 [8] menawarkan solusi untuk implementasi pada perangkat dengan sumber daya terbatas. Model ini memiliki efisiensi tinggi, namun dengan sedikit penurunan akurasi. Oleh karena itu, pemilihan metode yang tepat sangat bergantung pada kebutuhan aplikasi, apakah lebih mengutamakan akurasi, kecepatan, atau efisiensi.

3.5 Analisis Performa Model



Gambar 3. Perbandingan Performa Model

Analisis terhadap performa model menunjukkan bahwa sebagian besar penelitian melaporkan tingkat akurasi yang tinggi, yaitu di atas 90%, dengan beberapa studi mencapai hingga 98% [5]. Hal ini mengindikasikan bahwa pendekatan *deep learning* sangat efektif dalam mengenali pola visual penyakit daun padi.

Namun, jika dianalisis lebih kritis, terdapat beberapa faktor yang mempengaruhi performa tersebut:

a. Pengaruh Dataset

Model dengan akurasi tinggi umumnya menggunakan dataset yang bersifat terkontrol, seperti citra dengan latar belakang homogen dan pencahayaan yang stabil. Sebaliknya, penelitian yang menggunakan dataset lapangan [6], [9] cenderung menunjukkan penurunan akurasi. Hal ini menunjukkan bahwa performa model sangat bergantung pada kualitas dan karakteristik dataset.

b. Kompleksitas Model

Model dengan arsitektur kompleks seperti CNN + U-Net [10] atau CNN + ViT [3] cenderung menghasilkan akurasi lebih tinggi karena mampu menangkap fitur yang lebih kompleks. Namun, peningkatan performa ini sering kali diiringi dengan peningkatan kebutuhan komputasi, sehingga kurang efisien untuk implementasi nyata.

c. Teknik Optimasi

Penggunaan teknik seperti *transfer learning*, *data augmentation*, dan *ensemble learning* terbukti meningkatkan performa model secara signifikan [5], [8]. Teknik ini membantu model dalam mengatasi keterbatasan dataset dan meningkatkan kemampuan generalisasi.

d. Trade-off Akurasi vs Efisiensi

Model *lightweight* seperti MobileNetV2 [8] menunjukkan akurasi yang sedikit lebih rendah dibandingkan model kompleks, tetapi memiliki keunggulan dalam efisiensi dan kecepatan. Hal ini menunjukkan adanya trade-off antara akurasi dan efisiensi yang perlu dipertimbangkan dalam pengembangan sistem.

3.6 Analisis Dataset

Dataset merupakan salah satu faktor kunci dalam keberhasilan model *deep learning*. Berdasarkan studi yang dianalisis, terdapat beberapa karakteristik umum dataset yang digunakan:

a. Ukuran Dataset

Sebagian besar penelitian menggunakan dataset dengan jumlah citra yang relatif terbatas. Hal ini menjadi kendala dalam proses pelatihan model, karena model *deep learning* umumnya membutuhkan data dalam jumlah besar.

b. Variasi Data

Dataset yang digunakan sering kali kurang memiliki variasi dalam hal:

- 1) kondisi pencahayaan
- 2) latar belakang
- 3) tingkat keparahan penyakit

Kurangnya variasi ini menyebabkan model sulit untuk melakukan generalisasi pada data baru.

c. Dataset Publik vs Dataset Lokal

Beberapa penelitian menggunakan dataset publik, sementara yang lain menggunakan dataset hasil pengumpulan sendiri. Dataset publik biasanya lebih terstandarisasi, tetapi kurang merepresentasikan kondisi

lapangan. Sebaliknya, dataset lokal lebih realistis, tetapi seringkali terbatas dalam jumlah dan kualitas.

d. Imbalance Data

Distribusi kelas yang tidak seimbang juga menjadi masalah umum, di mana jumlah citra untuk setiap jenis penyakit tidak sama. Hal ini dapat menyebabkan bias pada model.

3.7 Analisis Metode Evaluasi Model

Evaluasi performa model merupakan aspek penting dalam penelitian *deep learning*, karena menentukan sejauh mana model mampu melakukan klasifikasi dengan benar. Berdasarkan studi yang dianalisis, metrik evaluasi yang paling umum digunakan adalah *accuracy*, diikuti oleh *precision*, *recall*, *F1-score*, serta *mean Average Precision* (mAP) pada kasus deteksi objek.

Meskipun *accuracy* sering digunakan sebagai indikator utama, metrik ini memiliki keterbatasan, terutama pada dataset yang tidak seimbang (*imbalanced dataset*). Dalam kondisi tersebut, model dapat menghasilkan nilai *accuracy* yang tinggi meskipun tidak mampu mendeteksi kelas minoritas dengan baik. Oleh karena itu, penggunaan metrik lain seperti *precision* dan *recall* menjadi penting untuk memberikan gambaran yang lebih komprehensif terhadap performa model.

Precision mengukur tingkat ketepatan prediksi positif, sedangkan *recall* mengukur kemampuan model dalam mendeteksi seluruh data positif. Kombinasi kedua metrik ini dalam bentuk *F1-score* memberikan keseimbangan antara keduanya. Dalam konteks deteksi penyakit tanaman, *recall* menjadi sangat penting untuk meminimalkan kasus penyakit yang tidak terdeteksi, yang dapat berdampak pada kerugian hasil panen.

Untuk metode *object detection* seperti YOLO dan Faster R-CNN, metrik *mean Average Precision* (mAP) digunakan untuk mengevaluasi performa model dalam mendeteksi objek secara akurat. Metrik ini mempertimbangkan baik lokasi maupun klasifikasi objek, sehingga lebih kompleks dibandingkan metrik klasifikasi biasa.

Berdasarkan analisis ini, dapat disimpulkan bahwa penggunaan satu metrik saja tidak cukup untuk mengevaluasi performa model secara menyeluruh. Oleh karena itu, penelitian selanjutnya disarankan untuk menggunakan kombinasi beberapa metrik evaluasi agar hasil yang diperoleh lebih representatif dan dapat dibandingkan secara adil.

3.8 Analisis Tantangan (*Gap Analysis*)

Berdasarkan sintesis dari seluruh studi, terdapat beberapa kesenjangan penelitian yang signifikan:

a. Kesenjangan antara Lab dan Dunia Nyata

Sebagian besar penelitian masih dilakukan dalam kondisi laboratorium, sehingga performa model belum tentu optimal ketika diterapkan di lapangan. Variasi kondisi lingkungan menjadi tantangan utama.

b. Generalisasi Model yang Rendah

Model yang dilatih pada dataset tertentu sering kali tidak dapat bekerja dengan baik pada dataset lain. Hal ini menunjukkan bahwa kemampuan generalisasi model masih terbatas.

c. Keterbatasan Dataset Terstandarisasi

Tidak adanya dataset penyakit daun padi yang besar dan terstandarisasi menjadi hambatan dalam pengembangan model yang robust dan dapat dibandingkan secara adil.

d. Kompleksitas dan Keterbatasan Implementasi

Model dengan performa tinggi biasanya memiliki kompleksitas yang tinggi, sehingga sulit diimplementasikan pada perangkat dengan sumber daya terbatas, seperti smartphone yang digunakan oleh petani.

e. Kurangnya Interpretabilitas Model

Sebagian besar model *deep learning* bersifat *black box*, sehingga sulit untuk menjelaskan bagaimana keputusan diambil. Hal ini menjadi hambatan dalam adopsi teknologi oleh pengguna non-teknis.

3.9 Implikasi Penerapan di Dunia Nyata

Meskipun berbagai penelitian menunjukkan performa model *deep learning* yang tinggi dalam identifikasi penyakit daun padi, implementasi di dunia nyata masih menghadapi berbagai tantangan. Salah satu aspek utama adalah perbedaan kondisi antara dataset penelitian dan lingkungan lapangan. Faktor seperti pencahayaan yang tidak stabil, latar belakang yang kompleks, serta variasi kondisi daun dapat mempengaruhi performa model secara signifikan.

Dalam konteks penerapan praktis, sistem deteksi penyakit tanaman diharapkan dapat digunakan oleh petani secara langsung, misalnya melalui aplikasi berbasis mobile. Oleh karena itu, model yang dikembangkan harus mempertimbangkan keterbatasan perangkat, seperti kapasitas memori dan kemampuan komputasi. Model lightweight seperti MobileNetV2 menjadi solusi yang potensial dalam hal ini, meskipun perlu dilakukan optimasi lebih lanjut untuk menjaga keseimbangan antara akurasi dan efisiensi.

Selain itu, ketersediaan infrastruktur juga menjadi faktor penting dalam implementasi sistem berbasis *deep learning*. Di beberapa daerah, keterbatasan akses internet dapat menjadi kendala dalam penggunaan

sistem berbasis cloud. Oleh karena itu, pengembangan sistem yang dapat berjalan secara offline atau berbasis edge computing menjadi arah yang menjanjikan.

Selain aspek performa dan infrastruktur, interpretabilitas model menjadi faktor penting dalam implementasi sistem identifikasi penyakit tanaman berbasis deep learning. Sebagian besar model deep learning modern masih bersifat black box, sehingga pengguna sulit memahami alasan di balik hasil prediksi yang diberikan. Dalam konteks sistem informasi pertanian, kondisi ini dapat menurunkan tingkat kepercayaan pengguna, khususnya petani yang tidak memiliki latar belakang teknis di bidang kecerdasan buatan. Oleh karena itu, integrasi Explainable AI (XAI) menjadi arah pengembangan yang penting pada penelitian selanjutnya. Pendekatan seperti Grad-CAM, saliency map, dan attention visualization memungkinkan sistem untuk menampilkan area daun yang dianggap penting dalam proses prediksi. Dengan demikian, sistem tidak hanya memberikan hasil klasifikasi penyakit, tetapi juga memberikan penjelasan visual yang dapat membantu pengguna memahami dasar pengambilan keputusan model.

Integrasi XAI dalam sistem informasi pertanian juga berpotensi meningkatkan transparansi, usability, dan kepercayaan pengguna terhadap teknologi berbasis AI. Selain itu, pendekatan ini dapat membantu proses validasi hasil prediksi oleh pakar pertanian, sehingga sistem dapat digunakan sebagai alat bantu pengambilan keputusan yang lebih terpercaya.

Dengan mempertimbangkan berbagai faktor tersebut, dapat disimpulkan bahwa keberhasilan implementasi *deep learning* dalam deteksi penyakit tanaman tidak hanya bergantung pada performa model, tetapi juga pada aspek teknis, infrastruktur, dan kebutuhan pengguna di lapangan.

3.10 Analisis Infrastruktur dan Deployment Sistem

Implementasi model deep learning untuk identifikasi penyakit daun padi tidak hanya bergantung pada performa akurasi, tetapi juga pada kesiapan infrastruktur sistem informasi yang mendukung proses deployment model di lingkungan nyata. Berdasarkan studi yang dianalisis, model dengan kompleksitas tinggi seperti Vision Transformer (ViT), Faster R-CNN, dan hybrid CNN-ViT membutuhkan sumber daya komputasi yang besar, terutama pada tahap pelatihan (training).

Secara umum, proses training model deep learning memerlukan perangkat dengan GPU dedicated seperti NVIDIA RTX Series atau Tesla GPU, RAM minimal 16–32 GB, serta kapasitas penyimpanan yang cukup besar untuk menangani dataset citra beresolusi tinggi. Sebaliknya, pada tahap deployment, kebutuhan komputasi dapat dioptimalkan menggunakan model

lightweight seperti MobileNetV2 atau teknik model compression sehingga sistem dapat dijalankan pada perangkat dengan spesifikasi lebih rendah.

Dalam konteks sistem informasi pertanian, terdapat beberapa pendekatan arsitektur deployment yang dapat digunakan:

- a. *Cloud-based architecture*, di mana proses inferensi dilakukan pada server cloud sehingga perangkat pengguna hanya berfungsi sebagai antarmuka input-output.
- b. *Edge computing architecture*, di mana model dijalankan langsung pada perangkat mobile atau edge device untuk mengurangi ketergantungan terhadap koneksi internet.
- c. *Hybrid architecture*, yang mengombinasikan pemrosesan lokal dan cloud untuk meningkatkan efisiensi sistem.

Bagi petani di daerah dengan keterbatasan infrastruktur internet, pendekatan edge computing menjadi solusi yang lebih realistis. Namun demikian, keterbatasan kapasitas memori, daya komputasi, dan konsumsi energi perangkat mobile masih menjadi tantangan utama.

Oleh karena itu, penelitian selanjutnya perlu mempertimbangkan aspek deployment sejak tahap perancangan model, termasuk optimasi ukuran model, latency inference, efisiensi energi, serta integrasi dengan sistem informasi pertanian berbasis mobile atau Internet of Things (IoT).

3.11 Diskusi Kritis dan Arah Penelitian Masa Depan

Berdasarkan analisis yang telah dilakukan, dapat disimpulkan bahwa penelitian di bidang ini masih memiliki peluang besar untuk dikembangkan. Beberapa arah penelitian yang dapat dilakukan di masa depan antara lain:

- a) Pengembangan dataset yang lebih besar dan representatif
- b) Peningkatan kemampuan generalisasi model
- c) Pengembangan model lightweight untuk implementasi mobile
- d) Integrasi *Explainable AI* untuk meningkatkan interpretabilitas
- e) Pengujian model dalam kondisi dunia nyata secara lebih luas

Selain itu, integrasi antara teknologi *deep learning* dengan sistem berbasis Internet of Things (IoT) juga menjadi peluang untuk menciptakan sistem deteksi penyakit tanaman yang lebih cerdas dan terintegrasi.

4. Kesimpulan

Penelitian ini menyajikan tinjauan literatur sistematis terhadap penerapan deep learning berbasis citra dalam identifikasi penyakit daun padi dengan menganalisis sepuluh studi utama pada periode 5 tahun terakhir. Hasil

kajian menunjukkan bahwa Convolutional Neural Network (CNN) masih menjadi pendekatan yang paling dominan digunakan, terutama melalui arsitektur seperti ResNet, VGG, dan MobileNet yang mampu menghasilkan akurasi tinggi. Selain itu, perkembangan terbaru mengarah pada penggunaan metode yang lebih adaptif seperti YOLOv8, hybrid CNN–Vision Transformer (ViT), serta attention mechanism untuk meningkatkan representasi fitur dan kemampuan deteksi penyakit.

Sebagian besar penelitian melaporkan tingkat akurasi di atas 90%, namun performa model sangat dipengaruhi oleh karakteristik dataset yang digunakan. Model yang diuji pada dataset terkontrol cenderung menghasilkan performa lebih baik dibandingkan dataset lapangan yang memiliki variasi pencahayaan, latar belakang, dan kondisi daun yang lebih kompleks. Temuan ini menunjukkan bahwa kemampuan generalisasi model masih menjadi tantangan utama dalam implementasi sistem deteksi penyakit tanaman di dunia nyata.

Selain aspek performa, penelitian ini juga menunjukkan adanya trade-off antara akurasi, kompleksitas komputasi, dan efisiensi deployment model. Model dengan performa tinggi umumnya membutuhkan sumber daya komputasi yang besar, sedangkan model lightweight seperti MobileNetV2 lebih efisien untuk implementasi pada perangkat mobile atau edge computing. Di sisi lain, sebagian besar penelitian masih berfokus pada tahap eksperimental dan belum banyak mengintegrasikan aspek interpretabilitas model, sehingga penerapan Explainable AI (XAI) menjadi penting untuk meningkatkan transparansi dan kepercayaan pengguna terhadap sistem berbasis deep learning.

Sebagai kontribusi, penelitian ini tidak hanya memetakan perkembangan metode deep learning dalam identifikasi penyakit daun padi, tetapi juga menganalisis keterkaitan antara performa model, kompleksitas komputasi, serta tantangan implementasi sistem informasi pertanian di dunia nyata. Penelitian selanjutnya disarankan untuk mengembangkan dataset yang lebih representatif, meningkatkan kemampuan generalisasi model, merancang model lightweight yang efisien untuk deployment mobile, serta mengintegrasikan Explainable AI guna mendukung pengembangan sistem deteksi penyakit tanaman yang lebih robust, transparan, dan aplikatif.

Referensi

- [1] S. Akter, R. I. Sumon, H. Ali, and H. C. Kim, "Utilizing convolutional neural networks for the effective classification of rice leaf diseases through a deep learning approach," *Electronics*, vol. 13, no. 20, p. 4095, 2024. <https://doi.org/10.3390/electronics13204095>
- [2] C. Dewi, F. Y. Bilaut, H. J. Christanto, and G. Dai, "Deep learning for the classification of rice leaf diseases using YOLOv8," 2024. <https://doi.org/10.18280/mmep.111115>

- [3] T. P. Pavithra and B. Baranidharan, "A hybrid ViT–CNN model premeditated for rice leaf disease identification," *Int. J. Comput. Model. Electr. Netw.*, vol. 12, no. 1, 2024. <https://doi.org/10.18280/ijcmem.120104>
- [4] X. Bi and H. Wang, "Double-branch deep convolutional neural network-based rice leaf diseases recognition and classification," *Journal of Agricultural Engineering*, vol. 55, no. 1, 2024. <https://doi.org/10.4081/jae.2023.1544>
- [5] M. T. Ahad, Y. Li, B. Song, and T. Bhuiyan, "Comparison of CNN-based deep learning architectures for rice diseases classification," *Artificial Intelligence in Agriculture*, vol. 9, pp. 22–35, 2023. <https://doi.org/10.1016/j.aiaa.2023.07.00>
- [6] J. Arcila-Diaz, D. Altamirano-Chavez, L. Arcila-Diaz, and C. Valdivia, "Real-time identification of rice leaf diseases using convolutional neural networks," *International Journal of Computing*, vol. 23, no. 4, pp. 709–714, 2024. <https://doi.org/10.47839/ijc.23.4.3773>
- [7] R. Gahane, "Rice Leaf Disease Detection and Remedies using Deep Learning", *Int J Intell Syst Appl Eng*, vol. 12, no. 4, pp. 3380–, Jun. 2024.
- [8] R. Tiwari and N. Vora, "Enhancing paddy leaf disease classification using CNN and MobileNetV2," *Journal of Soft Computing Paradigm*, vol. 6, no. 3, pp. 324–340, 2024. <https://doi.org/10.36548/jscp.2024.3.008>
- [9] B. S. Bari *et al.*, "A real-time approach of diagnosing rice leaf disease using deep learning-based faster R-CNN framework," *PeerJ Computer Science*, vol. 7, p. e432, 2021. <https://doi.org/10.7717/peerj-cs.432>
- [10] M. Dutta *et al.*, "Rice leaf disease classification—A comparative approach using convolutional neural network (CNN), cascading autoencoder with attention residual U-net (CAAR-U-Net), and MobileNet-V2 architectures," *Technologies*, vol. 12, no. 11, p. 214, 2024. <https://doi.org/10.3390/technologies12110214>
- [11] D. Moher, A. Liberati, J. Tetzlaff, D. G. Altman, and PRISMA Group, "Preferred reporting items for systematic reviews and meta-analyses: The PRISMA statement," *International Journal of Surgery*, vol. 8, no. 5, pp. 336–341, 2010. <https://doi.org/10.1016/j.ijssu.2010.02.007>
- [12] B. Kitchenham and S. Charters, *Guidelines for performing systematic literature reviews in software engineering*, EBSE Technical Report, ver. 2.3, 2007.
- [13] H. Snyder, "Literature review as a research methodology: An overview and guidelines," *Journal of Business Research*, vol. 104, pp. 333–339, 2019. <https://doi.org/10.1016/j.jbusres.2019.07.039>
- [14] M. Sharma, C. J. Kumar, and D. K. Bhattacharyya, "Machine/deep learning techniques for disease and nutrient deficiency disorder diagnosis in rice crops: A systematic review," *Biosystems Engineering*, vol. 244, pp. 77–92, 2024. <https://doi.org/10.1016/j.biosystemseng.2024.05.014>