



Analisis Perbandingan Arsitektur *Deep Learning* Pada Klasifikasi Penyakit Tanaman Berbasis Citra Daun: *Systematic Literature Review*

Ananda Krisna Kurnia Ramadhan^{1*}, Yulia Fatma²

^{1,2}Program Studi Teknik Informatika, Universitas Muhammadiyah Riau, Indonesia

Email: 220401038@student.umri.ac.id¹ yuliafatma@umri.ac.id²

*Penulis Korespondensi: 220401038@student.umri.ac.id

Abstract. *Plant disease classification based on leaf images has become an important approach to supporting precision agriculture and early plant disease detection systems. This study aims to examine the development of Deep Learning methods for plant disease classification through a Systematic Literature Review (SLR) approach. The review analyzed 15 scientific articles covering various crops, including rice, maize, tomato, tea, cassava, citrus, tobacco, and coffee. The literature selection process followed the PRISMA framework. The analysis focused on comparing Deep Learning architectures, dataset characteristics, and model performance based on accuracy metrics. The findings indicate that conventional Convolutional Neural Networks (CNNs), modern architectures such as ResNet, Inception, EfficientNet, and DenseNet, as well as lightweight models such as MobileNetV2, are the most widely adopted methods. Model performance is influenced by dataset size and source, with large-scale public datasets generally achieving higher and more consistent accuracy. This study highlights that selecting an appropriate Deep Learning architecture requires balancing model complexity, data availability, computational efficiency, and practical deployment requirements to develop effective and reliable plant disease classification systems.*

Keywords: *Deep Learning, CNN, Transfer Learning, Plant Disease Classification, Leaf Image.*

Abstark. Klasifikasi penyakit tanaman berbasis citra daun merupakan pendekatan penting dalam mendukung pertanian presisi dan sistem deteksi dini penyakit tanaman. Penelitian ini bertujuan mengkaji perkembangan penerapan metode *Deep Learning* untuk klasifikasi penyakit tanaman melalui pendekatan *Systematic Literature Review* (SLR). Kajian dilakukan terhadap 15 artikel ilmiah yang membahas berbagai komoditas, seperti padi, jagung, tomat, teh, singkong, jeruk, tembakau, dan kopi. Proses seleksi literatur menggunakan pendekatan PRISMA. Analisis difokuskan pada perbandingan arsitektur *Deep Learning*, karakteristik dataset, serta performa model berdasarkan metrik akurasi. Hasil kajian menunjukkan bahwa *Convolutional Neural Network* (CNN) konvensional, arsitektur modern seperti ResNet, Inception, EfficientNet, dan DenseNet, serta model *lightweight* seperti MobileNetV2 merupakan metode yang paling banyak digunakan. Performa model dipengaruhi oleh ukuran dan sumber dataset, di mana dataset publik berskala besar cenderung menghasilkan akurasi yang lebih tinggi dan lebih stabil. Studi ini menegaskan bahwa pemilihan arsitektur *Deep Learning* perlu mempertimbangkan keseimbangan antara kompleksitas model, ketersediaan data, efisiensi komputasi, dan kebutuhan implementasi di lapangan agar menghasilkan sistem klasifikasi yang efektif dan andal.

Kata kunci: Citra Daun; CNN; Klasifikasi Penyakit Tanaman; Pembelajaran Mendalam; Pembelajaran Transfer.

1. LATAR BELAKANG

Perkembangan teknologi kecerdasan buatan (*Artificial Intelligence/AI*) dalam beberapa tahun terakhir semakin pesat dan memberikan dampak signifikan di berbagai bidang, termasuk sektor pertanian. Implementasi AI, khususnya dalam pengolahan citra berbasis *Deep Learning* (DL), telah memungkinkan sistem otomatis untuk mendeteksi dan mengklasifikasikan objek visual dengan tingkat akurasi yang tinggi. Salah satu aplikasi penting dari teknologi tersebut adalah identifikasi penyakit tanaman melalui citra daun, yang menjadi perhatian utama karena penyakit tanaman merupakan penyebab signifikan penurunan produktivitas serta kualitas hasil pertanian.

Metode tradisional dalam identifikasi penyakit tanaman masih bergantung pada inspeksi manual oleh tenaga ahli melalui pengamatan visual. Pendekatan tersebut memiliki sejumlah keterbatasan, antara lain subjektivitas penilaian, ketersediaan tenaga pakar yang terbatas, serta potensi kesalahan diagnosis yang cukup tinggi. Kondisi ini mendorong perlunya sistem otomatis berbasis citra digital yang mampu memberikan analisis cepat, konsisten, dan akurat. Teknologi *Deep Learning* telah terbukti efektif dalam mengatasi keterbatasan tersebut melalui kemampuan ekstraksi fitur secara otomatis tanpa memerlukan rekayasa fitur secara manual, sehingga mampu meningkatkan akurasi klasifikasi (Anggiratih et al., 2021).

Sejumlah penelitian telah mengeksplorasi metode *Deep Learning* untuk klasifikasi penyakit tanaman berbasis citra daun. Salah satu penelitian menunjukkan bahwa arsitektur EfficientNet-B3 dengan transfer *learning* berhasil digunakan untuk identifikasi penyakit daun padi (Anggiratih et al., 2021). Penelitian lain menerapkan *Convolutional Neural Network* (CNN) dalam mendeteksi penyakit daun jagung dan menunjukkan performa akurasi yang tinggi (Fadhilla et al., 2023). Selain itu, penggunaan arsitektur ResNet-50 dan Inception-V3 juga terbukti efektif dalam mengidentifikasi penyakit daun pada tanaman teh (Trihardianingsih et al., 2023). Lebih lanjut, varian EfficientNet-B6 telah dimanfaatkan untuk meningkatkan kemampuan generalisasi model menggunakan dataset citra daun padi yang lebih beragam (Milano et al., 2024). Variasi kinerja pada penelitian tersebut menunjukkan bahwa pemilihan arsitektur model, konfigurasi *training*, dan karakteristik dataset sangat berpengaruh terhadap tingkat akurasi yang dihasilkan.

Namun demikian, penelitian terkait klasifikasi penyakit tanaman berbasis *Deep Learning* masih menghadapi sejumlah tantangan utama, seperti keterbatasan dataset yang representatif, variasi pencahayaan dan kondisi lingkungan pada citra daun, serta kebutuhan pengembangan model yang lebih ringan dan efisien untuk dapat diimplementasikan langsung pada perangkat lapangan seperti *smartphone* atau *drone*. Selain itu, sebagian besar penelitian terdahulu bersifat parsial dan berfokus pada komoditas atau arsitektur tunggal, sehingga belum memberikan gambaran komprehensif mengenai perbandingan efektivitas antar metode *Deep Learning*. Dengan demikian, masih terdapat kebutuhan penelitian berbasis *Systematic Literature Review* (SLR) yang terstruktur untuk meninjau perkembangan riset, membandingkan performa berbagai arsitektur, mengidentifikasi tren penelitian, serta memetakan tantangan riset yang masih terbuka (Oktaviyan et al., 2024).

Berdasarkan latar belakang tersebut, tinjauan literatur ini disusun untuk memberikan pemahaman menyeluruh mengenai penggunaan metode *Deep Learning* dalam klasifikasi penyakit tanaman melalui citra daun. Tinjauan ini berfokus pada analisis perbandingan kinerja

model *Deep Learning*, karakteristik dataset yang digunakan, tren pengembangan arsitektur model, serta tantangan dan arah penelitian selanjutnya dalam pengembangan sistem deteksi penyakit tanaman berbasis citra digital. Hasil dari SLR ini diharapkan dapat menjadi landasan ilmiah dalam pengembangan solusi deteksi penyakit tanaman yang lebih akurat, efisien, dan aplikatif di lapangan.

2. KAJIAN TEORITIS

Deep Learning merupakan cabang dari *machine learning* yang menggunakan jaringan saraf tiruan berlapis untuk mempelajari representasi data secara otomatis. Pada bidang pengolahan citra, *Deep Learning* mampu melakukan ekstraksi fitur tanpa memerlukan perancangan fitur secara manual sehingga banyak digunakan dalam berbagai tugas klasifikasi citra, termasuk identifikasi penyakit tanaman berbasis citra daun. Kemampuan tersebut menjadikan *Deep Learning* sebagai salah satu pendekatan yang paling banyak digunakan dalam sistem pertanian cerdas modern.

Salah satu arsitektur *Deep Learning* yang paling umum digunakan adalah *Convolutional Neural Network* (CNN). CNN dirancang untuk mengolah data berbentuk citra melalui proses konvolusi, *pooling*, dan *fully connected* layer sehingga mampu mengenali pola visual secara efektif. Seiring perkembangannya, berbagai arsitektur turunan CNN telah dikembangkan untuk meningkatkan performa klasifikasi, seperti ResNet yang menggunakan *residual connection*, EfficientNet yang menerapkan *compound scaling*, DenseNet yang memanfaatkan *dense connection*, serta MobileNetV2 yang dirancang untuk perangkat dengan keterbatasan sumber daya komputasi.

Selain pengembangan arsitektur, teknik transfer *learning* juga banyak digunakan dalam klasifikasi penyakit tanaman. Transfer *learning* memungkinkan model memanfaatkan bobot hasil pelatihan pada dataset besar sehingga dapat meningkatkan performa klasifikasi ketika jumlah data pelatihan terbatas. Pendekatan ini terbukti mampu mempercepat proses pelatihan sekaligus meningkatkan kemampuan generalisasi model pada berbagai jenis tanaman dan penyakit.

Beberapa penelitian terdahulu menunjukkan bahwa berbagai arsitektur *Deep Learning* telah berhasil diterapkan untuk klasifikasi penyakit tanaman berbasis citra daun dengan tingkat akurasi yang beragam. Perbedaan performa tersebut dipengaruhi oleh berbagai faktor, seperti arsitektur model, ukuran dan kualitas dataset, teknik argumentasi data, serta metode pelatihan yang digunakan. Oleh karena itu, diperlukan kajian literatur yang sistematis untuk

membandingkan efektivitas berbagai arsitektur *Deep Learning* dalam klasifikasi penyakit tanaman berbasis citra daun.

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan *Systematic Literature Review* (SLR) untuk meninjau dan menganalisis penerapan metode *Deep Learning* dalam klasifikasi penyakit tanaman berbasis citra daun. Prosedur SLR pada studi ini mengikuti pedoman PRISMA 2020 (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) agar proses peninjauan literatur dilakukan secara transparan, sistematis, dan dapat di replikasi. Tahapan PRISMA meliputi identifikasi, penyaringan, penilaian kelayakan, dan pemilihan artikel akhir.

Pencarian literatur dilakukan melalui beberapa basis data ilmiah, yaitu Google Scholar, SINTA, Garuda, IEEE Xplore, dan ResearchGate, dengan rentang publikasi tahun 2020–2025. ResearchGate digunakan sebagai sumber pelengkap, khususnya untuk memperoleh artikel atau naskah yang tidak tersedia *full-text* pada basis data utama. Proses pencarian dilakukan menggunakan kata kunci: “*Plant Disease Classification*”, “*Deep Learning*”, “*Leaf Image*”, “*CNN*”, “*EfficientNet*”, “*Transfer Learning*”, dan “*Deep Learning Architecture*”. Tahap pencarian awal menemukan 315 artikel dari seluruh database. Setelah proses penyaringan judul, abstrak, dan duplikasi, tersisa 117 artikel, dan setelah peninjauan menyeluruh terhadap metode dan hasil penelitian, 30 artikel dipilih sebagai sumber analisis utama. Untuk memastikan kualitas studi yang digunakan, seleksi artikel dilakukan berdasarkan kriteria inklusi dan eksklusi berikut:

Tabel 1. Kriteria Inklusi dan Ensklusi.

Kategori	Kriteria
Inklusi (IC)	1) Artikel membahas klasifikasi penyakit tanaman berbasis citra daun menggunakan metode <i>Deep Learning</i>
	2) Publikasi tahun 2020–2025
	3) Bahasa Indonesia atau Inggris
	4) Memuat hasil evaluasi model (mis. akurasi, <i>precision</i> , <i>recall</i> , <i>F1-score</i>)
	5) Artikel berupa jurnal ilmiah atau prosiding.
Eksklusi (EC)	1) Tidak menyertakan hasil eksperimen atau metrik performa.
	2) Fokus pada metode selain citra daun
	3) Artikel <i>review non-sistematis</i> .
	4) Duplikasi publikasi atau versi revisi.

Selain itu, penelitian ini mendokumentasikan proses seleksi artikel berdasarkan basis data asal dan jumlah artikel yang tersaring pada setiap tahapan. Ringkasan tahapan seleksi ditunjukkan pada tabel berikut:

Tabel 2. Hasil Seleksi Literatur

Basis Data	Ditemukan	Setelah Screening Judul & Abstrak	Artikel Terpilih
Google Scholar	45	20	8
SINTA	22	12	4
Garuda	15	8	2
IEEE Xplore	12	5	1
ResearchGate	8	4	0
Total	102	49	15

Proses manajemen referensi dan penyaringan artikel dilakukan menggunakan perangkat lunak Mendeley untuk menghindari duplikasi publikasi serta mendukung pengelompokan dokumen berdasarkan tema dan relevansi penelitian.

Penelitian ini disusun untuk menjawab pertanyaan utama penelitian, yaitu: 1) metode *Deep Learning* apa yang digunakan dalam klasifikasi penyakit tanaman berbasis citra daun, 2) dataset apa yang digunakan dan bagaimana karakteristiknya, 3) bagaimana perbandingan performa antar model *Deep Learning*, 4) tren dan arah perkembangan penelitian terbaru dan, 5) tantangan riset serta peluang untuk penelitian lanjutan.

Pada tahap ekstraksi data, setiap artikel dianalisis menggunakan lembar ekstraksi data yang mencakup parameter: judul publikasi, tahun penerbitan, jenis tanaman dan penyakit, arsitektur *Deep Learning*, ukuran dan sumber dataset, teknik argumentasi, metrik evaluasi (*accuracy*, *precision*, *recall*, *F1-score*), serta hasil performa model terbaik. Analisis data dilakukan menggunakan pendekatan *comparative analysis* untuk membandingkan performa antar model dan *thematic synthesis* untuk mengidentifikasi pola, tren, dan gap penelitian yang relevan. Hasil analisis digunakan sebagai dasar dalam penyusunan kesimpulan ilmiah terkait efektivitas metode *Deep Learning* pada klasifikasi penyakit tanaman.

4. HASIL DAN PEMBAHASAN

Berdasarkan proses seleksi literatur menggunakan pendekatan PRISMA, diperoleh 15 artikel penelitian yang dianalisis secara mendalam pada studi ini. Seluruh artikel membahas penerapan metode *Deep Learning* untuk klasifikasi penyakit tanaman berbasis citra daun, dengan komoditas yang beragam, meliputi padi, jagung, teh, singkong, tomat, jeruk, tembakau, dan kopi.

Dari sisi jenis tanaman, padi dan jagung merupakan komoditas yang paling banyak diteliti, masing-masing muncul pada empat dan tiga penelitian (Anggiratih et al., 2021; Milano et al., 2024; Guan et al., 2023). Hal ini menunjukkan tingginya perhatian peneliti terhadap tanaman pangan utama. Selain itu, beberapa penelitian juga mengkaji klasifikasi penyakit pada tanaman hortikultura seperti tomat, jeruk, dan tanaman perkebunan seperti kopi.

Berdasarkan analisis terhadap studi yang terpilih, metode *Deep Learning* (DL) yang digunakan dalam klasifikasi penyakit tanaman dapat dikelompokkan menjadi tiga kategori utama, yaitu CNN konvensional, arsitektur DL modern (ResNet, EfficientNet, Inception, DenseNet), serta model *lightweight* seperti MobileNetV2. Pengelompokan ini menunjukkan adanya variasi pendekatan dalam pengembangan model klasifikasi penyakit tanaman berbasis citra daun. Dataset yang digunakan dalam penelitian terdahulu menunjukkan variasi yang signifikan baik dari segi sumber maupun ukuran dataset. Beberapa penelitian menggunakan dataset lokal yang dikumpulkan langsung dari kondisi lapangan, sementara penelitian lainnya memanfaatkan dataset publik berskala besar seperti *PlantVillage* dan *CassavaLeaf*.

Tabel 3 Perbandingan Performa Metode *Deep Learning* dalam Klasifikasi Penyakit Tanaman.

No	Judul Penelitian	Metode	Dataset	Jumlah Data	Akurasi	Tanaman
1	Klasifikasi Penyakit Tanaman Padi Menggunakan Model <i>Deep Learning Efficientnet</i> B3 dengan Transfer Learning(Anggiratih et al., 2021)	EfficientNet-B3	Citra daun padi	2.156	79,53 %	Padi
2	<i>Corn Leaf Diseases Recognition Based on Convolutional Neural Network</i> (Fadhilla et al., 2023)	CNN	Data tidak terbuka	1000	93%	Jagung
3	<i>Classification of Tea Leaf Diseases Based on ResNet-50 and Inception V3</i> (Trihardianingsih et al., 2023)	Inception-V3	Tea leaf dataset	5.867	97.62 %	Teh
4	Klasifikasi Penyakit Daun Padi Menggunakan Model <i>Deep Learning Efficientnet</i> -B6(Milano et al., 2024)	EfficientNet-B6	Citra daun padi	3.355	77,05 %	Padi
5	<i>A lightweight model for efficient identification of plant diseases and pests based on deep learning</i>	Lightweight CNN	PlantVillage	54.000	99.71	Multitanaman
6	Klasifikasi Citra Penyakit Daun Padi Dengan Metode CNN Menggunakan Arsitektur ResNet50V2(Muhamad Filla Akbar Maulana, Nanda Martyan Anggadimas, 2025)	ResNet50V2	Data lokal	15.241	94.14 %	Padi
7	Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network(Putra & Alamsyah, 2022)	ResNet-50 (Adam)	Corn Leaf Infection	4.225	98.40 %	Jagung
8	Optimisasi VGG16 dengan Transfer Learning dalam Mendeteksi Penyakit Pada Daun Jagung	VGG16-TL	Corn or Maize Leaf Disease	1.200	96.25 %	Jagung
9	Deteksi Penyakit Blas, Tungro & Bercak Coklat Pada Tanaman Padi Menggunakan Metode <i>Convolutional Neural Network</i> (Hia et al., 2025)	CNN	Rice Leaf	120	100%	Padi
10	Analisis Penggunaan Pra proses pada Metode Transfer Learning untuk Mendeteksi Penyakit Daun Singkong(Amelia Devi Putri Ariyanto,	MobileNet V2	CassavaLeaf	21.267	92.50 %	Singkong

Salsabiil Hasanah, M. Bahrul Subkhi,
2023)

11	Klasifikasi Penyakit Daun Tomat Menggunakan Algoritma CNN Mobilenet V2(Aryaputra et al., n.d.)	MobileNet V2	Tomato leaf	6000	88%	Tomat
12	Klasifikasi penyakit pada buah jeruk berdasarkan citra dengan pendekatan transfer <i>learning</i> menggunakan arsitektur densenet-121(Sheli Agustina, Asep Toyib Hidayat, Satrianansyah, 2025)	DenseNet-121	CitrusLeaf	594	99%	Jeruk
13	Identifikasi Penyakit Daun Tembakau Berbasis Pengolahan Citra dengan Metode <i>Convolutional Neural Network</i> (CNN) Dan Metode Transfer <i>Learning</i> (Umam, 2024)	CNN	Data Lokal	261	69%	Tembakau
14	Klasifikasi Penyakit Tanaman Tomat Berdasarkan Citra Daun Menggunakan CNN(Soekarta et al., 2023)	CNN	TomatoLeaf	11.619	98%	Tomat
15	Implementasi MobileNetV2 Untuk Pengenalan Presisi Penyakit Daun Kopi Berbasis Citra(Anggraini, 2025)	MobileNet V2	Data lokal	501	64%	Kopi

Berdasarkan Tabel 3, terlihat bahwa performa model *Deep Learning* menunjukkan variasi yang cukup signifikan antar penelitian. Nilai akurasi yang dilaporkan berkisar antara 64% hingga 99,71%, bergantung pada jenis arsitektur dan karakteristik dataset yang digunakan. Beberapa penelitian melaporkan akurasi yang sangat tinggi, terutama pada dataset publik berskala besar, sementara penelitian dengan dataset lokal berukuran kecil cenderung menunjukkan performa yang lebih fluktuatif.

Perbandingan Performa Berdasarkan Arsitektur

Berdasarkan Tabel 3, metode *Deep Learning* yang digunakan dalam penelitian terdahulu dapat dikelompokkan ke dalam tiga kategori utama, yaitu CNN konvensional, arsitektur *Deep Learning* modern, dan model *lightweight*.

Tabel 4. Hasil Perbandingan Performa Metode *Deep Learning* dalam Klasifikasi Penyakit Tanaman.

No	Metode	Jumlah Penelitian	Rentang Akurasi (%)
1	CNN dasar	4	69% – 100%
2	EfficientNet (B3–B6)	3	77,05% – 99,71%
3	ResNet (50 / 50V2)	2	94,14% – 98,40%
4	Inception (V3)	1	97,62%
5	VGG (VGG16-TL)	1	96,25%
6	MobileNet (V2)	3	64% – 92,50%
7	DenseNet (121)	1	99%

Berdasarkan Tabel 4, CNN konvensional masih menjadi pendekatan yang paling sering digunakan dengan empat penelitian dan rentang akurasi 69%–100% (Fadhilla et al., 2023; Hia et al., 2025; Umam, 2024; Soekarta et al., 2023). Namun demikian, performa CNN

menunjukkan variabilitas yang tinggi. Akurasi yang sangat tinggi pada beberapa studi, seperti mencapai 100%, diperoleh dari dataset berukuran sangat kecil dan homogen, sehingga berpotensi mengalami *overfitting* dan kurang mencerminkan kemampuan generalisasi model pada kondisi nyata. Sebaliknya, pada dataset yang lebih kompleks, performa CNN cenderung menurun secara signifikan.

Arsitektur EfficientNet (B3–B6) digunakan pada tiga penelitian dengan rentang akurasi 77,05%–99,71% Anggiratih et al. (2021), Milano et al. (2024) variasi performa ini menunjukkan bahwa EfficientNet sangat bergantung pada ukuran dataset. Model ini cenderung memberikan hasil optimal ketika dilatih pada dataset berskala besar, namun kurang maksimal pada dataset menengah dengan variasi terbatas.


ResNet (50 dan 50V2) menunjukkan performa yang relatif stabil dengan rentang akurasi 94,14%–98,40% Maulana & Anggadimas, (2025), Putra & Alamsyah, (2022), terutama pada dataset berukuran menengah hingga besar. Stabilitas ini didukung oleh penggunaan *residual connection* yang memungkinkan pelatihan jaringan yang lebih dalam tanpa mengalami degradasi performa.

Selain itu, arsitektur Inception V3 Trihardianingsih et al. (2023) dan VGG16 dengan transfer *learning* Trihardianingsih et al. (2023) juga menghasilkan performa tinggi di atas 96%, meskipun masing-masing hanya diuji pada satu penelitian. Hal ini menunjukkan bahwa arsitektur *pretrained* memiliki potensi besar dalam meningkatkan performa klasifikasi, terutama ketika dikombinasikan dengan teknik transfer *learning*.

Sementara itu, MobileNetV2 sebagai arsitektur lightweight memiliki rentang akurasi 64%–92,50% (Ariyanto et al., 2023; Aryaputra et al., n.d.; Anggraini, 2025). Rentang ini menunjukkan adanya *trade-off* antara efisiensi komputasi dan performa. Meskipun tidak selalu menghasilkan akurasi tertinggi, MobileNetV2 tetap menjadi pilihan yang relevan untuk implementasi pada perangkat dengan keterbatasan sumber daya.

Tren Penggunaan Arsitektur Deep Learning

Tren penggunaan arsitektur *Deep Learning* (DL) pada penelitian klasifikasi penyakit tanaman berbasis citra daun dianalisis berdasarkan frekuensi kemunculan metode pada 15 studi yang terpilih dalam *Systematic Literature Review* ini. Distribusi penggunaan arsitektur ditunjukkan pada Gambar 1.



Gambar 1. Grafik Tren Pada Metode *Deep Learning*.

Berdasarkan hasil analisis, CNN konvensional merupakan arsitektur yang paling sering digunakan dengan proporsi sekitar 27% dari total penelitian (4 dari 15 studi). Dominasi ini menunjukkan bahwa CNN masih banyak digunakan sebagai pendekatan dasar karena kesederhanaan arsitektur dan kemudahan implementasinya. Namun demikian, jika ditinjau dari hasil performa pada Tabel 3 dan Tabel 5, CNN tidak selalu memberikan hasil yang stabil. Pada beberapa penelitian dengan dataset berukuran kecil, CNN menunjukkan akurasi yang sangat tinggi namun berpotensi mengalami *overfitting*, sedangkan pada dataset dengan variasi lebih tinggi, performanya cenderung menurun secara signifikan. Hal ini mengindikasikan bahwa CNN lebih sensitif terhadap ukuran dan kompleksitas dataset.

Selain CNN, arsitektur EfficientNet dan MobileNetV2 masing-masing memiliki proporsi sekitar 20% (3 dari 15 studi). EfficientNet umumnya digunakan untuk meningkatkan performa model melalui optimasi skala jaringan (*compound scaling*), namun berdasarkan hasil analisis, performanya masih sangat bergantung pada ketersediaan dataset yang memadai. Pada dataset menengah dengan jumlah terbatas, performa EfficientNet belum optimal. Sementara itu, MobileNetV2 sebagai arsitektur *lightweight* menunjukkan kecenderungan penggunaan pada penelitian yang berorientasi pada efisiensi komputasi. Meskipun memiliki jumlah parameter yang lebih kecil, MobileNetV2 tetap mampu memberikan performa yang cukup kompetitif, terutama pada dataset berskala besar.

Arsitektur ResNet memiliki proporsi sekitar 13% (2 dari 15 studi) dan menunjukkan performa yang relatif lebih stabil dibanding CNN konvensional. Hal ini disebabkan oleh penggunaan *residual connection* yang memungkinkan pelatihan jaringan yang lebih dalam tanpa mengalami degradasi performa. ResNet terbukti mampu bekerja dengan baik pada dataset berukuran menengah hingga besar.

Sementara itu, arsitektur lain seperti Inception-V3 Trihardianingsih et al. (2023), VGG16 dengan transfer *learning* Trihardianingsih et al. (2023), dan DenseNet-121 masing-masing memiliki proporsi sekitar 7%. Meskipun frekuensi penggunaannya relatif rendah, arsitektur tersebut umumnya menunjukkan performa yang tinggi dengan akurasi di atas 96%. Namun, hasil ini perlu ditafsirkan secara hati-hati karena biasanya didukung oleh dataset yang lebih terstruktur atau proses pelatihan yang optimal.

Secara keseluruhan, tren penggunaan arsitektur *Deep Learning* menunjukkan bahwa meskipun CNN masih menjadi metode yang paling dominan dari segi frekuensi penggunaan, penelitian terbaru mulai beralih ke arsitektur yang lebih modern dan efisien. Selain itu, terlihat adanya keseimbangan antara tiga pendekatan utama, yaitu penggunaan CNN sebagai baseline model, pemanfaatan arsitektur modern untuk meningkatkan performa, serta penggunaan model *lightweight* untuk mendukung efisiensi komputasi dan implementasi di perangkat lapangan. Temuan ini menunjukkan bahwa arah penelitian tidak hanya berfokus pada peningkatan akurasi, tetapi juga mempertimbangkan stabilitas model dan kesiapan implementasi di lingkungan nyata.

Karakteristik Dataset dan Pengaruhnya terhadap Performa

Tabel 5 Karakteristik Dataset dan Pengaruhnya terhadap Akurasi Klasifikasi.

No	Referensi	Arsitektur	Ukuran Dataset	Sumber Dataset	Kompleksitas Data	Akurasi (%)	Catatan Analitis
1	(Hia et al., 2025)	CNN	Kecil (120)	Lokal	Rendah (homogen)	100	Potensi <i>overfitting</i> tinggi
2	(Umam, 2024)	CNN + TL	Kecil (261)	Lokal	Sedang	69	Data terbatas, variasi tinggi
3	(Anggiratih et al., 2021)	EfficientNet-B3	Menengah (2.156)	Lokal	Sedang	79,53	Model kompleks, data kurang
4	(Milano et al., 2024)	EfficientNet-B6	Menengah (3.355)	Lokal	Sedang	77,05	Belum optimal tanpa data besar
5	(Putra & Alamsyah, 2022)	ResNet-50	Menengah (4.225)	Publik	Sedang–Tinggi	98,40	TL efektif pada data cukup
6	(Amelia Devi Putri Ariyanto, Salsabiil Hasanah, M. Bahrul Subkhi, 2023)	MobileNetV2	Besar (21.267)	Publik	Tinggi	92,50	Efisien, generalisasi baik
7	(Guan et al., 2023)c	<i>Lightweight</i> CNN	Sangat Besar (54.000)	Publik	Tinggi	99,71	Data besar dominan

Berdasarkan Tabel 5, sebagian besar penelitian menggunakan dataset lokal dengan ukuran kecil hingga menengah, khususnya pada tanaman padi Anggiratih et al. (2021), Milano et al. (2024), Hia et al. (2025) tembakau Umam (2024), dan kopi (Anggraini, 2025). Dataset lokal umumnya diperoleh dari kondisi lapangan nyata sehingga memiliki variasi pencahayaan, latar belakang, dan kualitas citra yang lebih kompleks. Namun, keterbatasan jumlah data menjadi kendala utama dalam proses pelatihan model.

Sebaliknya, dataset publik berskala besar seperti *PlantVillage* Guan et al. (2023) dan *CassavaLeaf* Ariyanto et al. (2023) menyediakan jumlah data yang jauh lebih besar dengan distribusi kelas yang lebih seimbang. Hal ini memungkinkan model *Deep Learning* dilatih secara lebih optimal dan menghasilkan performa yang lebih stabil.

Berdasarkan analisis, ukuran dataset terbukti memiliki pengaruh yang sangat signifikan terhadap performa model. Pada dataset berukuran kecil, model cenderung mengalami *overfitting*, yang ditunjukkan oleh akurasi tinggi namun tidak mencerminkan kemampuan generalisasi yang baik, seperti pada penelitian (Hia et al., 2025). Sebaliknya, pada dataset yang lebih besar, model menunjukkan performa yang lebih konsisten dan mampu melakukan generalisasi dengan lebih baik, seperti pada penelitian (Guan et al., 2023; Ariyanto et al. 2023).

Selain ukuran dataset, kompleksitas data juga berpengaruh terhadap performa model. Dataset dengan variasi tinggi (misalnya variasi pencahayaan, sudut pengambilan, dan kondisi daun) cenderung lebih menantang, sehingga memerlukan model yang lebih robust serta teknik pelatihan tambahan seperti argumentasi data dan transfer *learning*.

Dengan demikian, dapat disimpulkan bahwa performa model *Deep Learning* dalam klasifikasi penyakit tanaman tidak hanya ditentukan oleh arsitektur yang digunakan, tetapi sangat dipengaruhi oleh ukuran dataset, sumber data, serta kompleksitas citra. Bahkan, dalam beberapa kasus, model sederhana seperti CNN dapat menghasilkan performa tinggi pada dataset kecil, namun berisiko mengalami *overfitting* dan kurang mampu melakukan generalisasi pada data baru.

Sintesis Hasil dan Implikasi Penelitian

Berdasarkan analisis terhadap 15 studi yang ditinjau dalam penelitian ini, dapat diidentifikasi beberapa pola penelitian yang relatif konsisten dalam penerapan *Deep Learning* (DL) untuk klasifikasi penyakit tanaman berbasis citra daun.

Temuan pertama menunjukkan bahwa terdapat variasi penggunaan *arsitektur Deep Learning*, mulai dari CNN konvensional, arsitektur modern seperti EfficientNet, ResNet, Inception, dan DenseNet, hingga model *lightweight* seperti MobileNetV2. Meskipun CNN konvensional cukup sering digunakan dalam penelitian, hasil analisis menunjukkan bahwa

performanya tidak selalu konsisten. Pada beberapa kasus, CNN menghasilkan akurasi tinggi pada dataset kecil, namun berpotensi mengalami *overfitting* dan kurang optimal dalam generalisasi.

Temuan kedua menunjukkan bahwa ukuran dan sumber dataset merupakan faktor yang paling berpengaruh terhadap performa model. Penelitian yang menggunakan dataset publik berskala besar cenderung menghasilkan akurasi yang lebih tinggi dan stabil dibandingkan dataset lokal berukuran kecil. Hal ini menunjukkan bahwa ketersediaan data yang besar dan beragam menjadi kunci utama dalam meningkatkan kemampuan generalisasi model *Deep Learning*.

Temuan ketiga menunjukkan bahwa penggunaan transfer *learning* menjadi pendekatan yang semakin umum dalam penelitian klasifikasi penyakit tanaman. Arsitektur seperti ResNet, EfficientNet, MobileNetV2, dan DenseNet banyak digunakan dalam bentuk *pretrained* model untuk mengatasi keterbatasan dataset. Pendekatan ini terbukti mampu meningkatkan performa model sekaligus mengurangi waktu pelatihan.

Temuan keempat menunjukkan adanya *trade-off* antara kompleksitas model dan efisiensi komputasi. Arsitektur modern seperti ResNet dan EfficientNet cenderung memberikan performa yang lebih stabil pada dataset berukuran menengah hingga besar. Sementara itu, model *lightweight* seperti MobileNetV2 lebih banyak digunakan untuk kebutuhan implementasi pada perangkat dengan keterbatasan sumber daya, meskipun performanya cenderung lebih bervariasi.

Secara keseluruhan, hasil sintesis menunjukkan bahwa tidak terdapat satu arsitektur *Deep Learning* yang secara konsisten unggul dalam semua kondisi. Keberhasilan model sangat bergantung pada kesesuaian antara arsitektur, ukuran dataset, kompleksitas data, serta tujuan implementasi sistem. Oleh karena itu, penelitian di masa depan perlu lebih menekankan pada pengembangan dataset yang representatif serta evaluasi model dalam kondisi lapangan nyata.

5. KESIMPULAN DAN SARAN

Penelitian ini melakukan *Systematic Literature Review* terhadap 15 artikel ilmiah yang membahas penerapan *Deep Learning* (DL) untuk klasifikasi penyakit tanaman berbasis citra daun. Hasil kajian menunjukkan bahwa berbagai arsitektur digunakan, meliputi CNN konvensional, arsitektur modern seperti EfficientNet, ResNet, Inception, VGG, dan DenseNet, serta model *lightweight* seperti MobileNetV2.

Analisis menunjukkan bahwa meskipun CNN konvensional merupakan pendekatan yang paling sering digunakan sebagai baseline, performanya cenderung tidak stabil dan rentan terhadap *overfitting*, terutama pada dataset berukuran kecil. Sebaliknya, arsitektur modern seperti ResNet dan EfficientNet menunjukkan performa yang lebih konsisten dan stabil, khususnya ketika diterapkan pada dataset berukuran menengah hingga besar atau dikombinasikan dengan teknik transfer *learning*.

Dari sisi data, ukuran dan sumber dataset terbukti menjadi faktor yang paling dominan dalam menentukan performa model. Dataset publik berskala besar seperti *PlantVillage* dan *CassavaLeaf* mampu menghasilkan akurasi yang lebih tinggi dan stabil dibandingkan dataset lokal yang terbatas, sehingga menegaskan bahwa kualitas dan kuantitas data memiliki peran yang lebih krusial dibandingkan pemilihan arsitektur semata.

Selain itu, tren penelitian menunjukkan peningkatan penggunaan transfer *learning* untuk mengatasi keterbatasan data, serta adopsi model *lightweight* seperti MobileNetV2 untuk mendukung implementasi pada perangkat dengan sumber daya terbatas, seperti *smartphone* dan sistem berbasis Internet of Things (IoT).

Secara keseluruhan, hasil studi ini menegaskan bahwa tidak terdapat satu arsitektur *Deep Learning* yang secara universal paling unggul. Performa model sangat bergantung pada kesesuaian antara arsitektur, karakteristik dataset, serta kebutuhan implementasi. Oleh karena itu, penelitian selanjutnya perlu difokuskan pada pengembangan dataset yang lebih besar dan representatif, serta pengujian model pada kondisi lapangan nyata guna meningkatkan kemampuan generalisasi dan kesiapan implementasi sistem klasifikasi penyakit tanaman.

UCAPAN TERIMA KASIH

Peneliti mengucapkan rasa terima kasih yang sebesar-besarnya kepada dosen pembimbing dan penguji yang telah bersedia memberikan segenap ilmunya untuk mengarahkan kepada peneliti dalam penelitian ini. Peneliti juga berterima kasih kepada pihak-pihak yang membantu peneliti untuk menyelesaikan penelitian ini, sehingga penelitian ini dapat selesai sesuai dengan yang diharapkan.

DAFTAR REFERENSI

- Agustina, S., Hidayat, A. T., Satrianansyah, & K., R. (2025). Klasifikasi penyakit pada buah jeruk berdasarkan citra dengan pendekatan transfer learning menggunakan arsitektur DenseNet-121. *10*(1), 42–47. <https://doi.org/10.35316/jimi.v10i1.42-47>
- Amelia Devi Putri Ariyanto, A. D. P., Hasanah, S., Subkhi, M. B., & N. S. (2023). Analisis penggunaan pra-proses pada metode transfer learning untuk mendeteksi penyakit daun singkong. *22*(2), 336–347. <https://doi.org/10.33633/tc.v22i2.7769>
- Anggiratih, E., Siswanti, S., & Octaviani, S. K. (2021). Klasifikasi penyakit tanaman padi menggunakan model deep learning EfficientNet-B3 dengan transfer learning. *1*, 75–83. <https://doi.org/10.30646/sinus.v19i1.526>
- Anggraini, S. F. (2025). Implementasi MobileNetV2 untuk pengenalan presisi penyakit daun kopi berbasis citra. *4*. <https://doi.org/10.24127/jisi.v4i2.9876>
- Aryaputra, A., Widodo, D., & Sanjaya, A. (n.d.). Klasifikasi penyakit daun tomat menggunakan algoritma CNN MobileNetV2. *9*, 102–108.
- Fadhilla, M., Suryani, D., Labellapansa, A., & Gunawan, H. (2023). Corn leaf diseases recognition based on convolutional neural network. *8*(1), 14–21. <https://doi.org/10.25299/itjrd.2023.13904>
- Guan, H., Fu, C., Zhang, G., Li, K., Wang, P., & Zhu, Z. (2023). A lightweight model for efficient identification of plant diseases and pests based on deep learning. *Frontiers in Plant Science*, *14*. <https://doi.org/10.3389/fpls.2023.1227011>
- Hia, C., Tiara, M., Hutasuhut, D. R., & Hutaaruk, E. M. (2025). Deteksi penyakit blas, tungro, dan bercak coklat pada tanaman padi menggunakan metode convolutional neural network. *Jurnal Media Informatika (JUMIN)*, *6*(3), 2221–2232.
- Maulana, M. F. A., Anggadimas, N. M., & S. D. A. (2025). Klasifikasi citra penyakit daun padi dengan metode CNN menggunakan arsitektur ResNet50V2. *10*(2), 517–529. <https://doi.org/10.24114/cess.v10i2.66960>
- Milano, A. C., Yasid, A., & Wahyuningrum, R. T. (2024). Klasifikasi penyakit daun padi menggunakan model deep learning EfficientNet-B6. *Jurnal Teknik Informatika dan Teknik Elektro Terapan*, *12*(1). <https://doi.org/10.23960/jitet.v12i1.3855>
- Oktaviyan, T., Chaeri, A. P., & Ibrahim, I. (2024). Studi literatur klasifikasi penyakit daun dengan deep learning pada tanaman kacang. *2*(3), 521–526.
- Putra, I. P., & Alamsyah, D. (2022). Klasifikasi penyakit daun jagung menggunakan metode convolutional neural network. *2*(2), 102–112. <https://doi.org/10.35957/algoritme.v2i2.2360>
- Soekarta, R., Nurdjan, N., & Syah, A. (2023). Klasifikasi penyakit tanaman tomat menggunakan metode convolutional neural network (CNN). *8*(2), 143–151. <https://doi.org/10.33506/insect.v8i2.2356>
- Trihardianingsih, L., Sunyoto, A., & Hidayat, T. (2023). Classification of tea leaf diseases based on ResNet-50 and Inception V3. *Sinkron*, *8*(3), 1564–1573. <https://doi.org/10.33395/sinkron.v8i3.12604>