



BAB II

TINJAUAN LITERATUR

Bab ini menyajikan tinjauan pustaka yang komprehensif sebagai landasan teoritis penelitian klasifikasi penyakit tanaman tebu menggunakan teknologi *deep learning*. Kajian literatur difokuskan pada konsep-konsep fundamental yang meliputi *deep learning* dan arsitektur *Convolutional Neural Network (CNN)*, teknik *transfer learning* untuk optimalisasi pembelajaran model, pendekatan *self-supervised learning* melalui *Masked Autoencoder (MAE)*, arsitektur modern *ConvNeXt V2* beserta komponennya yaitu *Fully Convolutional Masked Autoencoder (FCMAE)*, metrik evaluasi confusion matrix, serta analisis mendalam terhadap penelitian-penelitian terdahulu yang relevan. Tinjauan ini bertujuan untuk membangun pemahaman teoretis yang solid dan mengidentifikasi research gap yang akan dijawab melalui implementasi arsitektur *ConvNeXt V2* dalam konteks klasifikasi penyakit tanaman tebu.

2.1 Deep Learning

Deep learning merupakan subbidang dari machine learning yang memanfaatkan jaringan saraf tiruan berlapis dalam (deep neural networks) untuk mempelajari representasi hirarki dari data secara otomatis tanpa rekayasa fitur manual. Setiap lapisan jaringan mempelajari abstraksi fitur yang semakin tinggi, dari fitur tingkat rendah seperti tepi dan tekstur pada lapisan awal, hingga fitur semantik kompleks seperti pola penyakit pada lapisan akhir. Kemampuan ini menjadikan deep learning sangat efektif untuk tugas klasifikasi citra, termasuk identifikasi penyakit tanaman dari citra daun dengan akurasi tinggi. Penelitian oleh Meghana dkk. yang mengembangkan model CNN 5-layer untuk deteksi penyakit



1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.
 2. Penggunaan untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.
 3. Penggunaan tanpa izin untuk kepentingan komersial atau pelanggaran hak cipta dapat dikenakan sanksi sesuai dengan UU Hak Cipta di Indonesia.
 4. Plagiarisme juga dilarang dan dapat dikenakan sanksi.
 5. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

Hak Cipta Dilindungi Undang-Undang

Universitas Islam Indragiri

daun padi (*Bacterial Leaf Blight*, *Leaf Blast*, *Brown Spot*) dengan *preprocessing* meliputi *resizing*, normalisasi, dan augmentasi data. Model CNN 5-layer mencapai akurasi 78,2%, melampaui VGG16 (58,4%), membuktikan arsitektur sederhana dapat mencapai akurasi tinggi dengan efisiensi komputasi optimal[5].

Penelitian oleh M. Basthikodi yang mengembangkan arsitektur *Twin CNN* dengan fitur gabungan yang mengintegrasikan tiga model *pre-trained* (VGG16, ResNet50, InceptionV3) untuk klasifikasi penyakit daun padi. Model mencapai akurasi 96,8% dengan inference time 12 ms, mengungguli baseline VGG16 (94,3%), ResNet50 (95,2%), InceptionV3 (95,0%), dan Simple CNN (91,8%), membuktikan keunggulan feature fusion dalam meningkatkan performa dengan efisiensi komputasi tinggi[6].

Penelitian oleh Ashurov dkk. memperkenalkan modified depthwise CNN dengan *squeeze-and-excitation* (SE) blocks dan improved residual skip connections untuk deteksi penyakit tanaman. Model memodifikasi MobileNetV2 pada dataset 38 kelas dengan 87.000 gambar, mencapai akurasi 98% dan F1 score 98,2% dengan inference time 12 ms, mengungguli model state-of-the-art. Ablation study membuktikan pentingnya SE block dan residual skip connections dalam performa model.[7].

2.2 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah jenis deep learning yang dirancang khusus untuk mengenali gambar. CNN bekerja seperti mata manusia yang melihat gambar secara bertahap pertama mendeteksi garis dan tepi, kemudian bentuk dan pola, lalu akhirnya mengenali objek lengkap seperti daun yang sakit. Teknologi ini sangat efektif untuk mengklasifikasi penyakit tanaman dari foto daun



1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.
 2. Penggunaan untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.
 3. Penggunaan tanpa izin untuk kepentingan komersial atau pelanggaran hak cipta dapat dikenakan sanksi sesuai dengan UU Hak Cipta di Indonesia.
 4. Plagiarisme juga dilarang dan dapat dikenakan sanksi.
 5. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

Hak Cipta Dilindungi Undang-Undang

Universitas Islam Indragiri

karena bisa belajar sendiri membedakan ciri-ciri daun sehat dan sakit tanpa perlu diberitahu secara manual fitur apa yang harus dicari.

Penelitian oleh Arrasyid dkk. yang mengusulkan metode *Support Vector Machine* (SVM) untuk klasifikasi penyakit tanaman tebu melalui *Systematic Literature Review* (SLR) yang menganalisis lima jurnal ilmiah. SVM dipilih karena kemampuannya menangani data kompleks dan dataset kecil dengan ekstraksi fitur bentuk, tekstur, dan warna. Hasil menunjukkan akurasi bervariasi 80,55%-84,40%, dengan kombinasi GLCM dan SVM mencapai performa tertinggi. Penelitian membuktikan SVM efektif membedakan tanaman sehat dan terinfeksi, berpotensi sebagai sistem pendukung keputusan deteksi dini penyakit[8].

Penelitian oleh H. Wang dkk. menjelaskan bagian-bagian CNN untuk deteksi penyakit tanaman. *Layer* konvolusi mendeteksi ciri penyakit menggunakan *filter* kecil, *pooling layer* mengecilkan ukuran gambar, fungsi ReLU mengenali pola, dan *layer* terakhir menentukan jenis penyakit. Teknik *dropout* dan *batch normalization* mencegah model hanya hafal data latih. Augmentasi data (rotasi, *flipping*, ubah kecerahan) membuat model bisa deteksi dari berbagai kondisi. *Optimizer* Adam paling cepat belajar, tapi SGD lebih baik untuk aplikasi lapangan[9].

Penelitian oleh W.ullah dkk. membandingkan lima arsitektur CNN untuk deteksi penyakit pada dataset 2.652 gambar. AlexNet paling bagus dengan akurasi 97,42% menggunakan SGD, tapi turun jadi 95,71% menggunakan Adam. LeNet cocok untuk aplikasi sederhana (akurasi 95,92%), ResNet-50 dapat 96,35%, VGG16 dapat 93,56%, dan Inception-V1 dapat 95,06%. SGD memberikan hasil paling konsisten (rata-rata 95,66%), lebih baik dari Adam (94,37%) dan RMSprop (93,98%). AlexNet dengan SGD hanya salah klasifikasi 2,58%[10].



1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.
 2. Penggunaan untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.
 3. Penggunaan tanpa izin untuk kepentingan komersial atau pelanggaran hak cipta dapat dikenakan sanksi sesuai dengan UU Hak Cipta di Indonesia.
 4. Plagiarisme juga dilarang dan dapat dikenakan sanksi.
 5. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

Hak Cipta Dilindungi Undang-Undang

Universitas Islam Indragiri

2.3 Transfer Learning

Transfer learning adalah teknik *deep learning* yang memanfaatkan pengetahuan yang sudah dipelajari dari satu tugas untuk diterapkan pada tugas yang berbeda namun serupa. Bayangkan seperti seorang dokter yang sudah ahli mendiagnosis penyakit pada manusia, kemudian menggunakan pengalamannya untuk lebih cepat belajar mendiagnosis penyakit pada hewan prinsipnya mirip, hanya objeknya berbeda. Dalam konteks deteksi penyakit tanaman, *transfer learning* menggunakan model CNN yang sudah dilatih pada jutaan gambar umum (seperti ImageNet) dan kemudian disesuaikan untuk mengenali penyakit tanaman. Teknik ini sangat efektif karena mengurangi kebutuhan data *training* yang sangat besar dan mempercepat proses pembelajaran.

Penelitian oleh Deepsikha dkk. menggunakan VGG19 dengan *transfer learning* pada dataset *PlantVillage* (61.486 gambar, 38 kelas penyakit, 14 jenis tanaman). VGG19 yang sudah dilatih sebelumnya digunakan ulang, hanya tiga *layer* terakhir diganti untuk klasifikasi penyakit. Data latih diperbanyak dengan rotasi, *flipping*, dan ubah warna. Model dilatih menggunakan Adam (*batch size* 20, 50 *epochs*) dapat akurasi 95,6%. Model dipasang di Android menggunakan *TensorFlow Lite*, ukurannya diperkecil dari 528MB jadi 80MB, bisa deteksi 2-3 detik per gambar[11].

penelitian oleh Shafik dkk. yang menggabungkan sembilan model CNN untuk deteksi penyakit tanaman pada dataset *PlantVillage* (54.305 gambar, 15 kelas). PDDNet-EA menggabungkan hasil dari sembilan CNN, sedangkan PDDNet-LVE menggunakan sistem voting. Data latih diperbanyak dengan berbagai cara (rotasi, *flipping*, ubah warna dan kecerahan). Model tunggal DenseNet201 dapat 94,86%,



1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.
 2. Penggunaan untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.
 3. Penggunaan tanpa izin untuk kepentingan komersial atau pelanggaran hak cipta dapat dikenakan sanksi sesuai dengan UU Hak Cipta di Indonesia.
 4. Plagiarisme juga dilarang dan dapat dikenakan sanksi.
 5. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

Hak Cipta Dilindungi Undang-Undang

Universitas Islam Indragiri

tapi model gabungan lebih bagus: PDDNet-EA dapat 96,74% dan PDDNet-LVE dapat 97,79%[12].

Penelitian oleh Sharma dkk. menggunakan model 3 tahap dengan EfficientNetB7 untuk deteksi penyakit padi pada 8.883 gambar penyakit dan 1.200 gambar sehat (lima kelas). Model dilatih bertahap dari gambar kecil (64×64 piksel) sampai besar (224×224 piksel) dan menggunakan fungsi aktivasi PReLU. Pelatihan bertahap meningkatkan akurasi dari 89,5% (tahap 1) jadi 93,99% (tahap 3), dengan PReLU lebih baik 3,2% dari ReLU. Model akhir dapat akurasi 94%[13].

2.4 Masked Autoencoder (MAE)

Masked Autoencoder (MAE) adalah pendekatan *self-supervised learning* yang bekerja dengan cara menutupi sebagian besar *patch* gambar secara acak (misalnya 75%), kemudian melatih model untuk merekonstruksi bagian yang hilang tersebut. Berbeda dengan *supervised learning* yang memerlukan label manual untuk setiap gambar, MAE dapat belajar representasi visual yang kuat hanya dari data gambar tanpa label. Pendekatan ini terinspirasi dari BERT dalam *Natural Language Processing*, namun dirancang khusus untuk visi komputer dengan mempertimbangkan perbedaan fundamental antara teks dan gambar – gambar memiliki redundansi spasial tinggi sehingga memerlukan *masking ratio* yang jauh lebih besar.

Penelitian oleh Girshick dkk. menggunakan teknik MAE yang hanya proses 25% bagian gambar, sisanya ditutup dan direkonstruksi ulang. Cara ini bikin *training* $3 \times$ lebih cepat dengan akurasi tetap tinggi. Model terbesar (ViT-Huge) dapat akurasi 87,8% pada ImageNet. MAE bagus saat diperbesar: akurasi naik dari 83,6% (model kecil) sampai 86,9% (model besar). Dengan menutup 75% gambar,



Hak Cipta Dilindungi Undang-Undang

1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.
 2. Penggunaan untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.
 3. Penggunaan tanpa izin untuk kepentingan komersial atau pelanggaran hak cipta dapat dikenakan sanksi sesuai dengan UU Hak Cipta di Indonesia.
 3. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

model dipaksa pahami gambar secara keseluruhan, bukan cuma bagian-bagian kecil[14].

Penelitian oleh Marwaha dkk. menggunakan konsep MAE untuk pertanian dengan model PDSE-Lite yang ringan dan hemat data. Model ini bekerja dua tahap: pertama, *Autoencoder* belajar rekonstruksi gambar daun. Kedua, bagian *encoder* digunakan untuk klasifikasi dan segmentasi yang cuma butuh 2 gambar per kelas. Pada dataset penyakit apel (4 kelas), model dapat akurasi 98,35% untuk klasifikasi dan 97,59% untuk segmentasi. Model ini sangat ringan (8.749 parameter) dibanding DeepLabV3+ (11,85 juta parameter) yang akurasinya lebih rendah (93,16%). Hasil prediksi model ini terbukti tidak beda signifikan dengan data asli. Penelitian ini membuktikan model ringan bisa akurat meski menggunakan data latih sangat sedikit[15].

Penelitian oleh Wubneh dkk. membandingkan tiga model CNN untuk deteksi penyakit jagung di aplikasi *mobile* pada dataset 4.188 gambar. VGG16 paling bagus dengan akurasi 95%, AlexNet dapat 91%, sedangkan ResNet50 hanya 72%. ResNet50 gagal karena data latih kurang (cuma 3.139 gambar), terlalu sedikit untuk model yang dalam. Masalah data tidak seimbang diatasi dengan teknik *weighted loss*, meningkatkan deteksi kelas minoritas dari 69% jadi 83%. VGG16 dipasang di aplikasi *mobile* dengan ukuran 56,38 MB dan waktu deteksi ~850ms. Untuk aplikasi *mobile* dengan data terbatas, model sedang seperti VGG16 lebih cocok dibanding model yang terlalu dalam[16].

2.5 ConvNeXt Dan Variannya

ConvNeXt merupakan arsitektur *Convolutional Neural Network* modern yang menggabungkan kekuatan CNN tradisional dengan inovasi dari *Vision*



1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.
 2. Penggunaan untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.
 3. Penggunaan tanpa izin untuk kepentingan komersial atau pelanggaran hak cipta dapat dikenakan sanksi sesuai dengan UU Hak Cipta di Indonesia.
 4. Plagiarisme juga dilarang dan dapat dikenakan sanksi.
 5. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

Hak Cipta Dilindungi Undang-Undang

Universitas Islam Indragiri

Transformer. Arsitektur ini dirancang khusus untuk meningkatkan efisiensi komputasi sambil mempertahankan akurasi tinggi dalam analisis citra. ConvNeXt menggunakan teknik *depthwise separable convolutions* dengan *kernel* besar berukuran 7×7 , *Layer Normalization* untuk menjaga stabilitas saat *training*, dan *pre-trained weights* dari *dataset* ImageNet-22k yang memungkinkan *transfer learning* efektif meskipun data berlabel sangat terbatas. Desain hierarkis ConvNeXt memungkinkan ekstraksi fitur dari berbagai skala mulai dari detail kecil seperti bentuk parasit hingga informasi besar seperti distribusi sel menjadikannya sangat cocok untuk aplikasi diagnostik di lingkungan dengan keterbatasan sumber daya.

Terkhususnya dalam penelitian ini varian yang di gunakan adalah varian Tiny, ConvNeXtV2 Tiny merupakan salah satu varian kecil dari arsitektur ConvNeXtV2 yang dikembangkan oleh Meta AI sebagai penyempurnaan dari ConvNeXtV1, dimana model ini menggabungkan desain jaringan konvolusional klasik dengan teknik pembelajaran modern menggunakan metode *Fully Convolutional Masked Autoencoder* (FCMAE) untuk pre-training. Dengan jumlah parameter sekitar 28-29 juta, varian Tiny dirancang khusus untuk aplikasi dengan keterbatasan sumber daya komputasi seperti perangkat *mobile* atau *edge devices*, namun tetap mampu memberikan performa yang kompetitif pada berbagai tugas *computer vision* seperti klasifikasi gambar, deteksi objek, dan segmentasi. Keunggulan utama ConvNeXtV2 Tiny terletak pada efisiensi komputasi dan kecepatan inferensi yang tinggi tanpa mengorbankan akurasi secara signifikan, sehingga menjadikannya pilihan ideal ketika keseimbangan antara performa model dan efisiensi resource menjadi prioritas dalam implementasi sistem.



Penelitian Yamagishi dkk. menggunakan gabungan ConvNeXt V2 dan MaxViT untuk klasifikasi *X-ray* dada, menghadapi masalah data tidak seimbang (penyakit umum banyak, penyakit langka sedikit) dan harus gabungkan foto dari dua sudut (depan dan samping). Solusinya: kasih bobot lebih tinggi untuk kelas langka, dan gabungkan prediksi dari dua sudut dengan perbandingan 8:2 (foto depan lebih penting). Model ConvNeXt V2 Tiny dapat akurasi 83% pada ImageNet. Sistem ini dapat peringkat 4 dan 5 di kompetisi MICCAI 2024. Penggabungan foto dua sudut meningkatkan performa dari 0,4908 jadi 0,5065[17].

Penelitian oleh whata dkk. menggunakan ConvNeXt untuk deteksi parasit malaria pada gambar mikroskopis. Dataset 27.558 gambar diperbanyak jadi 606.276 dengan berbagai variasi (rotasi, *flipping*, ubah kecerahan, *blur*, dll) untuk simulasi kondisi lapangan. ConvNeXt V2 Tiny dapat akurasi 98,1% lebih baik dari ConvNeXt V1 (95,9%), Swin Tiny (61,4%), ResNet18 (62,6%), dan ResNet50 (81,4%). Model menggunakan kombinasi teknik *label smoothing*, *optimizer* AdamW, dan *transfer learning* dari ImageNet, cuma butuh 10 *epochs* latih. Hasil validasi konsisten dengan rata-rata akurasi 98,12%[18].

Penelitian oleh dong dkk. mengembangkan SC-ConvNeXt mengintegrasikan SimCLR *pre-training* dan *improved CBAM attention* pada ConvNeXt-T (216,37 MB). *Two-stage training* meliputi *self-supervised* SimCLR tanpa label dan *supervised fine-tuning* dengan label. Dataset 2.028 gambar diperluas menjadi 10.140 dengan augmentasi (*random brightness*, *Gaussian noise*, *random occlusion*, rotasi). CBAM menggunakan LeakyReLU untuk mencegah *neuron* mati, dengan *Focal Loss* mengatasi ketidakseimbangan sampel. *Training* 100 *epochs* dengan *optimizer* Adam mencapai akurasi 88,05%—3,83% lebih tinggi dari ConvNeXt-T



1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.
 2. Penggunaan tanpa izin untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.
 3. Plagiarisme juga dilarang dan dapat dikenakan sanksi.
 3. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

Hak Cipta Dilindungi Undang-Undang

Universitas Islam Indragiri

dan 16,67% dari SqueezeNet. Ablasi menunjukkan SimCLR meningkatkan >1% dan *improved CBAM* meningkatkan 84,47%→88,05%, mengungguli ECA dan *Triple Attention*. Validasi 10 eksperimen: rata-rata 88,00% (CI 95%: 0,8793-0,8807)[19].

2.6 Confusion Matrix

Confusion matrix merupakan alat evaluasi fundamental dalam *machine learning* yang menyajikan representasi visual komprehensif tentang performa model klasifikasi dengan membandingkan prediksi model terhadap label aktual.

Matrix ini menampilkan empat kategori utama: *True Positive* (TP) - prediksi benar untuk kelas positif, *False Positive* (FP) - prediksi salah sebagai positif padahal sebenarnya negatif, *False Negative* (FN) - prediksi salah sebagai negatif padahal sebenarnya positif, dan *True Negative* (TN) - prediksi benar untuk kelas negatif. *Confusion matrix* sangat berharga karena memberikan *insight* mendalam tentang jenis kesalahan yang dibuat model, membantu mengidentifikasi kelas yang sering dikacaukan, dan memungkinkan analisis *trade-off* antara berbagai metrik performa.

Penelitian oleh fadhilla dkk. menggunakan CNN 4 *layer* untuk deteksi penyakit daun jagung pada 1.000 gambar (4 kategori: sehat, *common rust*, *leaf blight*, *leaf spot*). Dataset dibagi 80% latih dan 20% uji, model dilatih 50 *epochs*. Model dapat akurasi 93%. Hasil per kelas: *Common Rust* paling bagus (100% presisi, 98% *recall*), *Healthy Leaf* (96% presisi, 100% *recall*), *Leaf Blight* (84% presisi, 92% *recall*), dan *Leaf Spot* paling lemah (93% presisi, 82% *recall*). *Leaf Blight* dan *Leaf Spot* sering tertukar karena mirip[20].

Penelitian oleh Rekha dkk. mengembangkan CNN untuk deteksi *early blight* dan *late blight* pada tomat menggunakan 4.500 gambar PlantVillage (80% latih,



1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.
 2. Penggunaan untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.
 3. Penggunaan tanpa izin untuk kepentingan komersial atau pelanggaran hak cipta dapat dikenakan sanksi sesuai dengan UU Hak Cipta di Indonesia.
 4. Plagiarisme juga dilarang dan dapat dikenakan sanksi.
 5. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

Hak Cipta Dilindungi Undang-Undang

Universitas Islam Indragiri

20% uji). Model punya 6 *layer* dengan *filter* 32-64, dilatih 50 *epochs* menggunakan *optimizer* Adam dan augmentasi data. Model dapat akurasi latih 97,40% dan akurasi validasi 96,43%. Model sempurna deteksi daun sehat, tapi agak kesulitan bedakan *early* dan *late blight* karena mirip [21].

Penelitian oleh Ifthikar membuat model *Enhanced CNN* (E-CNN) untuk deteksi penyakit pada Apel, Jagung, dan Kentang lewat aplikasi *mobile*. Dataset PlantVillage 9.175 gambar (10 jenis penyakit) dibagi 80% latih, 10% validasi, 10% uji. Model punya 6 *layer* konvolusi dengan *filter* 32-64, dilatih 100 *epochs* menggunakan *optimizer* Adamax dan augmentasi data. Model dapat akurasi 98,17% lebih baik dari ResNet50 (97,8%), DenseNet121 (94,2%), MobileNetV2 (95,69%), AlexNet (87,56%), VGG16 (91%). Model bagus deteksi penyakit kentang tapi kesulitan pada penyakit yang jarang muncul. Waktu deteksi di HP sekitar 25 detik[22].

2.7 Penelitian Terdahulu

Penelitian terdahulu merupakan tinjauan terhadap penelitian-penelitian sebelumnya yang relevan dengan topik penelitian ini. Kajian penelitian terdahulu bertujuan untuk mengidentifikasi metode, teknik, dan pendekatan yang telah digunakan oleh peneliti lain, serta hasil yang telah dicapai. Melalui tinjauan ini, dapat diketahui kelebihan dan kekurangan dari masing-masing penelitian, sehingga dapat dijadikan acuan untuk pengembangan metode yang lebih baik dan menghindari pengulangan penelitian yang sama. Berikut adalah beberapa penelitian terdahulu yang memiliki keterkaitan dengan penelitian ini:

Tabel 2.1 Penelitian Terdahulu

No	Penulis	Tahun	Judul	Metode	Hasil
1	Wijaya Samdoria dkk	2025	Implementasi Deep Learning Menggunakan Arsitektur VGG-19 Untuk Deteksi Penyakit Pada Tebu	VGG-19	Akurasi 92.3%
2	Riska Aryanti dkk	2024	Optimisasi Model Deep Learning untuk Deteksi Penyakit Daun Tebu dengan Fine-Tuning MobileNetV2	MobileNetV2 (Fine-tuning)	Akurasi 95.01% (setelah fine-tuning), 93.12% (baseline)
3	Daphal & Koli	2024	Enhanced deep learning technique for sugarcane leaf disease classification	AMRCNN (Attention-based), VGG19, ResNet50, XceptionNet, EfficientNet_B7	AMRCNN: Akurasi 86.53%, ResNet50: 84% untuk 5 kelas penyakit
4	Malik dkk	2021	Disease Recognition in Sugarcane Crop Using Deep Learning	ResNet-34, ResNet-50, VGG-19	ResNet-50: Akurasi 93.2% menggunakan kombinasi ResNet-50 dan CNN



1. Diartikan memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.
 2. Penggunaan untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.
 3. Penggunaan tanpa izin untuk kepentingan komersial atau pelanggaran hak cipta dapat dikenakan sanksi sesuai dengan UU Hak Cipta di Indonesia.
 4. Plagiarisme juga dilarang dan dapat dikenakan sanksi.
 5. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

Tabel 2.1 Penelitian Terdahulu Lanjutan

No	Penulis	Tahun	Judul	Metode	Hasil
5	Srivastava dkk	2020	A Novel Deep Learning Framework Approach for Sugarcane Disease Detection	InceptionV3, VGG-16, VGG-19 dengan SVM	VGG-16 + SVM: Akurasi 90.2% AUC
6	Kumar dkk	2025	Hybrid Deep Learning Framework for Real-Time Sugarcane Disease Detection	DenseNet201 + GRU, InceptionV3 + GRU, InceptionResNet V2 + GRU	DenseNet201 + GRU: Akurasi 96.49%
7	Aswani & Sinha	2025	Early diagnosis of Sugarcane leaf diseases through CNN and Vision Transformer hybrid model	CNN + Vision Transformer (VIT) Hybrid	CNN: 84.3%, VIT: 93.07%, CNN+VIT Hybrid: Akurasi 97.43%
8	Kunduracı oğlu & Paçal	2024	Deep Learning-Based Disease Detection in Sugarcane Leaves: Evaluating EfficientNet Models	EfficientNet-B0 sampai B7	EfficientNet-B7: Akurasi 95%+ untuk multi-class disease detection
9	Daphal & Koli	2023	Enhancing Sugarcane Disease Classification with Ensemble Deep Learning	MobileNet-V2, VGG-19, ResNet-50, XceptionNet, EfficientNet-B7	Ensemble: Akurasi 86.53%, MobileNet-V2: 84% untuk 5 kelas penyakit



Hak Cipta Dilindungi Undang-Undang

1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.

2. Penggunaan untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.

3. Penggunaan tanpa izin untuk kepentingan komersial atau pelanggaran hak cipta dapat dikenakan sanksi sesuai dengan UU Hak Cipta di Indonesia.

4. Plagiarisme juga dilarang dan dapat dikenakan sanksi.

5. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

Universitas Islam Indragiri

Tabel 2.1 Penelitian Terdahulu Lanjutan

No	Penulis	Tahun	Judul	Metode	Hasil
10	Pawar dkk.	2023	<i>Sugarcane Leaf Disease Detection: A Comparative Analysis Using Deep Learning</i>	ResNet101, DenseNet161, MobileNetV2, AlexNet	DenseNet161: Akurasi 97.41%, ResNet101: 97.21%, MobileNetV2: 95.82%, AlexNet: 91.43%
11	Upadhye dkk.	2023	Sugarcane Disease Detection Using CNN-Deep Learning Method: An Indian Perspective	AlexNet dengan ReLU, AlexNet dengan LeakyReLU	AlexNet + ReLU: Akurasi 87.90% (47 menit training), AlexNet + LeakyReLU: Akurasi 90.67% (54 menit training) untuk 4 kelas
12	Chen dkk.	2022	Evaluating Data Augmentation Effects on the Recognition of Sugarcane Leaf Spot	MobileNetV3-large, AlexNet, ResNet, DenseNet dengan DCGAN augmentation	Tanpa augmentation: AlexNet 53.5%, MobileNetV3 53.5%. Dengan DCGAN: DenseNet 93%, MobileNetV3 87.5% untuk 4 kelas (red rot, ring spot, rust, healthy)



Hak Cipta Dilindungi Undang-Undang

1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.

2. Penggunaan untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.

3. Penggunaan tanpa izin untuk kepentingan komersial atau pelanggaran hak cipta dapat dikenakan sanksi sesuai dengan UU Hak Cipta di Indonesia.

Plagiarisme juga dilarang dan dapat dikenakan sanksi. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

Universitas Islam Indragiri



1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.
 2. Penggunaan untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.
 3. Penggunaan tanpa izin untuk kepentingan komersial atau pelanggaran hak cipta dapat dikenakan sanksi sesuai dengan UU Hak Cipta di Indonesia.
 4. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

Hak Cipta Dilindungi Undang-Undang

Universitas Islam Indragiri

Penelitian Wijaya Samdoria dkk. (2025) menggunakan VGG-19 untuk deteksi penyakit tebu lewat website. Penelitian ini dibuat karena petani butuh sistem deteksi yang mudah diakses. Kelebihan penelitian ini adalah berbasis website sehingga petani bisa akses langsung tanpa install aplikasi, dan menggunakan VGG-19 yang terbukti bagus dengan akurasi 92,3%. Namun kekurangannya adalah VGG-19 cukup berat untuk proses deteksi. Keterbatasan penelitian ini adalah belum diuji pada berbagai kondisi pencahayaan dan latar belakang, belum dibandingkan dengan model modern lain seperti EfficientNet atau ResNet, serta belum mencoba menggunakan teknik gabungan model untuk hasil lebih akurat[23].

Penelitian Riska Aryanti dkk. (2024) menggunakan MobileNetV2 dengan *fine-tuning* untuk deteksi penyakit daun tebu. Penelitian ini bertujuan meningkatkan akurasi model dengan penyesuaian *layer* secara bertahap. Kelebihan penelitian ini berhasil meningkatkan akurasi dari 93,12% jadi 95,01% (naik 1,89%) sambil tetap jaga model tetap ringan untuk dipasang di aplikasi. Hasil menunjukkan *fine-tuning* pada *layer* terakhir model yang sudah dilatih sebelumnya bisa kasih peningkatan yang cukup berarti. Namun kekurangannya adalah peningkatan akurasi relatif kecil dengan waktu latih yang lebih lama. Keterbatasan penelitian ini belum coba teknik optimisasi lain seperti *learning rate* yang adaptif atau augmentasi data lebih agresif seperti *AutoAugment* atau *RandAugment* yang mungkin bisa kasih peningkatan lebih besar, dan belum ada analisis mendalam tentang *layer* mana yang paling berpengaruh setelah *fine-tuning*[24].

Penelitian Daphal & Koli (2024) mengembangkan AMRCNN (*Attention-based Multi-level Residual CNN*) untuk klasifikasi penyakit daun tebu. Tujuannya



Hak Cipta Dilindungi Undang-Undang

1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.
 2. Penggunaan untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.
 3. Penggunaan tanpa izin untuk kepentingan komersial atau pelanggaran hak cipta dapat dikenakan sanksi sesuai dengan UU Hak Cipta di Indonesia.
 4. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

Universitas Islam Indragiri

memanfaatkan mekanisme *attention* untuk fokus pada bagian penting dalam gambar daun yang menunjukkan ciri penyakit. Kelebihan model ini gabungan *spatial* dan *channel attention* untuk deteksi area penting dan menggabungkan fitur dari berbagai *layer*. Model AMRCNN dapat akurasi 86,53%, lebih baik dari ResNet50 yang cuma 84% untuk 5 kelas penyakit. Namun kekurangannya adalah arsitektur terlalu rumit dan butuh komputasi besar karena mekanisme *attention*, serta akurasi 86,53% masih tergolong sedang dibanding model terbaru lainnya. Keterbatasan penelitian ini belum memanfaatkan teknik *pre-training* modern dengan *self-supervised learning* dan metode gabungan model yang bisa meningkatkan performa lebih signifikan, serta mekanisme *attention* yang rumit belum dioptimasi untuk efisiensi deteksi[25].

Penelitian Malik dkk. (2021) menggunakan kombinasi ResNet-50 dan CNN konvensional untuk deteksi penyakit tebu. Penelitian ini bertujuan membuat sistem deteksi otomatis yang bisa mengidentifikasi berbagai penyakit tebu di tahap awal. Kelebihan utama adalah menggunakan ResNet-50 yang punya *skip connections* untuk atasi masalah *vanishing gradient*, dapat akurasi 93,2%. Hasil ini menunjukkan *deep residual learning* efektif untuk klasifikasi penyakit tebu. Namun kekurangannya adalah butuh komputasi tinggi untuk arsitektur ResNet-50 yang dalam dan waktu latih yang cukup lama. Keterbatasan penelitian ini adalah arsitektur masih konvensional (tahun 2021) dan belum memanfaatkan teknik *pre-training* modern seperti *transfer learning* ImageNet secara optimal, belum coba arsitektur modern seperti EfficientNet atau *Vision Transformer* yang terbukti lebih bagus untuk klasifikasi gambar, serta belum ada analisis kesalahan untuk pahami kasus yang gagal dideteksi[26].



Penelitian Srivastava dkk. (2020) menggunakan VGG-16 dengan *classifier* SVM untuk deteksi penyakit tebu. Tujuannya membuat sistem klasifikasi gabungan yang memanfaatkan CNN untuk ekstraksi fitur dan SVM untuk klasifikasi. Kelebihan penelitian ini menggunakan pendekatan gabungan yang coba maksimalkan kekuatan VGG-16 sebagai pengekstrak fitur dan SVM sebagai *classifier* yang *robust*, dapat akurasi 90,2%. Namun kekurangannya adalah akurasi masih tergolong sedang (90,2%) dibanding model terbaru saat itu, dan menggunakan *classifier* terpisah kurang efisien dibanding *deep learning* langsung karena butuh dua tahap latih (*CNN feature extraction* + latih SVM) dan tidak bisa optimasi secara bersamaan. Keterbatasan penelitian ini adalah pendekatan gabungan kurang efisien karena butuh dua tahap latih terpisah dan model tidak bisa belajar secara menyeluruh dari awal sampai akhir yang batasi kemampuan untuk hasil optimal, serta belum coba *classifier* modern lain atau pendekatan *deep learning* langsung yang bisa kasih performa lebih baik dengan arsitektur lebih sederhana[27].

Penelitian Kumar dkk. (2025) gabungan DenseNet201 dengan GRU untuk deteksi penyakit tebu secara *real-time*. Kelebihan model ini bisa tangkap fitur spasial dan pola temporal secara bersamaan, dapat akurasi 96,49% dengan penggunaan ulang fitur yang optimal. Namun kekurangannya butuh komputasi sangat tinggi karena gabungan dua arsitektur kompleks, waktu latih sangat lama dan butuh GPU kuat. Keterbatasan penelitian ini belum ada analisis kontribusi masing-masing komponen, dan penggunaan GRU untuk klasifikasi gambar tunggal mungkin berlebihan tanpa justifikasi jelas soal keuntungan biaya komputasi dibanding peningkatan akurasi[28].



Penelitian Aswani & Sinha (2025) menggunakan model gabungan CNN + *Vision Transformer* (VIT) untuk diagnosis dini penyakit tebu. Kelebihan model ini gabungan kekuatan CNN untuk ekstraksi fitur lokal dan VIT untuk pemahaman konteks global, dapat akurasi tertinggi 97,43% (lebih baik dari CNN 84,3% dan VIT 93,07% sendiri-sendiri). Model efektif deteksi penyakit tahap awal dan bisa klasifikasi 5 penyakit tebu. Namun kekurangannya VIT butuh komputasi sangat besar untuk latih dan deteksi, serta arsitektur gabungan yang kompleks butuh keahlian tinggi untuk penyesuaian. Keterbatasan penelitian ini waktu latih sangat lama dan biaya komputasi tinggi, belum coba kompresi model atau kuantisasi untuk bikin model lebih efisien tanpa kurangi akurasi, dan belum ada analisis interpretasi model untuk jelaskan hasil prediksi ke petani yang penting untuk bangun kepercayaan[29].

Penelitian Kunderacioğlu & Paçal (2024) evaluasi semua varian EfficientNet (B0-B7) untuk deteksi penyakit daun tebu, bertujuan cari keseimbangan optimal antara akurasi, ukuran model, dan biaya komputasi. Kelebihan penelitian ini menggunakan metode *compound scaling* yang memungkinkan penyesuaian optimal pada kedalaman, lebar, dan resolusi secara seimbang, EfficientNet-B7 dapat akurasi 95%+ untuk deteksi penyakit multi-kelas. Namun kekurangannya EfficientNet-B7 butuh komputasi sangat besar dengan ukuran model besar, waktu latih sangat lama dan kecepatan deteksi relatif lambat. Keterbatasan penelitian ini belum bandingkan dengan arsitektur modern lain seperti ConvNeXt atau *Vision Transformer*, belum coba teknik kompresi model seperti *pruning* atau *knowledge distillation* untuk hasilkan model lebih efisien untuk produksi, dan analisis interpretasi model masih terbatas[30].



Penelitian Daphal & Koli (2023) menggunakan *Ensemble Deep Learning* dengan gabungan MobileNet-V2, VGG-19, ResNet-50, XceptionNet, dan EfficientNet-B7 untuk meningkatkan akurasi melalui kombinasi berbagai arsitektur CNN dengan *transfer learning*. Kelebihan penelitian ini keberagaman model kasih prediksi yang saling melengkapi, model *ensemble* dapat akurasi 86,53% dibanding MobileNet-V2 sendiri cuma 84% untuk 5 kelas penyakit. Namun kekurangannya kompleksitas sangat tinggi, waktu deteksi sangat lama karena harus jalankan 5 model sekaligus, dan butuh memori besar untuk muat 5 model bersamaan. Keterbatasan penelitian ini akurasi *ensemble* (86,53%) masih sedang dan tidak kasih peningkatan signifikan dibanding model terbaik tunggal sehingga mempertanyakan efektivitas pendekatan *ensemble*, belum coba metode *weighted ensemble* atau *stacking* yang mungkin lebih efektif, dan belum ada analisis biaya-manfaat untuk justifikasi kompleksitas *ensemble* terhadap peningkatan akurasi kecil yang didapat[31].

Penelitian K.Nomani dkk. (2023) bandingkan ResNet101, DenseNet161, MobileNetV2, dan AlexNet untuk deteksi penyakit daun tebu, bertujuan identifikasi arsitektur optimal dengan pertimbangan akurasi, kompleksitas model, dan kecepatan deteksi. Kelebihan penelitian ini perbandingan sistematis dengan evaluasi adil, DenseNet161 dapat akurasi tertinggi 97,41%, disusul ResNet101 97,21%, MobileNetV2 95,82%, dan AlexNet 91,43% untuk 4 kelas penyakit. Hasil ini menunjukkan DenseNet161 unggul dalam penggunaan ulang fitur dan generalisasi. Namun kekurangannya DenseNet161 dan ResNet101 butuh GPU kuat dengan ukuran model sangat besar (115-170 MB). Keterbatasan penelitian ini belum coba arsitektur gabungan (CNN+*Transformer*) atau metode



ensemble yang mungkin kasih akurasi lebih tinggi, belum uji implementasi pada kondisi dunia nyata dengan lingkungan bervariasi seperti pencahayaan berbeda atau tahap keparahan penyakit berbeda, dan perlu analisis lebih dalam tentang kemampuan model pada kondisi berbeda dari data latih.[32]

Penelitian Upadhye dkk. (2023) bandingkan AlexNet dengan ReLU vs AlexNet dengan LeakyReLU untuk deteksi penyakit tebu, bertujuan analisis dampak fungsi aktivasi pada performa. Kelebihan penelitian ini temukan AlexNet + LeakyReLU dapat akurasi 90,67% (waktu latih+uji 54 menit), lebih baik dari AlexNet + ReLU dengan 87,90% (47 menit) untuk 4 kelas penyakit. Peningkatan +2,77% dengan biaya cuma 7 menit tambahan menunjukkan LeakyReLU lebih cocok untuk aplikasi pertanian yang butuh akurasi tinggi. Namun kekurangannya akurasi masih sedang (dibawah 95%) dan ada pertukaran antara akurasi versus waktu komputasi. Keterbatasan penelitian ini cuma coba modifikasi fungsi aktivasi sederhana tanpa peningkatan arsitektur lebih besar, belum bandingkan dengan arsitektur modern (EfficientNet, ResNet, DenseNet) yang bisa kasih performa lebih tinggi, dan belum coba fungsi aktivasi modern lain seperti Swish, Mish, atau GELU yang mungkin kasih peningkatan lebih signifikan[33].

Penelitian Chen dkk. (2022) menggunakan MobileNetV3-Large dengan DeepLabV3+ untuk hapus latar belakang dan DCGAN untuk augmentasi data sintetis pada deteksi penyakit daun tebu. Dataset terbatas 120 gambar (empat kelas: *red rot*, *ring spot*, sehat, karat) dibagi enam grup dengan perlakuan berbeda: dataset asli dan dataset tanpa latar belakang, masing-masing tanpa augmentasi, dengan augmentasi supervisi, dan dengan augmentasi DCGAN. Kelebihan penelitian ini MobileNetV3-Large dapat performa terbaik dengan akurasi



meningkat drastis dari 53,5% (dataset asli tanpa augmentasi) jadi 87,5% (hapus latar belakang), dan mencapai akurasi tertinggi 99% (hapus latar belakang + augmentasi DCGAN) dengan metrik sempurna untuk kelas *red rot* dan sehat. Augmentasi DCGAN lebih efektif dibanding augmentasi supervisi karena bisa hasilkan variasi warna, bentuk, dan distribusi bercak baru. Namun kekurangannya masih ada kesalahan klasifikasi kecil antara *ring spot* dan karat karena kesamaan warna dan distribusi bercak saat infestasi parah[34].

Tinjauan terhadap literatur penelitian menunjukkan tren kuat dalam pemanfaatan teknologi *deep learning* untuk identifikasi penyakit tanaman, dengan fokus utama pada penerapan arsitektur CNN dan model *hybrid* di sektor pertanian. Studi-studi terdahulu secara umum membuktikan bahwa teknologi *deep learning* memberikan potensi besar dalam meningkatkan deteksi dini penyakit, yang tercermin melalui peningkatan presisi klasifikasi, pengurangan beban komputasi, dan kemudahan akses bagi praktisi di lapangan. Secara praktis, mayoritas penelitian sebelumnya memanfaatkan arsitektur CNN klasik (VGG, ResNet, MobileNet) dan pendekatan *hybrid* (CNN+ViT, CNN+RNN) untuk mengidentifikasi pola visual gejala penyakit tebu, dengan pencapaian akurasi yang berkisar antara 85% hingga 97%+.

Meskipun penelitian terdahulu telah menunjukkan hasil yang menjanjikan, penelitian ini menawarkan pendekatan yang lebih komprehensif melalui integrasi holistik antara pemilihan arsitektur optimal, strategi augmentasi modern, dan implementasi sistem yang praktis. Penelitian sebelumnya umumnya menghadapi dilema antara akurasi tinggi dengan biaya komputasi ekstrem atau efisiensi ringan dengan akurasi terbatas, serta cenderung fokus pada aspek teknis tanpa



Hak Cipta Dilindungi Undang-Undang

1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.
Penggunaan untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.

2. Penggunaan tanpa izin untuk kepentingan komersial atau pelanggaran hak cipta dapat dikenakan sanksi sesuai dengan UU Hak Cipta di Indonesia. Plagiarisme juga dilarang dan dapat dikenakan sanksi.

3. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

Universitas Islam Indragiri

mempertimbangkan aksesibilitas pengguna akhir. Penelitian ini mengatasi keterbatasan tersebut dengan menggunakan ConvNeXtV2 yang menawarkan keseimbangan ideal antara akurasi tinggi (96-97%+) dan efisiensi komputasi, menerapkan teknik augmentasi data seperti *RandAugment* dan *AutoAugment* yang lebih stabil dibanding *GAN-based augmentation*, serta mengembangkan sistem berbasis *web* yang mudah diakses petani tanpa instalasi khusus. Integrasi ketiga aspek ini bertujuan menciptakan sistem klasifikasi penyakit tanaman tebu yang tidak hanya akurat secara teknis, tetapi juga praktis diterapkan untuk mendukung pengambilan keputusan petani dalam manajemen kesehatan tanaman di lapangan.

2.1 Kesimpulan

Tinjauan literatur menunjukkan bahwa teknologi *deep learning*, khususnya arsitektur CNN modern, telah terbukti efektif untuk klasifikasi penyakit tanaman tebu dengan akurasi mencapai 85-97%. Penelitian-penelitian terdahulu umumnya menggunakan arsitektur klasik seperti VGG, ResNet, MobileNet, atau pendekatan *hybrid CNN+Transformer* yang meskipun memberikan akurasi tinggi, namun menghadapi *trade-off* antara kompleksitas komputasi dan efisiensi. ConvNeXt V2 sebagai arsitektur modern menawarkan keunggulan melalui mekanisme *Fully Convolutional Masked Autoencoder* (FCMAE) untuk *pre-training* dan *Global Response Normalization* (GRN) untuk mencegah *feature collapse*, sehingga mampu mencapai keseimbangan optimal antara akurasi tinggi dan efisiensi komputasi. Penelitian ini memiliki nilai kebaruan dengan mengimplementasikan ConvNeXt V2 Tiny yang belum banyak dieksplorasi untuk klasifikasi penyakit tebu.