

CEK TURNITIN

SKRIPSI AGUNG SI

 SATSET DIGITAL 1

Document Details

Submission ID

trn:oid:::3618:150982540

Submission Date

Sep 8, 2026, 3:22 PM GMT+7

Download Date

Sep 8, 2026, 3:32 PM GMT+7

File Name

SKRIPSI AGUNG SI.pdf

File Size

2.2 MB

83 Pages

14,779 Words

94,804 Characters

27% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

Filtered from the Report

- Bibliography

Top Sources

- 19%  Internet sources
- 11%  Publications
- 21%  Submitted works (Student Papers)

Integrity Flags

0 Integrity Flags for Review

Our system's algorithms look deeply at a document for any inconsistencies that would set it apart from a normal submission. If we notice something strange, we flag it for you to review.

A Flag is not necessarily an indicator of a problem. However, we'd recommend you focus your attention there for further review.

Top Sources

- 19% Internet sources
- 11% Publications
- 21% Submitted works (Student Papers)

Top Sources

The sources with the highest number of matches within the submission. Overlapping sources will not be displayed.

1	Internet	repository.unisi.ac.id	4%
2	Internet	jurnal.amikom.ac.id	2%
3	Internet	positori.uma.ac.id	1%
4	Student papers	Universitas Sangga Buana YPKP on 2026-07-29	<1%
5	Internet	etheses.uin-malang.ac.id	<1%
6	Internet	positori.ub.ac.id	<1%
7	Student papers	Universitas Islam Riau on 2025-12-08	<1%
8	Student papers	UPN Veteran Yogyakarta on 2026-05-29	<1%
9	Internet	dspace.uir.ac.id	<1%
10	Student papers	Universitas Putera Batam on 2026-07-25	<1%
11	Internet	jurnal.polibatam.ac.id	<1%

12	Student papers	UPN Veteran Yogyakarta on 2026-06-03	<1%
13	Student papers	UPN Veteran Yogyakarta on 2026-06-03	<1%
14	Student papers	UPN Veteran Yogyakarta on 2026-07-06	<1%
15	Internet	ejurnal.provisi.ac.id	<1%
16	Publication	Eko Fuji Pangestu -, Bambang Irawan -. "KLASIFIKASI PENYAKIT TANAMAN PADI ...	<1%
17	Student papers	Sekolah Teknik Elektro & Informatika on 2026-07-20	<1%
18	Internet	eprints.upnyk.ac.id	<1%
19	Student papers	Universitas Jember on 2026-01-11	<1%
20	Student papers	Universitas Pamulang on 2026-07-25	<1%
21	Internet	repository.uhn.ac.id	<1%
22	Internet	repository.uin-suska.ac.id	<1%
23	Student papers	UPN Veteran Yogyakarta on 2026-07-06	<1%
24	Student papers	East Union High School on 2026-07-02	<1%
25	Student papers	UPN Veteran Yogyakarta on 2026-05-25	<1%

26	Student papers	Universitas Islam Riau on 2026-08-31	<1%
27	Internet	repository.uigm.ac.id	<1%
28	Student papers	Universitas Sangga Buana YPKP on 2026-07-31	<1%
29	Internet	ejurnal.stmik-budidarma.ac.id	<1%
30	Student papers	UPN Veteran Yogyakarta on 2026-06-29	<1%
31	Student papers	Universitas Malikussaleh on 2026-04-28	<1%
32	Internet	qtanalytics.in	<1%
33	Internet	123dok.com	<1%
34	Student papers	Universitas Ahmad Dahlan on 2025-08-20	<1%
35	Internet	proceeding.unpkediri.ac.id	<1%
36	Publication	Ilham Ismail, Fauzi Nur Maqi, Nur Hidayah. "PC Component Classification Using C...	<1%
37	Student papers	Institut Bisnis dan Teknologi Indonesia (INSTIKI) on 2025-09-16	<1%
38	Student papers	Sriwijaya University on 2020-06-10	<1%
39	Internet	digilib.unila.ac.id	<1%

40	Internet	eprints.itn.ac.id	<1%
41	Internet	rama.unimal.ac.id	<1%
42	Student papers	Institut Bisnis dan Teknologi Indonesia (INSTIKI) on 2025-05-30	<1%
43	Student papers	Universitas Islam Riau on 2026-06-10	<1%
44	Internet	journals.upi-yai.ac.id	<1%
45	Internet	ojs.stmik-banjarbaru.ac.id	<1%
46	Student papers	Corporación Universitaria del Caribe on 2024-08-07	<1%
47	Internet	kc.umn.ac.id	<1%
48	Student papers	UPN Veteran Yogyakarta on 2026-06-18	<1%
49	Student papers	Universitas Sangga Buana YPKP on 2026-07-24	<1%
50	Internet	digilib.ulm.ac.id	<1%
51	Internet	journal.stmikjayakarta.ac.id	<1%
52	Internet	lab.tik.pnj.ac.id	<1%
53	Publication	Aryan Kumar, Gaurav Saini. "A Comparative Study of Deep Learning Approaches f...	<1%

54	Publication	Charladinna Arvianne, Otong Saeful, Nur Ramdhan. "Klasifikasi penyakit daun ta...	<1%
55	Student papers	Institut Teknologi Sumatera on 2026-07-21	<1%
56	Student papers	UPN Veteran Yogyakarta on 2026-04-22	<1%
57	Student papers	Universitas Islam Riau on 2026-07-29	<1%
58	Student papers	Universitas Tarumanagara on 2025-12-24	<1%
59	Publication	Yonal Supit. "Penerapan Algoritma Support Vector Machine (SVM) untuk Deteksi ...	<1%
60	Internet	file.techscience.com	<1%
61	Student papers	UPN Veteran Yogyakarta on 2026-05-04	<1%
62	Student papers	Universitas Kristen Duta Wacana on 2026-04-14	<1%
63	Student papers	UPN Veteran Yogyakarta on 2026-05-04	<1%
64	Student papers	Universitas Dian Nuswantoro on 2026-01-09	<1%
65	Student papers	Universitas Gunadarma on 2025-09-25	<1%
66	Student papers	Universitas Sangga Buana YPKP on 2026-07-28	<1%
67	Internet	docplayer.info	<1%

68	Internet	iieta.org	<1%
69	Internet	repository.uinsaizu.ac.id	<1%
70	Internet	repository.unissula.ac.id	<1%
71	Publication	Siska Ayudia Adiyanti, Granit Agustina, Riva NurNatasya. "Strategi Self-Managem...	<1%
72	Internet	journal.darmajaya.ac.id	<1%
73	Internet	mafiadoc.com	<1%
74	Internet	sistemasi.ftik.unisi.ac.id	<1%
75	Publication	Adi Suryadi, Suhirman Suhirman. "Model Convolutional Neural Network berbasis ...	<1%
76	Student papers	Politeknik Manufaktur Negeri Bangka Belitung on 2024-10-31	<1%
77	Student papers	Politeknik Manufaktur Negeri Bangka Belitung on 2026-09-02	<1%
78	Student papers	Sriwijaya University on 2021-03-16	<1%
79	Student papers	Universitas Islam Riau on 2026-03-05	<1%
80	Student papers	Universitas Islam Riau on 2026-08-21	<1%
81	Student papers	Universitas Muhammadiyah Kotabumi on 2025-09-16	<1%

82	Student papers	Universitas Pamulang on 2026-04-08	<1%
83	Student papers	Universitas Pamulang on 2026-08-05	<1%
84	Student papers	Universitas Tarumanagara on 2025-12-19	<1%
85	Student papers	Universitas Tidar on 2025-10-20	<1%
86	Internet	ejournal.almaata.ac.id	<1%
87	Internet	ejurnal.swadharma.ac.id	<1%
88	Internet	inass.org	<1%
89	Internet	journal.unismuh.ac.id	<1%
90	Internet	jurnal.polinema.ac.id	<1%
91	Internet	pmc.ncbi.nlm.nih.gov	<1%
92	Internet	text-id.123dok.com	<1%
93	Publication	Elyas Anggara Pangestu, Fasya Salwa Fatiha, Rolis Ade Putra Dappa Loka, Nanan...	<1%
94	Student papers	Tarumanagara University on 2026-06-22	<1%
95	Student papers	Universitas Mercu Buana Yogyakarta on 2026-07-27	<1%

96	Student papers	University of Surrey on 2024-09-10	<1%
97	Internet	core.ac.uk	<1%
98	Internet	international.artei.or.id	<1%
99	Internet	prosiding.stekom.ac.id	<1%
100	Internet	scholar.archive.org	<1%
101	Student papers	Anna University on 2025-10-16	<1%
102	Publication	Dila Aura Putri, Ivana Lucia Kharisma, Somantri Somantri. "Implementasi Model ...	<1%
103	Student papers	FAKULTAS TEKNIK on 2026-07-28	<1%
104	Student papers	Forum Komunikasi Perpustakaan Perguruan Tinggi Kristen Indonesia (FKPPTKI) o...	<1%
105	Student papers	Telkom University on 2026-06-08	<1%
106	Student papers	UIN Sunan Gunung Djati Bandung on 2026-06-07	<1%
107	Student papers	Universitas Dian Nuswantoro on 2015-06-29	<1%
108	Student papers	Universitas Islam Riau on 2026-07-01	<1%
109	Student papers	Universitas Pertamina on 2022-08-10	<1%

110	Student papers	Universitas Tarumanagara on 2025-12-18	<1%
111	Student papers	University of Nairobi on 2025-10-08	<1%
112	Internet	cdn.juris.id	<1%
113	Internet	id.global.ieice.org	<1%
114	Internet	jurnal.kdi.or.id	<1%
115	Internet	repository.polibatam.ac.id	<1%
116	Internet	repository.syekhnurjati.ac.id	<1%
117	Internet	scholar.unand.ac.id	<1%
118	Student papers	Fakultas Teknologi Pertanian on 2026-02-19	<1%
119	Student papers	UNIVERSITAS BUDI LUHUR on 2025-07-23	<1%
120	Student papers	UPN Veteran Yogyakarta on 2026-04-30	<1%
121	Student papers	Universitas Islam Riau on 2025-12-17	<1%
122	Student papers	Universitas Islam Riau on 2026-07-20	<1%
123	Student papers	Universitas Khairun on 2026-07-13	<1%

124	Student papers	Universitas Muslim Indonesia on 2025-08-16	<1%
125	Internet	digilib.uinkhas.ac.id	<1%
126	Internet	jopi-journal.org	<1%
127	Internet	jurnal.polbangtanmanokwari.ac.id	<1%
128	Internet	repository.ubharajaya.ac.id	<1%
129	Internet	repository.unej.ac.id	<1%
130	Internet	repository.unjaya.ac.id	<1%
131	Internet	www.ijert.org	<1%
132	Internet	www.researchsquare.com	<1%
133	Publication	Azizah Azizah, Setio Ardy Nuswantoro, Firman Jaya, Rahmat Shofan Razaqi, Ansor...	<1%
134	Student papers	Badan PPSDM Kesehatan Kementerian Kesehatan on 2024-07-31	<1%
135	Student papers	East Union High School on 2026-06-30	<1%
136	Student papers	FAKULTAS ILMU KOMPUTER on 2026-07-09	<1%
137	Publication	Muhammad Sidiq Pramono, Aditya Permana Wibowo. "PENERAPAN CONVOLUTIO...	<1%

138	Publication	Rizqy Supriyadi, Muhamad Irfan, Rizki Dwi Hapijar, Fadil Abubakar et al. "PENGE...	<1%
139	Student papers	Tarumanagara University on 2026-06-20	<1%
140	Student papers	UPN Veteran Yogyakarta on 2026-01-06	<1%
141	Student papers	UPN Veteran Yogyakarta on 2026-02-27	<1%
142	Student papers	Universitas Brawijaya on 2017-08-03	<1%
143	Student papers	Universitas Brawijaya on 2018-07-20	<1%
144	Student papers	Universitas Brawijaya on 2021-03-30	<1%
145	Student papers	Universitas Khairun on 2026-08-14	<1%
146	Student papers	Universitas Muhammadiyah Purwokerto on 2025-05-20	<1%
147	Student papers	Universitas Pamulang on 2025-07-12	<1%
148	Student papers	Universitas Pamulang on 2026-07-08	<1%
149	Student papers	Universitas Pendidikan Ganesha on 2025-01-25	<1%
150	Internet	gameandroidmodterbaik.blogspot.com	<1%
151	Internet	hostjournals.com	<1%

152	Internet	journal.isi.ac.id	<1%
153	Internet	jtit.polije.ac.id	<1%
154	Internet	moam.info	<1%
155	Internet	ojs.uajy.ac.id	<1%
156	Internet	repository.bku.ac.id	<1%
157	Internet	uisi-repository.sgp1.cdn.digitaloceanspaces.com	<1%
158	Internet	www.coursehero.com	<1%
159	Internet	www.ejournal.itn.ac.id	<1%
160	Publication	Christian Richie Wijaya, Muhammad Rizky Pribadi. "Klasifikasi Penyakit Tanaman..."	<1%
161	Student papers	Dr. B R Ambedkar National Institute of Technology, Jalandhar on 2023-05-17	<1%
162	Student papers	East Union High School on 2026-06-29	<1%
163	Student papers	UIN Sjech M.Djamil Djambek Bukittinggi on 2026-07-10	<1%
164	Student papers	UPN Veteran Yogyakarta on 2026-05-05	<1%
165	Student papers	Universitas Islam Riau on 2025-10-17	<1%

166	Student papers	Universitas Musamus Merauke on 2026-07-09	<1%
167	Student papers	Universitas Tarumanagara on 2025-12-12	<1%
168	Student papers	Universitas Trisakti on 2026-07-19	<1%
169	Publication	A. Anitha rani. "SUGARCANE DISEASE DIAGNOSIS UTILIZING A COMBINED RESNET...	<1%
170	Student papers	Institut Pertanian Bogor on 2026-08-27	<1%
171	Student papers	Institut Teknologi Sumatera on 2026-07-30	<1%
172	Publication	Nicholas Bagus Pamungkas, Agus Suhendar. "Penerapan Metode Convolutional ...	<1%
173	Student papers	UIN Sultan Syarif Kasim Riau on 2020-06-04	<1%
174	Student papers	Universitas Brawijaya on 2018-07-20	<1%
175	Student papers	Universitas Brawijaya on 2019-06-28	<1%
176	Student papers	Universitas Islam Riau on 2026-04-28	<1%
177	Student papers	Universitas Islam Riau on 2026-07-08	<1%
178	Student papers	Universitas Negeri Jakarta on 2025-07-29	<1%
179	Student papers	Universitas Pamulang on 2026-06-06	<1%

180

Student papers

Universitas Pamulang on 2026-07-03

<1%

181

Student papers

Universitas Putera Batam on 2026-02-03

<1%

182

Student papers

Universitas Sangga Buana YPKP on 2026-07-20

<1%

**KLASIFIKASI PENYAKIT TANAMAN TEBU BERDASARKAN
CITRA DAUN MENGGUNAKAN MODEL DEEP LEARNING
CONVNEXT V2**

SKRIPSI



Disusun Oleh :

AGUNG

403221010076

**PROGRAM STUDI SISTEM INFORMASI
FAKULTAS TEKNIK DAN ILMU KOMPUTER
UNIVERSITAS ISLAM INDRAGIRI
TEMBILAHAN
2025**

**KLASIFIKASI PENYAKIT TANAMAN TEBU BERDASARKAN
CITRA DAUN MENGGUNAKAN MODEL DEEP LEARNING
CONVNEXT V2**

**CLASSIFICATION OF SUGARCANE PLANT DISEASES
BASED ON LEAF IMAGES USING THE CONVNEXT V2 DEEP
LEARNING MODEL**

TUGAS AKHIR

Diajukan Untuk Memenuhi Sebagian Persyaratan
Mencapai Gelar Sarjana Strata (S1) Komputer
Pada Program Studi Sistem Informasi



Disusun Oleh :

AGUNG

403221010076

**PROGRAM STUDI SISTEM INFORMASI
FAKULTAS TEKNIK DAN ILMU KOMPUTER
UNIVERSITAS ISLAM INDRAGIRI
TEMBILAHAN
2025**

PERNYATAAN

Dengan ini saya menyatakan bahwa skripsi yang berjudul “Klasifikasi Penyakit Tanaman Tebu Berdasarkan Citra Daun Menggunakan Model Deep Learning ConvNeXt V2” ini benar-benar merupakan hasil karya saya sendiri dan belum pernah diajukan untuk memperoleh gelar akademik apa pun, baik di Universitas Islam Indragiri maupun di perguruan tinggi lain.

Setiap kutipan, data, maupun pendapat pihak lain yang digunakan dalam penulisan skripsi ini telah saya cantumkan sumbernya sesuai dengan kaidah penulisan ilmiah yang berlaku. Saya bertanggung jawab penuh atas seluruh isi tulisan ini, dan bersedia menerima konsekuensi akademik sesuai peraturan yang berlaku apabila di kemudian hari terbukti terdapat pelanggaran, termasuk tindakan plagiarisme, dalam karya ini.

Tembilahan, 05 September 2026

Agung
NIM : 403221010076

6

KATA PENGANTAR

Puji dan syukur penulis panjatkan kehadiran Allah SWT atas segala limpahan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Klasifikasi Penyakit Tanaman Tebu Berdasarkan Citra Daun Menggunakan Model Deep Learning ConvNeXt V2”. Skripsi ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer pada Program Studi Sistem Informasi, Fakultas Teknik dan Ilmu Komputer, Universitas Islam Indragiri.

Skripsi ini menguraikan hasil penelitian mengenai penerapan arsitektur ConvNeXt V2 Tiny dalam mengklasifikasikan lima kondisi daun tebu, yaitu Busuk Merah, Mozaik, Karat, daun sehat, dan daun menguning. Penelitian mencakup tahap pengumpulan dan pengolahan dataset, pelatihan model menggunakan strategi Stratified K-Fold Cross Validation, evaluasi performa model pada data uji lapangan, perbandingan dengan arsitektur CNN lain, hingga implementasi sistem ke dalam aplikasi berbasis web SugarScan yang dapat digunakan langsung oleh petani. Penulis menyadari bahwa penyusunan skripsi ini tidak lepas dari bantuan, bimbingan, dan dukungan berbagai pihak. Oleh karena itu, pada kesempatan ini penulis ingin mengucapkan terima kasih kepada:

1. Bapak Dr. H. Najamuddin, Lc., MA, selaku Rektor Universitas Islam Indragiri, atas dukungan yang diberikan selama penulis menempuh pendidikan di Universitas Islam Indragiri.
2. Bapak Dr. Bayu Rianto, S.SI., M.Kom, selaku Dekan Fakultas Teknik dan Ilmu Komputer, atas arahan dan dukungannya dalam penyelesaian skripsi ini.

3. Ibu Fitri Yunita, S.SI., M. Kom., selaku Ketua Program Studi Sistem Informasi dan juga selaku Dosen Pembimbing Utama, atas bimbingan, saran, dan waktu yang telah diluangkan selama proses penyusunan skripsi ini.

4. Usman, S.T, M.Kom, selaku Dosen Pembimbing Pendamping, atas masukan dan arahan yang diberikan.

5. Seluruh Dosen dan Staf Program Studi Sistem Informasi yang telah membekali penulis dengan ilmu pengetahuan selama masa perkuliahan.

6. Ibunda Hasmiati dan Kakak saya Rahmawati Indra Lestari serta keluarga penulis, atas doa, dukungan, dan motivasi yang tiada henti.

7. Rekan-rekan seperjuangan CTN Calling Pajar, Panja, Fawwaz, Rizkan, Fezli, Amel, Maria, Afriandi dan Ari, yang senantiasa membantu, menemani, dan berbagi pemikiran selama proses penyusunan skripsi ini.

Penulis menyadari bahwa skripsi ini masih jauh dari sempurna dan memerlukan penyempurnaan lebih lanjut. Oleh karena itu, kritik dan saran yang membangun sangat penulis harapkan. Semoga skripsi ini dapat bermanfaat dan menjadi langkah awal yang baik bagi penelitian selanjutnya.

Tembilahan, 05 September 2026

Agung
NIM : 403221010076

ABSTRAK

Produktivitas tebu, komoditas penting bagi petani dan pelaku UMKM di Tembilahan, kerap terganggu oleh penyakit seperti Busuk Merah, Mozaik, dan Karat yang sulit dikenali secara cepat dan akurat melalui inspeksi visual manual. Penelitian ini mengembangkan sistem klasifikasi penyakit tanaman tebu berbasis citra daun menggunakan arsitektur deep learning ConvNeXt V2 Tiny untuk lima kelas, yaitu Busuk Merah, Mozaik, Karat, daun sehat, dan daun menguning. Dataset penelitian berjumlah 2.948 citra, berasal dari kombinasi data primer di lapangan dan data sekunder dari Kaggle. Model dilatih menggunakan pendekatan transfer learning dengan skema Stratified K-Fold Cross Validation (K=6), sementara data lapangan digunakan sebagai data uji yang terpisah dan tidak pernah dilihat model selama pelatihan. Hasil pelatihan menunjukkan rata-rata val_accuracy sebesar $98,49\% \pm 0,58\%$ pada seluruh fold. Pada tahap pengujian akhir, model ensemble dari fold-fold terbaik berhasil mencapai akurasi sebesar 96,25% dengan precision, recall, dan F1-score yang tinggi dan seimbang di seluruh kelas. Performa ini juga unggul dibandingkan arsitektur CNN lain, yaitu ResNet-50 (87,35%) dan EfficientNetV2-S (83,37%). Sistem klasifikasi ini selanjutnya diimplementasikan ke dalam aplikasi web SugarScan, yang memungkinkan petani mengunggah atau memotret daun tebu dan memperoleh hasil diagnosis beserta rekomendasi penanganan secara langsung. Penelitian ini membuktikan bahwa ConvNeXt V2 efektif dan praktis digunakan untuk deteksi dini penyakit tanaman tebu.

Kata Kunci: ConvNeXt V2, deep learning, klasifikasi citra, penyakit tebu, computer vision

ABSTRACT

Sugarcane productivity, vital to farmers and small businesses in Tembilahan, is frequently disrupted by diseases such as Red Rot, Mosaic, and Rust, which are difficult to identify quickly and accurately through manual visual inspection. This study developed a leaf-image-based classification system for sugarcane diseases using the ConvNeXt V2 Tiny deep learning architecture across five classes: Red Rot, Mosaic, Rust, healthy leaves, and yellow leaves. The dataset consisted of 2,948 images, combining field-collected primary data with a secondary dataset from Kaggle. The model was trained using a transfer learning approach with a Stratified K-Fold Cross Validation scheme (K=6), while field-collected data was reserved as a separate test set never seen by the model during training. Training results showed an average val_accuracy of $98.02\% \pm 0.59\%$ across all folds. In the final evaluation, the ensemble of the best-performing folds achieved an accuracy of 96,25%, with high and balanced precision, recall, and F1-score across all classes. This performance also outperformed other CNN architectures, namely ResNet-50 (87.35%) and EfficientNetV2-S (83.37%). The resulting classification system was implemented as the SugarScan web application, allowing farmers to upload or capture leaf images and instantly receive a diagnosis along with treatment recommendations. This study demonstrates that ConvNeXt V2 is both effective and practical for the early detection of sugarcane diseases.

Keywords: *ConvNeXt V2, deep learning, image classification, sugarcane disease, computer vision*

DAFTAR ISI

DAFTAR ISI	v
DAFTAR TABEL	viii
DAFTAR GAMBAR	ix
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Batasan Penelitian	3
1.4 Tujuan Penelitian	4
1.5 Manfaat Penelitian	4
1.6 Sistematika Penulisan	5
BAB II TINJAUAN LITERATUR	7
2.1 Deep Learning	7
2.2 Convolutional Neural Network (CNN)	8
2.3 Transfer Learning	10
2.4 Masked Autoencoder (MAE)	11
2.5 ConvNeXt Dan Variannya	12
2.6 Confusion Matrix	15
2.7 Penelitian Terdahulu	16
BAB III METODE PENELITIAN	28
3.1 Kerangka Penelitian	28
3.1.1 Studi Literatur	29
3.1.2 Pengumpulan Data	30
3.1.3 Pembagian Data	32
3.1.4 Melatih Model Convnext V2 Tiny	33
3.1.5 Metode Evaluasi Model Dengan Confusion Matrix	36
3.1.6 Perancangan Sistem	38
3.1.7 Implementasi Sistem	39
BAB IV HASIL DAN PEMBAHASAN	40
4.1 Persiapan dan Analisis Dataset	40

96	4.1.1 Komposisi Dataset	40
	4.1.2 Pembagian Dataset	41
	4.1.3 Preprocessing dan Augmentasi Data	42
	4.2 Hasil Pelatihan Model ConvNeXt V2 Tiny	43
	4.2.1 Konfigurasi Pelatihan	43
12	4.2.2 Hasil Pelatihan Berdasarkan Fold	45
	4.3 Evaluasi Model Menggunakan Confusion Matrix	46
	4.3.1 Hasil Confusion Matrix	46
	4.3.2 Metrik Evaluasi Per Kelas	47
	4.4 Perbandingan Performa dengan Model CNN Lainnya	48
	4.4.1 ResNet-50	49
	4.4.2 EfficientNetV2-S	52
	4.4.3 Ringkasan Perbandingan	54
73	4.5 Implementasi Sistem Berbasis Web	55
	4.5.1 Arsitektur Sistem	56
	4.5.2 Tampilan Antarmuka Pengguna	59
21	4.5.3 Pengujian Sistem	61
	BAB V KESIMPULAN DAN SARAN	63
	5.1 Kesimpulan	63
	5.2 Saran	65
	DAFTAR PUSTAKA	66
	LAMPIRAN	72

DAFTAR TABEL

Tabel 2.1 Penelitian Terdahulu.....	17
Tabel 3.1 Sampel Data	31
Tabel 3.2 Pembagian Dataset Training, Validasi, dan Testing	32
Tabel 4.1 Distribusi Keseluruhan Dataset.....	41
Tabel 4.2 Pembagian Dataset Training, Validasi, dan Testing	42
Tabel 4.3 Konfigurasi Hyperparameter Pelatihan.....	44
Tabel 4.4 Hasil Pelatihan K-Fold Cross Validation (K=6).....	45
Tabel 4.5 Metrik Evaluasi Per Kelas Model ConvNeXt V2 Tiny	48
Tabel 4.6 Hasil Pelatihan K-Fold Cross Validation ResNet-50 (K=6)	49
Tabel 4.7 Metrik Evaluasi Per Kelas Model ResNet-50	51
Tabel 4.8 Hasil Pelatihan K-Fold Cross Validation EfficientNetV2-S (K=6)	52
Tabel 4.9 Metrik Evaluasi Per Kelas Model EfficientNetV2-S	54
Tabel 4.10 Ringkasan Perbandingan Performa Ketiga Model CNN	55
Tabel 4.11 Hasil Pengujian Fungsional Sistem.....	62

DAFTAR GAMBAR

142	Gambar 3.1 Kerangka Penelitian	29
	Gambar 3.2 Alur Kerja Convnext V2 Tiny	33
36	Gambar 4.1 Confusion Matrix Model ConvNeXt V2 Tiny pada Data Testing	47
36	Gambar 4.2 Confusion Matrix Model ResNet-50 pada Data Testing	50
36	Gambar 4.3 Confusion Matrix Model EfficientNetV2-S pada Data Testing	53
22	Gambar 4.4 Use Case Diagram Sistem Klasifikasi Penyakit Tanaman Tebu	57
48 182	Gambar 4.5 Activity Diagram Sistem Klasifikasi Penyakit Tanaman Tebu	58
	Gambar 4.6 Halaman Utama Aplikasi Web SugarScan	59
	Gambar 4.7 Halaman Diagnosa Area Unggah dan Ambil Foto	60
22	Gambar 4.8 Halaman Database Penyakit Lima Kondisi yang Terdeteksi	61

BAB I

PENDAHULUAN

1.1 Latar Belakang

Tanaman tebu merupakan komoditas pertanian penting sebagai sumber utama produksi gula putih dan *biofuel*. Di Tembilahan, Kabupaten Indragiri Hilir, Riau, Ada UMKM yang menggantungkan usahanya pada bahan baku tebu segar, seperti usaha es tebu yang menjadi minuman khas dan favorit masyarakat lokal. Produktivitas tebu sangat dipengaruhi oleh serangan penyakit yang dapat menurunkan kualitas dan kuantitas hasil panen secara signifikan. Busuk Merah (*Red rot*), Mozaik (*mosaic*), dan Karat (*rust*) adalah tiga penyakit utama yang paling merugikan dan dapat diidentifikasi melalui gejala visual pada daun. Busuk Merah (*Red rot*) menimbulkan lesi nekrotik kemerahan dengan tepi bergelombang pada daun, diikuti pembusukan batang internal berwarna merah. Mozaik (*Mosaic*) menghasilkan pola garis-garis hijau muda hingga kuning pada permukaan daun disertai pertumbuhan terhambat. Karat (*Rust*) ditandai dengan pustula coklat kemerahan hingga oren pada permukaan daun yang menyebar ke seluruh helai daun, menyebabkan pengeringan prematur dan menurunnya kapasitas fotosintesis[1].

Salah satu permasalahan yang dihadapi petani tebu adalah keterbatasan dalam mengidentifikasi penyakit secara dini dan akurat. Metode konvensional yang masih bergantung pada inspeksi visual manual memiliki kelemahan yaitu yang pertama membutuhkan waktu lama, memerlukan keahlian khusus yang tidak semua petani miliki, rentan kesalahan akibat subjektivitas, dan seringkali terlambat sehingga

penyakit sudah menyebar luas. Keterbatasan ini bisa berdampak pada pendapatan UMKM es tebu dan pelaku usaha lainnya yang bergantung pada kualitas tebu [2].

Perkembangan teknologi kecerdasan buatan, khususnya *deep learning*, membuka peluang untuk mengotomatisasi klasifikasi penyakit tanaman dengan tingkat akurasi tinggi. *Convolutional Neural Networks (CNN)* telah terbukti sangat efektif dalam klasifikasi citra penyakit tanaman. Penelitian terbaru menunjukkan berbagai arsitektur CNN seperti *EfficientNet*, *DenseNet*, dan *MobileNet* berhasil mengklasifikasikan berbagai penyakit tanaman[3].

ConvNeXt V2 merupakan arsitektur deep learning terbaru yang diperkenalkan Sanghyun Woo dkk. pada konferensi *CVPR 2023*. Arsitektur ini menggabungkan keunggulan konvolusi murni dengan *self-supervised learning* dan memperkenalkan lapisan *Global Response Normalization (GRN)* yang inovatif. *ConvNeXt V2* mencapai akurasi 88,9% pada dataset *ImageNet-1K*, melampaui berbagai arsitektur *Vision Transformer* dengan efisiensi komputasi lebih baik. Model ini tersedia dalam berbagai ukuran, dari *Atto* (3,7 juta parameter) hingga *Huge* (650 juta parameter), memberikan fleksibilitas untuk berbagai kebutuhan[4].

Meskipun *ConvNeXt V2* menunjukkan performa superior pada berbagai tugas computer vision, penerapannya untuk klasifikasi penyakit tebu, khususnya yang fokus pada konteks lokal, masih sangat terbatas. Penelitian tentang klasifikasi penyakit tebu masih didominasi arsitektur CNN konvensional. Oleh karena itu, penelitian ini penting untuk mengisi kesenjangan tersebut dengan mengimplementasikan *ConvNeXt V2* untuk mengidentifikasi penyakit Busuk merah (*red rot*), Mozaik (*Mosaic*), dan Karat (*rust*) serta 2 kelas tambahan yaitu sehat (*Healthy*) dan Kekuningan (*Yellow Leaf*) pada daun tebu. Diharapkan

penelitian ini dapat memberikan solusi praktis bagi petani dan UMKM tebu di Tembilahan dan wilayah sekitarnya untuk mengidentifikasi penyakit secara dini, sehingga dapat menjaga kualitas bahan baku dan keberlanjutan usaha mereka.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, rumusan masalah dalam penelitian ini adalah:

1. Bagaimana membangun sistem klasifikasi penyakit tanaman tebu menggunakan model *ConvNeXt V2*?
2. Bagaimana performa akurasi model *ConvNeXt V2* dalam mengklasifikasikan penyakit yang dibagi menjadi 5 kelas pada citra daun tebu?
3. Bagaimana perbandingan performa model *ConvNeXt V2* dengan arsitektur model CNN lainnya dalam klasifikasi penyakit daun tebu?
4. Bagaimana perancangan dan implementasi sistem berbasis web untuk klasifikasi penyakit tanaman tebu menggunakan model *ConvNeXt V2*?

1.3 Batasan Penelitian

Agar penelitian lebih fokus dan terarah, ditetapkan batasan penelitian sebagai berikut:

1. Klasifikasi dibatasi 5 kategori kondisi daun tebu yaitu Sehat (*Healthy*), Busuk Merah (*Red rot*), Mozaik (*Mosaic*), Karat (*rust*), dan Kekuningan (*Yellow leaf*) pada daun tebu.
2. Dataset yang digunakan adalah citra daun tebu yang diperoleh dari lapangan dan *Sugarcane Leaf Dataset (SLD)* yang tersedia secara publik.
3. Model yang digunakan adalah *ConvNeXt V2* dengan varian ukuran *Tiny*.

4. Evaluasi performa model menggunakan *confusion matrix* akurasi, *precision*, *recall*, dan *F1-score*.

1.4 Tujuan Penelitian

Tujuan yang ingin dicapai dalam penelitian ini adalah:

1. Membangun sistem klasifikasi penyakit tanaman tebu menggunakan model *ConvNeXt V2*.
2. Menganalisis performa model *ConvNeXt V2* dalam mengklasifikasikan penyakit pada daun tebu yang dibagi dalam 5 kelas.
3. Membandingkan performa model *ConvNeXt V2* dengan model CNN lainnya seperti *ResNet-50* dan *EfficientNetV2-S* untuk klasifikasi penyakit berdasarkan citra daun tebu.
4. Merancang dan mengimplementasikan sistem klasifikasi penyakit tanaman tebu menggunakan model *ConvNeXt V2* berbasis web.

1.5 Manfaat Penelitian

Penelitian ini diharapkan memberikan manfaat sebagai berikut:

1. Memberikan kontribusi ilmiah dalam bidang computer vision dan deep learning, khususnya penerapan *ConvNeXt V2* untuk klasifikasi penyakit tanaman.
2. Memperkaya literatur penelitian tentang sistem klasifikasi penyakit tanaman tebu menggunakan teknologi kecerdasan buatan.
3. Menyediakan sistem klasifikasi penyakit tebu yang akurat dan efisien untuk membantu petani dalam identifikasi jenis penyakit sejak dini.

4. Mengurangi ketergantungan pada inspeksi manual oleh ahli patologi yang memerlukan waktu lama dan biaya tinggi.

1.6 Sistematika Penulisan

Pada bagian ini dituliskan urutan dan sistematika penulisan yang dilakukan. Berikut ringkasan mengenai isi masing-masing bab:

BAB I PENDAHULUAN

Bab ini berisi latar belakang penelitian, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, dan sistematika penulisan.

BAB II TINJAUAN LITERATUR

Bab ini berisi kajian teori yang relevan meliputi: tanaman tebu dan penyakitnya, *deep learning*, CNN, *ConvNeXt V2*, *transfer learning*, dan penelitian terkait.

BAB III METODE PENELITIAN

Bab ini menjelaskan metode penelitian meliputi: kerangka penelitian, tahapan penelitian, dataset, arsitektur model, proses training, dan metrik evaluasi.

BAB IV HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil implementasi dan pengujian sistem klasifikasi penyakit tanaman tebu. Pembahasan mencakup persiapan dataset, hasil pelatihan model *ConvNeXt V2 Tiny* menggunakan strategi *Stratified K-Fold Cross Validation* ($K=6$), evaluasi performa model menggunakan confusion matrix dan metrik akurasi, precision, recall, serta F1-score pada data uji lapangan, perbandingan performa dengan

model CNN lainnya (ResNet-50 dan EfficientNetV2-S), serta implementasi sistem berbasis web yang dikembangkan.

BAB V KESIMPULAN DAN SARAN

Bab ini berisi kesimpulan yang diperoleh dari hasil penelitian dan pengujian sistem, serta saran untuk pengembangan penelitian selanjutnya dalam bidang klasifikasi penyakit tanaman tebu menggunakan teknologi deep learning.

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

124 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].

88 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].

47 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

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].

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%,

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,

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*

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

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,

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

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

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)

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].

151 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. 164 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

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 tingkatkan 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 identifikasi 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) gabungkan 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 gabungkan 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 kurang akurasi, dan belum ada analisis interpretasi model untuk jelaskan hasil prediksi ke petani yang penting untuk bangun kepercayaan[29].

Penelitian Kunduracioğlu & 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 pertimbangkan 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].

114 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%+.

118 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

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.

BAB III


METODE PENELITIAN

Bab ini menjelaskan secara rinci pendekatan dan langkah-langkah yang digunakan dalam penelitian untuk mengembangkan sistem klasifikasi penyakit tanaman tebu berbasis citra daun menggunakan model ConvNeXt V2 Tiny. Penelitian ini bertujuan untuk membantu petani dan petugas pertanian dalam mengidentifikasi penyakit tanaman tebu secara dini dan akurat melalui analisis visual daun. Proses pengembangan dilakukan melalui beberapa tahapan sistematis, mulai dari studi literatur, pengumpulan data citra daun tebu, pembagian data menjadi set training, validasi, dan testing, pelatihan model dengan transfer learning dan fine-tuning melalui proses iteratif antara training dan validasi, implementasi klasifikasi penyakit, hingga evaluasi performa model menggunakan confusion matrix dan metrik evaluasi lainnya. Setiap tahapan dirancang agar mendukung pencapaian sistem yang akurat, robust terhadap variasi kondisi citra lapangan, serta dapat diimplementasikan sebagai solusi praktis untuk monitoring kesehatan tanaman tebu.

3.1 Kerangka Penelitian

Dalam rangka mendukung pelaksanaan penelitian ini agar lebih terarah dan sistematis, diperlukan suatu kerangka kerja penelitian yang tersusun secara terstruktur. Kerangka kerja ini mencakup tahapan-tahapan penelitian yang bertujuan untuk memberikan panduan dari tahap awal hingga tahap akhir penelitian. Dengan adanya kerangka kerja ini, proses penelitian dapat berjalan secara terorganisasi dan sesuai dengan tujuan yang telah ditetapkan. Tahapan-tahapan tersebut dirancang untuk memastikan bahwa setiap langkah yang dilakukan

memberikan kontribusi nyata terhadap pencapaian hasil yang diinginkan. Secara visual, tahapan-tahapan dalam penelitian ini disajikan pada Gambar 3.1.



Gambar 3.1 Kerangka Penelitian

Berdasarkan kerangka penelitian pada Gambar 3.1, penelitian ini dilakukan melalui tahapan-tahapan sistematis sebagai berikut

3.1.1 Studi Literatur

Studi literatur dilakukan untuk memahami landasan teoritis dan pendekatan teknis yang relevan dengan pengembangan sistem klasifikasi penyakit tanaman tebu menggunakan model ConvNeXtV2. Kajian ini mencakup teori deep learning, khususnya teknik klasifikasi citra menggunakan Convolutional Neural Network


(CNN), arsitektur ConvNeXtV2 sebagai model state-of-the-art yang menggabungkan keunggulan Vision Transformer dengan efisiensi CNN, serta implementasi transfer learning untuk mengatasi keterbatasan dataset. Selain itu, literatur yang dikaji juga mencakup metode preprocessing citra seperti augmentasi data, normalisasi, dan resizing, serta teknik evaluasi model klasifikasi menggunakan confusion matrix untuk mengukur akurasi, precision, recall, dan F1-score. Studi literatur juga mencakup kajian terhadap penelitian-penelitian terdahulu yang menggunakan deep learning untuk penyakit tanaman, seperti klasifikasi penyakit daun padi, deteksi penyakit jagung berbasis citra, identifikasi hama dan penyakit tebu, hingga perbandingan performa berbagai arsitektur CNN (ResNet, EfficientNet ConvNeXt) dalam computer vision pertanian.

3.1.2 Pengumpulan Data

Tahap pengumpulan data dilakukan untuk memperoleh dataset berupa citra daun penyakit. Data dikumpulkan dari dua sumber utama, yaitu data primer dari salah satu kebun tebu yang ada di tembilahan dan data sekunder dari dataset public Kaggle yang berisi citra penyakit tanaman tebu. Data primer diperoleh langsung dari lapangan, dengan memotret daun-daun yang terindikasi penyakit berdasarkan kelasnya. Sementara itu, data sekunder diperoleh dari dataset publik di platform Kaggle yang menyediakan dataset citra penyakit tanaman tebu. Dataset ini disesuaikan dengan kebutuhan penelitian yang diperoleh dari (<https://www.kaggle.com/datasets/pritpal2873/sugarcane-leaf-disease-dataset>), kemudian digabungkan dengan data lapangan untuk menghasilkan dataset yang lebih komprehensif.

3

Tabel 3.1 Sampel Data

Citra Daun	Nama Kelas Penyakit	Jumlah Data Kaggle	Jumlah Data Lapangan
	Busuk Merah (<i>Red Rot</i>)	518	97
	Mosaik (<i>Mosaic</i>)	462	68
	Karat (<i>Rust</i>)	514	89
	Kekuningan (<i>Yellow Leaf</i>)	505	76
	Sehat (<i>Healthy</i>)	522	97

3.1.3 Pembagian Data

Dataset dibagi menjadi dua bagian utama: data Kaggle sebanyak 2.521 citra digunakan sebagai data training dan validasi melalui skema Stratified K-Fold Cross Validation dengan K=6 fold, sedangkan data lapangan sebanyak 427 citra ditetapkan sebagai data uji yang bersifat tetap dan tidak ikut dalam proses K-Fold. Pemisahan ini dilakukan untuk memastikan evaluasi akhir model dilakukan pada data yang benar-benar belum pernah dilihat oleh model selama pelatihan. Rincian pembagian ditampilkan pada Tabel 3.2.


Tabel 3.2 Pembagian Dataset Training, Validasi, dan Testing

No	Kelas Penyakit	Data Train	Data Test Lapangan	Total
1	Busuk Merah (Red Rot)	518	97	615
2	Mosaik (Mosaic)	462	68	530
3	Karat (Rust)	514	89	603
4	Kekuningan (Yellow Leaf)	505	76	581
5	Sehat (Healthy)	522	97	619
Total		2.521	427	2.948

Pada setiap iterasi K-Fold, data Kaggle (2.521 citra) dibagi secara otomatis menjadi data training (sekitar 5/6 bagian, ± 2.100 citra) dan data validasi (sekitar 1/6 bagian, ± 420 citra) dengan stratifikasi untuk menjaga proporsi kelas tetap seimbang di setiap subset.

3.1.4 Melatih Model Convnext V2 Tiny

Proses klasifikasi penyakit tanaman tebu menggunakan model Convnext V2 versi tiny dilakukan secara sistematis melalui serangkaian tahapan yang saling berkaitan dan terintegrasi.



Gambar 3.2 Alur Kerja Convnext V2 Tiny

Berdasarkan Gambar 3.2 Model ConvNeXt v2 memproses gambar melalui empat tahap bertingkat yang terstruktur secara hierarkis. Gambar masukan pertama kali melewati lapisan awal yang berfungsi mengubah data gambar mentah menjadi komponen visual dasar berupa deteksi tepi, garis, dan distribusi warna yang dapat diproses lebih lanjut oleh jaringan.

Pada Tahap 1, gambar masih mempertahankan ukuran yang tinggi sehingga detail-detail halus dapat dianalisis secara menyeluruh. Data diproses melalui 3 Blok ConvNeXt v2 secara berurutan yang mengambil ciri-ciri tingkat dasar dari gambar. Ciri-ciri yang diambil pada tahap ini mencakup informasi tekstur, pola lokal, dan karakteristik visual yang sangat detail. Ukuran yang masih besar pada tahap ini

memungkinkan model untuk menangkap nuansa visual yang halus dan informasi spasial yang presisi.

Perpindahan dari Tahap 1 ke Tahap 2 melibatkan operasi pengurangan ukuran pertama yang mengurangi dimensi gambar sambil meningkatkan kedalaman informasi. Proses ini mengubah fokus pemrosesan dari detail tingkat kecil menjadi bentuk yang lebih ringkas dengan mempertahankan informasi penting yang relevan. Tahap 2 kemudian memproses data yang telah mengalami pengurangan ukuran melalui 3 Blok ConvNeXt v2. Pada ukuran yang lebih kecil ini, model tidak lagi fokus pada detail tekstur halus melainkan mulai mengenali pola-pola struktural yang lebih besar, bentuk geometris, pola distribusi warna, dan hubungan antar area dalam gambar. Pengurangan ukuran ini juga meningkatkan efisiensi komputasi karena jumlah operasi yang diperlukan berkurang secara signifikan.

Tahap 3 merupakan komponen terpenting dalam arsitektur ConvNeXt v2. Sebelum memasuki tahap ini, dilakukan pengurangan ukuran kedua yang kembali mengurangi dimensi gambar dan meningkatkan kedalaman informasi, menghilangkan detail-detail kecil yang tidak lagi relevan untuk pemahaman tingkat tinggi. Tahap 3 memproses data melalui 9 Blok ConvNeXt v2, jumlah terbanyak dibandingkan tahap-tahap lainnya. Jumlah blok yang lebih banyak pada tahap ini memberikan kemampuan yang lebih tinggi untuk mengambil ciri-ciri kompleks. Model melakukan analisis mendalam untuk mengenali objek secara utuh, memahami konteks, dan membedakan kategori objek berdasarkan karakteristik tingkat tinggi. Proses pengambilan ciri pada tahap ini menghasilkan informasi yang tidak hanya menangkap keberadaan objek tetapi juga sifat-sifat yang membedakan satu kategori dari kategori lainnya.

Pengurangan ukuran ketiga dilakukan sebelum Tahap 4, menghasilkan data dengan ukuran paling kecil namun dengan kedalaman informasi paling tinggi. Tahap 4 sebagai tahap terakhir memproses data melalui 3 Blok ConvNeXt v2 akhir yang melakukan penyempurnaan terhadap informasi yang sudah sangat ringkas. Pemrosesan pada tahap ini mengintegrasikan seluruh informasi yang telah diambil dari tahap-tahap sebelumnya untuk menghasilkan hasil akhir yang optimal untuk berbagai tugas pengenalan visual.

Setiap Blok ConvNeXt v2 dalam arsitektur ini memiliki struktur internal yang terdiri dari beberapa komponen yang bekerja secara berurutan. Lapisan konvolusi dengan ukuran 7×7 melakukan pengambilan ciri spasial yang menangkap informasi kontekstual lokal dari area yang cukup besar. Normalisasi lapisan kemudian diterapkan untuk menyeimbangkan distribusi data sehingga menstabilkan proses pelatihan. Konvolusi 1×1 pertama melakukan peningkatan dimensi untuk meningkatkan kemampuan model dalam menangkap variasi ciri yang kompleks. Fungsi aktivasi diterapkan setelah peningkatan dimensi untuk memperkenalkan kemampuan model mempelajari pola non-linear yang lebih kompleks.

Setelah aktivasi, data melewati modul Normalisasi Respons Global yang merupakan inovasi utama pada ConvNeXt v2. Modul ini melakukan normalisasi berdasarkan respons keseluruhan dari data, meningkatkan persaingan antar saluran sehingga saluran yang membawa informasi penting diperkuat sedangkan yang kurang informatif ditekan. Mekanisme ini meningkatkan kemampuan model dalam memilih ciri-ciri yang relevan. Konvolusi 1×1 kedua kemudian melakukan proyeksi untuk mengembalikan dimensi ke ukuran yang sesuai. Komponen terakhir adalah koneksi langsung yang menambahkan masukan blok langsung ke keluaran setelah

semua transformasi dilakukan. Koneksi langsung ini memfasilitasi aliran informasi yang lebih baik selama pelatihan, mengatasi masalah hilangnya informasi pada jaringan yang sangat dalam, dan memungkinkan model untuk mempelajari perubahan yang lebih mudah dioptimasi.

Desain bertingkat dengan pengurangan ukuran bertahap pada arsitektur ConvNeXt v2 memungkinkan model untuk mengambil informasi dari berbagai tingkat detail. Tahap-tahap awal dengan ukuran tinggi menangkap detail lokal dan tekstur halus, sementara tahap-tahap akhir dengan ukuran kecil menangkap struktur global dan hubungan antar objek. Kombinasi informasi dari berbagai tingkat ini memberikan model kemampuan untuk menangani berbagai ukuran objek dan kompleksitas visual dalam gambar masukan, menjadikan ConvNeXt v2 sebagai arsitektur yang efektif untuk berbagai tugas pengenalan visual yang memerlukan pemahaman mendalam dan akurat.

3.1.5 Metode Evaluasi Model Dengan Confusion Matrix

Untuk mengetahui kualitas dari model bisa dilihat dari nilai confusion matrix yang bertujuan untuk menganalisis tingkat accuracy, precision, recall, dan F1-Score. Untuk memahami metrik yang digunakan sebelumnya akan didefinisikan terlebih dahulu bahwa *true positif* (TP) didefinisikan sebagai data positif yang diprediksi positif, *true negative* (TN) yang didefinisikan sebagai data negative yang diprediksi negative, *false positif* (FP) yang didefinisikan sebagai data negative yang diprediksi positif, dan *false negative* (FN) yang didefinisikan sebagai data positif yang diprediksi negative.

Dibawah ini menunjukkan rumus perhitungan dari *accuracy*, *precision*, *recall*, dan *f1-score*:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Persamaan (1) menunjukkan rumus *Accuracy* yang dihitung dengan menjumlahkan *True Positive* (TP) dan *True Negative* (TN), kemudian dibagi dengan total semua prediksi yaitu penjumlahan *True Positive*, *True Negative*, *False Positive* (FP), dan *False Negative* (FN). Metrik ini mengukur proporsi prediksi yang benar dari keseluruhan prediksi yang dilakukan oleh model.

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

Persamaan (2) merupakan rumus *Precision* yang dihitung dengan membagi *True Positive* (TP) dengan penjumlahan *True Positive* dan *False Positive* (FP). *Precision* mengukur seberapa tepat model dalam memprediksi kelas positif, atau dengan kata lain mengukur proporsi prediksi positif yang benar-benar positif.

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

Persamaan (3) adalah rumus *Recall* yang dihitung dengan membagi *True Positive* (TP) dengan penjumlahan *True Positive* dan *False Negative* (FN). *Recall* mengukur kemampuan model dalam menemukan semua kasus positif yang sebenarnya, atau proporsi kasus positif yang berhasil diidentifikasi dengan benar oleh model.

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

Persamaan (4) menunjukkan *F1-Score* yang dihitung dengan mengalikan angka 2 dengan hasil perkalian *Precision* dan *Recall*, kemudian dibagi dengan

penjumlahan Precision dan Recall. F1-Score merupakan harmonic mean yang memberikan keseimbangan antara Precision dan Recall dalam satu nilai evaluasi tunggal, sehingga memberikan gambaran performa model yang lebih komprehensif.

3.1.6 Perancangan Sistem

Tahap perancangan sistem bertujuan untuk menggambarkan alur kerja dan interaksi pengguna dengan sistem klasifikasi penyakit tanaman tebu sebelum implementasi. Perancangan dilakukan menggunakan diagram use case dan diagram aktivitas yang mengacu pada hasil analisis kebutuhan di mana sistem harus mampu memberikan hasil klasifikasi yang akurat serta memberikan kemudahan bagi pengguna. Sistem klasifikasi penyakit tanaman tebu dirancang dengan alur kerja yang sederhana dimulai ketika pengguna mengakses web dan mengunggah foto daun tebu yang ingin dianalisis. Setelah foto diunggah, sistem akan melakukan validasi terhadap foto tersebut untuk memastikan kualitas gambar memadai. Foto yang valid kemudian diproses oleh sistem melalui model kecerdasan buatan ConvNextV2 yang akan menganalisis pola visual pada daun tebu dan mengklasifikasikannya ke dalam kategori penyakit yang telah dipelajari. Hasil analisis ditampilkan kepada pengguna dalam bentuk nama penyakit yang teridentifikasi dengan persentase tingkat keyakinan, disertai gambar referensi penyakit tersebut, penjelasan singkat mengenai gejala dan penyebab penyakit, serta rekomendasi penanganan yang dapat dilakukan seperti jenis pestisida yang digunakan atau tindakan pencegahan lainnya, dan pengguna dapat kembali ke halaman awal untuk melakukan deteksi baru pada citra tebu lainnya.

3.1.7 Implementasi Sistem

Implementasi sistem ini berupa system klasifikasi penyakit tanaman tebu berbasis web yang dapat diakses melalui browser dengan tampilan interface sederhana yang terdiri dari halaman utama berisi area upload foto dengan tombol pilih file dan tombol submit, halaman loading yang menampilkan animasi proses analisis ketika foto sedang diklasifikasi oleh model, serta halaman hasil yang menampilkan card informasi lengkap meliputi nama penyakit, persentase confidence score dalam bentuk progress bar, gambar referensi penyakit untuk perbandingan visual, deskripsi tekstual mengenai karakteristik dan gejala penyakit, serta panel rekomendasi penanganan yang berisi langkah-langkah konkret yang harus dilakukan petani. Sistem ini menggunakan model deep learning berbasis Convolutional Neural Network yang telah dilatih menggunakan ribuan gambar daun tebu dengan berbagai kondisi penyakit sehingga mampu mengenali pola-pola visual spesifik yang menjadi ciri khas setiap jenis penyakit dengan tingkat akurasi tinggi. Output akhir dari implementasi adalah sebuah platform digital yang siap digunakan oleh petani atau agronomis untuk melakukan diagnosis cepat terhadap kondisi kesehatan tanaman tebu mereka secara mandiri tanpa konsultasi langsung dengan ahli, sehingga penanganan penyakit dapat dilakukan lebih cepat dan tepat untuk mencegah penyebaran yang lebih luas di perkebunan.

13

BAB IV

HASIL DAN PEMBAHASAN

13

28

23

Bab ini menyajikan hasil implementasi dan pengujian sistem klasifikasi penyakit tanaman tebu berbasis citra daun menggunakan model ConvNeXt V2 Tiny dengan strategi K-Fold Cross Validation. Pembahasan mencakup proses persiapan dataset, hasil pelatihan model pada setiap fold, evaluasi performa menggunakan confusion matrix dan metrik-metrik terkait pada data uji lapangan, perbandingan dengan model CNN lainnya, serta implementasi sistem berbasis web yang dikembangkan. Setiap tahapan diuraikan secara sistematis untuk memberikan gambaran komprehensif mengenai kinerja sistem yang dibangun.

4.1 Persiapan dan Analisis Dataset

28

Tahap persiapan dan analisis dataset merupakan fondasi utama dalam penelitian ini. Kualitas dan distribusi data yang digunakan akan sangat menentukan kemampuan model dalam melakukan generalisasi terhadap data baru. Subbab ini menguraikan proses pengumpulan, komposisi, pembagian, serta preprocessing dan augmentasi data yang diterapkan sebelum model dilatih.

70

4.1.1 Komposisi Dataset

105

Dataset yang digunakan dalam penelitian ini merupakan gabungan antara data primer yang dikumpulkan langsung dari kebun tebu di Tembilahan, Kabupaten Indragiri Hilir, dan data sekunder dari Sugarcane Leaf Dataset (SLD) yang tersedia secara publik di platform Kaggle. Penggabungan kedua sumber data ini bertujuan untuk menghasilkan dataset yang lebih representatif terhadap kondisi lapangan sekaligus memiliki volume yang memadai untuk proses pelatihan model deep learning.

Total keseluruhan dataset yang berhasil dikumpulkan mencapai 2.948 citra daun tebu yang terbagi ke dalam lima kelas penyakit. Distribusi dataset secara lengkap ditampilkan pada Tabel 4.1 berikut.

Tabel 4.1 Distribusi Keseluruhan Dataset

No	Kelas Penyakit	Data Kaggle	Data Lapangan	Total	Persentase
1	Busuk Merah (Red Rot)	518	97	615	20,86%
2	Mosaik (Mosaic)	462	68	530	17,98%
3	Karat (Rust)	514	89	603	20,45%
4	Kekuningan (Yellow Leaf)	505	76	581	19,71%
5	Sehat (Healthy)	522	97	619	21,00%
Total Keseluruhan		2.521	427	2.948	100%

Berdasarkan Tabel 4.1, distribusi kelas dataset terlihat cukup seimbang dengan persentase masing-masing kelas berkisar antara 17,98% hingga 21,00%. Kelas Busuk Merah memiliki jumlah 615 citra (20,86%), diikuti kelas Sehat dengan 619 citra (21%), Karat dengan 603 citra (20,45%), Kekuningan dengan 581 citra (19,71%), dan Mosaik dengan 530 citra (17,98%). Keseimbangan distribusi kelas ini sangat penting untuk menghindari bias model dalam proses pelatihan.

4.1.2 Pembagian Dataset

Dataset dibagi menjadi dua bagian utama: data Kaggle sebanyak 2.521 citra digunakan sebagai data training dan validasi melalui skema Stratified K-Fold Cross Validation dengan K=6 fold, sedangkan data lapangan sebanyak 427 citra ditetapkan sebagai data uji (test set) yang bersifat tetap (fixed) dan tidak ikut dalam proses K-Fold. Pemisahan ini dilakukan untuk memastikan evaluasi akhir model

dilakukan pada data yang benar-benar belum pernah dilihat oleh model selama pelatihan. Rincian pembagian ditampilkan pada Tabel 4.2.

Tabel 4.2 Pembagian Dataset Training, Validasi, dan Testing

No	Kelas Penyakit	Data Train+Val K-Fold (Kaggle)	Data Test Lapangan	Total
1	Busuk Merah (Red Rot)	518	97	615
2	Mosaik (Mosaic)	462	68	530
3	Karat (Rust)	514	89	603
4	Kekuningan (Yellow Leaf)	505	76	581
5	Sehat (Healthy)	522	97	619
Total		2.521	427	2.948

Pada setiap iterasi K-Fold, data Kaggle (2.521 citra) dibagi secara otomatis menjadi data training (sekitar 5/6 bagian, ± 2.100 citra) dan data validasi (sekitar 1/6 bagian, ± 420 citra) dengan stratifikasi untuk menjaga proporsi kelas tetap seimbang di setiap subset.

4.1.3 Preprocessing dan Augmentasi Data

Sebelum digunakan dalam proses pelatihan, seluruh citra daun tebu melewati tahapan preprocessing yang terdiri dari resizing ke dimensi 224x224 piksel sesuai dengan input standar model ConvNeXt V2, normalisasi nilai piksel ke rentang [0,1], dan standardisasi menggunakan nilai mean dan standar deviasi dari dataset ImageNet (mean=[0.485, 0.456, 0.406], std=[0.229, 0.224, 0.225]).

Teknik augmentasi data diterapkan secara eksklusif pada data training untuk meningkatkan variasi dan generalisasi model. Augmentasi yang digunakan meliputi: Random Horizontal Flip, Random Vertical Flip, Random Rotation dengan sudut 20 derajat, Color Jitter dengan variasi brightness=0.2, contrast=0.2, saturation=0.2, hue=0.1, dan Random Grayscale dengan probabilitas p=0.05. Data validasi dan testing hanya menjalani Resize ke 224×224 piksel dan normalisasi tanpa augmentasi tambahan.

4.2 Hasil Pelatihan Model ConvNeXt V2 Tiny

Subbab ini memaparkan hasil proses pelatihan model ConvNeXt V2 Tiny menggunakan pendekatan transfer learning. Pembahasan mencakup konfigurasi hyperparameter yang digunakan serta analisis kurva pelatihan yang menggambarkan dinamika konvergensi model selama proses training berlangsung.

4.2.1 Konfigurasi Pelatihan

Proses pelatihan model ConvNeXt V2 Tiny dilakukan menggunakan pendekatan transfer learning dengan memanfaatkan bobot pre-trained convnextv2_tiny.fcmae_ft_in1k dari ImageNet-1K yang telah melalui tahap pre-training FCMAE. Strategi validasi yang digunakan adalah Stratified K-Fold Cross Validation dengan K=6 fold, di mana setiap fold menghasilkan model independen yang disimpan berdasarkan nilai val_accuracy terbaik. Konfigurasi hyperparameter yang digunakan ditampilkan pada Tabel 4.3.

Tabel 4.3 Konfigurasi Hyperparameter Pelatihan

Hyperparameter	Nilai
Model Arsitektur	ConvNeXt V2 Tiny
Pre-trained Weights	ImageNet-1K (convnextv2_tiny.fcmae_ft_in1k)
Strategi Validasi	Stratified K-Fold Cross Validation (K=6)
Optimizer	AdamW
Learning Rate Awal	3e-5
Weight Decay	1e-3
Batch Size	16
Maks. Epoch (Early Stopping patience=5)	30 (maks)
Learning Rate Scheduler	CosineAnnealingLR
Loss Function	CrossEntropyLoss
Label Smoothing	0.1
Dropout Rate (Classifier Head)	0.3
Input Image Size	224 x 224 piksel
Jumlah Kelas	5
GPU	NVIDIA Tesla T4 16GB

Strategi fine-tuning dilakukan secara end-to-end, yaitu seluruh parameter model (backbone ConvNeXtV2 Tiny dan classifier head) dilatih sekaligus sejak awal tanpa pembekuan layer. Setiap fold memulai pelatihan dengan model yang di-reset dari bobot pre-trained yang sama untuk memastikan independensi antar fold. Mekanisme early stopping dengan patience=5 digunakan untuk menghentikan pelatihan secara otomatis apabila val_accuracy tidak meningkat selama 5 epoch berturut-turut, dan model dengan val_accuracy terbaik pada masing-masing fold disimpan (Best_Fold1.pth hingga Best_Fold6.pth).

4.2.2 Hasil Pelatihan Berdasarkan Fold

Pelatihan dilakukan sebanyak 6 fold dengan hasil yang ditampilkan pada Tabel 4.4. Setiap fold menggunakan sekitar 2.100 citra untuk training dan 420 citra untuk validasi, dengan jumlah epoch aktual bervariasi karena mekanisme early stopping.

Tabel 4.4 Hasil Pelatihan K-Fold Cross Validation (K=6)

Fold	Jumlah Train	Jumlah Val	Best Epoch	Best Val Acc (%)	Keterangan
1	2.100	421	17	99,29%	Early stop epoch 22
2	2.101	420	6	98,10%	Early stop epoch 11
3	2.101	420	19	98,10%	Early stop epoch 24
4	2.101	420	12	97,86%	Early stop epoch 17
5	2.101	420	10	99,29%	Early stop epoch 15
6	2.101	420	7	98,33%	Early stop epoch 12
Rata-rata K-Fold				98,49% ± 0,58%	Fold Terbaik = 1

Berdasarkan Tabel 4.4, seluruh fold menunjukkan konvergensi yang baik dengan val_accuracy di atas 97%. Fold 1 dan 5 menghasilkan val_accuracy tertinggi sebesar 99,29%. Fold 1 tercatat sebagai fold terbaik karena dalam skrip training, logika penyimpanan model terbaik menggunakan kondisi val_accuracy lebih besar dari akurasi terbaik sebelumnya, bukan lebih besar atau sama dengan. Karena Fold 1 dilatih lebih dulu dan mencapai 99,29%, sementara Fold 5 hanya sama dengan bukan melampaui angka tersebut, maka status fold terbaik tetap oleh

Fold 1 sesuai urutan proses training sehingga ditetapkan sebagai fold terbaik. Rata-rata val_accuracy lintas fold mencapai $98,49\% \pm 0,58\%$, menunjukkan konsistensi performa model yang tinggi tanpa ketergantungan pada satu pembagian data tertentu. Nilai standar deviasi yang kecil (0,58%) mengindikasikan bahwa model memiliki kemampuan generalisasi yang stabil pada berbagai pembagian data training dan validasi.


4.3 Evaluasi Model Menggunakan Confusion Matrix

Evaluasi model dilakukan secara komprehensif menggunakan confusion matrix dan berbagai metrik klasifikasi untuk mengukur sejauh mana model mampu membedakan kelas penyakit tanaman tebu secara akurat. Subbab ini menganalisis hasil confusion matrix serta menghitung nilai precision, recall, dan F1-Score untuk setiap kelas secara terperinci.

4.3.1 Hasil Confusion Matrix

Evaluasi performa akhir dilakukan pada data test lapangan yang terdiri dari 427 citra (setelah preprocessing) menggunakan pendekatan ensemble. Ensemble dilakukan dengan merata-ratakan probabilitas prediksi dari 6 model fold terbaik (Fold 1 hingga Fold 6), kemudian kelas dengan probabilitas tertinggi dipilih sebagai prediksi akhir. Pendekatan ini menghasilkan akurasi ensemble sebesar 96,25% dengan hanya 16 citra yang salah diklasifikasikan dari total 427 citra pada pengujian akhir.

Confusion matrix hasil prediksi ensemble pada data test lapangan ditampilkan pada Gambar 4.1. Baris pada confusion matrix merepresentasikan kelas aktual (label asli), sedangkan kolom merepresentasikan kelas prediksi model.



Gambar 4.1 Confusion Matrix Model ConvNeXt V2 Tiny pada Data Testing

Berdasarkan Gambar 4.1, nilai diagonal utama confusion matrix menunjukkan angka yang sangat tinggi. Kelas Karat (Rust) dan Mosaic (Mozaik) berhasil diklasifikasikan hampir sempurna dengan kesalahan yang sangat minimal. Kesalahan terbesar terjadi pada kelas Sehat (Healthy) dengan 7 citra salah diklasifikasikan sebagai mosaic dan redrot, kelas Kekuningan (Yellow Leaf) dan Busuk Merah(Redrot) dengan 3 citra salah. Hal ini dapat dipahami karena gejala visual antara kelas-kelas tersebut dapat memiliki kemiripan terutama pada kondisi pencahayaan lapangan yang tidak terkontrol.

4.3.2 Metrik Evaluasi Per Kelas

Berdasarkan confusion matrix pada Gambar 4.1, nilai precision, recall, dan F1-Score dihitung untuk setiap kelas menggunakan persamaan yang telah didefinisikan pada bab sebelumnya. Hasil perhitungan disajikan secara lengkap pada Tabel 4.5.

Tabel 4.5 Metrik Evaluasi Per Kelas Model ConvNeXt V2 Tiny

No	Kelas	Precision	Recall	F1-Score	Support
1	Busuk Merah (Red Rot)	92%	97%	94%	97
2	Mosaik (Mosaic)	96%	97%	96%	68
3	Karat (Rust)	95%	99%	97%	89
4	Kekuningan (Yellow Leaf)	100%	96%	98%	76
5	Sehat (Healthy)	100%	93%	96%	97
Rata-rata (Macro Average)		97%	96%	96%	427
Akurasi Keseluruhan		96,25%			

Berdasarkan Tabel 4.5, model ConvNeXt V2 Tiny dengan pendekatan ensemble berhasil mencapai akurasi keseluruhan sebesar 96,25% pada data test lapangan. Kekuningan (Yellow Leaf) memperoleh F1-Score tertinggi sebesar 98%, diikuti Karat (Rust) dengan 97% lalu Sehat (Healthy) dan Mosaik (Mosaic) sebesar 96% serta Busuk Merah (Red Rot) dengan 94%. Rata-rata macro F1-Score sebesar 96% membuktikan bahwa model memiliki performa yang seimbang dan konsisten di seluruh kelas. Gap antara rata-rata val_accuracy K-Fold (98,49%) dengan test accuracy ensemble (96,25%) yang sangat kecil (2,24%) mengkonfirmasi bahwa model berhasil menggeneralisasi dengan sangat baik pada data lapangan yang belum pernah dilihat sebelumnya.

4.4 Perbandingan Performa dengan Model CNN Lainnya

Untuk mendukung analisis perbandingan performa dilakukan pelatihan terhadap dua arsitektur CNN populer sebagai model pembanding, yaitu ResNet-50 dan EfficientNetV2-S. Kedua model dilatih menggunakan konfigurasi yang identik dengan ConvNeXt V2 Tiny, meliputi dataset, skema Stratified K-Fold Cross

Validation (K=6), optimizer AdamW, learning rate, batch size, serta mekanisme early stopping (patience=5), sehingga perbandingan performa antar arsitektur dapat dilakukan secara adil dan objektif. Subbab berikut menguraikan hasil pelatihan tiap fold serta evaluasi akhir masing-masing model pada data uji lapangan.

4.4.1 ResNet-50

Model ResNet-50 dilatih melalui 6 fold dengan hasil yang ditampilkan pada Tabel 4.6. Setiap fold menggunakan sekitar 2.100 citra untuk training dan 420 citra untuk validasi.


Tabel 4.6 Hasil Pelatihan K-Fold Cross Validation ResNet-50 (K=6)

Fold	Jumlah Train	Jumlah Val	Best Epoch	Best Val Acc (%)	Keterangan
1	2.100	421	21	92,87%	Early stop epoch 26
2	2.101	420	23	94,52%	Early stop epoch 28
3	2.101	420	24	94,29%	Early stop epoch 29
4	2.101	420	24	92,38%	Early stop epoch 29
5	2.101	420	24	93,33%	Early stop epoch 29
6	2.101	420	25	92,86%	Early stop epoch 30
Rata-rata K-Fold				93,38% ± 0,78%	Fold Terbaik = 2

Berdasarkan Tabel 4.6, seluruh fold menunjukkan konvergensi yang jauh lebih lambat dibandingkan ConvNeXt V2 Tiny, dengan val_accuracy berkisar antara 92,38% hingga 94,52%. Fold 2 menghasilkan val_accuracy tertinggi sebesar 94,52% sehingga ditetapkan sebagai fold terbaik. Rata-rata val_accuracy lintas fold

hanya mencapai $93,38\% \pm 0,78\%$, lebih rendah 5,11 poin dibandingkan ConvNeXt V2 Tiny ($98,49\% \pm 0,58\%$). Hal ini mengindikasikan bahwa arsitektur ResNet-50 memerlukan proses pembelajaran fitur yang lebih panjang dan kurang efisien dalam mengekstraksi pola visual penyakit tebu dibandingkan ConvNeXt V2 Tiny pada jumlah epoch dan konfigurasi hyperparameter yang sama.

Evaluasi akhir dilakukan pada 427 citra data uji lapangan menggunakan model terbaik dari Fold 2. Confusion matrix hasil prediksi ditampilkan pada Gambar 4.2.



Gambar 4.2 Confusion Matrix Model ResNet-50 pada Data Testing

Model ResNet-50 memperoleh akurasi 87,35% pada data uji lapangan. Nilai precision dan recall per kelas ditampilkan pada Tabel 4.7.

Tabel 4.7 Metrik Evaluasi Per Kelas Model ResNet-50

No	Kelas	Precision	Recall	F1-Score	Support
1	Sehat (Healthy)	100%	77%	87%	97
2	Mosaik (Mosaic)	94%	88%	91%	68
3	Busuk Merah (Red Rot)	70%	100%	82%	97
4	Karat (Rust)	89%	76%	82%	89
5	Kekuningan (Yellow Leaf)	100%	96%	98%	76
Rata-rata (Macro Average)		91%	88%	88%	427
Akurasi Keseluruhan		87,35%			

Berdasarkan Tabel 4.7, terlihat bahwa kelas Busuk Merah (Red Rot) memiliki precision paling rendah (70%) meskipun recall-nya sempurna (100%). Kondisi ini menunjukkan bahwa model ResNet-50 cenderung terlalu sering memprediksi citra sebagai Busuk Merah meskipun kelas aslinya berbeda (over-prediction), sehingga banyak citra kelas lain, khususnya Sehat, yang salah diklasifikasikan sebagai Busuk Merah. Hal ini juga tercermin dari precision Sehat (Healthy) yang sempurna (100%) namun recall-nya hanya 77%, mengindikasikan banyak citra daun sehat yang justru terklasifikasi ke kelas lain. Gap antara val_accuracy fold terbaik (94,52%) dan test accuracy (87,35%) mencapai 7,17%, mengindikasikan adanya kecenderungan overfitting pada ResNet-50 saat berhadapan dengan variasi kondisi citra lapangan yang tidak sepenuhnya tercakup pada data Kaggle.

4.4.2 EfficientNetV2-S

Model EfficientNetV2-S dilatih dengan skema yang sama melalui 6 fold dengan hasil yang ditampilkan pada Tabel 4.8. Setiap fold menggunakan sekitar 2.100 citra untuk training dan 420 citra untuk validasi.


Tabel 4.8 Hasil Pelatihan K-Fold Cross Validation EfficientNetV2-S (K=6)

Fold	Jumlah Train	Jumlah Val	Best Epoch	Best Val Acc (%)	Keterangan
1	2.100	421	8	96,91%	Early stop epoch 13
2	2.101	420	8	98,10%	Early stop epoch 13
3	2.101	420	13	98,33%	Early stop epoch 18
4	2.101	420	6	96,43%	Early stop epoch 11
5	2.101	420	10	97,86%	Early stop epoch 15
6	2.101	420	14	98,33%	Early stop epoch 19
Rata-rata K-Fold				97,66% ± 0,73%	Fold Terbaik = 3

Berdasarkan Tabel 4.8, EfficientNetV2-S menunjukkan konvergensi yang jauh lebih cepat dibandingkan ResNet-50, dengan val_accuracy di atas 96% pada seluruh fold. Fold 3 dan Fold 6 sama-sama mencapai val_accuracy tertinggi sebesar 98,33%. Karena logika penyimpanan model terbaik pada skrip training menggunakan kondisi val_accuracy lebih besar dari akurasi terbaik sebelumnya (bukan lebih besar atau sama dengan), dan Fold 3 dilatih lebih dulu, maka status fold terbaik tetap dipegang oleh Fold 3 sesuai urutan proses training. Rata-rata

val_accuracy lintas fold mencapai $97,66\% \pm 0,73\%$, mendekati performa ConvNeXt V2 Tiny ($98,49\% \pm 0,58\%$) pada tahap validasi.

Evaluasi akhir dilakukan pada 427 citra data uji lapangan menggunakan model terbaik dari Fold 3. Confusion matrix hasil prediksi ditampilkan pada Gambar 4.3.



Gambar 4.3 Confusion Matrix Model EfficientNetV2-S pada Data Testing

Model EfficientNetV2-S memperoleh akurasi 83,37% pada data uji lapangan, terendah di antara ketiga model yang dibandingkan. Nilai precision dan recall per kelas ditampilkan pada Tabel 4.9.

Tabel 4.9 Metrik Evaluasi Per Kelas Model EfficientNetV2-S

No	Kelas	Precision	Recall	F1-Score	Support
1	Sehat (Healthy)	97%	87%	91%	97
2	Mosaik (Mosaic)	89%	93%	91%	68
3	Busuk Merah (Red Rot)	64%	94%	76%	97
4	Karat (Rust)	89%	81%	85%	89
5	Kekuningan (Yellow Leaf)	100%	61%	75%	76
Rata-rata (Macro Average)		88%	83%	84%	427
Akurasi Keseluruhan		83,37%			

Berdasarkan Tabel 4.9, kelas Kekuningan (Yellow Leaf) memiliki recall paling rendah (61%) meskipun precision-nya sempurna (100%), yang berarti model sangat konservatif dalam memprediksi kelas ini sehingga banyak citra Kekuningan justru salah diklasifikasikan ke kelas lain. Sebaliknya, kelas Busuk Merah (Red Rot) memiliki precision paling rendah (64%) dengan recall tinggi (94%), menunjukkan pola over-prediction yang serupa dengan yang terjadi pada ResNet-50. Gap antara val_accuracy fold terbaik (98,33%) dan test accuracy (83,37%) mencapai 14,96%, merupakan gap terbesar di antara ketiga model yang diuji, mengindikasikan overfitting yang signifikan terhadap distribusi data Kaggle dan kesulitan beradaptasi dengan variasi kondisi pencahayaan serta latar belakang pada data lapangan.

4.4.3 Ringkasan Perbandingan

Secara keseluruhan, hasil pelatihan dan evaluasi kedua model perbandingan menunjukkan bahwa meskipun rata-rata val_accuracy pada tahap K-Fold cukup

tinggi (ResNet-50: $93,38\% \pm 0,78\%$; EfficientNetV2-S: $97,66\% \pm 0,73\%$), keduanya mengalami penurunan akurasi yang jauh lebih besar saat diuji pada data lapangan dibandingkan ConvNeXt V2 Tiny (gap 2,24%). ResNet-50 mengalami gap sebesar 7,17% dan EfficientNetV2-S mengalami gap terbesar sebesar 14,96%. Rincian perbandingan akurasi akhir, precision, recall, F1-score, dan jumlah parameter ketiga model disajikan pada Tabel 4.10.

Tabel 4.10 Ringkasan Perbandingan Performa Ketiga Model CNN

Model	Akurasi (%)	Precision (%)	Recall (%)	F1-Score (%)	Param (M)
ResNet-50	87,35	91,00	88,00	88,00	25,6
EfficientNetV2-S	83,37	88,00	83,00	84,00	21,5
ConvNeXt V2 Tiny	96,25	97,00	96,00	96,00	28,6

Tabel 4.10 secara jelas menunjukkan bahwa ConvNeXt V2 Tiny mengungguli kedua model pembanding secara konsisten, baik pada tahap validasi K-Fold maupun pengujian data lapangan. Dengan test accuracy 96,25%, ConvNeXt V2 Tiny mampu mempertahankan generalisasi yang kuat (gap hanya 2,24%) sekaligus menunjukkan keunggulan arsitekturalnya dalam menangkap representasi fitur visual penyakit tebu secara efektif dan efisien.

4.5 Implementasi Sistem Berbasis Web

Sistem klasifikasi penyakit tanaman tebu yang telah dikembangkan diimplementasikan dalam bentuk aplikasi web yang dapat diakses secara mudah oleh petani maupun pelaku UMKM. Subbab ini menguraikan arsitektur sistem secara keseluruhan, tampilan antarmuka pengguna yang dirancang dengan


mempertimbangkan kemudahan penggunaan, serta hasil pengujian sistem yang mencakup aspek fungsional dan antarmuka.

4.5.1 Arsitektur Sistem

Sistem klasifikasi penyakit tanaman tebu diimplementasikan sebagai aplikasi web yang dapat diakses melalui browser tanpa memerlukan instalasi perangkat lunak tambahan. Arsitektur sistem terdiri dari tiga komponen utama, yaitu antarmuka pengguna (frontend) yang dibangun menggunakan HTML, CSS, dan JavaScript, server backend yang dikembangkan menggunakan framework Flask berbasis Python, serta model inference yang menggunakan ConvNeXt V2 Tiny yang telah dilatih dan disimpan dalam format PyTorch (.pth).


Alur kerja sistem secara keseluruhan dimulai ketika pengguna mengakses halaman web dan mengunggah citra daun tebu melalui antarmuka yang disediakan. Citra yang diunggah kemudian dikirim ke server backend melalui HTTP POST request. Server melakukan preprocessing terhadap citra dan meneruskannya ke model ConvNeXt V2 Tiny untuk proses inferensi. Hasil prediksi berupa nama kelas penyakit dan confidence score kemudian dikembalikan ke antarmuka pengguna untuk ditampilkan bersama informasi deskriptif mengenai penyakit yang teridentifikasi.

Untuk menggambarkan alur interaksi dan proses dalam sistem secara lebih terstruktur, berikut disajikan diagram UML yang terdiri dari Use Case Diagram dan Activity Diagram.



Gambar 4.4 Use Case Diagram Sistem Klasifikasi Penyakit Tanaman Tebu

Gambar 4.4 menampilkan Use Case Diagram sistem yang menggambarkan interaksi antara pengguna (User) dengan sistem. Terdapat dua use case utama untuk mengunggah citra daun tebu, yaitu melalui unggahan foto dari galeri (Upload Foto Daun Tebu) dan pengambilan foto langsung via kamera (Ambil Foto Via Kamera). Kedua use case tersebut menyertakan proses normalisasi gambar (Normalisasi Gambar) yang kemudian diteruskan ke proses analisis penyakit (Analisis Penyakit). Hasil diagnosis kemudian ditampilkan kepada pengguna (Tampilkan Hasil Diagnosis) beserta saran penanganan (Baca Saran Penanganan).




Gambar 4.5 Activity Diagram Sistem Klasifikasi Penyakit Tanaman Tebu

Gambar 4.5 menampilkan Activity Diagram yang mengilustrasikan alur aktivitas sistem dari tiga perspektif swimlane: Pengguna, Website, dan Model ConvNext. Alur dimulai dari pengguna membuka website dan memilih foto dari galeri atau mengambil foto menggunakan kamera. Sistem kemudian memvalidasi input; jika tidak valid, pengguna diminta mengulang. Jika valid, foto diterima oleh website dan diteruskan ke Model ConvNext untuk dilakukan pemeriksaan dan penyesuaian ukuran (normalisasi), pengenalan penyakit, serta perhitungan tingkat keyakinan (confidence score). Hasil terbaik diambil oleh website, kemudian diagnosis dan saran disiapkan dan ditampilkan kepada pengguna untuk dibaca.

4.5.2 Tampilan Antarmuka Pengguna


Antarmuka pengguna dirancang dengan mempertimbangkan kemudahan penggunaan bagi petani dan pelaku UMKM yang mungkin tidak memiliki latar belakang teknis. Halaman utama menyediakan area drag-and-drop untuk mengunggah foto daun tebu yang ingin dianalisis. Pengguna dapat memilih file dari perangkat atau langsung mengambil foto menggunakan kamera pada perangkat mobile.



Gambar 4.6 Halaman Utama Aplikasi Web SugarScan


Gambar 4.6 menampilkan halaman utama aplikasi web SugarScan yang dapat diakses melalui browser di alamat sugarscan.my.id. Halaman ini menampilkan judul utama "Deteksi penyakit tanaman tebu dalam satu foto" disertai deskripsi singkat mengenai kemampuan sistem dalam mengenali 5 kondisi penyakit secara instan. Pada bagian kanan halaman, terdapat contoh hasil diagnosis yang menampilkan kelas penyakit terdeteksi beserta nilai confidence score, nama model yang digunakan (ConvNeXtV2), serta waktu proses inferensi. Halaman utama juga dilengkapi navigasi menu meliputi Diagnosa, Penyakit, Training, Fitur, Cara Kerja,

dan FAQ, serta tombol ajakan bertindak (call-to-action) "Coba Sekarang – Gratis" untuk memudahkan pengguna memulai proses diagnosis.



Gambar 4.7 Halaman Diagnosa, Area Unggah dan Ambil Foto

Gambar 4.7 menampilkan halaman hasil menampilkan informasi yang komprehensif namun mudah dipahami, meliputi nama penyakit yang terdeteksi beserta nama ilmiahnya, persentase confidence score yang divisualisasikan dalam bentuk progress bar berwarna, gambar referensi penyakit untuk perbandingan visual, deskripsi singkat mengenai karakteristik dan gejala penyakit, serta panel rekomendasi penanganan yang berisi langkah-langkah konkret yang dapat segera dilakukan petani. Jika confidence score di bawah ambang batas 70%, sistem secara otomatis menampilkan pesan peringatan agar pengguna mempertimbangkan untuk mengambil foto dengan kualitas yang lebih baik atau berkonsultasi dengan ahli pertanian.



Gambar 4.8 Halaman Database Penyakit Lima Kondisi yang Terdeteksi

Gambar 4.8 menampilkan halaman database penyakit menyajikan informasi referensi mengenai lima kondisi tanaman tebu yang dapat dideteksi oleh sistem, yaitu Healthy (*Saccharum officinarum*), Red Rot (*Colletotrichum falcatum*), Rust (*Puccinia melanocephala*), Yellow Leaf (*SCYLV Luteoviridae*), dan Mosaic (*Sugarcane Mosaic Virus/SCMV*). Setiap kondisi ditampilkan dalam bentuk kartu yang memuat nama penyakit, nama ilmiah, tingkat keparahan, serta deskripsi singkat mengenai gejala dan dampaknya terhadap tanaman tebu.

4.5.3 Pengujian Sistem

Pengujian sistem dilakukan dari dua aspek, yaitu pengujian fungsional dan pengujian antarmuka pengguna. Pengujian fungsional bertujuan memastikan setiap fitur berjalan sesuai spesifikasi yang telah ditetapkan.

Tabel 4.11 Hasil Pengujian Fungsional Sistem

No	Skenario Pengujian	Hasil yang Diharapkan	Hasil Aktual	Status
1	Upload citra format JPG/PNG resolusi normal	Sistem menerima file dan menampilkan preview	Sesuai harapan	Lulus
2	Upload citra dengan ukuran lebih dari 5MB	Sistem menampilkan pesan error batas ukuran file	Sesuai harapan	Lulus
3	Upload file bukan format gambar (PDF/DOCX)	Sistem menolak file dan menampilkan pesan format tidak didukung	Sesuai harapan	Lulus
4	Proses klasifikasi citra daun tebu yang valid	Sistem menampilkan nama penyakit, confidence score, deskripsi, dan rekomendasi	Sesuai harapan	Lulus
5	Klasifikasi citra dengan pencahayaan rendah	Sistem tetap mengklasifikasikan dan menampilkan confidence score	Sesuai harapan	Lulus
6	Akses sistem melalui perangkat mobile	Tampilan responsif dan seluruh fitur dapat digunakan	Sesuai harapan	Lulus
7	Klik tombol "Deteksi Ulang" setelah mendapat hasil	Sistem kembali ke halaman unggah untuk deteksi baru	Sesuai harapan	Lulus

Seluruh skenario pengujian fungsional berhasil lulus (pass) sesuai dengan hasil yang diharapkan. Waktu rata-rata respons sistem dari saat pengguna mengirim citra hingga hasil ditampilkan adalah sekitar 1,2 detik pada koneksi jaringan lokal, yang dinilai cukup responsif untuk kebutuhan pengguna di lapangan.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa sistem klasifikasi penyakit tanaman tebu berbasis citra daun yang dikembangkan menggunakan model ConvNeXt V2 Tiny dengan strategi K-Fold Cross Validation mampu memberikan hasil klasifikasi yang sangat akurat dan efisien. Penerapan preprocessing citra berupa resizing ke dimensi 224x224 piksel, normalisasi menggunakan nilai mean dan standar deviasi ImageNet, serta teknik augmentasi data terbukti efektif dalam meningkatkan kemampuan generalisasi model, terutama dalam menghadapi variasi kondisi pencahayaan, jenis wadah, dan latar belakang pada citra daun tebu lapangan.

Model yang dikembangkan menggunakan pendekatan transfer learning dengan bobot pre-trained ImageNet-1K menunjukkan hasil pelatihan yang konsisten pada 6 fold K-Fold Cross Validation dengan rata-rata val_accuracy sebesar $98,49\% \pm 0,58\%$. Pada tahap pengujian akhir terhadap 427 citra uji lapangan yang tidak pernah digunakan selama pelatihan, model ensemble dari 6 fold terbaik berhasil memperoleh akurasi sebesar 96,25%, dengan nilai precision, recall, dan F1-score masing-masing mencapai 96%. Hasil ini menunjukkan bahwa model memiliki kemampuan generalisasi yang sangat baik dalam membedakan lima kondisi tanaman tebu, yaitu Busuk Merah (Red Rot), Mosaik (Mosaic), Karat (Rust), Kekuningan (Yellow Leaf), dan Sehat (Healthy).

Perbandingan performa dengan model CNN lainnya menunjukkan bahwa ConvNeXt V2 Tiny unggul secara signifikan dibandingkan ResNet-50 (akurasi 87,35%) dan EfficientNetV2-S (akurasi 83,37%). Inovasi arsitektur ConvNeXt V2, khususnya mekanisme Global Response Normalization (GRN), terbukti berkontribusi nyata dalam mencegah feature collapse dan meningkatkan kemampuan generalisasi pada data lapangan yang bervariasi.

Implementasi model ke dalam aplikasi web SugarScan juga berjalan dengan baik. Aplikasi yang dikembangkan menggunakan Flask sebagai backend dan HTML/CSS/JavaScript sebagai frontend mampu menerima input gambar secara langsung dari perangkat pengguna dan menampilkan hasil klasifikasi beserta confidence score, deskripsi penyakit, dan rekomendasi penanganan secara real-time. Seluruh skenario pengujian fungsional berhasil lulus dengan waktu respons rata-rata 1,2 detik. Dengan demikian, sistem ini tidak hanya berhasil secara teknis, tetapi juga memberikan solusi yang praktis, efisien, dan aplikatif bagi petani serta pelaku UMKM untuk mendeteksi penyakit tanaman tebu secara mandiri.

Penelitian ini diharapkan dapat menjadi kontribusi nyata dalam penerapan teknologi kecerdasan buatan (AI) pada bidang pertanian, khususnya kontrol kualitas tanaman tebu, serta dapat mendorong kesadaran petani dan pelaku UMKM terhadap pentingnya deteksi dini penyakit tanaman untuk menjaga produktivitas dan kualitas hasil panen.

5.2 Saran

Berdasarkan hasil penelitian yang telah dicapai, terdapat beberapa saran yang dapat dijadikan acuan untuk pengembangan lebih lanjut.

1. Jumlah dataset citra sebaiknya diperbanyak dan divariasikan, baik dari segi kondisi pencahayaan, jenis daun, tahap keparahan penyakit, maupun latar belakang pengambilan gambar di lapangan, agar model memiliki kemampuan generalisasi yang lebih baik terhadap kondisi nyata yang lebih beragam.
2. Pengembangan sistem dapat diarahkan untuk mendeteksi lebih banyak jenis penyakit tanaman tebu di luar lima kelas yang telah dikembangkan, serta dapat diperluas ke jenis tanaman pertanian lainnya yang relevan di wilayah Indragiri Hilir, guna memperluas cakupan penggunaannya di sektor pertanian.
3. Integrasi fitur tambahan seperti riwayat deteksi, penyimpanan data hasil klasifikasi, notifikasi peringatan dini, dan laporan dalam bentuk grafik dapat meningkatkan fungsionalitas dan nilai guna aplikasi web SugarScan bagi petani dan pelaku UMKM.

DAFTAR PUSTAKA

- [1] S. Thite, Y. Suryawanshi, K. Patil, and P. Chumchu, "Sugarcane leaf dataset: A dataset for disease detection and classification for machine learning applications," *Data Br.*, vol. 53, p. 110268, 2024, doi: 10.1016/j.dib.2024.110268.
- [2] F. R. Silva, M. L. V. d. Resende, L. C. Ferreira, O. Adesina, and K. V. Xavier, "Molecular Characterization and Pathogenicity of *Colletotrichum falcatum* Causing Red Rot on Sugarcane in Southern Florida," *J. Fungi*, vol. 10, no. 11, 2024, doi: 10.3390/jof10110742.
- [3] W. B. Demilie, "Plant disease detection and classification techniques: a comparative study of the performances," *J. Big Data*, vol. 11, no. 1, 2024, doi: 10.1186/s40537-023-00863-9.
- [4] S. Woo *et al.*, "ConvNeXt V2: Co-designing and Scaling ConvNets with Masked Autoencoders," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2023-June, pp. 16133–16142, 2023, doi: 10.1109/CVPR52729.2023.01548.
- [5] C. Meghana, "Rice Leaf Disease Recognition using CNN," *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 12, no. 7, pp. 593–599, 2024, doi: 10.22214/ijraset.2024.63609.
- [6] P. Pai, S. Amutha, M. Basthikodi, B. M. Ahamed Shafeeq, K. M. Chaitra, and A. P. Gurpur, "A twin CNN-based framework for optimized rice leaf disease classification with feature fusion," *J. Big Data*, vol. 12, no. 1, 2025, doi: 10.1186/s40537-025-01148-z.

- [7] A. Y. Ashurov *et al.*, “Enhancing plant disease detection through deep learning: a Depthwise CNN with squeeze and excitation integration and residual skip connections,” *Front. Plant Sci.*, vol. 15, no. January, pp. 1–16, 2024, doi: 10.3389/fpls.2024.1505857.
- [8] A. I. Arifin, A. Arrasyid, M. A. Firlata, and S. A. Putra, “Klasifikasi Penyakit Tanaman Tebu dengan Pendekatan Support Vector Machine,” *OKTAL J. Ilmu Komput. dan Sci.*, vol. 3, no. 10, pp. 2613–2617, 2024.
- [9] B. Liu, Z. Ding, L. Tian, D. He, S. Li, and H. Wang, “Grape Leaf Disease Identification Using Improved Deep Convolutional Neural Networks,” *Front. Plant Sci.*, vol. 11, no. July, pp. 1–14, 2020, doi: 10.3389/fpls.2020.01082.
- [10] W. Ullah *et al.*, “Efficient identification and classification of apple leaf diseases using lightweight vision transformer (ViT),” *Discov. Sustain.*, vol. 5, no. 1, 2024, doi: 10.1007/s43621-024-00307-1.
- [11] G. Shrestha, Deepsikha, M. Das, and N. Dey, “Plant Disease Detection Using CNN,” *Proc. 2020 IEEE Appl. Signal Process. Conf. ASPCON 2020*, vol. 03049, pp. 109–113, 2020, doi: 10.1109/ASPCON49795.2020.9276722.
- [12] W. Shafik, A. Tufail, C. De Silva Liyanage, and R. A. A. H. M. Apong, “Using transfer learning-based plant disease classification and detection for sustainable agriculture,” *BMC Plant Biol.*, vol. 24, no. 1, pp. 1–19, 2024, doi: 10.1186/s12870-024-04825-y.
- [13] M. Gogoi, V. Kumar, S. A. Begum, N. Sharma, and S. Kant, “Classification

- and Detection of Rice Diseases Using a 3-Stage CNN Architecture with Transfer Learning Approach,” *Agric.*, vol. 13, no. 8, 2023, doi: 10.3390/agriculture13081505.
- [14] K. He, X. Chen, S. Xie, Y. Li, P. Dollar, and R. Girshick, “Masked Autoencoders Are Scalable Vision Learners,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2022-June, pp. 15979–15988, 2022, doi: 10.1109/CVPR52688.2022.01553.
- [15] P. Bedi, P. Gole, and S. Marwaha, “PDSE-Lite: lightweight framework for plant disease severity estimation based on Convolutional Autoencoder and Few-Shot Learning,” *Front. Plant Sci.*, vol. 14, no. January, pp. 1–20, 2023, doi: 10.3389/fpls.2023.1319894.
- [16] G. T. Askale, A. B. Yibel, B. M. Taye, and G. D. Wubneh, “Mobile based deep CNN model for maize leaf disease detection and classification,” *Plant Methods*, vol. 21, no. 1, 2025, doi: 10.1186/s13007-025-01386-5.
- [17] Y. Yamagishi and S. Hanaoka, “Ensemble of ConvNeXt V2 and MaxViT for Long-Tailed CXR Classification with View-Based Aggregation,” pp. 1–8, 2024, [Online]. Available: <http://arxiv.org/abs/2410.10710>
- [18] O. P. Mmileng, A. Whata, M. Olusanya, and S. Mhlongo, “Application of ConvNeXt with transfer learning and data augmentation for malaria parasite detection in resource-limited settings using microscopic images,” *PLoS One*, vol. 20, no. 6 June, pp. 1–39, 2025, doi: 10.1371/journal.pone.0313734.
- [19] T. Dong *et al.*, “Wheat disease recognition method based on the SC-

- ConvNeXt network model,” *Sci. Rep.*, vol. 14, no. 1, pp. 1–13, 2024, doi: 10.1038/s41598-024-83636-5.
- [20] Mutia Fadhilla, D. Suryani, A. Labellapansa, and H. Gunawan, “Corn Leaf Diseases Recognition Based on Convolutional Neural Network,” *IT J. Res. Dev.*, vol. 8, no. 1, pp. 14–21, 2023, doi: 10.25299/itjrd.2023.13904.
- [21] K. S. Rekha, H. D. Phaneendra, B. C. S. Gandha, H. Rohan, B. N. S. Niranjan, and C. Badrinat, “Disease Detection in Tomato Plants Using CNN,” *2022 IEEE 3rd Glob. Conf. Adv. Technol. GCAT 2022*, no. 11, pp. 719–724, 2022, doi: 10.1109/GCAT55367.2022.9972186.
- [22] M. Iftikhar, I. A. Kandhro, N. Kausar, A. Kehar, M. Uddin, and A. Dandoush, “Plant disease management: a fine-tuned enhanced CNN approach with mobile app integration for early detection and classification,” *Artif. Intell. Rev.*, vol. 57, no. 7, pp. 1–29, 2024, doi: 10.1007/s10462-024-10809-z.
- [23] S. Wijaya Samdoria and N. Nisar, “Implementasi Deep Learning Menggunakan Arsitektur Vgg-19 Untuk Deteksi Penyakit Pada Tebu Berdasarkan Citra Daun Berbasis Website,” *J. Compr. Sci.*, vol. 4, no. 5, pp. 1650–1667, 2025, doi: 10.59188/jcs.v4i5.3155.
- [24] S. Agustiani, R. Aryanti, S. Khotimatul Wildah, Y. T. Arifin, S. Marlina, and T. Misriati, “Optimisasi Model Deep Learning untuk Deteksi Penyakit Daun Tebu dengan Fine-Tuning MobileNetV2,” *J. Informatics Manag. Inf. Technol.*, vol. 4, no. 4, pp. 150–157, 2024.
- [25] S. D. Daphal and S. M. Koli, “Enhanced deep learning technique for

sugarcane leaf disease classification and mobile application integration,” *Heliyon*, vol. 10, no. 8, p. e29438, 2024, doi: 10.1016/j.heliyon.2024.e29438.

- [26] H. S. Malik *et al.*, “Disease Recognition in Sugarcane Crop Using Deep Learning,” *Adv. Intell. Syst. Comput.*, vol. 1133, pp. 189–206, 2021, doi: 10.1007/978-981-15-3514-7_17.
- [27] S. Srivastava, P. Kumar, N. Mohd, A. Singh, and F. S. Gill, “A Novel Deep Learning Framework Approach for Sugarcane Disease Detection,” *SN Comput. Sci.*, vol. 1, no. 2, pp. 1–7, 2020, doi: 10.1007/s42979-020-0094-9.
- [28] S. Kumar, L. Sharma, and D. Sharma, *Hybrid Deep Learning Framework for Real-Time Sugarcane Disease Detection*, no. Icdlair 2024. Atlantis Press International BV, 2025. doi: 10.2991/978-94-6463-740-3_7.
- [29] K. Lakshmaiah, E. Foundation, A. Sinha, K. Lakshmaiah, E. Foundation, and R. F. License, “Early diagnosis of Sugarcane leaf diseases through CNN and Vision Transformer hybrid model,” 2025.
- [30] I. P. Ismail Kunduracioglu^{1,19}, “Deep Learning-Based Disease Detection in Sugarcane Leaves: Evaluating EfficientNet Models,” vol. 2, no. 1, pp. 321–335, 2024.
- [31] S. D. Daphal and S. M. Koli, “Enhancing sugarcane disease classification with ensemble deep learning: A comparative study with transfer learning techniques,” *Heliyon*, vol. 9, no. 8, p. e18261, 2023, doi: 10.1016/j.heliyon.2023.e18261.

- [32] K. M. S. Nomani, M. Nuruzzaman, A. Nadia, and M. M. Billal, “Sugarcane Leaf Disease Detection: A Comparative Analysis Using Deep Learning,” pp. 139–144, 2024, doi: 10.1145/3723178.3723197.
- [33] S. A. Upadhye, M. R. Dhanvijay, and S. M. Patil, “Sugarcane Disease Detection Using CNN-Deep Learning Method: An Indian Perspective,” *Univers. J. Agric. Res.*, vol. 11, no. 1, pp. 80–97, 2023, doi: 10.13189/ujar.2023.110108.
- [34] Y. Huang, R. Li, X. Wei, Z. Wang, T. Ge, and X. Qiao, “Evaluating Data Augmentation Effects on the Recognition of Sugarcane Leaf Spot,” *Agric.*, vol. 12, no. 12, 2022, doi: 10.3390/agriculture12121997.

LAMPIRAN

