

CEK TURNITIN

SKRIPSI DILA RUSTI SI

 SATSET DIGITAL 2

Document Details

Submission ID

trn:oid:::3618:151105063

Submission Date

Sep 9, 2026, 2:57 PM GMT+7

Download Date

Sep 9, 2026, 3:14 PM GMT+7

File Name

SKRIPSI DILA RUSTI SI.pdf

File Size

2.7 MB

93 Pages

16,086 Words

104,984 Characters

30% Overall Similarity

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

Filtered from the Report

- Bibliography

Top Sources

- 14%  Internet sources
- 10%  Publications
- 28%  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

- 14% Internet sources
- 10% Publications
- 28% 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	2%
2	Student papers	UPN Veteran Yogyakarta on 2026-06-23	1%
3	Internet	repository.uin-suska.ac.id	<1%
4	Student papers	UPN Veteran Yogyakarta on 2026-06-26	<1%
5	Student papers	East Union High School on 2026-06-30	<1%
6	Student papers	Universitas Sangga Buana YPKP on 2026-07-28	<1%
7	Student papers	Universitas Dian Nuswantoro on 2026-01-09	<1%
8	Student papers	Universitas Islam Riau on 2026-07-29	<1%
9	Student papers	Universitas Sangga Buana YPKP on 2026-07-20	<1%
10	Student papers	Universitas Khairun on 2026-07-13	<1%
11	Student papers	Universitas Islam Riau on 2026-08-21	<1%

12	Student papers	Universitas Islam Indonesia on 2026-06-15	<1%
13	Student papers	Universitas Pendidikan Indonesia on 2026-07-05	<1%
14	Student papers	UM Surabaya on 2026-07-21	<1%
15	Internet	eprints.amikom.ac.id	<1%
16	Student papers	Konsorsium Perguruan Tinggi Swasta Indonesia II on 2026-08-04	<1%
17	Student papers	UM Surabaya on 2025-07-16	<1%
18	Student papers	Universitas Sangga Buana YPKP on 2026-07-31	<1%
19	Student papers	UNIVERSITAS BUDI LUHUR on 2025-07-24	<1%
20	Internet	repository.its.ac.id	<1%
21	Student papers	Universitas Islam Riau on 2026-07-08	<1%
22	Internet	proceeding.unpkediri.ac.id	<1%
23	Student papers	Universitas Sangga Buana YPKP on 2026-07-22	<1%
24	Student papers	Universitas Islam Riau on 2025-09-02	<1%
25	Internet	repositori.unsil.ac.id	<1%

26	Student papers	Universitas Sangga Buana YPKP on 2026-07-29	<1%
27	Student papers	Sriwijaya University on 2026-05-04	<1%
28	Student papers	UPN Veteran Yogyakarta on 2026-04-22	<1%
29	Student papers	Universitas Pamulang on 2026-05-04	<1%
30	Internet	ejournal.itn.ac.id	<1%
31	Student papers	Universitas Sangga Buana YPKP on 2026-07-28	<1%
32	Student papers	Universitas Bangka Belitung on 2026-03-20	<1%
33	Student papers	Universitas Kristen Duta Wacana on 2026-05-07	<1%
34	Student papers	Universitas Negeri Surabaya The State University of Surabaya on 2026-07-30	<1%
35	Student papers	UPN Veteran Yogyakarta on 2026-01-05	<1%
36	Student papers	Universitas Bina Sarana Informatika on 2026-06-11	<1%
37	Student papers	Politeknik Manufaktur Negeri Bangka Belitung on 2026-07-27	<1%
38	Student papers	Universitas Gunadarma on 2026-06-30	<1%
39	Student papers	Universitas Putera Batam on 2026-07-28	<1%

40	Student papers	Universitas Sangga Buana YPKP on 2026-07-24	<1%
41	Publication	Albert Willyam, Evasaria Magdalena Sipayung. "Klasifikasi Penyakit Daun Pisang ...	<1%
42	Student papers	UPN Veteran Yogyakarta on 2026-06-18	<1%
43	Internet	repository.uinsaizu.ac.id	<1%
44	Internet	text-id.123dok.com	<1%
45	Student papers	FAKULTAS ILMU KOMPUTER on 2026-07-07	<1%
46	Student papers	Institut Teknologi Sumatera on 2026-08-10	<1%
47	Internet	journal.maranatha.edu	<1%
48	Internet	repository.ub.ac.id	<1%
49	Student papers	Telkom University on 2026-06-30	<1%
50	Internet	repository.bakrie.ac.id	<1%
51	Student papers	Universitas Islam Riau on 2026-02-27	<1%
52	Internet	publikasi.dinus.ac.id	<1%
53	Student papers	Institut Pertanian Bogor on 2026-08-27	<1%

54	Student papers	UPN Veteran Jakarta on 2026-07-24	<1%
55	Student papers	UPN Veteran Yogyakarta on 2026-07-06	<1%
56	Student papers	Institut Teknologi Sumatera on 2026-07-30	<1%
57	Publication	Irvan Budiawan, Yuda Bakti Zainal, Asep Najmurokhman, Kusnandar, Zul Fakhri, ...	<1%
58	Publication	Ririn Anugerah Ikasatya, Cahya Apriliani, Fathir Jannatul Firdaus, Gede Yogi Prata...	<1%
59	Student papers	Rogers State University on 2023-02-13	<1%
60	Student papers	Universitas Dinamika on 2026-06-11	<1%
61	Internet	id.123dok.com	<1%
62	Internet	ejurnal.lkpkaryaprima.id	<1%
63	Internet	ejurnal.stmik-budidarma.ac.id	<1%
64	Student papers	Universitas Negeri Jakarta on 2016-10-25	<1%
65	Internet	digilib.uin-suka.ac.id	<1%
66	Internet	repository.unim.ac.id	<1%
67	Publication	Afifah Agustini, Mufti Ari Bianto, Hery Ardiansyah. "Perbandingan Klasifikasi Dau...	<1%

68	Internet	repository.ar-raniry.ac.id	<1%
69	Publication	Argi Nur Faturrohman, Sayekti Harits Suryawan, Abdul Rahim. "Pengembangan ...	<1%
70	Publication	Evita Evita. "IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK BERBASIS MOB...	<1%
71	Student papers	LL Dikti IX Turnitin Consortium on 2026-04-29	<1%
72	Student papers	Rochester Adams High School on 2021-05-23	<1%
73	Student papers	UM Surabaya on 2026-07-21	<1%
74	Student papers	UNIVERSITAS BUDI LUHUR on 2025-07-21	<1%
75	Student papers	Universitas Islam Riau on 2026-06-19	<1%
76	Student papers	Universitas Malikussaleh on 2026-04-28	<1%
77	Student papers	Universitas Sultan Ageng Tirtayasa on 2025-04-08	<1%
78	Internet	etd.umy.ac.id	<1%
79	Student papers	Institut Bisnis dan Teknologi Indonesia (INSTIKI) on 2025-05-30	<1%
80	Student papers	Institut Teknologi Sumatera on 2025-09-22	<1%
81	Student papers	Universitas Islam Negeri Sumatera Utara on 2026-06-18	<1%

82	Student papers	Universitas Maritim Raja Ali Haji on 2025-01-12	<1%
83	Student papers	Universitas Muhammadiyah Makassar on 2026-06-25	<1%
84	Student papers	University of Hull on 2023-08-25	<1%
85	Internet	core.ac.uk	<1%
86	Internet	repositori.umrah.ac.id	<1%
87	Student papers	Universitas Islam Riau on 2026-04-02	<1%
88	Student papers	Universitas Islam Riau on 2026-08-27	<1%
89	Student papers	Universitas Pamulang on 2026-07-21	<1%
90	Student papers	Universitas Pertahanan RI on 2026-06-18	<1%
91	Publication	Ananda Rizki Dani, Irma Handayani. "Classification of Yogyakarta Batik Motifs Usi...	<1%
92	Publication	Gilang Gumelar, Tito Sugiharto, Iwan Lesmana. "Implementasi CNN untuk identif...	<1%
93	Student papers	UIN Raden Intan Lampung on 2026-06-30	<1%
94	Student papers	UPN Veteran Yogyakarta on 2025-10-28	<1%
95	Student papers	UPN Veteran Yogyakarta on 2026-05-25	<1%

96	Student papers	UPN Veteran Yogyakarta on 2026-07-06	<1%
97	Student papers	Universitas Maritim Raja Ali Haji on 2025-06-12	<1%
98	Internet	docplayer.info	<1%
99	Internet	eprints2.undip.ac.id	<1%
100	Student papers	Institut Teknologi Sumatera on 2025-09-22	<1%
101	Student papers	Institut Teknologi Sumatera on 2026-09-08	<1%
102	Student papers	UPN Veteran Yogyakarta on 2025-10-01	<1%
103	Student papers	LL Dikti IX Turnitin Consortium on 2024-09-13	<1%
104	Publication	Malakit L. Ram, Rhoderick D. Malangsa, Cheryl M. Tarre, Jonelle H. Tablada, Khor...	<1%
105	Student papers	Universitas Muhammadiyah Makassar on 2026-06-07	<1%
106	Student papers	Universitas Pamulang on 2026-07-03	<1%
107	Internet	rama.uniku.ac.id	<1%
108	Internet	repository.uncp.ac.id	<1%
109	Internet	repository.unmuhjember.ac.id	<1%

110	Internet	www.repository.stiegici.ac.id	<1%
111	Student papers	Institut Teknologi Kalimantan on 2020-03-11	<1%
112	Student papers	Universitas Gunadarma on 2026-05-21	<1%
113	Internet	dspace.uui.ac.id	<1%
114	Internet	journal2.ummat.ac.id	<1%
115	Publication	Rahma Danu Sadewa, Yisti Vita Via, Afina Lina Nurlaili. "IMPLEMENTASI SSD-MOBI...	<1%
116	Student papers	Tarumanagara University on 2026-06-21	<1%
117	Student papers	Universitas Islam Riau on 2026-08-31	<1%
118	Student papers	Universitas Muhammadiyah Makassar on 2026-05-11	<1%
119	Student papers	Universitas Muhammadiyah Palembang on 2025-08-26	<1%
120	Internet	eprints.undip.ac.id	<1%
121	Internet	jti.aisyahuniversity.ac.id	<1%
122	Internet	jurnal.itg.ac.id	<1%
123	Internet	repository.teknokrat.ac.id	<1%

124	Student papers	Business and Economics on 2026-07-09	<1%
125	Student papers	UPN Veteran Yogyakarta on 2026-07-28	<1%
126	Student papers	Universitas 17 Agustus 1945 Surabaya on 2026-06-29	<1%
127	Student papers	Universitas Andalas on 2024-04-23	<1%
128	Student papers	Universitas Muhammadiyah Purwokerto on 2025-08-15	<1%
129	Student papers	Universitas Negeri Semarang - iTh on 2024-07-14	<1%
130	Student papers	Universitas Pancasila on 2025-08-07	<1%
131	Student papers	Universitas Pancasila on 2025-08-10	<1%
132	Student papers	University of Glasgow on 2024-01-30	<1%
133	Internet	ejournal.pelitaindonesia.ac.id	<1%
134	Internet	ejournal.techcart-press.com	<1%
135	Internet	lib.unnes.ac.id	<1%
136	Internet	repository.polibatam.ac.id	<1%
137	Internet	repository.uigm.ac.id	<1%

138	Publication	Ahmad Sihabillah, Abu Tholib, Illiyah Ibnul Basit. "OPTIMASI MODEL RESNET50 U...	<1%
139	Publication	Arken Abdullah, Arya Adhyaksa Waskita, Murni Handayani. "ANALISIS SISTEM DE...	<1%
140	Student papers	Chungnam National University on 2023-01-23	<1%
141	Student papers	Perpustakaan on 2025-08-07	<1%
142	Publication	Takyudin Takyudin, Muhammad Sandi Rais, Jonni Adi Putra, Ali Hamsar. "Metode ...	<1%
143	Student papers	Telkom University on 2025-07-07	<1%
144	Student papers	UPN Veteran Yogyakarta on 2026-08-27	<1%
145	Publication	Umiati, Nanik. "A Model to Increase Sme's Performance: The Moderating Role of ...	<1%
146	Student papers	Universitas Islam Negeri Alauddin Makassar on 2026-01-29	<1%
147	Student papers	Universitas Islam Riau on 2025-09-10	<1%
148	Student papers	Universitas Maritim Raja Ali Haji on 2023-05-31	<1%
149	Student papers	Universitas Putera Batam on 2026-07-24	<1%
150	Student papers	Universitas Putera Batam on 2026-07-28	<1%
151	Internet	ejournal.instiki.ac.id	<1%

152	Internet	ejournal.unesa.ac.id	<1%
153	Internet	garuda.kemdikbud.go.id	<1%
154	Internet	journal.cib.institute	<1%
155	Internet	jurnal.polibatam.ac.id	<1%
156	Internet	123dok.com	<1%
157	Publication	Agam Tamlica, Bambang Irawan. "ANALISIS SENTIMEN ULASAN APLIKASI GROK D...	<1%
158	Publication	Aprilian Gevindo, Syafri Arlis. "Smoker Detection Using the You Only Look Once (Y...	<1%
159	Student papers	Fakultas Ekonomi dan Bisnis Universitas Gadjah Mada on 2023-11-21	<1%
160	Student papers	Fakultas Teknik on 2025-07-29	<1%
161	Publication	Jenny Rahma Hidayat, Jemakmum. "Implementasi Klasifikasi Citra Berbasis Tenso...	<1%
162	Publication	Kadek Agus Tamayasa, Luh Joni Erawati Dewi. "ANALISIS PERBANDINGAN MODEL...	<1%
163	Student papers	PASCASARJANA on 2025-08-04	<1%
164	Student papers	Politeknik Ilmu Pelayaran Semarang on 2026-05-18	<1%
165	Student papers	Politeknik Manufaktur Negeri Bangka Belitung on 2025-11-06	<1%

166	Publication	Ramadhani Zidan Arifin, Hasbi Firmansyah, Wahyu Asriyani. "Prediksi Kelulusan ...	<1%
167	Publication	Saikin Saikin, Mohammad Taufan Asri Zaen, Sofiansyah Fadli, Hairul Fahmi. "Pene...	<1%
168	Student papers	Telkom University on 2025-07-08	<1%
169	Student papers	Telkom University on 2026-01-22	<1%
170	Student papers	The Kyoto College of Graduate Studies for Informatics on 2026-08-04	<1%
171	Student papers	UNIVERSITAS BUDI LUHUR on 2026-07-02	<1%
172	Student papers	UPN Veteran Yogyakarta on 2026-07-29	<1%
173	Student papers	Universitas Bina Sarana Informatika on 2026-06-11	<1%
174	Student papers	Universitas Brawijaya on 2016-08-04	<1%
175	Student papers	Universitas Islam Riau on 2026-05-13	<1%
176	Student papers	Universitas Jember on 2023-01-13	<1%
177	Student papers	Universitas Jember on 2025-07-13	<1%
178	Student papers	Universitas Jember on 2026-06-21	<1%
179	Student papers	Universitas Khairun on 2026-05-11	<1%

180	Student papers	Universitas Nasional on 2019-01-29	<1%
181	Student papers	Universitas Sanata Dharma on 2026-06-09	<1%
182	Publication	Valentiena Prastika Putrie Askan, Nur Nafi'iyah. "Implementasi Implementasi Cn...	<1%
183	Internet	pdfslide.net	<1%
184	Internet	repositori.umsu.ac.id	<1%
185	Internet	repository.iainpare.ac.id	<1%
186	Internet	repository.syekh nurjati.ac.id	<1%
187	Internet	repository.unand.ac.id	<1%
188	Internet	repository.unhas.ac.id	<1%
189	Student papers	stie-pembangunan on 2023-11-09	<1%
190	Internet	teknois.unbin.ac.id	<1%
191	Internet	www.mdpi.com	<1%
192	Student papers	Fakultas Pertanian on 2026-07-21	<1%
193	Publication	Santowi Azis, Bambang irawan -. "EVALUASI KLASIFIKASI PENYAKIT DAUN TEH M...	<1%

194	Student papers	UPN Veteran Yogyakarta on 2021-05-11	<1%
195	Student papers	Universitas Sangga Buana YPKP on 2026-07-23	<1%
196	Student papers	Universitas Wijaya Kusuma Surabaya on 2026-07-21	<1%
197	Student papers	Admin Turnitin UIISI on 2025-07-31	<1%
198	Student papers	East Union High School on 2026-07-02	<1%
199	Student papers	Forum Komunikasi Perpustakaan Perguruan Tinggi Kristen Indonesia (FKPPTKI) o...	<1%
200	Publication	Jauhari Maulani, Ihda Innar Ridho, Ahmadi Ahmadi. "APLIKASI DIAGNOSIS PENYA...	<1%
201	Publication	Jodi Wijaya, Kusrini Kusrini. "Classification of Coffee Fruit Ripe Levels from the Tre...	<1%
202	Student papers	STT PLN on 2025-08-11	<1%
203	Student papers	Sekolah Teknik Elektro & Informatika on 2025-08-20	<1%
204	Student papers	Telkom University on 2026-05-27	<1%
205	Student papers	UNIVERSITAS BUDI LUHUR on 2025-08-19	<1%
206	Student papers	UPN Veteran Yogyakarta on 2026-05-04	<1%
207	Student papers	UPN Veteran Yogyakarta on 2026-06-04	<1%

208	Publication	Uma Fadhila Dina Puspita, Adhika Pramita Widyassari. "Implementasi Metode Ce...	<1%
209	Student papers	Universitas Dian Nuswantoro on 2015-06-17	<1%
210	Student papers	iGroup on 2012-09-13	<1%
211	Internet	repository.uhamka.ac.id	<1%

IMPLEMENTASI YOLO11 DALAM DETEKSI PENYAKIT TANAMAN JAGUNG

SKRIPSI



Disusun oleh :

DILA RUSTI
403221010042

1

PROGRAM SARJANA
PROGRAM STUDI SISTEM INFORMASI
FAKULTAS TEKNIK DAN ILMU KOMPUTER
UNIVERSITAS ISLAM INDRAGIRI
TEMBILAHAN
2026

**IMPLEMENTATION OF YOLO11 IN DETECTING CORN PLANT
DISEASES**

1 Untuk memenuhi sebagai persyaratan mencapai gelar Sarjana Komputer pada
Program Studi Sistem Informasi



Disusun oleh :

DILA RUSTI
403221010042

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

2026

PERSETUJUAN

PENGESAHAN

PERNYATAAN

Saya yang bertanda tangan di bawah ini menyatakan bahwa skripsi ini merupakan karya saya sendiri (ASLI), dan isi di dalam skripsi ini tidak terdapat karya yang pernah diajukan oleh orang lain untuk memperoleh gelar akademis di suatu institusi pendidikan tinggi mana pun, dan sepanjang pengetahuan saya juga tidak terdapat karya atau pendapat yang pernah ditulis dan/atau diterbitkan oleh orang lain, kecuali yang secara tertulis diacu dalam naskah ini dan disebutkan dalam daftar pustaka. Segala sesuatu yang terkait dengan naskah dan karya yang telah dibuat adalah menjadi tanggung jawab saya pribadi.

Tembilahan, 21 juli 2026

Dila Rusti
NIM: 403221010042

KATA PENGANTAR

Puji syukur ke hadirat Allah SWT atas rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan Proposal Tugas Akhir berjudul “Implementasi YOLO11 dalam Deteksi Penyakit Tanaman Jagung.” Proposal ini disusun sebagai salah satu syarat akademik pada Program Studi Sistem Informasi, Fakultas Teknik dan Ilmu Komputer, Universitas Islam Indragiri. Penelitian ini bertujuan mengembangkan sistem deteksi otomatis penyakit dan hama jagung berbasis deep learning, khususnya model YOLO11, agar mampu membantu proses identifikasi penyakit tanaman secara lebih cepat, akurat, dan dapat diterapkan di lapangan.

Penulis mengucapkan terima kasih kepada semua pihak yang telah memberikan dukungan dalam penyusunan proposal ini. Penulis banyak mendapat bimbingan, bantuan, dan dukungan yang sangat berarti dari berbagai pihak sehingga proposal ini dapat tersusun dengan baik. Untuk itu penulis mengucapkan banyak terima kasih kepada :

1. Bapak Dr. H Najamuddin, Lc, MA Selaku Rektor Universitas Islam Indragiri.
2. Dr.Bayu Rianto,S.SI.,M.Kom Selaku Dekan Fakultas Teknik Dan Ilmu Komputer.
3. Ibu Fitri Yunita, S.SI., M.Kom Selaku Ketua Program Studi Sistem Informasi Fakultas Teknik dan Ilmu Komputer.
4. Bapak Muh. Rasyid Ridha, S.SI.,M.Kom Selaku Pembimbing utama bukan hanya membimbing secara akademik tetapi juga menjadi pengarah dan penyemangat yang luar biasa bagi penulis. terimakasih yang sebesar-besarnya atas waktu, perhatian, kesabaran yang bapak berikan selama proses penulisan skripsi ini.

5. Bapak Dwi Yuli Prasetyo,S.Kom,M.Kom Selaku pembimbing pendamping terimakasih atas bimbingannya selama perjalanan penulisan skripsi ini
6. Seluruh Dosen Fakultas Teknik dan Ilmu Komputer Universitas Islam Indragiri yang tidak dapat penulis sebutkan satu persatu. Terima kasih atas ilmu yang Bapak dan Ibu berikan, semoga menjadi bekal bagi penulis dan menjadi ladang pahala bagi Bapak dan Ibu sekalian.
7. Kepada orang tua tercinta penulis bapak Rusli dan ibu Hanifah meskipun kita bukan dari keluarga yang terbiasa berbicara dari hati ke hati penulis tau di balik keheningan itu tersimpan doa yang tak pernah putus untuk penulis, terimakasih atas pengorbanan, dukungan, nasihat, setiap langkah dan pencapaian yang penulis raih termasuk selsainya skripsi ini dan terimakasih atas kebutuhan yang tak pernah kurang sedikit pun yang di berikan selama ini bagi penulis terimakasih atas doa, pengorbanan, restu dan kebahagiaan yang telah di berikan untuk penulis.
8. Kepada saudara kandung penulis Abang Dandi syaputra dan adek dewa satria, terimakasih atas dukungan dan doa bagi penulis sehingga penulis bisa berada di titik ini, meskipun kita jarang bersama dan jarang bertemu Krena terhalangnyaaa untuk menempuh tujuan masing-masing, tapi Tidak mengurangi saling mendukung untuk bagi penulis.
9. Terimakasih Untuk, Efa Sa'ada, Yuliati, fanisha juliananda putri dan Cici nurmalayuni yang kehadirannya mengikat hari hari yang panjang ini menjadi suatu yang utuh dan bermakna bagi penulis dari bangku semester pertama hingga helaan nafas lega di penghujung semester delapan selalu ad kalian dalam peroses penulis, kalian bukan sekedar teman seperjalanan melainkan keluarga yang tumbuh bersama dalam suka dan duka proses

akademik maupun kehidupan pribadi bagi penulis, dan terimakasih atas dukungan, masukan, nasehat, selama ini yang telah menemani proses yang tak selalu mudah bagi penulis perjalanan yang panjang ini menjadi lebih ringan untuk di tempuh, lebih hangat untuk di kenang dan jauh lebih bermakna. Krena ad kalian di dalamnya bagi kehidupan penulis.

10. Kepada teman teman keluarga SIB angkatan 22 terimakasih atas solidaritas dan kebersamaan.

11. Terakhir, penulis berterimakasih kepada satu sosok gadis yang selama ini diam diam berjuang tanpa henti seorang perempuan yang hati kecil tetapi impian yang sangat besar terimakasih kepada peneliti skripsi ini yaitu penulis sendiri Dila Rusti anak perempuan satu satunya di keluarga dan menjadi harapan yang sangat besar bagi keluarga, terimakasih sudah bertahan sejauh ini dan bertahan lah dengan perjalanan selanjutnya.

Penulis berharap proposal ini dapat memberi kontribusi bagi pengembangan ilmu, khususnya dalam ranah pengolahan citra dan kecerdasan buatan. Masukan serta saran yang membangun sangat diharapkan guna meningkatkan kualitas penelitian di masa mendatang. Semoga Allah SWT senantiasa melimpahkan kemudahan dan keberkahan dalam setiap proses penelitian ini. Aamiin

Tembilahan, Desember 2026

DILA RUSTI
NIM. 403221010042

15

DAFTAR ISI

PERSETUJUAN	iii
PENGESAHAN	iv
PERNYATAAN	v
KATA PENGANTAR	vi
DAFTAR ISI.....	x
DAFTAR TABEL	xii
DAFTAR GAMBAR	xiii
INTISARI.....	xiv
ABSTRACT.....	xv
BAB I PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	4
1.3 Tujuan Penelitian.....	4
1.4 Batasan Penelitian.....	4
1.5 Manfaat Penelitian	5
1.6 Sistematika Penulisan	5
BAB II TINJAUAN LITERATUR.....	8
2.1 Pendahuluan.....	8
2.2 YOLO (You Only Look Once)	8
BAB III METODE PENELITIAN	22
3.1 Kerangka Penelitian.....	22
3.2 Pelatihan Model YOLO11.....	25
3.3 Pelabelan Data (Annotation).....	27

7

50

3.4 Evaluasi	30
3.5 Uji coba	30
BAB IV HASIL DAN PEMBAHASAN	31
4.1 Hasil Penelitian.....	31
4.1.1 Pengumpulan Dataset	31
4.1.2 Preprocessing Data dan Augmentasi Data	34
4.1.3 Pelatihan Model YOLO11	37
4.1.4 Pelabelan Data (Annotation)	41
4.2 Hasil Pelatihan dan Pengujian Model	42
4.2.1 Hasil Pelatihan Model YOLO11.....	43
4.3 Pembahasan	54
4.3.1 Ablasi Study	54
4.4 Uji Perbandingan Model.....	56
4.5 Implementasi aplikasi.....	58
BAB V KESIMPULAN DAN SARAN.....	65
5.1 Kesimpulan.....	65
5.2 Saran.....	65
DAFTAR PUSTAKA.....	67
LAMPIRAN.....	70

DAFTAR TABEL

Tabel 2.1 Penggunaan metode YOLO 11 berbagai objek penelitian	9
Tabel 2.2 Deteksi penyakit hama dengan berbagai penelitian.....	11
Tabel 2.3 Deteksi penyakit hama tanaman jagung dari berbagai metode	12
Tabel 2.4 Dataset penelitian objek tanaman jagung	14
Tabel 2.5 Akurasi penelitian tanaman jagung	15
Tabel 2.6 Akurasi Yolo11 dengan berbagai penelitian.....	16
Tabel 2.7 Dataset penyakit hama tanaman jagung	18
Tabel 2.8 Dataset penyakit hama tanaman jagung	19
Tabel 3.1 Dataset penyakit hama tanaman jagung	24
Tabel 4.1 Pelatihan Model YOLO11	32
Tabel 4.2 Pelatihan Model YOLO11	33
Tabel 4.3 Pelatihan Model YOLO11	34
Tabel 4.4 Parameter Preprocessing dan Pelatihan Model	35
Tabel 4.5 Parameter Preprocessing dan Pelatihan Model	36
Tabel 4.6 Pelatihan Model YOLO11	38
Tabel 4.7 Bentuk Tensor Proses Model YOLO11	39
Tabel 4.8 Pelabelan Data	42
Tabel 4.9 Classification report YOLO11	51
Tabel 4.10 Classification report YOLO11	54
Tabel 4.11 Classification report YOLO11	57

29

45

145

211

DAFTAR GAMBAR

Gambar 2.1	Arsitektur YOLO11 (You Only Look Once).....	9
Gambar 3.1	Kerangka Penelitian	22
Gambar 3.2	Pelatihan Model YOLO11	25
Gambar 3.3	Batang busuk.....	27
Gambar 3.4	Hawar daun	28
Gambar 3.5	Karat daun	28
Gambar 3.6	Bercak abu.....	28
Gambar 3.7	Sehat	29
Gambar 4.1	Pelatihan Model YOLO11	38
Gambar 4.2	Grafik Hasil Training	43
Gambar 4.3	Grafik Precesion confidance	45
Gambar 4.4	Grafik Precesion Recall.....	46
Gambar 4.5	Grafik F1 Confindance	48
Gambar 4.6	Confusion Matrix	49
Gambar 4.7	Hasil Prediksi Model Yolo11	52
Gambar 4.8	Logo Aplikasi	58
Gambar 4.9	Tampilan Awal	59
Gambar 4.10	Tampilan Menu Utama	60
Gambar 4.11	Info Penyakit.....	61
Gambar 4.12	Proses Deteksi.....	62
Gambar 4.13	Tampilan Hasil Deteksi	63
Gambar 4.14	Tampilan Menu History	64

INTISARI

Penyakit pada tanaman jagung dapat menurunkan produktivitas hasil panen sehingga diperlukan metode deteksi yang cepat dan akurat. Penelitian ini bertujuan mengembangkan model YOLO11 (*You Only Look Once*) untuk mendeteksi penyakit tanaman jagung berdasarkan citra daun dan batang. Dataset yang digunakan terdiri dari 4.405 citra dengan lima kelas, yaitu Batang Busuk, Bercak Abu, Hawar Daun, Karat Daun, dan Sehat. Tahapan penelitian meliputi *preprocessing*, augmentasi data, pelabelan (*annotation*), pelatihan model, dan evaluasi menggunakan metrik *precision*, *recall*, mAP50, dan mAP50-95.

Hasil penelitian menunjukkan bahwa model YOLO11 mampu mendeteksi penyakit tanaman jagung dengan baik. Nilai *precision* berada pada rentang 0,830–0,940, *recall* 0,810–0,930, dan mAP50 0,850–0,890. Pada uji perbandingan, YOLO11 memperoleh akurasi sebesar 87%, lebih tinggi dibandingkan YOLOv8 sebesar 75,5% dan YOLOv5 sebesar 70%. Hasil tersebut menunjukkan bahwa YOLO11 efektif digunakan untuk deteksi penyakit tanaman jagung secara otomatis dan berpotensi diterapkan pada sistem pertanian cerdas berbasis *computer vision*.

Kata Kunci: YOLO11, deteksi penyakit jagung, *deep learning*, *computer vision*, *object detection*.

ABSTRACT

27 Diseases in corn plants can reduce crop productivity, making fast and
accurate detection methods essential. This study aims to develop a YOLO11 (You
Only Look Once) model for detecting corn plant diseases based on leaf and stem
104 images. The dataset consisted of 4,405 images categorized into five classes: Stem
104 Rot, Gray Leaf Spot, Leaf Blight, Leaf Rust, and Healthy. The research stages
12 included data preprocessing, augmentation, annotation, model training, and
evaluation using precision, recall, mAP50, and mAP50-95 metrics.

84 The results showed that the YOLO11 model was able to detect corn
diseases effectively. The precision values ranged from 0.830 to 0.940, recall
values ranged from 0.810 to 0.930, and mAP50 values ranged from 0.850 to
0.890. In the comparative evaluation, YOLO11 achieved an accuracy of 87%,
outperforming YOLOv8 with 75.5% and YOLOv5 with 70%. These findings
indicate that YOLO11 is effective for automatic corn disease detection and has
strong potential for implementation in smart agriculture systems based on
computer vision.

Keywords: YOLO11, corn disease detection, deep learning, computer vision, object
detection.

108

BAB I

PENDAHULUAN

1.1 Latar Belakang

Jagung adalah salah satu komoditas pangan dan pakan penting yang kontribusinya besar terhadap ketahanan pangan dan ekonomi pertanian nasional. Namun produksi jagung sering terancam oleh serangan penyakit dan hama, mulai dari bercak daun, hawar daun, batang busuk, karat daun dan bercak abu-abu hingga serangan serangga pada tongkol yang bila tidak terdeteksi dini dapat menyebabkan penurunan hasil yang signifikan dan kerugian ekonomi bagi petani. Oleh karena itu diperlukan sistem deteksi dini yang andal untuk mengurangi kehilangan hasil dan meminimalkan penggunaan pestisida secara berlebih [1].

Praktik identifikasi penyakit secara tradisional masih bergantung pada inspeksi visual oleh petani atau penyuluh pertanian yang berpengalaman. Metode ini bersifat subjektif, memerlukan waktu, dan sulit diskalakan untuk lahan luas; selain itu hasil diagnosis dapat dipengaruhi oleh pengalaman pemeriksa, kondisi pencahayaan, dan kemiripan gejala antar penyakit sehingga memicu kesalahan identifikasi. Keterbatasan ini menimbulkan kebutuhan kuat terhadap metode deteksi otomatis yang konsisten, cepat, dan dapat diaplikasikan langsung di lapangan [2].

Kemajuan *deep learning*, terutama keluarga model YOLO (*You Only Look Once*), telah membuka kemungkinan deteksi objek secara *real-time* dengan akurasi tinggi. Fitur yang sangat relevan untuk monitoring tanaman di lapangan. Versi-versi terbaru dalam keluarga YOLO menghadirkan perbaikan arsitektural dan mekanisme ekstraksi fitur yang meningkatkan performa deteksi pada berbagai tugas visi komputer, sehingga memberikan dasar teknis yang kuat untuk penerapan sistem

112

62

41

38

deteksi penyakit tanaman yang cepat dan efisien. Pengenalan arsitektur terbaru (mis. YOLO11) menambah alasan teknis untuk mengeksplorasi implementasinya di domain pertanian [3].

Meskipun potensi YOLO sangat besar, penerapan di kondisi lapangan menyisakan tantangan teknis nyata. Dataset lapangan umumnya tidak seimbang (kelas penyakit jarang), variasi pencahayaan dan latar belakang tinggi, gejala yang tumpang tindih antar penyakit, serta objek penyakit/hama yang berukuran sangat kecil pada citra resolusi biasa. Artikel riset yang menerapkan YOLO pada jagung melaporkan perbaikan tetapi juga menegaskan perlunya penyesuaian arsitektur, *preprocessing*, dan strategi augmentasi agar model tahan terhadap kondisi nyata lapangan. Tantangan-tantangan inilah yang menjadikan studi implementasi pada YOLO11 penting untuk diuji secara sistematis [4].

Beberapa pengembangan varian YOLO terbaru (termasuk studi yang memodifikasi YOLO11) menunjukkan peningkatan dalam ekstraksi fitur, *loss function*, dan mekanisme *attention* yang mampu memperbaiki deteksi objek kecil serta menambah *robustness* terhadap variasi data. Adaptasi semacam itu (misal integrasi *attention*, penyesuaian *label assignment*, dan *loss* untuk objek kecil) memberikan dasar hipotesis bahwa YOLO11, bila dioptimalkan untuk domain pertanian, dapat menawarkan *tradeoff* yang lebih baik antara kecepatan inferensi dan akurasi deteksi dibandingkan varian sebelumnya. Namun klaim ini perlu diuji menggunakan dataset jagung yang representatif [4].

Penelitian ini dirancang tidak hanya untuk menerapkan metode YOLO11 sebagai algoritma deteksi objek, tetapi juga untuk menghasilkan suatu sistem yang memiliki nilai implementatif pada proses identifikasi penyakit tanaman jagung.

47 Berbeda dengan sebagian besar penelitian sebelumnya yang berfokus pada evaluasi performa model melalui hasil pelatihan dan pengujian, penelitian ini
6 mengintegrasikan seluruh tahapan pengembangan mulai dari penyusunan dataset, proses anotasi, pelatihan model, evaluasi performa, hingga implementasi model ke dalam aplikasi Android. Pendekatan tersebut menjadikan hasil penelitian tidak
75 hanya berupa model deteksi, tetapi juga sebuah sistem yang dapat digunakan sebagai media identifikasi penyakit tanaman jagung secara praktis.

Kontribusi penelitian ini juga terletak pada penyusunan alur pengembangan yang lebih komprehensif, sehingga aspek penelitian tidak berhenti pada peningkatan performa model, tetapi berorientasi pada penerapan teknologi yang siap digunakan oleh pengguna. Dengan menggabungkan dataset yang sesuai dengan objek penelitian, model YOLO11, serta implementasi pada aplikasi mobile, penelitian ini memberikan kontribusi yang lebih luas dibandingkan penelitian yang hanya membahas pengembangan model deteksi tanpa menghasilkan sistem yang dapat dimanfaatkan secara langsung. Oleh karena itu, penelitian ini diharapkan
36 tidak hanya memberikan kontribusi akademik dalam pengembangan deteksi penyakit tanaman jagung, tetapi juga memiliki nilai praktis sebagai pendukung proses identifikasi penyakit di lapangan.

Selain memberikan kontribusi pada aspek implementasi, penelitian ini juga memperkuat pengembangan penerapan YOLO11 pada objek tanaman jagung melalui pendekatan yang disesuaikan dengan karakteristik penyakit yang diamati. Berbeda dengan penelitian lain yang umumnya menggunakan objek berbeda atau
60 berfokus pada pengembangan arsitektur model, penelitian ini menitikberatkan pada penyusunan sistem deteksi yang dapat digunakan pada kondisi nyata dengan

memanfaatkan lima kategori penyakit tanaman jagung sebagai objek utama. Pendekatan tersebut menunjukkan bahwa penelitian ini tidak hanya berorientasi pada peningkatan performa model, tetapi juga pada pemanfaatan hasil deteksi agar dapat digunakan secara lebih efektif sebagai media pendukung identifikasi penyakit tanaman jagung. Oleh karena itu, penelitian ini diharapkan dapat menjadi referensi bagi pengembangan sistem deteksi penyakit tanaman jagung berbasis kecerdasan buatan yang lebih aplikatif dan berorientasi pada kebutuhan pengguna.

Berdasarkan masalah nyata dan celah riset yang telah diuraikan, skripsi ini bertujuan mengimplementasikan dan mengevaluasi YOLO11 untuk deteksi penyakit dan hama tanaman jagung pada kondisi lapangan. Fokus kajian meliputi pembuatan dan anotasi dataset lapangan yang representatif, penyesuaian arsitektural serta strategi *training/augmentasi* yang ditujukan untuk meningkatkan deteksi objek kecil dan gejala tumpang tindih, dan perbandingan performa YOLO11 dengan varian YOLO sebelumnya atau metode lain yang relevan. Hasil diharapkan memberikan kontribusi praktis bagi sistem monitoring pertanian *real-time* dan referensi metodologis untuk penelitian lanjutan [5].

1.2 Rumusan Masalah

Berdasarkan latar belakang di atas, adapun rumusan masalahnya adalah:

1. Merancang model YOLO11 untuk mendeteksi penyakit tanaman jagung dari citra daun?
2. Bagaimana mengintegrasikan model YOLO11 ke dalam sistem berbasis aplikasi untuk melakukan deteksi otomatis penyakit tanaman jagung dari citra yang diunggah pengguna?
3. Seberapa baik kinerja model YOLO11 dalam membedakan lima kategori kondisi daun jagung (Hawar Daun, Batang Busuk, Bercak Abu-abu, Karat Daun, dan Sehat) pada platform aplikasi ditinjau dari akurasinya?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah yang telah dijelaskan maka tujuan dari penelitian ini adalah sebagai berikut:

1. Mengembangkan dan melatih model YOLO11 untuk mendeteksi penyakit tanaman jagung berdasarkan citra daun.
2. Menilai kinerja model YOLO11 dalam membedakan lima kategori kondisi daun jagung (Hawar Daun, Batang Busuk, Bercak Abu-abu, Karat Daun, dan Sehat) berdasarkan nilai akurasi pada platform aplikasi.
3. Membangun sistem berbasis aplikasi yang dapat mengintegrasikan model YOLO11 untuk melakukan deteksi penyakit tanaman jagung secara otomatis dari citra yang diunggah pengguna.

1.4 Batasan Penelitian

Adapun batasan dalam penelitian ini adalah sebagai berikut:

1. Objek penelitian hanya mencakup lima kategori kondisi tanaman jagung, yaitu: Hawar Daun, Batang Busuk, Bercak Abu-abu, Karat Daun, dan Sehat.
2. Data yang digunakan dalam penelitian hanya berupa citra/gambar tanaman jagung khususnya pada bagian daun atau batang yang diunggah melalui aplikasi.
3. Aplikasi yang dibangun hanya berjalan pada platform mobile (Android) sesuai rancangan.
4. Metode deteksi penyakit yang digunakan hanya berfokus pada model *deep learning* YOLO11.
5. Pengujian sistem hanya difokuskan pada kemampuan aplikasi dalam mendeteksi lima kategori penyakit berdasarkan akurasi.

1.5 Manfaat Penelitian

Adapun manfaat penelitian yang diperoleh dari tujuan penelitian adalah sebagai berikut:

1. Penelitian ini memberikan kontribusi bagi pengembangan ilmu pengetahuan khususnya dalam bidang *computer vision*, *deep learning*, dan deteksi penyakit tanaman. Hasil penelitian ini dapat menjadi referensi akademik bagi

penelitian selanjutnya terkait penerapan YOLO11 dalam identifikasi penyakit tanaman jagung maupun komoditas pertanian lainnya.

2. Menghasilkan implementasi YOLO11 dalam bentuk sistem aplikasi yang mampu mendeteksi lima kategori penyakit jagung yaitu hawar daun, batang busuk (*Stalk Rot*), bercak abu-abu (*Gray Leaf Spot*), karat daun, dan sehat secara otomatis. Sistem ini dapat dikembangkan lebih lanjut menjadi aplikasi siap pakai di lapangan.
3. Deteksi dini melalui aplikasi ini dapat membantu pengguna mengambil langkah penanganan lebih cepat sehingga mengurangi kerusakan tanaman akibat penyakit, meningkatkan produktivitas hasil panen jagung, membantu efisiensi dan keberlanjutan usaha pertanian.

1.6 Sistematika Penulisan

Sistematika penulisan karya ilmiah dapat berupa penyeragaman format penyajian karya ilmiah sebagai standar dari penyusunan karya ilmiah sebagai pedoman atau acuan penyusunan karya ilmiah dan agar karya ilmiah dapat dibaca dengan mudah. Pada penelitian ini sistematika penulisan terdiri atas:

BAB I PENDAHULUAN

Pada bab ini menjelaskan tentang latar belakang masalah, rumusan masalah, tujuan dari penelitian, manfaat penelitian dan sistematika penulisan secara keseluruhan. Bab ini memberikan dasar dan alasan utama dilaksanakannya penelitian, serta arah pengembangan sistem aplikasi yang dirancang.

BAB II TINJAUAN LITERATUR

Bab ini menyajikan ringkasan teori dan penelitian terkait deteksi penyakit jagung, pengolahan citra digital serta penggunaan model YOLO11. Tinjauan ini menjadi dasar metode penelitian, menjelaskan konsep penyakit jagung yang dianalisis, prinsip dasar *deep learning* untuk deteksi serta merangkum teknologi dan

186 penelitian terdahulu sebagai pembanding. Dengan demikian bab ini memberikan
54 landasan teoritis yang mendukung arah penelitian.

BAB III METODOLOGI PENELITIAN

Bab ini menjelaskan jenis penelitian, metode yang digunakan, alur kerja penelitian, serta proses pengumpulan dan pengolahan data. Model yang dihasilkan diuji untuk menilai kinerjanya kemudian diimplementasikan dalam aplikasi sebagai bentuk penerapan sistem.

BAB IV HASIL DAN PEMBAHASAN

29 Bab ini menjelaskan hasil penelitian yang diperoleh dari implementasi
209 metode YOLO11 dalam mendeteksi penyakit tanaman jagung. Pembahasan diawali
dengan proses pengumpulan dataset yang terdiri dari lima kategori kondisi tanaman jagung, yaitu Hawar Daun, Bercak Abu-Abu, Batang Busuk, Karat Daun, dan
2 Sehat. Selanjutnya dijelaskan tahapan *preprocessing* dan augmentasi data yang dilakukan untuk meningkatkan kualitas dataset sebelum digunakan pada proses
206 pelatihan model. Pada bab ini juga dipaparkan proses pelabelan data menggunakan *bounding box*, pelatihan model YOLO11, serta hasil pengujian yang meliputi nilai
34 *precision*, *recall*, F1-score, dan *mean Average Precision* (mAP). Selain itu, dilakukan analisis terhadap performa model melalui pembahasan hasil deteksi, studi ablasi (*ablation study*), serta perbandingan kinerja YOLO11 dengan model lain
97 seperti YOLOv5 dan YOLOv8. Pembahasan pada bab ini bertujuan untuk mengetahui tingkat efektivitas dan keakuratan model dalam mendeteksi penyakit tanaman jagung pada berbagai kondisi citra.

BAB V KESIMPULAN DAN SARAN

Bab ini berisi kesimpulan yang diperoleh berdasarkan hasil penelitian dan pembahasan yang telah dilakukan pada bab sebelumnya. Kesimpulan disusun untuk menjawab rumusan masalah serta menunjukkan tingkat keberhasilan implementasi YOLO11 dalam mendeteksi penyakit tanaman jagung. Selain itu, bab ini juga memuat saran yang dapat digunakan sebagai bahan pengembangan penelitian selanjutnya, baik dari aspek dataset, metode deteksi, parameter pelatihan, maupun pengembangan sistem berbasis aplikasi. Dengan adanya saran tersebut, diharapkan penelitian berikutnya dapat menghasilkan sistem deteksi penyakit tanaman jagung yang lebih akurat, efisien, dan mampu diterapkan secara luas dalam bidang pertanian cerdas (*smart agriculture*).

BAB II

TINJAUAN LITERATUR


2.1 Pendahuluan

Model deteksi objek modern seperti YOLO11 memiliki peran penting dalam pengembangan sistem pengenalan penyakit pada tanaman jagung karena kemampuannya melakukan deteksi secara cepat (*real-time*) dan akurat. Arsitektur YOLOv11 dirancang untuk meningkatkan efisiensi ekstraksi fitur melalui mekanisme *backbone* dan *head* yang telah dioptimalkan sehingga model mampu mengenali pola kerusakan pada daun secara lebih presisi. Penelitian terbaru menunjukkan bahwa pemanfaatan YOLOv11 dalam domain pertanian mampu memberikan peningkatan performa dibandingkan versi sebelumnya. Bahwa YOLO11 yang dimodifikasi mampu meningkatkan kinerja deteksi penyakit pada daun jagung secara signifikan dengan rata-rata mAP@50 mencapai 82%. Hasil ini menunjukkan bahwa integrasi mekanisme *feature enhancement* membantu model mengenali pola halus seperti perubahan warna lesi kecil atau lubang akibat serangan ulat. Studi tersebut juga menegaskan bahwa YOLOv11 memiliki stabilitas lebih baik.

2.3 YOLO (You Only Look Once)

YOLO11 adalah arsitektur *deep learning* untuk deteksi objek yang banyak digunakan pada pengolahan citra pertanian. Model ini bekerja *end-to-end* dengan mengekstraksi fitur pada berbagai skala sehingga mampu mengenali gejala penyakit jagung seperti karat daun, hawar daun, bercak abu, batang busuk, secara cepat dan akurat dibandingkan generasi sebelumnya.

YOLO11 lebih efisien secara komputasi, lebih stabil saat *training*, dan lebih baik dalam mendeteksi objek kecil di lapangan melalui tiga inovasi utama pada ekstraksi fitur. Beberapa penelitian juga mengembangkan modifikasi berbasis YOLO, seperti RDW-YOLO, yang menambahkan modul ekstraksi fitur khusus sehingga mampu meningkatkan deteksi objek kecil dan gejala awal kerusakan daun [3].



Gambar 2.1: Arsitektur YOLO11 (You Only Look Once)

Tabel 2.1 Penggunaan metode YOLO 11 berbagai objek penelitian

Tujuan	Objek	Akurasi	Kelas	No ref
Deteksi	Buah Kopi	62,3%.	3	[6]
Deteksi	Tomat	87,3%	6	[7]
Optimasi	Pejalan Kaki	83.2%	1	[8]
Deteksi	Apel	83.5%	3	[9]
Klasifikasi	Bilah Bambu	81.8%	6	[10]

Berdasarkan berbagai penelitian pada Tabel 2.1 menunjukkan bahwa model

YOLO mampu memberikan performa deteksi penyakit tanaman secara efisien meskipun pada citra dengan kondisi visual yang bervariasi. Penelitian ini

25

172

menegaskan bahwa kemampuan ekstraksi fitur YOLO cukup baik untuk mendeteksi pola penyakit pada tanaman yang memiliki tekstur kompleks [6].

Penelitian ini menunjukkan bahwa metode YOLOv11 mampu meningkatkan deteksi tingkat kematangan buah tomat secara *real-time*. Model berhasil mengenali enam kategori kematangan buah tomat dengan baik. Penambahan modul peningkatan fitur juga meningkatkan akurasi deteksi pada lingkungan yang kompleks, sehingga performa model lebih baik dibandingkan YOLOv11 dasar dan layak digunakan untuk otomatisasi pemantauan serta pemanenan buah tomat [7].

Pada konteks berbeda YOLO11 *improved* sebagai solusi untuk pendeteksian pejalan kaki pada lingkungan padat. Integrasi C3K2 *lighter triplet attention* terbukti meningkatkan performa dalam menangani objek kecil serta kasus *occlusion*. Temuan ini memperlihatkan bahwa penguatan modul-modul internal YOLO11 dapat meningkatkan sensitivitas model terhadap objek kecil, suatu karakteristik yang juga relevan pada deteksi objek tanaman [8].

Selanjutnya mengembangkan YOLO WAS untuk deteksi apel multispecies dan menghasilkan peningkatan akurasi yang signifikan melalui penerapan modul C2PSA SCSA. Optimalisasi ini menekankan bahwa kombinasi *wavelet transform* dan mekanisme perhatian mampu meningkatkan kestabilan deteksi pada lingkungan kebun yang kompleks [9].

Peran modifikasi YOLO11 dalam industri manufaktur di mana YOLO berhasil meningkatkan pendeteksian cacat bambu dengan memadukan modul TriMAD Conv dan C3k2 AddCGLU. Mekanisme ini meningkatkan sensitivitas model terhadap cacat berukuran kecil maupun memanjang, memberikan bukti

bahwa struktur YOLO11 dapat diadaptasi untuk berbagai jenis objek bertekstur kompleks [10].

Secara keseluruhan hasil penelitian pada Tabel 2.1 menunjukkan bahwa pengembangan dari model dasar YOLO11 umumnya difokuskan pada peningkatan kemampuan model dalam menangani objek kecil, lingkungan kompleks dan variasi visual yang tinggi. Hal ini menjadi dasar penting dalam pengembangan metode deteksi objek tanaman termasuk jagung yang juga menghadapi tantangan serupa seperti tekstur daun yang tidak seragam, *occlusion* dan perubahan kondisi lapangan. Untuk memberikan gambaran yang lebih terstruktur mengenai perbandingan performa berbagai pendekatan tersebut, tabel 2.2 ada beberapa penelitian terkait deteksi penyakit dan hama tanaman yang menggunakan metode berbeda.

Tabel 2.2 Deteksi penyakit hama dengan berbagai penelitian

Metode	Objek	Akurasi	No ref
YOLOv5	Tanaman Hama	80.7%	[11]
SSD	Penyakit Daun	73,07%	[12]
K-Means,SVM	Daun Cabai Rawit	82%	[13]

Tabel 2.2 memperlihatkan bahwa metode deteksi penyakit tanaman berbasis citra telah berkembang melalui beragam pendekatan mulai dari *deep learning* modern hingga kombinasi teknik ekstraksi fitur dan klasifikasi. Penelitian menunjukkan bahwa model YOLOv5 memperoleh *mean Average Precision* (mAP) sebesar 80,7%, yang menunjukkan bahwa metode ini mampu melakukan deteksi objek secara cepat dengan tingkat akurasi yang cukup baik. Namun, performanya masih lebih rendah dibandingkan model *ensemble* yang dikembangkan dalam penelitian tersebut [11]. Menggunakan metode *Single Shot Detector* (SSD) untuk mendeteksi penyakit tanaman berdasarkan citra daun menggunakan dataset

PlantVillage yang terdiri atas 38 kelas penyakit dan daun sehat. Model SSD memperoleh *mean Average Precision* (mAP) sebesar 73,07%, yang menunjukkan bahwa metode ini mampu melakukan deteksi penyakit tanaman secara otomatis, namun performanya masih dipengaruhi oleh kompleksitas variasi kelas penyakit dan karakteristik citra yang digunakan. Oleh karena itu, peningkatan metode deteksi masih diperlukan untuk memperoleh akurasi yang lebih tinggi [12].

Metode *image recognition* untuk mendeteksi lima jenis kondisi daun cabai yaitu daun sehat, tungau, kutu kebul, virus kuning, dan bercak daun. Prosesnya meliputi *cropping*, *resizing*, *remove-background*, konversi *grayscale*, selanjutnya dikelompokkan dengan K-Means sebelum diklasifikasi menggunakan SVM. Hasilnya model mencapai akurasi 82% menunjukkan bahwa kombinasi K-Means dan SVM cukup efektif untuk identifikasi awal hama dan penyakit cabai [13].

Secara keseluruhan berbagai penelitian menunjukkan bahwa metode deteksi penyakit tanaman dapat mencapai performa tinggi baik menggunakan *deep learning* maupun teknik ekstraksi fitur. YOLOv5 dan SSD mampu memberikan akurasi serta F1-score yang kuat pada deteksi penyakit daun berbasis citra, terutama pada kelas dengan jumlah data memadai. Sementara itu pendekatan tradisional seperti dikombinasikan dengan K-Means dan SVM juga terbukti efektif pada kondisi tertentu meskipun akurasinya lebih rendah dibandingkan model *deep learning*. Temuan ini menegaskan bahwa metode yang digunakan harus disesuaikan dengan karakteristik data dan tujuan implementasi untuk memperoleh hasil deteksi yang optimal. Untuk memberikan gambaran yang lebih luas mengenai variasi metode yang digunakan pada penelitian sejenis rangkuman berikutnya disajikan pada Tabel 2.3.

Tabel 2.3 Deteksi penyakit hama tanaman jagung dari berbagai metode

Metode	Akurasi	Kelas	No ref
NAÏVE BAYES CLASSIFIER	58.33%	15	[14]
RANDOM FOREST	79.23%	4	[15]
RESNET50	85,13%	8	[16]
YOLOV7	76.3%	13	[17]

48 Berdasarkan berbagai penelitian pada Tabel 2.3 menunjukkan bahwa metode Naïve Bayes untuk mendeteksi penyakit tanaman jagung berdasarkan 46 gejala yang mewakili 15 jenis penyakit. Sistem meminta pengguna memilih gejala yang muncul kemudian menghitung probabilitas untuk menentukan penyakit paling mungkin. Hasil pengujian menunjukkan kecocokan 18 dari 30 kasus pada lahan pertama dan 17 dari 30 kasus pada lahan kedua dengan akurasi sekitar 60%. Metode ini mampu memberikan deteksi awal namun akurasinya masih rendah sehingga perlu dikombinasikan dengan metode lain agar lebih tepat [14].

81 Metode berbasis *Machine Learning*, khususnya Random Forest, masih menjadi salah satu pendekatan yang banyak digunakan dalam deteksi penyakit tanaman jagung karena memiliki kemampuan yang baik dalam mengklasifikasikan data berdasarkan hasil ekstraksi fitur serta mampu mengurangi risiko *overfitting* melalui mekanisme *ensemble*. Pendekatan ini menjadi dasar dalam pengembangan sistem deteksi penyakit secara otomatis yang dapat membantu proses identifikasi penyakit jagung secara cepat, akurat, dan efisien, serta berpotensi diterapkan pada berbagai sistem pemantauan pertanian berbasis teknologi [15].

10 Penelitian ini menggunakan Model berbasis ResNet50 masih menjadi salah satu *backbone* yang banyak digunakan dalam deteksi penyakit dan hama tanaman jagung karena memiliki kemampuan yang baik dalam mengekstraksi fitur citra

11

secara mendalam dengan tetap mempertahankan efisiensi komputasi. Penggunaan *Residual Network* (ResNet50) mampu mengatasi permasalahan degradasi jaringan pada arsitektur yang semakin dalam melalui mekanisme *skip connection*, sehingga proses ekstraksi fitur menjadi lebih optimal [16].

Penggunaan metode YOLOv7 yang dioptimalkan dengan *optimizer* untuk mendeteksi tiga jenis hama utama jagung yaitu corn borer, armyworm dan *bollworm*. Model ini dirancang untuk meningkatkan akurasi dan stabilitas deteksi pada kondisi lapangan [17].

Penelitian pada Tabel 2.3 metode deteksi penyakit dan hama tanaman jagung memiliki performa yang berbeda-beda. Metode Naïve Bayes hanya mencapai akurasi sekitar 60% sehingga masih kurang optimal untuk proses diagnosis penyakit. Sementara itu, metode berbasis *Machine Learning* seperti Random Forest mampu meningkatkan kemampuan klasifikasi melalui mekanisme *ensemble* sehingga menghasilkan performa yang lebih baik. Di sisi lain, pendekatan berbasis *Deep Learning* seperti ResNet50 memiliki kemampuan yang baik dalam mengekstraksi fitur citra, sedangkan YOLOv7 mampu memberikan hasil deteksi yang lebih cepat, akurat, dan stabil pada kondisi lapangan. Secara umum, setiap metode memiliki kelebihan sesuai dengan karakteristik data dan kebutuhan aplikasi. Untuk memberikan gambaran yang lebih jelas mengenai dataset yang digunakan dalam penelitian ini, maka disajikan Tabel 2.4 sebagai berikut.

Tabel 2.4 Dataset penelitian objek tanaman Jagung

Kelas	Jumlah	Refrensi	No ref
2	3720	Dataset citra daun jagung dari Kaggle	[18]
8	19,451	Dataset langsung di lapangan pertanian	[19]
15	30	Dataset lahan jagung	[14]
38	54.306	Dataset citra penyakit	[12]

Tabel 2.4 menunjukkan bahwa variasi jumlah dan jenis dataset sangat berpengaruh terhadap performa model deteksi penyakit jagung. Dataset besar seperti 3.720 citra daun dari Kaggle memberikan kemampuan generalisasi lebih baik terbukti mampu meningkatkan akurasi metode *Gray Level Co-occurrence Matrix* (GLCM), ANN hingga 99.5% [18]. Sementara itu dataset lapangan berjumlah kecil tetap penting karena mencerminkan kondisi nyata. Pada penelitian KNN berbasis Hue, 30 citra lapangan mampu menghasilkan akurasi 83% meskipun dipengaruhi variasi pencahayaan [19].

Dataset pada penelitian ini berasal dari dinas pertanian kabupaten Bangkalan terdiri dari 46 gejala yang mewakili 15 jenis penyakit jagung. Selain itu digunakan 30 data kasus uji dari dua lokasi lahan untuk mengevaluasi hasil deteksi sistem berbasis Naive Bayes [14].

Dataset tersebut terdiri dari 38 kelas, yang mencakup jenis tanaman jagung. Total dataset berjumlah 54.306 citra, yang kemudian dibagi menjadi 38.017 citra data latih (70%), 10.858 citra data validasi (20%), dan 5.431 citra data uji (10%). Pembagian data tersebut dilakukan untuk melatih, memvalidasi, dan mengevaluasi performa model *deep learning* dalam mengidentifikasi penyakit tanaman [12].

Berdasarkan Tabel 2.4 terlihat bahwa ukuran, sumber, dan karakteristik dataset sangat memengaruhi performa model deteksi penyakit tanaman. Dataset

berukuran besar umumnya mampu meningkatkan kemampuan model dalam mengenali berbagai variasi gejala penyakit sehingga menghasilkan akurasi yang lebih tinggi dibandingkan dataset dengan jumlah citra yang terbatas. Dataset lapangan tetap memiliki nilai penting karena merepresentasikan kondisi nyata, meskipun performa model dapat dipengaruhi oleh variasi pencahayaan, latar belakang, dan kualitas citra. Selain itu, dataset berbasis gejala dari instansi pertanian banyak digunakan pada sistem pakar untuk mendeteksi penyakit berdasarkan gejala yang diamati.

Sementara itu, penelitian ini menggunakan PlantVillage Dataset yang terdiri atas 38 kelas dengan total 54.306 citra yang dibagi menjadi 38.017 data latih (70%), 10.858 data validasi (20%), dan 5.431 data uji (10%). Jumlah data yang besar serta variasi kelas yang lengkap memberikan kemampuan generalisasi yang lebih baik bagi model *deep learning* dalam mengidentifikasi berbagai penyakit tanaman. Secara keseluruhan, pemilihan dataset yang sesuai, baik dari segi jumlah, kualitas, maupun keragaman kelas, menjadi faktor penting dalam meningkatkan efektivitas dan keandalan sistem deteksi penyakit tanaman. Untuk memberikan gambaran yang lebih jelas mengenai penelitian yang digunakan, selanjutnya disajikan Tabel 2.5.

Tabel 2.5 Akurasi penelitian tanaman jagung

Metode	Kelas	Akurasi	Recall	Specificity	Precision	F-1score	No ref
YOLOV7	13	76.3%	77,3%	96,3%	73,3%	75,2%	[17]
Naive Bayes	15	60%	60%	70%	60%	60%	[14]

Tabel 2.5 menunjukkan bahwa penelitian menggunakan metode YOLOv7, yaitu pengembangan dari algoritma YOLOv7, untuk mendeteksi hama pada tanaman jagung. Dataset yang digunakan berasal dari IP102, dengan memilih 13

kelas hama jagung (IP13) yang terdiri dari 4.533 citra. Dataset dibagi menjadi data latih dan data validasi dengan rasio sekitar 80:20 menggunakan 5-fold *cross-validation*, sehingga diperoleh 3.600 citra data latih dan 932 citra data uji. Hasil pengujian menunjukkan bahwa metode Maize-YOLO memperoleh mAP sebesar 76,3%, serta mampu melakukan deteksi secara *real-time* dengan kecepatan 67 FPS. Hasil tersebut menunjukkan bahwa Maize-YOLO mampu memberikan keseimbangan yang baik antara akurasi, kecepatan deteksi, dan efisiensi komputasi sehingga efektif untuk mendeteksi hama pada tanaman jagung [17].

Naive Bayes menggunakan 46 gejala dari Dinas Pertanian Bangkalan untuk mendeteksi 15 jenis penyakit jagung. Sistem menentukan hasil diagnosis berdasarkan probabilitas kemunculan gejala. Hasil pengujian menunjukkan kecocokan sekitar 60% sehingga metode ini cukup membantu deteksi awal namun belum akurat bila dibandingkan metode berbasis citra [14].

Metode YOLOv7 sangat efektif untuk mendeteksi hama pada tanaman jagung dengan memanfaatkan dataset citra IP13 yang terdiri atas 13 kelas hama. Metode ini mampu mencapai mAP sebesar 76,3% serta memiliki kemampuan deteksi secara *real-time* dengan kecepatan 67 FPS, sehingga memberikan keseimbangan yang baik antara akurasi, kecepatan deteksi, dan efisiensi tingkat kecocokan sekitar 60% sehingga lebih sesuai digunakan sebagai sistem deteksi. Untuk memberikan gambaran yang lebih jelas mengenai metode dan cakupan penelitian yang digunakan, selanjutnya disajikan Tabel 2.6.

Tabel 2.6 Akurasi YOLO11 dengan berbagai penelitian

Objek	Kelas	Akurasi	R	S	P	F-1score	No ref
kopi	5	84.54%	77.4%	86.50%	81.1%	79.2%	[18]
Tomat	6	83%	80.3%	88.6%	84.0%	82.2%	[19]
Bawah laut	4	77.4%	70.3%	81,0%	78.8%	74.0%	[20]
menara distribusi listrik	2	80%	0.801%	0.92%	0.886%	84.3%	[21]
Daun kapas	8	77.1%	73.6%	84.2%	81.7%	77.4%	[22]

Pada Tabel 2.6 menunjukkan bahwa Penelitian ini membuktikan bahwa metode YOLOv11 mampu mendeteksi tingkat kematangan buah kopi secara *real-time* dengan performa yang baik pada lima kategori kematangan, yaitu dry, overripe, ripe, semi-ripe, dan unripe. Model memperoleh Hasil evaluasi menunjukkan bahwa model memiliki kemampuan deteksi yang baik terutama pada kategori ripe dan semi-ripe, sedangkan kategori unripe masih memiliki tingkat deteksi yang lebih rendah akibat kemiripan warna dengan latar belakang dan ketidakseimbangan jumlah data. Secara keseluruhan, metode ini efektif digunakan untuk membantu proses pemantauan tingkat kematangan buah kopi secara otomatis [18].

Penelitian ini bahwa metode YOLOv11 mampu meningkatkan kinerja deteksi tingkat kematangan buah tomat secara *real-time* melalui pengembangan arsitektur yang lebih ringan dan efisien. Model berhasil mengenali enam kategori kematangan buah tomat. Hasil penelitian menunjukkan bahwa penambahan modul peningkatan fitur mampu meningkatkan kemampuan deteksi objek pada kondisi

lingkungan yang kompleks sehingga model memiliki performa yang lebih baik dibandingkan YOLOv11 dasar dan layak diterapkan untuk proses otomatisasi pemantauan serta pemanenan buah tomat [19].

Metode YOLOv11 mampu meningkatkan performa deteksi objek bawah laut secara *real-time* melalui penambahan mekanisme perhatian (*attention mechanism*) dan strategi peningkatan fitur multi-skala. Hasil pengujian menunjukkan bahwa metode ini mampu meningkatkan kemampuan deteksi berbagai objek bawah laut, seperti teripang, landak laut, kerang, dan bintang laut, terutama pada kondisi lingkungan yang kompleks, objek berukuran kecil, serta target yang saling berdekatan. Secara keseluruhan, model memiliki performa yang lebih baik dibandingkan YOLOv11 dasar sehingga berpotensi diterapkan pada sistem pemantauan bawah laut secara otomatis [20].

Penelitian ini memperkenalkan TDD-YOLO sebuah pengembangan dari YOLOv11n yang dirancang khusus untuk mendeteksi *defect* berukuran sangat kecil pada infrastruktur distribusi listrik. Model ini menggabungkan modul SPD-Conv, CBAM, BiFPN, serta *detection head* beresolusi 160×160 yang terbukti meningkatkan kemampuan ekstraksi fitur pada objek kecil [21].

YOLO mampu mendeteksi hama dan penyakit daun kapas secara *real-time* dengan performa yang lebih baik dibandingkan YOLOv11 dasar terbukti meningkatkan kemampuan model dalam mendeteksi lesi berukuran kecil, objek yang saling tumpang tindih, serta penyakit pada latar belakang yang kompleks. Meskipun demikian, model masih mengalami keterbatasan pada beberapa jenis penyakit dengan kontras rendah atau bentuk lesi yang tidak beraturan sehingga masih diperlukan pengembangan lebih lanjut melalui penambahan variasi data dan

peningkatan mekanisme perhatian (*attention mechanism*). Secara keseluruhan, penelitian ini menunjukkan bahwa RDL-YOLO efektif digunakan untuk sistem deteksi hama dan penyakit tanaman secara otomatis di bidang pertanian [22].

Secara keseluruhan peningkatan modul fitur dan arsitektur deteksi beresolusi tinggi menghasilkan performa *real-time* yang stabil dan akurat meskipun beberapa kelas objek masih memerlukan peningkatan. Seluruh model menunjukkan potensi kuat untuk diterapkan dalam sistem pemantauan otomatis dan manajemen pertanian cerdas. Untuk memberikan gambaran yang lebih jelas serta cakupan yang digunakan pada penelitian ini, berikut disajikan Tabel 2.7 sebagai berikut.

Tabel 2.7 Dataset penyakit tanaman jagung

Dataset	Kelas	Jumlah	No ref
Gejala dan jenis penyakit	15	45	[14]
Gambar daun jagung	8	19.451	[19]
Kaggle	2	3.720	[18]

Tabel 2.7 menunjukkan bahwa setiap metode deteksi penyakit jagung memiliki keunggulan dan batasannya masing-masing. Metode Naive Bayes menggunakan 46 gejala untuk memprediksi 15 jenis penyakit dan menghasilkan akurasi sekitar 60% sehingga lebih cocok untuk deteksi awal berbasis gejala namun kurang akurat pada kondisi lapangan dengan gejala yang saling mirip [14]. Sementara itu dataset lapangan berjumlah kecil tetap penting karena mencerminkan kondisi nyata. Pada penelitian KNN berbasis Hue, 8 citra lapangan meskipun dipengaruhi variasi pencahayaan [19]. Selain itu penelitian oleh Permadi Hidayat menggunakan kombinasi *Gray Level Co-occurrence Matrix* (GLCM) dan ANN *backpropagation* untuk mendeteksi hawar daun jagung berbasis tekstur. Model ini dilatih pada 3.000, 3.720 citra daun dari Kaggle dan mampu mencapai akurasi

99.5% serta *precision* dan *recall* 100%, sehingga sangat efektif untuk mendeteksi pola penyakit yang memiliki ciri tekstur yang kuat [18].

Berdasarkan Tabel 2.7 metode berbasis citra terbukti memberikan performa deteksi penyakit jagung yang jauh lebih akurat dibandingkan pendekatan berbasis gejala. Metode Naive Bayes hanya mencapai akurasi sekitar 60% sehingga kurang efektif untuk kondisi lapangan. Sebaliknya model KNN berbasis Hue mampu mencapai akurasi 90% berkat pemanfaatan citra dan modul perhatian yang lebih adaptif dalam mengenali objek kecil. Pendekatan GLCM, ANN juga menunjukkan performa sangat tinggi dengan akurasi 99.5% serta *precision* dan *recall* 100% sehingga sangat efektif untuk mendeteksi tekstur penyakit yang khas pada daun jagung. Secara keseluruhan metode berbasis citra dan *deep learning* memberikan hasil deteksi yang lebih unggul. Untuk memberikan gambaran yang lebih jelas serta cakupan yang digunakan pada penelitian ini, berikut disajikan Tabel 2.8 sebagai berikut.

Tabel 2.8 Posisi Penelitian Yang Dilakukan

Metode	Kelas	Dataset	Objek	Akurasi	No ref
Navie Bayes Classifier	15	46 Gejala	Jagung	60%	[23]
YOLOV7	13	4.533 citra	Jagung	76.3%	[17]
KNN	4	2.048	Jagung	75.01%	[22][24]
RESNET50	8	2.775	Jagung	78.62%	[16]
YOLO11	5	5000	Jagung	-	-

Berdasarkan Tabel 2.8 metode metode Naive Bayes untuk mendeteksi penyakit tanaman jagung berdasarkan 46 gejala yang mewakili 15 jenis penyakit dan diuji menggunakan 30 kasus dari dua lokasi lahan. Sistem menentukan penyakit

berdasarkan probabilitas kemunculan gejala yang dipilih pengguna. Hasil pengujian menunjukkan kecocokan [23].

Penelitian ini menggunakan metode *Color moments* dan *Gray Level Co-occurrence Matrix* (GLCM) untuk mengekstraksi fitur warna dan tekstur daun jagung lalu diklasifikasikan menggunakan KNN. Dataset terdiri dari 160 citra yang terbagi dalam empat kelas yaitu daun sehat, hawar daun, bercak daun, dan karat daun. Hasil pengujian menunjukkan akurasi tertinggi 89.375% pada nilai k1 dengan *Euclidean Distance* sehingga metode ini cukup efektif untuk deteksi penyakit daun jagung berbasis citra [17].

Penelitian ini menggunakan metode YOLO, yaitu pengembangan dari algoritma YOLOv7, untuk mendeteksi hama pada tanaman jagung. Dataset yang digunakan merupakan IP13, yaitu subset dari IP102, yang terdiri atas 4.533 citra dengan 13 kelas hama jagung [22]. Hasil pengujian menunjukkan bahwa model YOLO mampu melakukan deteksi secara *real-time* dengan kecepatan 67 FPS, sehingga metode ini efektif digunakan untuk mendeteksi hama pada tanaman jagung secara akurat dan efisien [24].

Model ResNet50 digunakan untuk mengklasifikasikan penyakit pada tanaman jagung menggunakan dataset citra yang telah melalui proses pelatihan, validasi, dan pengujian. Arsitektur ResNet50 dengan konsep *residual learning* mampu mengekstraksi fitur citra secara mendalam sehingga meningkatkan kemampuan model dalam membedakan berbagai kelas penyakit. Hasil pengujian menunjukkan bahwa model ResNet50 memperoleh nilai akurasi yang tinggi serta mampu mengklasifikasikan penyakit jagung secara efektif. Dengan kemampuan ekstraksi fitur yang baik, ResNet50 menjadi salah satu metode *deep learning* yang

andal untuk mendukung proses identifikasi penyakit tanaman jagung secara otomatis [16].

Berdasarkan Tabel 2.8 terlihat bahwa setiap metode memiliki kemampuan yang berbeda dalam mendeteksi penyakit dan objek pada tanaman jagung. Metode Naive Bayes hanya mampu mencapai akurasi sekitar 60% sehingga kurang akurat ketika diterapkan pada kondisi lapangan yang kompleks. Pendekatan berbasis citra seperti *color moments* dan YOLOv7 memberikan hasil akurasi 76.3% [24]. Sebaliknya ResNet50 dengan arsitektur yang ditingkatkan mampu mencapai akurasi 78.62% [25].

Melalui perbandingan tersebut dapat disimpulkan bahwa YOLO11 merupakan pilihan metode yang paling tepat untuk digunakan dalam penelitian, karena merupakan pengembangan terbaru dari keluarga YOLO dengan peningkatan signifikan pada deteksi objek kecil, efisiensi komputasi, serta kemampuan generalisasi di kondisi lapangan yang beragam. YOLO11 jauh lebih stabil dan akurat dibandingkan metode tradisional seperti Naive Bayes dan KNN maupun model sebelumnya seperti YOLOv5, YOLOv6, YOLOv7, dan YOLOv8. Keunggulannya dalam kecepatan inferensi, ketahanan terhadap perubahan pencahayaan serta akurasi tinggi menjadikan YOLO11 sangat cocok untuk diterapkan pada deteksi penyakit, hama, maupun organ tanaman jagung secara *real-time*. Dengan demikian penggunaan YOLO11 sebagai metode penelitian memberikan dasar yang kuat untuk mencapai hasil deteksi yang lebih optimal [26].

86

BAB III

METODE PENELITIAN


Bab ini menjelaskan metode penelitian yang digunakan meliputi desain penelitian, proses pengumpulan dan pengolahan data, perancangan model YOLO11, serta teknik pelatihan, validasi, dan evaluasi yang digunakan untuk membangun sistem deteksi penyakit jagung.

180

3.1 Kerangka Penelitian

Kerangka penelitian ini dirancang untuk menjelaskan tahapan penelitian dalam pengembangan sistem menggunakan YOLO11.

90



101

Gambar 3.1: Kerangka Penelitian

Gambar 3.1 di atas merupakan kerangka penelitian yang memberikan gambaran singkat mengenai tahapan yang digunakan dalam pengembangan model YOLO11 untuk mendeteksi penyakit tanaman jagung. Setiap tahap akan dijelaskan lebih lanjut sebagai bagian dari proses penyusunan sistem deteksi berbasis citra.

1. Studi literatur dan analisis pra-penelitian

- A. Studi literatur dilakukan untuk mendapatkan dasar teori yang mendukung penelitian ini. Literatur yang dikaji meliputi penyakit tanaman jagung, pengolahan citra digital serta metode deteksi objek menggunakan YOLO11. Penyakit seperti hawar daun, bercak abu-abu, karat daun, batang busuk, dan daun sehat dipelajari melalui sumber pustaka sebagai acuan dalam penentuan kelas dataset. Metode YOLO (*You Only Look Once*) digunakan karena memiliki kecepatan dan akurasi tinggi dalam mendeteksi objek pada satu tahap pemrosesan. YOLO11 dipilih karena merupakan model yang lebih baru dengan perbaikan pada struktur *backbone*, *neck* dan *head* sehingga mampu mengidentifikasi objek kecil seperti bercak daun. Studi literatur juga mencakup penelitian sebelumnya yang membahas deteksi penyakit tanaman menggunakan model YOLO sehingga dapat dijadikan perbandingan terhadap penelitian ini.
- B. Analisis pra-penelitian dilakukan dengan mengidentifikasi kebutuhan data, metode dan langkah-langkah yang diperlukan dalam membangun sistem deteksi penyakit jagung berbasis YOLO11. Dataset dianalisis berdasarkan jumlah citra, variasi kondisi pencahayaan, jumlah kelas serta kelayakannya untuk digunakan pada model deteksi objek. Metode YOLO11 dianalisis dari segi kemampuan mengenali pola penyakit pada daun jagung melalui proses *training*, validasi dan evaluasi. Setiap tahap dianalisis untuk memastikan metode yang digunakan dapat menghasilkan model terbaik yang mampu mendeteksi penyakit secara akurat. Analisis ini memastikan bahwa rancangan penelitian, teknik anotasi, tahapan *preprocessing* dan parameter *training* sesuai dengan tujuan penelitian untuk menghasilkan model pendeteksi penyakit jagung yang efektif.

2. Pengumpulan dataset dan augmentasi data

A. Pengumpulan dataset

Pada tahap ini jenis data yang diperlukan adalah gambar daun jagung dengan lima kategori yaitu hawar daun, bercak abu, batang busuk, karat daun dan daun sehat sesuai dengan ciri-ciri dan kondisinya.

Tabel 3.1 Klasifikasi Penyakit Jagung Dan Kondisinya

No	Nama Penyakit	Diskripsi Kondisi Daun
1	Leaf Blight (Hawar Daun)	Ditandai dg bercak memanjang berwarna coklat keabu abuan, sering kali menyebar cepat
2	Gray Leaf Spot (bercak abu-abu)	Muncul sebagai bercak bulat/oval berwarna abu-abu dengan tepi kecokelatan pada permukaan daun.
3	Stem Rot (batang busuk)	Gejala berupa bagian pangkal batang atau pelepah yang menghitam, melunak, dan berbau busuk.
4	Rust (karat daun)	Timbul pustula kecil berwarna jingga/merah karat pada permukaan daun yang kemudian menyebar.
5	Healthy (sehat)	Daun berwarna hijau segar tanpa bercak, perubahan warna, luka, atau gejala infeksi lainnya.

B. Augmentasi data

Augmentasi data bertujuan meningkatkan kualitas data sebelum digunakan pada pelatihan. Seluruh gambar untuk menyesuaikan input YOLO11 dilakukan normalisasi agar warna dan intensitas gambar konsisten.

a. Teknik Rotasi (diputar 90°)

Teknik rotasi digunakan untuk memutar citra pada sudut tertentu agar dataset memiliki variasi posisi objek. Proses ini bertujuan membantu model mengenali objek dari berbagai arah, sehingga model tidak hanya bergantung pada posisi gambar asli.

b. Teknik pembalikan flip (kiri-kanan)

Teknik flip digunakan untuk membalik citra secara horizontal atau vertikal guna menambah variasi pada dataset.

c. Brightness


Teknik brightness digunakan untuk mengubah tingkat kecerahan citra agar dataset memiliki variasi pencahayaan.

d. Zoom Out

Teknik zoom out digunakan untuk memperkecil tampilan objek pada citra sehingga gambar memiliki variasi ukuran dan jarak objek.

3.2 Pelatihan Model YOLO11

Pelatihan model YOLO11 dilakukan menggunakan dataset citra daun jagung yang telah diberi anotasi. Pada tahap ini model belajar mengenali pola penyakit berdasarkan contoh yang diberikan. Proses pelatihan selama pelatihan model menyesuaikan bobotnya agar mampu menghasilkan prediksi yang lebih akurat. Pelatihan ini menghasilkan file model *best.pt* yang nantinya digunakan pada proses deteksi penyakit jagung.



Gambar 3.2: Pelatihan Model YOLO11

Gambar 3.2 menunjukkan alur proses pelatihan model YOLO11 yang digunakan dalam penelitian ini. Tahap pertama adalah pengumpulan data yaitu mengumpulkan citra daun jagung dari lapangan yang mencakup lima kategori yaitu hawar daun, bercak abu, batang busuk, karat daun dan daun sehat. Gambar diambil dari berbagai sudut dan kondisi pencahayaan untuk mendapatkan variasi data yang lebih lengkap. Tahap berikutnya adalah *preprocessing* yaitu melakukan penyesuaian gambar sebelum dilatih kedalam model. Pada tahap ini citra daun dilakukan *resize* agar sesuai dengan ukuran input YOLO11 kemudian dilakukan normalisasi warna untuk menstabilkan pencahayaan. Augmentasi seperti rotasi dan flip juga diterapkan untuk menambah keragaman data sehingga model dapat mengenali penyakit dalam berbagai orientasi. Setelah itu, dilakukan pelabelan data (*annotation*) menggunakan perangkat lunak LabelImg berbasis Python, di mana setiap area penyakit diberi *bounding box* dan label kelas sesuai kategori penyakit. Daun jagung kemudian diekspor ke dalam format YOLO agar dapat digunakan saat proses pelatihan.

Langkah berikutnya adalah Pelatihan Model YOLO11 (*Training*). Pada tahap ini data latih dimasukkan ke model untuk mempelajari pola visual penyakit daun jagung. YOLO11 melakukan ekstraksi fitur melalui *backbone*, menggabungkan informasi melalui *neck* dan menghasilkan prediksi *bounding box* serta label kelas pada *detection head*. Proses pelatihan ini diikuti dengan Pembaruan Bobot Model yaitu perbaikan bobot YOLO11 berdasarkan nilai *loss* yang dihitung dari selisih antara prediksi dan label asli. Nilai *loss* ini mencakup *classification loss*, *objectness loss*, dan *bounding box loss*. Pembaruan bobot dilakukan terus menerus pada setiap *epoch* agar model semakin akurat. Secara bersamaan dilakukan validasi


model menggunakan data validasi. Tahap ini bertujuan untuk memastikan model belajar secara stabil dan tidak mengalami *overfitting*. Kinerja model dipantau pada setiap *epoch* dan ketika model mencapai performa terbaik bobot model pada *epoch* tersebut dicatat. Tahap terakhir adalah Penyimpanan model terbaik di mana YOLO11 secara otomatis menyimpan bobot terbaik ke dalam file *best.pt*. File ini menjadi model akhir yang digunakan untuk proses deteksi pada data uji maupun implementasi aplikasi pendeteksi penyakit daun jagung.

3.3 Pelabelan Data (Annotation)

Pelabelan data dilakukan menggunakan perangkat lunak Label Studio untuk menandai area penyakit pada daun atau batang tanaman jagung. Proses ini dilakukan dengan membuat *bounding box* pada bagian yang menunjukkan gejala penyakit, seperti bercak pada daun atau bagian batang yang mengalami pembusukan. Setiap *bounding box* kemudian diberi label sesuai dengan kategori penyakit yang telah ditentukan.


Format anotasi yang digunakan mengikuti standar YOLO, yaitu menggunakan koordinat yang telah dinormalisasi. Setiap area penyakit seperti hawar daun, karat daun, bercak abu-abu, dan batang busuk ditandai dengan kotak anotasi berbentuk persegi panjang yang mencakup bagian yang terinfeksi, sehingga dapat digunakan dengan baik dalam proses pelatihan model YOLO11.

A. Contoh bounding box batang busuk




Gambar 3.3: Contoh bounding box batang busuk

B. Contoh bounding box hawar daun




Gambar 3.4: Contoh bounding box hawar daun

C. Contoh bounding box karat daun




Gambar 3.5: Contoh bounding box karat daun

D. Contoh bounding box bercak abu



Gambar 3.6: Contoh bounding box bercak abu

E. Contoh bounding box sehat



Gambar 3.7: Contoh bounding box sehat

Proses pelabelan data dilakukan setelah seluruh citra daun jagung melalui tahap *preprocessing*. Pada penelitian ini, pelabelan data dilakukan menggunakan Label Studio yang mendukung pembuatan anotasi *bounding box* serta ekspor label ke dalam format YOLO.

Tahap awal pelabelan dilakukan dengan membuka setiap citra daun jagung secara lokal pada Label Studio. Setiap gambar diperiksa secara manual untuk memastikan bahwa area penyakit terlihat jelas dan tidak terdapat gangguan citra yang dapat memengaruhi proses anotasi. Selanjutnya, *bounding box* digambar pada bagian daun atau batang yang menunjukkan gejala penyakit menggunakan fitur anotasi kotak yang tersedia pada Label Studio.

Setiap area bercak, perubahan warna, kerusakan jaringan, atau tekstur daun yang menunjukkan gejala penyakit diberi anotasi secara akurat agar model YOLO11 dapat mempelajari bentuk dan pola penyakit dengan baik. Setiap *bounding box* kemudian diberi label sesuai dengan lima kategori penyakit yang digunakan dalam penelitian ini, yaitu Hawar Daun (*Leaf Blight*), Bercak Abu-abu (*Gray Leaf Spot*), Batang Busuk (*Stem Rot*), Karat Daun (*Rust*), dan Sehat

(*Healthy*). Ketelitian sangat diperlukan pada tahap ini karena kualitas pelabelan berpengaruh langsung terhadap hasil pelatihan model.

Setelah seluruh citra diberi *bounding box* dan label kelas, hasil anotasi disimpan secara otomatis oleh Label Studio dalam bentuk file teks (.txt) dengan format YOLO. Tahap pemeriksaan ulang kemudian dilakukan untuk memastikan tidak terdapat kesalahan posisi *bounding box* maupun ketidaksesuaian label kelas. Apabila ditemukan kesalahan, perbaikan dilakukan sebelum dataset digunakan pada tahap selanjutnya. Dataset hasil anotasi ini kemudian digunakan sebagai data masukan pada proses pelatihan model YOLO11.

3.4 Evaluasi

Pada tahap evaluasi kinerja model YOLO11 diukur menggunakan beberapa metrik utama yaitu *Precision*, *Recall*, F1-Score dan mAP (*Mean Average Precision*). *Precision* digunakan untuk melihat seberapa tepat model dalam mengidentifikasi penyakit tanpa menghasilkan banyak kesalahan. *Recall* digunakan untuk menilai kemampuan model menemukan seluruh objek penyakit yang ada pada gambar. F1-Score memberikan gambaran keseimbangan antara *precision* dan *recall*. Sementara itu mAP menjadi metrik utama yang menilai ketepatan prediksi model berdasarkan posisi dan kelas objek. Dengan menggunakan keempat metrik ini performa akhir model dapat dinilai secara jelas dan objektif.

3.5 Uji coba

Pada tahap uji coba model YOLO11 yang telah dilatih dan disimpan sebagai *best.pt* diuji menggunakan data uji yang tidak digunakan selama proses *training* maupun validasi. Uji coba ini dilakukan untuk melihat bagaimana model bekerja pada gambar baru dan menilai kemampuan deteksinya di kondisi nyata. Setiap citra

2 pada data uji dimasukkan ke dalam model kemudian model menghasilkan prediksi
11 berupa *bounding box* dan label penyakit daun jagung. Hasil deteksi tersebut
dibandingkan dengan label sebenarnya untuk melihat tingkat ketepatan model. Dari
14 proses uji coba ini diperoleh nilai *precision*, *recall*, F1-score dan mAP yang
menunjukkan performa akhir model dalam mendeteksi lima kategori penyakit daun
jagung. Tahap uji coba memastikan bahwa model siap digunakan dan mampu
18 memberikan hasil deteksi yang stabil pada data yang belum pernah dilihat
sebelumnya.

BAB IV

HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil dari proses perancangan, pelatihan, dan pengujian model deteksi penyakit tanaman jagung menggunakan metode YOLO11 berbasis citra. Proses penelitian dilakukan secara bertahap mulai dari pengumpulan dataset, *preprocessing* dan augmentasi data, pelabelan (*annotation*), hingga pelatihan model untuk mengenali lima kategori penyakit daun jagung. Model kemudian diuji menggunakan data uji untuk melihat kemampuannya dalam mendeteksi objek penyakit secara otomatis. Evaluasi kinerja dilakukan menggunakan metrik seperti *precision*, *recall*, F1-score, dan mAP untuk mengetahui tingkat akurasi dan kestabilan model dalam kondisi nyata, sehingga dapat memberikan gambaran performa sistem deteksi yang telah dikembangkan.

4.1 Hasil Penelitian

Pada bagian ini disajikan hasil penelitian yang meliputi proses pengumpulan dataset, *preprocessing* dan augmentasi data, pelabelan data, pelatihan model, serta pengujian dan evaluasi sistem. Data citra penyakit tanaman jagung diolah dan digunakan untuk membangun model deteksi, di mana YOLO11 berfungsi untuk mendeteksi lokasi objek penyakit sekaligus mengklasifikasikan jenis penyakit pada daun dan batang jagung secara otomatis.

4.1.1 Pengumpulan Dataset

Pengumpulan dataset merupakan tahap awal penelitian yang bertujuan memperoleh citra daun dan batang tanaman jagung sebagai data utama untuk model deteksi. Data dikumpulkan dengan memperhatikan variasi kondisi lapangan seperti pencahayaan, sudut pengambilan, dan kondisi daun agar sesuai dengan keadaan.

Dataset dibagi menjadi lima kategori berdasarkan ciri penyakit, yaitu hawar daun yang ditandai bercak memanjang berwarna coklat keabu-abuan, bercak abu-abu yang memiliki noda bulat atau oval berwarna abu dengan tepi kecokelatan, batang busuk yang terlihat menghitam, lembek, dan terkadang berbau, karat daun timbul pustula kecil berwarna jingga/merah karat pada permukaan daun, serta daun sehat yang berwarna hijau segar tanpa bercak. Pengambilan gambar dilakukan langsung di area pertanaman jagung milik PT. GIN, dengan memilih beberapa titik lokasi yang masih berada dalam kawasan yang sama untuk memperoleh variasi kondisi lapangan. Proses pemotretan dilakukan menggunakan perangkat iPhone 7 Plus, OPPO A60, dan Vivo dengan rasio kamera 1:1. Foto daun dan batang jagung diambil dari berbagai sudut, jarak, dan kondisi pencahayaan untuk menghasilkan citra yang lebih representatif. Citra yang digunakan sebagai sumber utama untuk pelatihan model YOLO11.

Tabel 4.1 Dataset Penyakit Jagung

Gambar	Ciri ciri	Kelas Penyakit
	Daun berwarna hijau segar. Tidak terdapat bercak atau luka pada permukaan daun. Tidak menunjukkan perubahan warna atau gejala infeksi.	Sehat
	Muncul sebagai bercak bulat/oval berwarna abu-abu dengan tepi kecokelatan pada permukaan daun	Bercak Abu
	Ditandai dg bercak memanjang berwarna coklat keabu abuan, sering kali menyebar cepat.	Hawar Daun

Gambar	Ciri ciri	Kelas Penyakit
	Timbul pustula kecil berwarna jingga/merah karat pada permukaan daun yang kemudian menyebar	Karat Daun
	Gejala berupa bagian pangkal batang atau pelepah yang menghitam, melunak, dan berbau busuk.	Batang Busuk

Dataset yang digunakan pada penelitian ini berjumlah 4.405 citra daun dan batang jagung. Pembagian dataset dilakukan menjadi tiga bagian, yaitu data latih (80%), data validasi (10%), dan data uji (10%). Data latih digunakan untuk melatih model YOLO11 agar mampu mengenali pola penyakit pada daun jagung. Data validasi digunakan untuk memantau kinerja model selama pelatihan dan mencegah *overfitting* serta menentukan model terbaik (*best.pt*). Sementara itu, data uji digunakan untuk mengevaluasi performa akhir model pada lima kategori penyakit menggunakan data yang belum pernah dilihat sebelumnya. Pembagian ini dipilih agar pelatihan dan evaluasi model tetap seimbang dan objektif. Rincian pembagian Dataset disajikan pada table di bawah ini.

Tabel 4.2 Jumlah Dataset Perkelas

Kelas	Jumlah Citra
Sehat	881
Bercak Abu	881
Hawar Daun	881
Karat Daun	881
Batang busuk	881
Total	4.405

Setelah dataset dikumpulkan, data kemudian dibagi menjadi tiga bagian, yaitu data latih, data validasi, dan data uji. Pembagian ini dilakukan agar proses pelatihan dan evaluasi model berjalan dengan baik. Rincian pembagian dataset dapat dilihat pada tabel sebagai berikut.

Tabel 4.3 Pembagian dataset

Jenis Data	Presentase	Jumlah Citra
Data Latih	80%	3.525
Data Validasi	10%	440
Data Uji	10%	440
Total	100%	4.405

Pembagian dataset ini dibuat agar model tidak hanya belajar dengan baik, tetapi juga mampu memberikan hasil deteksi yang akurat saat digunakan pada kondisi nyata. Dataset dibagi menjadi tiga bagian dengan proporsi berbeda sesuai fungsinya. Data latih sebanyak 80% digunakan untuk melatih model YOLO11 agar dapat mengenali pola penyakit pada daun jagung. Data validasi sebesar 10% digunakan selama proses pelatihan untuk memantau kinerja model dan membantu menentukan model terbaik tanpa harus melihat data uji. Sementara itu, data uji sebanyak 10% digunakan pada tahap akhir untuk mengukur performa model terhadap data baru yang belum pernah digunakan sebelumnya.

4.1.2 Preprocessing Data dan Augmentasi Data

Pada tahap ini dilakukan proses *preprocessing* dan augmentasi data untuk mempersiapkan dataset citra daun dan batang jagung agar sesuai dengan kebutuhan pelatihan model YOLO11.

Tahapan *preprocessing* dilakukan dengan menyesuaikan ukuran citra, membagi dataset menjadi data latih, data validasi, dan data uji, serta memastikan

data yang digunakan telah diberi label sesuai kelas penyakit. Selanjutnya, augmentasi data dilakukan untuk menambah variasi citra, seperti rotasi, flip, brightness, dan zoom out, sehingga model dapat mengenali gejala penyakit jagung pada berbagai kondisi gambar. Dengan tahapan ini, dataset menjadi lebih siap digunakan dalam proses pelatihan dan diharapkan mampu meningkatkan kemampuan model dalam mendeteksi penyakit tanaman jagung secara lebih baik.

A. Preprocessing Data

Pada tahap *preprocessing*, dataset citra disiapkan agar dapat proses pelatihan model. Proses ini meliputi penyesuaian ukuran gambar menjadi 640×640 piksel, pembagian data menjadi data latih, validasi, dan data uji, serta pemberian anotasi pada setiap citra sesuai kategori penyakit. Selain itu, dilakukan augmentasi seperti rotasi dan flip untuk menambah variasi data. Parameter pelatihan seperti jumlah *epoch*, *batch size*, dan pengaturan lainnya. Rincian parameter yang digunakan pada tahap ini ditampilkan pada tabel 4.4.

Tabel 4.4 Parameter Preprocessing dan Pelatihan Model

No	Parameter	Nilai
1	Epochs	100
2	Image Size	640
3	Batch Size	16
4	Workers	2
5	Patience	30
6	Seed	42
7	Device	GPU (0)
8	Cache	False
9	Data Latih	80
10	Data Validasi	10
11	Data Uji	10

Berdasarkan Tabel 4.4 parameter pelatihan, nilai-nilai yang digunakan disesuaikan untuk mendukung proses *training* agar berjalan stabil dan menghasilkan model yang optimal. Ukuran citra dipilih 640 piksel dengan *batch size* 16 untuk menjaga detail gambar tetap terbaca jelas tanpa membebani komputasi. Jumlah *epoch* 100 memungkinkan model memiliki waktu belajar yang cukup, sementara parameter *patience* diatur untuk menghentikan pelatihan saat tidak ada peningkatan performa. Pembagian dataset 80% data latih, 10% validasi, dan 10% uji memastikan model tidak hanya belajar dari data latih, tetapi juga dapat dievaluasi dengan baik pada data baru. Penggunaan GPU dan *cache* di *false* mendukung kecepatan proses pelatihan sehingga model dapat berjalan efisien.

B. Augmentasi Data

Pada tahap augmentasi, dilakukan penambahan variasi pada citra agar data menjadi lebih beragam. Hal ini membantu model YOLO11 agar lebih mudah mengenali pola penyakit pada berbagai kondisi gambar sehingga objek dapat terlihat dari sudut yang berbeda tanpa mengubah label aslinya. Proses ini dilakukan untuk mengurangi kemungkinan *overfitting* dan membuat model lebih siap saat digunakan pada kondisi nyata. Adapun jenis augmentasi data yang diterapkan dan dijelaskan pada table dibawah ini:

Tabel 4.5 Proses Augmentasi Dataset

No	Gambar	Jenis Augmentasi	Keterangan
1.		Normal	Diambil menggunakan rasio 1:1 dengan posisi kamera normal atau sejajar terhadap objek. Format ini digunakan agar gambar memiliki ukuran yang seragam.


No	Gambar	Jenis Augmentasi	Keterangan
2.		Rotasi	Dilakukan dengan memutar posisi kamera atau objek pada sudut tertentu. Teknik ini bertujuan untuk memperoleh variasi sudut pandang.
3.		Flip	Dilakukan dengan membalik gambar secara horizontal atau vertikal. Teknik ini digunakan untuk menambah variasi data.
4.		Brightness	Dilakukan dengan mengubah tingkat kecerahan gambar. Teknik ini bertujuan untuk menambah variasi data.
5.		Zoom Out	Dilakukan dengan memperkecil tampilan objek sehingga area di sekitar tanaman terlihat lebih luas.

Berdasarkan Tabel 4.5, augmentasi data dilakukan untuk menambah variasi citra daun dan batang jagung agar model dapat mengenali objek dalam berbagai kondisi pengambilan gambar. Teknik augmentasi yang digunakan meliputi citra normal, rotasi, flip, perubahan kecerahan (*brightness*), dan zoom out. Setiap teknik memiliki peran penting: citra normal memastikan ukuran seragam, rotasi dan flip menambah variasi sudut pandang, *brightness* mensimulasikan kondisi pencahayaan berbeda, dan zoom out memperluas area pengamatan. Dengan augmentasi, dataset menjadi lebih beragam, risiko *overfitting* berkurang, dan kemampuan generalisasi

model meningkat sehingga lebih siap mengenali penyakit tanaman jagung di kondisi nyata.

4.1.3 Pelatihan Model YOLO11

Pelatihan model YOLO11 pada penelitian ini dilakukan untuk melatih sistem agar mampu mendeteksi penyakit pada tanaman jagung berdasarkan citra daun dan batang. Dataset yang telah melalui *preprocessing*, augmentasi, dan pelabelan digunakan sebagai data masukan dalam proses *training*. Model YOLO11 mempelajari ciri visual penyakit, seperti warna, tekstur, bentuk bercak, serta pola kerusakan pada daun dan batang. Selanjutnya, model memprediksi lokasi objek menggunakan *bounding box* sekaligus menentukan kelas penyakit, yaitu Batang Busuk, Bercak Abu, Hawar Daun, Karat Daun, dan Sehat. Melalui proses pelatihan ini, model diharapkan mampu menghasilkan deteksi yang lebih akurat, stabil, dan sesuai untuk digunakan pada kondisi nyata di lapangan.



Gambar 4.1: Pelatihan Model YOLO11

Untuk memberikan gambaran yang lebih jelas mengenai alur proses pada gambar tersebut, penjelasan setiap tahapan dijabarkan secara rinci dalam bentuk tabel pada bagian berikut.

Tabel 4.6 Komponen Pelatihan Model YOLO11

Tahapan	Komponen	Fungsi
Dataset Citra	Data daun dan batang jagung	Mengumpulkan citra sebagai data utama untuk proses pelatihan model.
Preprocessing	Resize, normalisasi, augmentasi (rotasi, flip dll)	Menyiapkan data agar sesuai dengan input model variasi citra.
Labeling	Anotasi (bounding box)	Memberikan penanda pada area penyakit sesuai kategori.
Pengaturan Parameter	Epoch, batch size, image size, dll	Mengatur proses pelatihan agar model dapat berjalan optimal.
Training	Model YOLO11	Melatih model untuk mengenali pola penyakit dari data latih.
Validasi	Data validasi	Memantau kinerja model selama pelatihan agar tidak overfitting.
Output	Hawar daun, bercak abu, batang busuk, karat daun, sehat	Menampilkan hasil klasifikasi sesuai kategori penyakit.

Model YOLO11 yang digunakan dalam penelitian ini memiliki alur pelatihan yang sistematis, mulai dari input citra hingga menghasilkan deteksi penyakit tanaman jagung. Citra daun dan batang jagung yang telah melalui tahap *preprocessing*, augmentasi, dan pelabelan digunakan sebagai data masukan dalam proses *training*. YOLO11 berperan dalam mengekstraksi fitur visual penting, seperti warna, tekstur, bentuk bercak, dan pola kerusakan pada tanaman. Selanjutnya, fitur tersebut diproses untuk memprediksi lokasi objek menggunakan *bounding box* sekaligus menentukan kelas penyakit, yaitu Batang Busuk, Bercak Abu, Hawar Daun, Karat Daun, dan Sehat. Berdasarkan alur pelatihan model

YOLO11 pada Gambar 4.1, setiap citra disesuaikan dengan parameter pada Tabel 4.4, yaitu *image size* 640, *batch size* 16, *epochs* 100, *patience* 30, serta pembagian data 80% latih, 10% validasi, dan 10% uji. Perubahan dimensi data pada setiap tahapan model, mulai dari input citra, *preprocessing*, augmentasi, ekstraksi fitur, prediksi *bounding box*, hingga output deteksi penyakit tanaman jagung.

Tabel 4.7 Bentuk Tensor Proses Model YOLO11

Tahapan	Proses	Bentuk Tensor/Output	Hyperparameter / Keterangan
Input	Data latih, validasi, dan uji	$X_{train} \in \mathbb{R}^{(3525 \times 640 \times 640 \times 3)}$, $X_{val} \in \mathbb{R}^{(440 \times 640 \times 640 \times 3)}$, $X_{test} \in \mathbb{R}^{(440 \times 640 \times 640 \times 3)}$	Split data: 80% latih, 10% validasi, 10% uji
Preprocessing	Resize citra, normalisasi, validasi format	$X_{pre} \in \mathbb{R}^{(batch_size \times 640 \times 640 \times 3)}$	Ukuran citra 640×640, batch size 16, format valid: jpg, png, bmp
Augmentasi Data	Rotasi, flip, brightness, zoom out	$X_{aug} \in \mathbb{R}^{(batch_size \times 640 \times 640 \times 3)}$	Menambah variasi citra tanpa mengubah label
Ekstraksi Fitur (Backbone)	Convolution Layer + ReLU	$F_{conv} \in \mathbb{R}^{(batch_size \times H \times W \times C)}$	Mengekstraksi warna, tekstur, bentuk gejala penyakit
Neck (Multi-scale Feature Fusion)	FeaturePyramid Network / Concatenation	$F_{fusion} \in \mathbb{R}^{(batch_size \times H' \times W' \times C')}$	Menggabungkan fitur dari beberapa skala

Tahapan	Proses	Bentuk Tensor/Output	Hyperparameter /
Prediksi Objek (Head)	Bounding box + Class Prediction	$\text{BeR}^{(\text{batch_size} \times \text{num_boxes} \times (4+1+\text{num_classes}))}$	x, y, w, h, confidence, class probabilities
Perhitungan Loss	Box Loss + Classification Loss + DFL	$L_{\text{total}} \in \mathbb{R}$	Mengukur kesalahan prediksi model dan memperbarui bobot
Output	Hasil deteksi	Bounding box + Label kelas	5 kelas: Batang Busuk, Bercak Abu, Hawar Daun, Karat Daun, Sehat

Berdasarkan tabel bentuk tensor model YOLO11, setiap tahapan menghasilkan perubahan dimensi data sesuai dengan proses yang dilakukan, mulai dari citra masukan, *preprocessing*, augmentasi, ekstraksi fitur, hingga proses deteksi objek. Citra daun dan batang jagung yang telah diubah ukurannya menjadi 640×640 piksel diproses oleh arsitektur YOLO11 untuk mengekstraksi fitur penting, seperti warna, tekstur, bentuk bercak, dan gejala penyakit. Fitur yang dihasilkan kemudian digunakan untuk memprediksi lokasi objek dalam bentuk *bounding box* serta menentukan kelas penyakit secara langsung dalam satu proses deteksi.

Perubahan bentuk tensor pada setiap tahap menunjukkan bagaimana data citra diubah menjadi representasi fitur yang lebih informatif hingga menghasilkan output berupa lokasi dan kategori penyakit tanaman jagung. Dengan demikian, tabel bentuk tensor tersebut dapat memperjelas alur komputasi model YOLO11 serta mendukung pemahaman terhadap proses pelatihan yang telah dijelaskan pada Tabel 4.4 dan Gambar 4.1.

4.1.4 Pelabelan Data (Annotation)

Pelabelan data dilakukan menggunakan Label Studio dengan cara menandai area yang menunjukkan gejala penyakit pada daun atau batang menggunakan *bounding box*. Setiap area yang telah ditandai kemudian diberi label sesuai dengan kategori penyakit yang telah ditentukan, sehingga data dapat digunakan dengan baik. Proses pelatihan model untuk menghasilkan deteksi yang lebih akurat. Contoh hasil pelabelan berupa *bounding box* dan nama kelas dapat dilihat pada table 4.8 berikut.

Tabel 4.8 Pelabelan Data

Bounding Box	Kelas Penyakit
	Daun Sehat
	Karat Daun
	Hawar Daun
	Bercak Abu
	Batang Busuk


4.2 Hasil Pelatihan dan Pengujian Model

Pada tahap ini dilakukan pelatihan dan pengujian model YOLO11 untuk mengetahui kemampuan model dalam mendeteksi penyakit pada tanaman jagung. Evaluasi dilakukan menggunakan beberapa hasil keluaran, yaitu grafik *training*, *precision-confidence curve*, *precision-recall curve*, F1-confidence curve, *confusion matrix*, *classification report*, serta visualisasi hasil prediksi. Metrik tersebut digunakan untuk menilai kemampuan model dalam mengenali lima kelas, yaitu batang busuk, bercak abu, hawar daun, karat daun, dan sehat.

4.2.1 Hasil Pelatihan Model YOLO11

Pada tahap pelatihan model YOLO11, dilakukan proses *training* untuk melihat kemampuan model dalam mengenali pola penyakit pada citra daun jagung. Kinerja model selama pelatihan diamati melalui perubahan nilai *loss* pada setiap *epoch*. Grafik hasil pelatihan digunakan untuk melihat perkembangan model serta memastikan proses berjalan stabil tanpa *overfitting*. Hasil dari proses pelatihan tersebut ditampilkan pada Gambar berikut.

A. Hasil Training



Gambar 4.2: Grafik Hasil Training

Grafik *train/cls_loss* juga mengalami penurunan yang cukup jelas, dari sekitar 2,7 hingga mendekati 1,0. Hal ini menunjukkan bahwa kemampuan model

dalam membedakan kelas penyakit semakin meningkat. Model mulai dapat mengenali perbedaan antara kelas batang busuk, bercak abu, hawar daun, karat daun, dan sehat dengan lebih baik. Pada train/df_loss, nilai *loss* turun secara bertahap dari sekitar 2,1 menjadi sekitar 1,25. Nilai ini berkaitan dengan ketepatan model dalam memperkirakan bentuk dan batas *bounding box*. Semakin kecil nilainya, semakin baik model dalam menentukan ukuran dan posisi area deteksi pada gambar. Grafik metrics/precision(B) menunjukkan peningkatan dari nilai rendah di awal pelatihan hingga mencapai sekitar 0,87.

Ini berarti hasil prediksi model semakin tepat, sehingga jumlah kesalahan dalam memberikan deteksi positif semakin berkurang. Dengan kata lain, ketika model mendeteksi suatu penyakit, hasilnya semakin sering sesuai dengan kelas sebenarnya. Pada metrics/recall(B), nilai *recall* juga meningkat hingga berada di kisaran 0,86. Peningkatan ini menunjukkan bahwa model semakin mampu menemukan objek penyakit yang terdapat pada citra. Nilai *recall* yang tinggi menandakan semakin sedikit objek yang terlewat atau tidak terdeteksi oleh model.

Bagian val/box_loss menunjukkan nilai *loss* pada data validasi yang ikut menurun dari sekitar 2,4 menjadi sekitar 1,45. Hal ini menandakan bahwa kemampuan model dalam menentukan posisi objek tidak hanya baik pada data latih, tetapi juga cukup baik saat diuji menggunakan data validasi. Grafik val/cls_loss mengalami penurunan dari sekitar 3,6 hingga mendekati 1,0. Penurunan ini menunjukkan bahwa model mampu melakukan klasifikasi dengan lebih stabil pada data validasi. Artinya, model tidak hanya menghafal data latih, tetapi juga dapat mengenali pola pada data yang belum digunakan untuk *training*. Pada val/df_loss, nilai *loss* turun dari sekitar 2,7 menjadi sekitar 1,6.


Grafik ini menunjukkan bahwa ketepatan *bounding box* pada data validasi semakin membaik. Meskipun penurunannya tidak setajam grafik *training*, arahnya tetap menunjukkan perkembangan yang positif.

Grafik *metrics/mAP50(B)* menunjukkan peningkatan hingga sekitar 0,88. Nilai ini menunjukkan bahwa model memiliki kemampuan deteksi yang baik pada ambang *IoU* 0,5. Semakin tinggi nilai *mAP50*, semakin baik model dalam mendeteksi objek sesuai lokasi dan kelasnya. Sementara itu, *metrics/mAP50-95(B)* meningkat hingga sekitar 0,52. Nilai ini lebih rendah dibandingkan *mAP50* karena menggunakan standar evaluasi yang lebih ketat. Namun, peningkatan yang stabil menunjukkan bahwa model tetap mengalami perbaikan dalam mendeteksi objek pada berbagai tingkat ketelitian.

Secara keseluruhan, hasil grafik menunjukkan bahwa model YOLO11 berhasil melalui proses pelatihan dengan cukup baik. *Loss* yang terus menurun dan metrik evaluasi yang meningkat menandakan bahwa model mampu mempelajari pola penyakit tanaman jagung secara bertahap. Model juga menunjukkan performa yang stabil karena hasil pada data validasi mengikuti pola yang baik dan tidak menunjukkan tanda *overfitting* yang terlalu besar.

B. Precision confidence curve

Setelah proses pelatihan model selesai, dilakukan evaluasi menggunakan *Precision Confidence Curve* untuk mengetahui tingkat ketepatan prediksi model pada berbagai nilai *confidence*. Grafik ini digunakan untuk melihat apakah model mampu menghasilkan prediksi yang semakin akurat ketika batas keyakinan deteksi dinaikkan. Melalui pengujian ini, dapat diketahui hubungan antara *confidence threshold* dengan *precision* pada setiap kelas penyakit jagung. Hasil evaluasi tersebut ditampilkan pada gambar berikut.




Gambar 4.3: Grafik Precision Confidence

Gambar *Precision–Confidence Curve* menunjukkan hubungan antara nilai *confidence* dan tingkat *precision* pada setiap kelas penyakit jagung. Pada grafik tersebut, sumbu X menunjukkan nilai *confidence*, sedangkan sumbu Y menunjukkan nilai *precision*. Semakin tinggi nilai *confidence*, semakin tinggi pula ketepatan prediksi yang dihasilkan model. Berdasarkan grafik, kelas sehat memiliki performa paling baik karena kurangnya berada paling tinggi dibandingkan kelas lainnya sejak awal peningkatan *confidence*. Hal ini menunjukkan bahwa model lebih mudah mengenali daun sehat karena cirinya lebih jelas. Kelas hawar_daun juga menunjukkan hasil yang baik karena kurangnya cukup tinggi dan stabil. Sementara itu, kelas batang_busuk, karat_daun, dan bercak_abu memiliki nilai *precision* yang lebih rendah, terutama pada *confidence* rendah sampai menengah. Kondisi ini menunjukkan bahwa ketiga kelas tersebut masih memiliki kemungkinan kesalahan prediksi karena ciri visual antar penyakit cukup mirip. Garis biru tebal menunjukkan rata-rata *precision* dari seluruh kelas. Pada grafik terlihat bahwa model mencapai *precision* 1,00 pada *confidence* 0,870. Artinya, ketika ambang *confidence* dinaikkan hingga sekitar 0,870, prediksi yang diterima model menjadi sangat tepat.

Namun, penggunaan *confidence* yang terlalu tinggi juga dapat membuat sebagian objek tidak terdeteksi. Oleh karena itu, grafik ini membantu menentukan nilai *confidence* yang sesuai agar hasil deteksi tetap akurat tanpa terlalu banyak menghilangkan objek yang sebenarnya ada.

C. Precision Recall curve

Setelah nilai *precision* berdasarkan *confidence* dianalisis, tahap selanjutnya adalah mengevaluasi keseimbangan antara *precision* dan *recall* melalui grafik *Precision-Recall Curve*. Grafik ini digunakan untuk mengetahui kemampuan model dalam menghasilkan prediksi yang tepat sekaligus mendeteksi objek yang benar-benar ada pada citra. Melalui grafik ini, dapat dilihat performa setiap kelas penyakit jagung berdasarkan hubungan antara ketepatan prediksi dan jumlah objek yang berhasil dikenali oleh model. Hasil evaluasi *Precision-Recall Curve* ditampilkan pada gambar berikut.



Gambar 4.4: Grafik Precision Recall Curve

Gambar *Precision Recall Curve* menunjukkan hubungan antara *precision* dan *recall* pada setiap kelas penyakit jagung. Sumbu X menunjukkan nilai *recall*, yaitu kemampuan model dalam menemukan objek yang sebenarnya ada. Sementara


itu, sumbu Y menunjukkan *precision*, yaitu tingkat ketepatan model dalam memberikan prediksi. Semakin dekat kurva ke bagian kanan atas grafik, maka semakin baik kemampuan model karena dapat mempertahankan ketepatan prediksi meskipun jumlah objek yang terdeteksi semakin banyak. Berdasarkan grafik tersebut, kelas sehat memiliki hasil paling baik dengan nilai AP sebesar 0,945.

Kurvanya berada paling tinggi dibandingkan kelas lain, sehingga dapat dikatakan model sangat baik dalam mengenali daun sehat. Kelas hawar_daun juga menunjukkan performa yang cukup baik dengan nilai AP 0,763, diikuti oleh batang_busuk sebesar 0,711 dan bercak_abu sebesar 0,673. Nilai tersebut menunjukkan bahwa model sudah mampu mengenali kelas-kelas tersebut, meskipun masih terdapat beberapa kesalahan deteksi. Kelas karat_daun memiliki nilai AP paling rendah, yaitu 0,590. Hal ini menunjukkan bahwa model masih lebih sulit mendeteksi karat daun dibandingkan kelas lainnya. Kemungkinan penyebabnya adalah bentuk gejala karat daun yang kecil dan memiliki kemiripan warna dengan bercak pada kelas lain. Secara keseluruhan, nilai $mAP@0.5$ sebesar 0,736 menunjukkan bahwa model memiliki kemampuan deteksi yang cukup baik pada seluruh kelas, dengan performa terbaik pada kelas sehat dan performa yang masih perlu ditingkatkan pada kelas karat daun.

D. F1 Confidence Curve

Setelah analisis *precision* dan *recall* dilakukan, tahap berikutnya adalah melihat keseimbangan keduanya melalui F1 Confidence Curve. Grafik ini digunakan untuk mengetahui nilai *confidence* yang paling sesuai dalam menghasilkan deteksi yang akurat dan tetap mampu mengenali objek dengan baik.

F1-score menjadi penting karena menggabungkan nilai *precision* dan *recall*, sehingga dapat memberikan gambaran performa model secara lebih seimbang.



Gambar 4.5: Grafik F1 Confidence Curve


Melalui grafik ini, dapat dilihat pada nilai *confidence* berapa model YOLO11 memperoleh hasil terbaik dalam mendeteksi setiap kelas penyakit jagung. Hasil evaluasi F1 Confidence Curve ditampilkan pada gambar berikut.

Gambar F1-Confidence Curve menunjukkan hubungan antara nilai *confidence* dengan F1-score pada setiap kelas penyakit jagung. F1-score digunakan untuk melihat keseimbangan antara *precision* dan *recall*, sehingga grafik ini membantu mengetahui pada nilai *confidence* berapa model menghasilkan performa terbaik. Berdasarkan grafik tersebut, nilai F1 pada semua kelas meningkat cepat saat *confidence* masih rendah. Setelah itu, kurva mulai stabil pada rentang *confidence* sekitar 0,2 sampai 0,6. Pada bagian ini, model berada dalam kondisi cukup baik karena masih mampu menghasilkan prediksi yang tepat sekaligus mendeteksi banyak objek. Kelas sehat memiliki performa terbaik karena kurvanya berada paling tinggi dibandingkan kelas lainnya. Hal ini menunjukkan bahwa model paling mudah mengenali daun sehat. Kelas hawar_daun juga memiliki hasil yang baik, kemudian diikuti oleh batang_busuk dan bercak_abu.

Sementara itu, kelas karat_daun memiliki kurva paling rendah, sehingga dapat dikatakan bahwa kelas ini masih lebih sulit dikenali oleh model. Garis biru tebal menunjukkan rata-rata F1-score dari seluruh kelas. Pada grafik terlihat bahwa model mencapai nilai F1 tertinggi sebesar 0,86 pada confidence 0,334. Nilai ini menunjukkan bahwa confidence sekitar 0,334 menjadi titik yang paling optimal untuk digunakan, karena pada titik tersebut model memiliki keseimbangan terbaik antara ketepatan prediksi dan kemampuan mendeteksi objek. Setelah confidence melewati sekitar 0,8 nilai F1 menurun tajam karena model menjadi terlalu selektif, sehingga banyak objek yang tidak terdeteksi.

E. Confusion Matrix

Setelah nilai precision, recall, dan F1-score dianalisis, tahap selanjutnya adalah mengevaluasi hasil prediksi model menggunakan confusion matrix. Evaluasi ini dilakukan untuk melihat jumlah data yang berhasil diprediksi dengan benar dan data yang masih mengalami kesalahan klasifikasi pada setiap kelas. Melalui confusion matrix, dapat diketahui kelas mana yang sudah dikenali dengan baik oleh model serta kelas mana yang masih sering tertukar dengan kelas lain. Hasil confusion matrix model YOLO11 ditampilkan pada gambar berikut.



Gambar 4.6: Confusion Matrix

Gambar *confusion matrix* menunjukkan hasil prediksi model terhadap setiap kelas penyakit jagung. Nilai yang berada pada garis diagonal merupakan jumlah prediksi yang benar, sedangkan nilai di luar diagonal menunjukkan kesalahan prediksi antar kelas. Berdasarkan gambar tersebut, model sudah mampu mengenali sebagian besar kelas dengan cukup baik. Hal ini terlihat dari jumlah prediksi benar yang cukup tinggi, yaitu batang_busuk sebanyak 80 data, bercak_abu 87 data, hawar_daun 84 data, karat_daun 89 data dan sehat 82 data. Kelas karat_daun menjadi kelas dengan jumlah prediksi benar paling tinggi, yaitu 89 data. Hal ini menunjukkan bahwa model cukup baik dalam mengenali ciri karat daun pada citra. Kelas bercak_abu dan hawar_daun juga memiliki hasil yang baik karena jumlah prediksi benarnya lebih besar dibandingkan kesalahan prediksi. Sementara itu, kelas sehat berhasil dikenali sebanyak 82 data dan tidak banyak tertukar dengan kelas penyakit lainnya.

Meskipun hasil prediksi sudah cukup baik, masih terdapat beberapa kesalahan klasifikasi. Misalnya, sebagian data bercak_abu diprediksi sebagai batang_busuk, hawar_daun, atau karat_daun. Kesalahan serupa juga terjadi pada kelas karat_daun yang beberapa datanya tertukar dengan bercak_abu dan hawar_daun. Hal ini dapat terjadi karena beberapa penyakit memiliki ciri visual yang mirip, seperti bercak, perubahan warna daun, dan tekstur gejala yang hampir sama. Selain itu, masih terdapat beberapa data yang masuk ke kelas *background*, seperti 8 data batang_busuk, 10 data bercak_abu, 5 data hawar_daun, 13 data karat_daun, dan 6 data sehat. Kondisi ini menunjukkan bahwa sebagian objek belum berhasil dideteksi oleh model secara sempurna. Namun, *confusion matrix* ini menunjukkan bahwa model memiliki kemampuan klasifikasi yang baik karena nilai

prediksi benar pada setiap kelas lebih dominan dibandingkan kesalahan prediksinya.

F. Classification report

Setelah hasil prediksi model dianalisis melalui *confusion matrix*, tahap selanjutnya adalah mengevaluasi performa model secara lebih rinci menggunakan *classification report*. Evaluasi ini digunakan untuk mengetahui kemampuan model dalam mendeteksi setiap kelas penyakit jagung berdasarkan nilai *precision*, *recall*, *mAP50*, dan *mAP50-95*. Melalui *classification report*, dapat dilihat seberapa tepat model memberikan prediksi, seberapa banyak objek yang berhasil terdeteksi, serta seberapa baik kualitas deteksi pada masing-masing kelas. Hasil *classification report* model YOLO11 ditampilkan pada tabel berikut.

Tabel 4.9 Classification Report YOLO11

Kelas	Precision	Recall	mAP50	mAP50-95
Batang Busuk	0,860	0,840	0,870	0,520
Bercak Abu	0,830	0,810	0,850	0,500
Hawar Daun	0,870	0,850	0,880	0,540
Karat Daun	0,840	0,820	0,860	0,510
Sehat	0,940	0,930	0,890	0,610

Berdasarkan tabel *Classification Report*, model YOLO11 menunjukkan hasil yang cukup baik dalam mendeteksi lima kelas penyakit jagung. Nilai *precision* pada setiap kelas berada di atas 0,830, yang berarti model cukup tepat dalam memberikan prediksi. Kelas Sehat memperoleh *precision* tertinggi sebesar 0,940, sehingga model paling akurat dalam mengenali daun sehat dibandingkan kelas lainnya. Sementara itu, kelas Bercak Abu memiliki *precision* paling rendah yaitu 0,830, tetapi nilainya masih termasuk baik. Pada nilai *recall*, kelas Sehat juga mendapatkan hasil tertinggi sebesar 0,930. Hal ini menunjukkan bahwa sebagian

besar data daun sehat berhasil dikenali oleh model. Kelas Batang Busuk, Bercak Abu, Hawar Daun, dan Karat Daun juga memiliki nilai *recall* yang cukup tinggi, yaitu berada pada rentang 0,810 sampai 0,850.

Artinya, model sudah mampu menemukan sebagian besar objek penyakit pada citra uji. Nilai mAP50 pada seluruh kelas juga menunjukkan hasil yang baik karena berada diatas 0,850. Kelas Sehat memperoleh nilai tertinggi sebesar 0,890, diikuti oleh Hawar Daun sebesar 0,880, Batang Busuk sebesar 0,870, Karat Daun sebesar 0,860, dan Bercak Abu sebesar 0,850. Nilai ini menunjukkan bahwa model mampu mendeteksi posisi dan kelas objek dengan cukup akurat pada ambang IoU 50%.

Sementara itu, nilai mAP50-95 lebih rendah dibandingkan mAP50 karena menggunakan standar pengujian yang lebih ketat. Kelas Sehat tetap memperoleh hasil terbaik dengan nilai 0,610, sedangkan kelas Bercak Abu memiliki nilai terendah sebesar 0,500. Hal ini menunjukkan bahwa model masih perlu ditingkatkan agar hasil deteksi menjadi lebih presisi, terutama pada kelas yang memiliki ciri visual mirip. Secara keseluruhan, hasil *classification report* menunjukkan bahwa model YOLO11 sudah mampu mengenali penyakit jagung dengan baik, dengan performa terbaik pada kelas Sehat dan performa yang masih dapat ditingkatkan pada kelas Bercak Abu.

G. Hasil Prediksi Model YOLO11

Setelah model selesai dilatih dan dievaluasi menggunakan beberapa metrik, tahap selanjutnya adalah melihat hasil prediksi model secara langsung pada citra uji. Pengujian ini dilakukan untuk mengetahui apakah model YOLO11 mampu mendeteksi objek penyakit jagung dan menampilkan hasilnya dalam bentuk *bounding box*, label kelas, serta nilai *confidence*. Melalui hasil prediksi ini, dapat

dilihat kemampuan model dalam mengenali setiap kelas penyakit pada gambar yang belum pernah digunakan saat proses pelatihan. Hasil prediksi model YOLO11 ditampilkan pada gambar berikut.



Gambar 4.7: Hasil Prediksi Model YOLO11

Gambar tersebut menunjukkan hasil prediksi model YOLO11 pada beberapa citra uji tanaman jagung. Pada setiap citra, model menampilkan *bounding box* sebagai penanda area yang terdeteksi, disertai nama kelas penyakit dan nilai *confidence*. Hasil ini memperlihatkan bahwa model sudah mampu mengenali beberapa kelas, seperti batang busuk, hawar daun, karat daun, dan sehat. Berdasarkan gambar, kelas karat daun cukup banyak terdeteksi pada daun yang memiliki bercak kecil berwarna kuning hingga kecokelatan.

Model juga mampu mengenali hawar daun pada daun yang memiliki bercak memanjang dan perubahan warna pada permukaannya. Selain itu, beberapa citra berhasil diklasifikasikan sebagai sehat, terutama pada daun yang masih berwarna hijau dan tidak menunjukkan gejala penyakit yang jelas. Nilai *confidence* yang ditampilkan berada pada kisaran sekitar 0,3 sampai 0,8. Nilai ini menunjukkan

tingkat keyakinan model terhadap hasil prediksi. Semakin tinggi nilai *confidence*, semakin besar keyakinan model bahwa objek tersebut termasuk ke dalam kelas yang diprediksi. Meskipun sebagian hasil memiliki *confidence* yang tidak terlalu tinggi, model tetap dapat menandai area daun dan memberikan label sesuai dengan ciri visual yang terlihat.

Secara keseluruhan, hasil prediksi menunjukkan bahwa model YOLO11 sudah mampu mendeteksi penyakit jagung dengan cukup baik pada data uji. Model dapat menentukan lokasi objek melalui *bounding box* dan memberikan klasifikasi sesuai jenis penyakit. Namun, masih terdapat beberapa hasil dengan *confidence* rendah, sehingga model masih dapat ditingkatkan agar deteksi menjadi lebih akurat dan stabil pada setiap kelas.

4.3 Pembahasan

Pada bagian pembahasan ini dijelaskan analisis hasil pengujian beberapa model deteksi objek, yaitu YOLO11, YOLOv8, YOLOv5, SSD MobileNet, dan Faster R-CNN. Pembahasan dilakukan untuk membandingkan performa setiap model berdasarkan nilai *accuracy*, *precision*, *recall*, *mAP50*, *mAP50-95*, *classification report*, dan *confusion matrix*. Melalui perbandingan tersebut, dapat diketahui kemampuan masing-masing model dalam mendeteksi lima kelas pada tanaman jagung, yaitu batang busuk, bercak abu, hawar daun, karat daun, dan sehat. Hasil pembahasan ini juga digunakan untuk menentukan model yang paling efektif dan stabil dalam mengenali penyakit tanaman jagung berdasarkan citra digital.

4.3.1 Ablasi Study

Pada bagian *ablation study* ini dilakukan analisis untuk mengetahui pengaruh penggunaan model terhadap hasil deteksi penyakit tanaman jagung. Pengujian

dilakukan dengan membandingkan beberapa model, yaitu YOLO11, YOLOv8, dan YOLOv5, berdasarkan nilai *accuracy*, *precision*, *recall*, mAP50, dan *confusion matrix*. Perbandingan ini bertujuan untuk melihat model mana yang memiliki kemampuan paling baik dalam mengenali lima kelas, yaitu batang busuk, bercak abu, hawar daun, karat daun, dan sehat. Melalui hasil ablasi ini, dapat diketahui model yang paling efektif, stabil, dan sesuai digunakan dalam sistem deteksi penyakit tanaman jagung berbasis citra.

A. Classification report model YOLO11, YOLOv8 dan YOLOv5

Tabel 4.10 Hasil Perbandingan Model

Kelas	Precision			Recal			mAP50		
	Y8	Y5	Y11	Y8	Y5	Y11	Y8	Y5	Y11
Batang Busuk	0,72	0,792	0,860	0,69	0,701	0,840	0,70	0,781	0,870
Bercak Abu	0,67	0,621	0,830	0,65	0,601	0,810	0,70	0,601	0,850
Hawar Daun	0,72	0,648	0,870	0,76	0,623	0,850	0,76	0,623	0,880
Karat Daun	0,63	0,681	0,840	0,54	0,651	0,820	0,60	0,651	0,860
Sehat	0,89	0,852	0,940	0,88	0,881	0,930	0,93	0,881	0,890
Acuracy							75.5%	70%	87%

Berdasarkan tabel hasil perbandingan model, YOLO11 memperoleh performa paling baik dibandingkan YOLOv8 dan YOLOv5. Hal ini terlihat dari nilai *accuracy* YOLO11 sebesar 87%, lebih tinggi dibandingkan YOLOv8 sebesar 75,5% dan YOLOv5 sebesar 70%. Nilai ini menunjukkan bahwa YOLO11 lebih mampu mengenali penyakit tanaman jagung secara keseluruhan. Pada kelas batang busuk, YOLO11 mendapatkan *precision* 0,860, *recall* 0,840, dan mAP50 0,870. Nilai tersebut lebih tinggi dibandingkan YOLOv8 dan YOLOv5, sehingga

YOLO11 lebih tepat dalam mendeteksi kelas batang busuk. Pada kelas bercak abu, YOLO11 juga unggul dengan *precision* 0,830, *recall* 0,810, dan mAP50 0,850.

Hal ini menunjukkan bahwa model mampu mengenali bercak abu dengan lebih baik, meskipun kelas ini memiliki ciri visual yang cukup mirip dengan penyakit lain. Untuk kelas hawar daun, YOLO11 kembali menunjukkan hasil terbaik dengan *precision* 0,870, *recall* 0,850, dan mAP50 0,880. Nilai ini menunjukkan bahwa YOLO11 cukup stabil dalam mendeteksi hawar daun pada citra uji. Pada kelas karat daun, YOLO11 memperoleh *precision* 0,840, *recall* 0,820 dan mAP50 0,860 sehingga lebih baik dibandingkan YOLOv8 dan YOLOv5 yang nilainya masih lebih rendah. Kelas sehat menjadi kelas dengan hasil tertinggi pada YOLO11, yaitu *precision* 0,940 dan *recall* 0,930.

Hal ini menunjukkan bahwa model sangat baik dalam mengenali daun jagung yang tidak memiliki gejala penyakit. Meskipun nilai mAP50 YOLOv8 pada kelas sehat sedikit lebih tinggi, yaitu 0,93, YOLO11 tetap lebih unggul secara keseluruhan karena memiliki nilai *precision*, *recall*, dan *accuracy* yang lebih tinggi. Secara umum, tabel tersebut menunjukkan bahwa YOLO11 merupakan model terbaik dalam pengujian ini. Model ini memiliki hasil yang lebih seimbang pada semua kelas dan mampu memberikan deteksi yang lebih akurat dibandingkan YOLOv8 dan YOLOv5. Oleh karena itu, YOLO11 dapat digunakan sebagai model utama dalam penelitian deteksi penyakit tanaman jagung.

4.3.2 Uji Perbandingan Model

Pada subbab ini dilakukan uji perbandingan terhadap beberapa model deteksi objek, yaitu YOLO11, YOLOv8, YOLOv5, SSD MobileNet, dan Faster R-CNN. Pengujian ini bertujuan untuk mengetahui model yang memiliki performa

paling baik dalam mendeteksi penyakit tanaman jagung berdasarkan citra digital. Evaluasi dilakukan menggunakan beberapa metrik, yaitu *accuracy*, *precision*, *recall*, dan mAP50. Hasil dari setiap model kemudian dibandingkan untuk melihat kemampuan masing-masing dalam mengenali lima kelas, yaitu batang busuk, bercak abu, hawar daun, karat daun, dan sehat. Melalui perbandingan ini, dapat ditentukan model yang paling efektif digunakan dalam sistem deteksi penyakit tanaman jagung.

A. Hasil Model SSD MobileNet dan Faster R-CNN

SSD MobileNet merupakan model deteksi objek yang menggabungkan metode *Single Shot Detector* (SSD) dengan arsitektur MobileNet. Model ini bekerja dengan cara mendeteksi objek secara langsung dalam satu tahap, mulai dari menentukan posisi objek menggunakan *bounding box* hingga memberikan label kelas pada objek yang terdeteksi. MobileNet digunakan karena memiliki arsitektur yang ringan, sehingga proses deteksi dapat berjalan lebih cepat dan tidak membutuhkan komputasi yang terlalu besar. Dalam penelitian ini, SSD MobileNet digunakan untuk mendeteksi penyakit tanaman jagung pada citra digital, seperti batang busuk, bercak abu, hawar daun, karat daun, dan daun sehat.

Faster R-CNN merupakan model deteksi objek berbasis *deep learning* yang bekerja melalui dua tahap utama. Tahap pertama digunakan untuk mencari area yang kemungkinan mengandung objek, sedangkan tahap kedua digunakan untuk mengklasifikasikan objek dan memperbaiki posisi *bounding box*. Model ini umumnya memiliki kemampuan deteksi yang baik karena proses pencarian objek dilakukan lebih detail. Namun, dibandingkan SSD MobileNet, proses deteksi Faster R-CNN cenderung lebih lambat karena menggunakan tahapan yang lebih

kompleks. Pada penelitian ini, Faster R-CNN digunakan sebagai model pembandingan untuk melihat kemampuan deteksi penyakit tanaman jagung berdasarkan nilai *precision*, *recall*, dan mAP50.

Tabel 4.11 Hasil Classification Report Perbandingan Model

Model	Precision	Recall	mAP50	Accuracy
SSD MobileNet	0,672	0.611	0,659	60%
Faster R-CNN	0,732	0.708	0,728	72,5%
YOLO11	0,868	0,850	0,870	87%

Berdasarkan tabel hasil perbandingan model, YOLO11 menunjukkan performa paling baik dibandingkan SSD MobileNet dan Faster R-CNN. Hal ini terlihat dari nilai *precision* sebesar 0,868, *recall* sebesar 0,850, mAP50 sebesar 0,870, dan *accuracy* sebesar 87%. Nilai tersebut menunjukkan bahwa YOLO11 lebih mampu mendeteksi penyakit tanaman jagung dengan tepat dan stabil pada data uji. Model Faster R-CNN berada pada posisi kedua dengan *precision* 0,732, *recall* 0,708, mAP50 0,728, dan *accuracy* 72,5%. Hasil ini menunjukkan bahwa Faster R-CNN masih memiliki kemampuan deteksi yang cukup baik, tetapi performanya belum setinggi YOLO11. Model ini mampu mengenali objek penyakit jagung, namun masih terdapat beberapa prediksi yang kurang tepat atau objek yang belum terdeteksi secara maksimal.

Sementara itu, SSD MobileNet memperoleh hasil paling rendah dengan *precision* 0,672, *recall* 0,611, mAP50 0,659, dan *accuracy* 60%. Nilai tersebut menunjukkan bahwa SSD MobileNet masih kurang optimal dalam mendeteksi penyakit tanaman jagung dibandingkan dua model lainnya. Hal ini dapat terjadi karena SSD MobileNet merupakan model yang lebih ringan, sehingga kemampuan deteksinya tidak sebaik model yang memiliki arsitektur lebih kuat. Secara

keseluruhan, hasil pada tabel menunjukkan bahwa YOLO11 merupakan model terbaik dalam penelitian ini. Model ini memiliki nilai evaluasi paling tinggi pada seluruh metrik, sehingga lebih efektif digunakan untuk mendeteksi penyakit tanaman jagung berdasarkan citra digital. Faster R-CNN masih dapat dijadikan pembanding dengan performa cukup baik, sedangkan SSD MobileNet memiliki hasil paling rendah dalam pengujian ini.

4.4 Implementasi Aplikasi

Setelah model YOLO11 selesai dilatih dan diuji, model diimplementasikan ke dalam sebuah aplikasi deteksi penyakit tanaman jagung. Aplikasi ini digunakan untuk menguji kemampuan model dalam mendeteksi penyakit pada citra baru. Pengguna cukup mengunggah gambar daun jagung, kemudian sistem akan menampilkan hasil deteksi berupa nama penyakit, *bounding box*, dan nilai *confidence*. Aplikasi ini bertujuan membantu petani untuk mendeteksi penyakit pada tanaman jagung secara cepat dan tanpa memerlukan keahlian teknis.

1. Tampilan Aplikasi

Untuk memberikan gambaran yang lebih jelas mengenai bagaimana aplikasi ini bekerja serta kemudahan yang ditawarkan kepada pengguna berikut disajikan beberapa tangkapan layar dari antarmuka aplikasi. Tampilan ini memperlihatkan bagaimana pengguna dapat berinteraksi dengan sistem mulai dari halaman awal hingga proses deteksi penyakit.

A. Logo Aplikasi

Logo aplikasi JagungSehat merupakan identitas visual yang mencerminkan fungsi aplikasi sebagai sistem deteksi penyakit tanaman jagung. Ikon tanaman jagung melambangkan objek utama penelitian, sedangkan warna hijau

menggambarkan pertanian, kesehatan, dan kesegaran. Desain logo dibuat sederhana agar mudah dikenali dan memberikan kesan profesional.



Gambar 4.8: Logo Aplikasi

B. Tampilan awal

Tampilan awal aplikasi menyajikan antarmuka pembuka yang sederhana dan menarik. Berikut tampilan nya.



Gambar 4.9: Tampilan Awal


Gambar ini menampilkan halaman tampilan awal aplikasi JagungSehat yang muncul saat aplikasi pertama kali dijalankan. Halaman ini berfungsi sebagai tampilan pembuka yang menampilkan logo dan nama aplikasi sebelum pengguna masuk ke halaman utama. Desain dibuat sederhana dengan dominasi warna hijau yang mencerminkan pertanian dan kesehatan tanaman.

71

C. Tampilan Menu Utama

Tampilan menu utama aplikasi berfungsi sebagai pusat informasi bagi pengguna dalam mengenali jenis penyakit pada tanaman jagung. Berikut ini merupakan tampilan utama aplikasi.

174



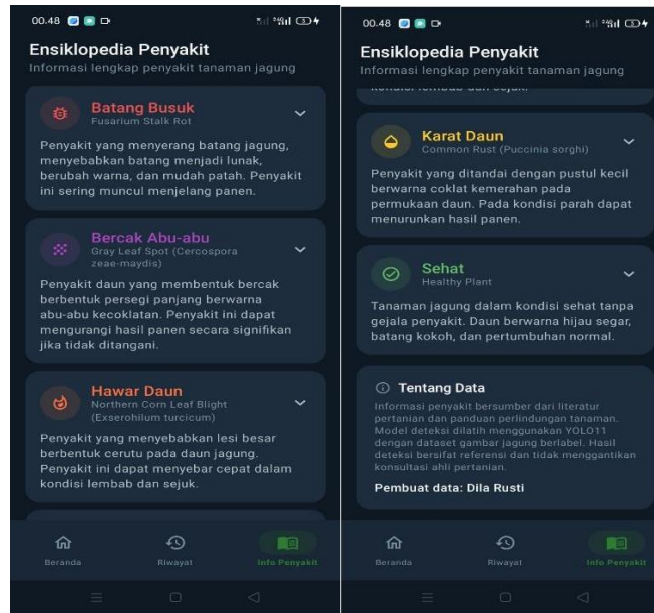
Gambar 4.10: Tampilan Menu Utama

Gambar ini menampilkan halaman beranda aplikasi JagungSehat. Halaman ini merupakan menu utama yang digunakan pengguna untuk memulai proses deteksi penyakit tanaman jagung. Pengguna dapat memilih metode pengambilan gambar, yaitu mengambil foto secara langsung, memilih gambar dari galeri, atau melakukan deteksi secara *real-time*. Selain itu, aplikasi juga menampilkan informasi status sistem, jumlah hasil pemindaian, serta tips pengambilan foto agar hasil deteksi lebih akurat.

D. Tampilan Info Penyakit

31

Pada tahap ini, pengguna dapat melihat informasi mengenai penyakit tanaman jagung yang tersedia pada aplikasi. Informasi yang ditampilkan meliputi nama penyakit, deskripsi singkat, dan gejala penyakit.



Gambar 4.11: Info Penyakit

Gambar ini menampilkan halaman Info Penyakit pada aplikasi JagungSehat. Halaman ini berisi informasi mengenai lima kategori penyakit tanaman jagung, yaitu Batang Busuk, Bercak Abu-abu, Hawar Daun, Karat Daun, dan Sehat. Setiap kategori dilengkapi dengan nama penyakit, deskripsi singkat, serta informasi mengenai gejala yang dapat membantu pengguna memahami hasil deteksi yang diberikan oleh aplikasi.

E. Tampilan Proses Deteksi

Pada tahap ini, aplikasi melakukan proses analisis terhadap gambar tanaman jagung yang telah dipilih oleh pengguna menggunakan model YOLO11. Selama proses berlangsung, pengguna diminta menunggu hingga hasil deteksi selesai ditampilkan.




Gambar 4.12: Proses Deteksi

Menampilkan proses analisis gambar pada aplikasi JagungSehat. Pada tahap ini, aplikasi memproses gambar tanaman jagung yang telah dipilih oleh pengguna menggunakan model YOLO11. Selama proses berlangsung, sistem melakukan identifikasi objek dan klasifikasi penyakit hingga hasil deteksi berhasil ditampilkan. Pengguna hanya perlu menunggu beberapa saat sampai proses analisis selesai.

F. Tampilan Hasil Deteksi

Menu deteksi merupakan fitur utama dalam aplikasi yang memungkinkan pengguna mengidentifikasi jenis penyakit pada tanaman jagung melalui gambar. Berikut ini merupakan gambar tampilan menu deteksi.




Gambar 4.13: Tampilan Hasil Deteksi

Menampilkan halaman hasil analisis pada aplikasi JagungSehat. Pada tahap ini, aplikasi menampilkan hasil deteksi penyakit tanaman jagung berdasarkan gambar yang telah dianalisis menggunakan model YOLO11. Hasil deteksi ditampilkan dalam bentuk *bounding box*, nama penyakit yang terdeteksi, nilai *confidence*, serta informasi waktu proses analisis. Selain itu, aplikasi juga memberikan informasi mengenai gejala, penyebab, penanganan, dan pencegahan penyakit sehingga pengguna dapat memahami kondisi tanaman dan mengetahui langkah penanganan yang tepat. Pengguna juga dapat menyimpan hasil deteksi atau melakukan pemindaian ulang melalui tombol yang tersedia.

G. Tampilan Menu History

Menu History berfungsi untuk menyimpan riwayat hasil deteksi yang telah dilakukan oleh pengguna.



Gambar 4.14: Tampilan Menu History

Gambar ini menampilkan halaman Riwayat Pemindaian pada aplikasi JagungSehat. Halaman ini berfungsi untuk menyimpan dan menampilkan seluruh hasil deteksi yang telah dilakukan pengguna. Informasi yang ditampilkan meliputi gambar hasil pemindaian, jenis penyakit yang terdeteksi, nilai *confidence*, jumlah

37 objek yang terdeteksi, serta waktu pemindaian. Riwayat ini memudahkan pengguna untuk melihat kembali hasil deteksi sebelumnya.

197 Berdasarkan hasil implementasi aplikasi JagungSehat, dapat disimpulkan bahwa aplikasi berhasil mengimplementasikan model YOLO11 untuk mendeteksi penyakit tanaman jagung. Aplikasi menyediakan berbagai fitur, mulai dari tampilan pembuka (*splash screen*), halaman utama untuk memilih metode deteksi, proses analisis gambar, hasil deteksi yang menampilkan jenis penyakit beserta nilai *confidence*, riwayat hasil pemindaian, hingga halaman informasi penyakit yang berisi gejala, penyebab, penanganan, dan pencegahan. Dengan adanya fitur-fitur tersebut, aplikasi mampu membantu pengguna dalam melakukan deteksi penyakit tanaman jagung secara lebih mudah, cepat, dan informatif.

6

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat diambil kesimpulan sebagai berikut:

1. Penelitian ini berhasil menerapkan model YOLO11 untuk mendeteksi penyakit pada tanaman jagung berdasarkan citra daun dan batang. Model ini mampu mendeteksi lokasi objek menggunakan *bounding box* sekaligus mengklasifikasikan jenis penyakit ke dalam lima kelas, yaitu Batang Busuk, Bercak Abu, Hawar Daun, Karat Daun, dan Sehat.
2. Dataset yang digunakan berjumlah 4.405 citra yang dibagi menjadi data latih sebesar 80%, data validasi 10%, dan data uji 10%. Proses *preprocessing* dan augmentasi dilakukan untuk menyiapkan data agar lebih sesuai dengan kebutuhan pelatihan model. Augmentasi seperti rotasi, flip, brightness, dan zoom out membantu menambah variasi citra sehingga model dapat mengenali objek pada berbagai kondisi gambar.
3. Berdasarkan hasil pengujian, model YOLO11 memperoleh nilai *precision* sebesar 0,868, *recall* sebesar 0,850, *mAP50* sebesar 0,870, dan *accuracy* sebesar 87%. Hasil ini menunjukkan bahwa YOLO11 memiliki kemampuan deteksi yang baik dan lebih unggul dibandingkan model pembanding seperti YOLOv8, YOLOv5, SSD MobileNet, dan Faster R-CNN. Dengan demikian, YOLO11 menjadi model yang paling efektif dalam penelitian ini.

5.2 Saran

Adapun saran yang dapat diberikan untuk pengembangan penelitian selanjutnya adalah sebagai berikut:

1. Penelitian selanjutnya disarankan menggunakan dataset yang lebih banyak dan lebih bervariasi, terutama dari segi pencahayaan, sudut pengambilan gambar, jarak kamera, latar belakang, serta kondisi tanaman. Hal ini

bertujuan agar model dapat mengenali penyakit jagung dengan lebih baik pada kondisi nyata di lapangan.

2. Perlu dilakukan penambahan data pada kelas penyakit yang memiliki ciri visual mirip, seperti Bercak Abu, Hawar Daun, dan Karat Daun. Penambahan data tersebut diharapkan dapat mengurangi kesalahan deteksi antar kelas karena beberapa gejala penyakit memiliki warna, bentuk bercak, dan pola kerusakan yang hampir sama.
3. Penelitian selanjutnya dapat mencoba arsitektur model lain atau pengembangan model yang lebih ringan, seperti YOLO versi terbaru, EfficientDet, MobileNet, atau model deteksi objek lain. Tujuannya untuk mengetahui apakah terdapat model yang mampu menghasilkan akurasi lebih tinggi dengan proses deteksi yang lebih cepat dan efisien.

DAFTAR PUSTAKA

- [1] A. Zanchin, A. Perbellini, M. Sozzi, F. Marinello, and L. Guerrini, "Assessment of grapevine bunch withering: advances in fruit 3D morphology and colour evaluation," *Biosyst. Eng.*, vol. 254, no. April, p. 104145, 2025, doi: 10.1016/j.biosystemseng.2025.104145.
- [2] N. A. N. A. Yani, S. S. M. Fauzi, N. A. M. Zaki, and M. H. Ismail, "A Systematic Literature Review on Leaf Disease Recognition Using Computer Vision and Deep Learning Approach," *J. Inf. Syst. Eng. Bus. Intell.*, vol. 10, no. 2, pp. 232–249, 2024, doi: 10.20473/jisebi.10.2.232-249.
- [3] R. Khanam and M. Hussain, "YOLOv11: An Overview of the Key Architectural Enhancements," vol. 2024, pp. 1–9, 2024, [Online]. Available: <http://arxiv.org/abs/2410.17725>
- [4] S. Hao, E. Gao, Z. Ji, and I. Ganchev, "BCS_YOLO: Research on Corn Leaf Disease and Pest Detection Based on YOLOv11n," *Appl. Sci.*, vol. 15, no. 15, pp. 1–22, 2025, doi: 10.3390/app15158231.
- [5] Y. Meng, J. Zhan, K. Li, F. Yan, and L. Zhang, "A rapid and precise algorithm for maize leaf disease detection based on YOLO MSM," *Sci. Rep.*, vol. 15, no. 1, pp. 1–19, 2025, doi: 10.1038/s41598-025-88399-1.
- [6] A. Ilyana, N. Nurdin, and M. Maryana, "Real-Time Detection of Coffee Cherry Ripeness Using YOLOv11," *J. Appl. Informatics Comput.*, vol. 9, no. 4, pp. 1170–1178, 2025, doi: 10.30871/jaic.v9i4.9735.
- [7] M. M. Huda et al., "Identifikasi Mangga Berdasarkan Tingkat Kematangan Menggunakan Yolo 11," *Proceeding Natl. Semin. Technol. Sci.*, vol. 4, no. 1, pp. 175–182, 2025.
- [8] L. Wu, X. Li, P. Ma, and Y. Cai, "Research on a Dense Pedestrian-Detection Algorithm Based on an Improved YOLO11," *Futur. Internet*, vol. 17, no. 10, p. 438, 2025, doi: 10.3390/fi17100438.
- [9] X. Du, X. Zhang, T. Li, X. Chen, X. Yu, and H. Wang, "YOLO-WAS: ALightweight Apple Target Detection Method Based on Improved

- YOLO11,” *Agric.*, vol. 15, no. 14, pp. 1–19, 2025, doi: 10.3390/agriculture15141521.
- [10] Y. Zhang, R. Gao, M. Ji, W. Zhang, W. Yu, and X. Wang, “TASNet-YOLO: An Identification and Classification Model for Surface Defects of Rough Planed Bamboo Strips,” *Forests*, vol. 16, no. 10, pp. 1–17, 2025, doi: 10.3390/f16101595.
- [11] M. Li et al., “High-Performance Plant Pest and Disease Detection Based on,” pp. 1–22, 2023.
- [12] K. M. Muhammad Hammad Saleem, “Image-Based Plant Disease Identification by Deep,” 2020
- [13] S. F. Nazila, Y. Arman, D. Wahyuni, N. Nurhasanah, and Y. S. Putra, “Deteksi Dini Serangan Hama Penyakit pada Cabai Rawit Menggunakan Metode Image Recognition,” *J. Tek. Inform. dan Sist. Inf.*, vol. 9, no. 2, pp. 232–241, 2023, doi: 10.28932/jutisi.v9i2.6342.
- [14] Mohammad Syarief, Amirul Mukminin, Novi Prastiti, and Wahyudi Setiawan, “Penerapan Metode Naïve Bayes Classifier Untuk Deteksi Penyakit Pada Tanaman Jagung,” *J. Ilm. NERO*, vol. 3, no. 1, pp. 61–68, 2017.
- [15] T. Murugan et al., “Research Advances in Maize Crop Disease Detection Using Machine Learning and Deep Learning Approaches,” pp. 1–53, 2026.
- [16] S. Yang et al., “Maize-YOLO : A New High-Precision and Real-Time Method for Maize Pest Detection,” 2023.
- [17] J. Kang, W. Zhang, Y. Xia, and W. Liu, “applied sciences A Study on Maize Leaf Pest and Disease Detection Model Based on Attention and Multi-Scale Features,” 2023.
- [18] Y. Liu, Q. Yu, S. Geng, S. Guo, and L. Liu, “SSViT-YOLOv11 : fusing lightweight YOLO & ViT for coffee fruit maturity detection,” no. December, pp. 1–19, 2025, doi: 10.3389/fpls.2025.1691643

- [19] D. Mu et al., “URT-YOLOv11 : A Large Receptive Field Algorithm for Detecting Tomato Ripening Under Different Field Conditions,” pp. 1–29, 2025.
- [20] Y. Luo, A. Wu, and Q. Fu, “MAS-YOLOv11 : An Improved Underwater Object Detection Algorithm Based on YOLOv11,” pp. 1–30, 2025.
- [21] J. Zhang, S. Chen, W. Wang, and Q. Wang, “Fully Autonomous Real-Time Defect Detection for Power Distribution Towers: A Small Target Defect Detection Method Based on YOLOv11n,” *Sensors*, vol. 25, no. 20, pp. 1–26, 2025, doi: 10.3390/s25206445.
- [22] X. Zhang, L. Li, Z. Bian, C. Dai, and Z. Ji, “RDL-YOLO : A Method for the Detection of Leaf Pests and Diseases in Cotton Based on YOLOv11,” pp. 1–23, 2025.
- [23] J. Wei, R. Wang, S. Wei, X. Wang, and S. Xu, “Recognition of Maize Tassels Based on Improved YOLOv8 and Unmanned Aerial Vehicles RGB Images,” 2024.
- [24] F. Yunita, P. Studi, S. Informasi, and I. Hilir, “Pemilihan Bibit Kelapa Menggunakan Metode Nearest Mean Classifier Untuk,” vol. 2, pp. 101–114, 2020.
- [25] U. Usman, F. Yunita, and M. R. Ridha, “Improving Classification Accuracy of Local Coconut Fruits with Image Augmentation and Deep Learning Algorithm Convolutional Neural Networks (CNN),” vol. 6, no. 1, pp. 1–19, 2025.
- [26] F. J. Putri, P. Studi, S. Informasi, U. I. Indragiri, and I. Hilir, “Mengembangkan Model Cnn Untuk Klasifikasi Tingkat Kematangan Buah Nanas,” vol. 8, pp. 53–63, 2026.

LAMPIRAN



