

CEK TURNITIN

SKRIPSI Fanisha Julianda Putri SI

 SATSET DIGITAL 3

Document Details

Submission ID

trn:oid:::3618:151071521

Submission Date

Sep 9, 2026, 10:13 AM GMT+7

Download Date

Sep 9, 2026, 10:16 AM GMT+7

File Name

SKRIPSI Fanisha Julianda Putri SI.pdf

File Size

2.6 MB

84 Pages

14,421 Words

93,482 Characters

35% Overall Similarity

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

Filtered from the Report

- Bibliography

Top Sources

- 25%  Internet sources
- 17%  Publications
- 30%  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

25% Internet sources
 17% Publications
 30% Submitted works (Student Papers)

Top Sources

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

1	Internet	repository.unisi.ac.id	4%
2	Internet	ejournal.itn.ac.id	1%
3	Internet	kc.umn.ac.id	<1%
4	Internet	proceeding.unpkediri.ac.id	<1%
5	Internet	etheses.uin-malang.ac.id	<1%
6	Internet	repository.uin-suska.ac.id	<1%
7	Student papers	Universitas Sangga Buana YPKP on 2026-07-20	<1%
8	Internet	jurnal.polibatam.ac.id	<1%
9	Internet	jurnal.umt.ac.id	<1%
10	Internet	ejurnal.stmik-budidarma.ac.id	<1%
11	Internet	jurnal.stkipppgritulungagung.ac.id	<1%

12	Student papers	Universitas Islam Sumatera Utara on 2026-04-20	<1%
13	Student papers	Universitas Khairun on 2026-07-13	<1%
14	Student papers	UPN Veteran Yogyakarta on 2026-07-06	<1%
15	Student papers	Universitas Sangga Buana YPKP on 2026-07-18	<1%
16	Internet	repo.darmajaya.ac.id	<1%
17	Student papers	Institut Teknologi Sumatera on 2026-06-17	<1%
18	Student papers	Universitas Islam Riau on 2026-04-02	<1%
19	Student papers	Universitas Pamulang on 2026-07-11	<1%
20	Student papers	Universitas Pamulang on 2026-07-13	<1%
21	Internet	digilib.unimed.ac.id	<1%
22	Internet	ojs.stmik-banjarbaru.ac.id	<1%
23	Internet	repository.unissula.ac.id	<1%
24	Student papers	UPN Veteran Yogyakarta on 2026-06-23	<1%
25	Student papers	Universitas Tarumanagara on 2025-12-19	<1%

26	Internet	ejurnal.seminar-id.com	<1%
27	Internet	repository.unhas.ac.id	<1%
28	Student papers	Universitas Islam Riau on 2026-08-21	<1%
29	Internet	jtika.if.unram.ac.id	<1%
30	Student papers	Universitas Islam Indonesia on 2025-09-17	<1%
31	Student papers	Universitas Pamulang on 2026-07-03	<1%
32	Student papers	Universitas Sangga Buana YPKP on 2026-07-28	<1%
33	Student papers	Universitas Sangga Buana YPKP on 2026-07-31	<1%
34	Student papers	UPN Veteran Yogyakarta on 2026-06-18	<1%
35	Internet	repository.upnjatim.ac.id	<1%
36	Student papers	Institut Teknologi Sumatera on 2026-07-21	<1%
37	Student papers	UPN Veteran Jakarta on 2026-07-24	<1%
38	Student papers	UPN Veteran Yogyakarta on 2025-10-01	<1%
39	Internet	cdn.juris.id	<1%

40	Student papers	Universitas Budi Luhur on 2026-01-31	<1%
41	Internet	jurnal.unived.ac.id	<1%
42	Publication	Gema Umara Muhammad, Erna Zuni Astuti. "Implementation of Convolutional N...	<1%
43	Internet	lab.tik.pnj.ac.id	<1%
44	Internet	jtera.polteksmi.ac.id	<1%
45	Internet	repository.ub.ac.id	<1%
46	Student papers	Universitas Jember on 2025-06-16	<1%
47	Student papers	Universitas Sangga Buana YPKP on 2026-07-29	<1%
48	Student papers	Universitas Islam Riau on 2025-12-15	<1%
49	Student papers	Universitas Sangga Buana YPKP on 2026-07-28	<1%
50	Internet	publikasi.hawari.id	<1%
51	Student papers	Sekolah Teknik Elektro & Informatika on 2026-07-20	<1%
52	Student papers	Universitas Islam Riau on 2026-07-08	<1%
53	Student papers	Universitas Islam Riau on 2026-07-20	<1%

54	Student papers	Universitas Pamulang on 2025-07-12	<1%
55	Internet	repository.polibatam.ac.id	<1%
56	Internet	repository.unnur.ac.id	<1%
57	Publication	Safa Emilita, Putri Sri Rahayu, Sekar Rania Larasati, Ghofar Taufiq, Jefina Tri Kum...	<1%
58	Student papers	UPN Veteran Yogyakarta on 2026-02-27	<1%
59	Student papers	Universitas Islam Riau on 2026-07-29	<1%
60	Student papers	Universitas Trunojoyo on 2026-07-07	<1%
61	Publication	Clift, Jennifer E.. "A Predictive Model to Increase Technology Transfer and Transiti...	<1%
62	Publication	Fini Ikhfiani Fadilah, Purwadi Purwadi. "Classification of Impulse Buying on TikTo...	<1%
63	Student papers	Telkom University on 2025-07-07	<1%
64	Student papers	Universitas Bengkulu on 2025-10-17	<1%
65	Student papers	Universitas Pamulang on 2026-07-29	<1%
66	Student papers	Universitas Sangga Buana YPKP on 2026-07-24	<1%
67	Student papers	Universitas Sangga Buana YPKP on 2026-07-28	<1%

68	Internet	journal.unilak.ac.id	<1%
69	Publication	Muhammad Suhada, Adil Setiawan, Roslina Roslina. "Perbandingan Kinerja Meto...	<1%
70	Publication	Sandi Badiwibowo Atim, Muhammad Afdhaluddin. "Komparasi Perceptron dan R...	<1%
71	Publication	Shofi Camila Laisya Amanda, Fitri Yunita, Samsudin Samsudin. "Optimasi Metode ...	<1%
72	Student papers	The Scientific & Technological Research Council of Turkey (TUBITAK) on 2024-09-11	<1%
73	Student papers	UPN Veteran Yogyakarta on 2025-10-28	<1%
74	Student papers	Universitas Bengkulu on 2025-11-05	<1%
75	Student papers	Universitas Pamulang on 2026-07-08	<1%
76	Internet	journal.untar.ac.id	<1%
77	Internet	rcf-indonesia.org	<1%
78	Internet	teknosi.fti.unand.ac.id	<1%
79	Student papers	UPN Veteran Yogyakarta on 2026-07-03	<1%
80	Student papers	Universitas Budi Luhur on 2026-01-27	<1%
81	Student papers	Universitas Islam Riau on 2026-06-19	<1%

82	Student papers	Universitas Sangga Buana YPKP on 2026-08-03	<1%
83	Publication	Yeheskiel Ravena Damanik, Albert Adolf Angie MS, Esther Laura Rumahorbo, Elis...	<1%
84	Internet	computersciencejournal.org	<1%
85	Internet	digilib.ulm.ac.id	<1%
86	Internet	repository.nusaputra.ac.id	<1%
87	Internet	repository.upi.edu	<1%
88	Internet	skripsi.tunasbangsa.ac.id	<1%
89	Publication	Asep Zainal Alfari, Enny Itje Sela. "Klasifikasi Rimpang Menggunakan Metode K...	<1%
90	Student papers	LL Dikti IX Turnitin Consortium on 2026-09-09	<1%
91	Publication	Muhammad Hasbi, Hendra Sanjaya. "Komparasi Support Vector Machine dan Ran...	<1%
92	Student papers	UPN Veteran Jakarta on 2025-12-19	<1%
93	Student papers	UPN Veteran Yogyakarta on 2026-03-02	<1%
94	Student papers	Universitas Pendidikan Indonesia on 2026-07-05	<1%
95	Internet	docplayer.info	<1%

96	Internet	repository.ittelkom-pwt.ac.id	<1%
97	Publication	Muhammad Totti Alfarabi, Daniel Udjulawa. "Klasifikasi Penyakit Daun Kelapa M...	<1%
98	Internet	es.scribd.com	<1%
99	Internet	hostjournals.com	<1%
100	Internet	journal.ilmudata.co.id	<1%
101	Publication	Andri Wijaya, Thomas Filikano. "MODEL TERBARUKAN HYBIRD CNN DAN LEXICO...	<1%
102	Publication	Better Swengky, M Hizbul Wathan, Indra Irawan, Rosaura Aulia. "Klasifikasi Mata ...	<1%
103	Student papers	Rektorat (ADM) on 2026-01-29	<1%
104	Student papers	Sekolah Tinggi Seminari Katolik on 2025-12-13	<1%
105	Student papers	UNIVERSITAS BUDI LUHUR on 2025-08-19	<1%
106	Student papers	Universitas Islam Riau on 2025-07-17	<1%
107	Student papers	Universitas Pamulang on 2026-07-21	<1%
108	Student papers	Universitas Pamulang on 2026-07-24	<1%
109	Student papers	University of Ulster on 2026-08-29	<1%

110	Internet	akademifarmasi-ypf.ac.id	<1%
111	Internet	journal.darmajaya.ac.id	<1%
112	Student papers	poltekssn on 2025-07-16	<1%
113	Internet	repositori.uma.ac.id	<1%
114	Student papers	Institut Teknologi Sumatera on 2026-06-24	<1%
115	Publication	Mellysa Pratama, Erwin Dwika Putra. "IMPLEMENTASI CONVOLUTIONAL NEURAL ...	<1%
116	Publication	Muhammad Irvan Maulana, Savana Putra Aditama, Harun Al Rosyid. "Komparasi...	<1%
117	Publication	Siti Hajar, Nurdin Nurdin. "PERBANDINGAN KLASIFIKASI ALGORITMA DECISION T...	<1%
118	Student papers	UPN Veteran Yogyakarta on 2026-05-05	<1%
119	Student papers	UPN Veteran Yogyakarta on 2026-06-02	<1%
120	Student papers	Universitas Islam Riau on 2025-10-31	<1%
121	Student papers	Universitas Muslim Indonesia on 2025-08-16	<1%
122	Student papers	Universitas Pamulang on 2026-06-08	<1%
123	Student papers	Universitas Sangga Buana YPKP on 2026-07-20	<1%

124	Internet	e-journals2.unmul.ac.id	<1%
125	Internet	jurnal.unimor.ac.id	<1%
126	Internet	repository.ubpkarawang.ac.id	<1%
127	Publication	Juanto Simangunsong, Mutiara S. Simanjuntak, Nurmala Dewi Simanjuntak. "Ana...	<1%
128	Student papers	Politeknik Negeri Lhokseumawe Turnitin on 2026-01-12	<1%
129	Student papers	Telkom University on 2026-04-27	<1%
130	Student papers	Universitas Islam Riau on 2026-06-15	<1%
131	Student papers	Universitas Sangga Buana YPKP on 2026-07-22	<1%
132	Internet	eprints.walisongo.ac.id	<1%
133	Internet	journal.aira.or.id	<1%
134	Internet	www.scribd.com	<1%
135	Internet	123dok.com	<1%
136	Publication	Nurhayati Nurhayati, Aditya Kusuma. "PERANCANGAN SISTEM DETEKSI KEMATAN...	<1%
137	Student papers	Politeknik Negeri Lhokseumawe Turnitin on 2026-01-11	<1%

138	Student papers	Tarumanagara University on 2026-06-21	<1%
139	Student papers	Universitas Diponegoro on 2019-11-01	<1%
140	Student papers	Universitas Islam Riau on 2026-07-15	<1%
141	Student papers	Universitas Muhammadiyah Palembang on 2026-04-26	<1%
142	Student papers	Universitas Putera Batam on 2026-07-25	<1%
143	Student papers	Universitas Sangga Buana YPKP on 2026-07-31	<1%
144	Student papers	Universitas Sumatera Utara on 2025-05-23	<1%
145	Publication	Yudha Prastya. "HYBRID CNN-SVM UNTUK ANALISIS SENTIMEN KLUB TIM NASIO..."	<1%
146	Internet	garuda.kemdikbud.go.id	<1%
147	Internet	repository.um-palembang.ac.id	<1%
148	Internet	repository.umsu.ac.id	<1%
149	Publication	Almira Zuhrotus Safira, Sindhu Rakasiwi. "Optimization of Transfer Learning VGG-..."	<1%
150	Student papers	Fakultas Teknik on 2026-07-10	<1%
151	Student papers	Politeknik Negeri Lhokseumawe Turnitin on 2026-01-07	<1%

152	Student papers	Sekolah Teknik Elektro & Informatika on 2025-07-18	<1%
153	Student papers	Sriwijaya University on 2017-09-10	<1%
154	Student papers	Telkom University on 2025-07-04	<1%
155	Student papers	Telkom University on 2026-06-30	<1%
156	Student papers	UPN Veteran Yogyakarta on 2026-04-22	<1%
157	Student papers	UPN Veteran Yogyakarta on 2026-05-04	<1%
158	Student papers	Universitas Brawijaya on 2021-06-11	<1%
159	Student papers	Universitas Trunojoyo on 2021-07-22	<1%
160	Internet	ojs.unimal.ac.id	<1%
161	Internet	publication.petra.ac.id	<1%
162	Publication	Afifah Agustin, Mufti Ari Bianto, Hery Ardiansyah. "Perbandingan Klasifikasi Dau...	<1%
163	Publication	Akhiyar Waladi. "Peningkatan Akurasi Klasifikasi Tutupan Lahan Menggunakan R...	<1%
164	Publication	Dela Puspita Helmi, Jumadil Nangi, Asa Hari Wibowo. "Sistem Informasi Analisis K...	<1%
165	Student papers	Exeed College on 2025-12-30	<1%

166	Publication	Felicia Amanda Cahyadewi, Ibnu Richo Kurniawan, Irsyad Umar Fakhrizal, Fahriza...	<1%
167	Publication	Hidayat Hidayat, Musliadi KH, Indar Kusmanto, Munawirah Kadir, Kristian Kristia...	<1%
168	Publication	Rihadatul 'Aisy, Tiara Devina Putri, Meilani Audi Kustanti, Muhajirul Fajri, Ceysh...	<1%
169	Student papers	Rijksuniversiteit Groningen - Tii on 2026-04-16	<1%
170	Student papers	STT PLN on 2022-08-09	<1%
171	Student papers	STT PLN on 2023-07-27	<1%
172	Student papers	Sekolah Teknik Elektro & Informatika on 2026-06-19	<1%
173	Student papers	Sultan Agung Islamic University on 2025-06-03	<1%
174	Student papers	Telkom University on 2026-07-21	<1%
175	Student papers	UM Surabaya on 2026-07-16	<1%
176	Student papers	UPN Veteran Yogyakarta on 2026-06-17	<1%
177	Student papers	Universitas Brawijaya on 2018-11-02	<1%
178	Student papers	Universitas Islam Indonesia on 2026-05-12	<1%
179	Student papers	Universitas Kristen Duta Wacana on 2026-05-07	<1%

180	Student papers	Universitas Musamus Merauke on 2026-07-09	<1%
181	Student papers	Universitas Pamulang on 2026-07-03	<1%
182	Student papers	Universitas Pamulang on 2026-07-06	<1%
183	Student papers	Universitas Pamulang on 2026-07-22	<1%
184	Student papers	Universitas Pendidikan Indonesia on 2014-02-18	<1%
185	Student papers	Universitas Prima Indonesia on 2025-06-10	<1%
186	Student papers	Universitas Sangga Buana YPKP on 2026-07-31	<1%
187	Publication	Virna Dalira Br Sebayang, I Gusti Ngurah Lanang Wijaya Kusuma. "Klasifikasi Jeni...	<1%
188	Internet	archive.umsida.ac.id	<1%
189	Internet	digilib.unila.ac.id	<1%
190	Internet	docobook.com	<1%
191	Internet	journal.unismuh.ac.id	<1%
192	Internet	journals.upi-yai.ac.id	<1%
193	Internet	jpti.journals.id	<1%

194	Internet	jurnal.itbsemarang.ac.id	<1%
195	Internet	jurnal.umb.ac.id	<1%
196	Internet	repositori.uin-alaudidin.ac.id	<1%
197	Internet	repositori.unibos.ac.id	<1%
198	Internet	repository.ipb.ac.id	<1%
199	Student papers	Sriwijaya University on 2021-03-22	<1%
200	Student papers	UPN Veteran Yogyakarta on 2026-05-29	<1%
201	Student papers	UPN Veteran Yogyakarta on 2026-06-02	<1%
202	Student papers	Universitas Brawijaya on 2018-12-15	<1%
203	Student papers	Universitas Islam Riau on 2025-09-10	<1%
204	Student papers	Universitas Khairun on 2026-05-25	<1%
205	Student papers	Universitas Muslim Indonesia on 2026-06-26	<1%
206	Student papers	Universitas Sangga Buana YPKP on 2026-07-29	<1%
207	Publication	Hasriadi Hasriadi, Iqbal Iqbal. "Prediksi Harga Bitcoin Multivariat OHLC Berbasis ...	<1%

208	Student papers	Institut Pertanian Bogor on 2026-08-27	<1%
209	Student papers	Institut Teknologi Sumatera on 2026-07-30	<1%
210	Student papers	Perpustakaan on 2025-08-06	<1%
211	Student papers	Perpustakaan on 2025-10-17	<1%
212	Publication	Santowi Azis, Bambang irawan -. "EVALUASI KLASIFIKASI PENYAKIT DAUN TEH M...	<1%
213	Student papers	UNIVERSITAS BUDI LUHUR on 2025-07-24	<1%
214	Student papers	Universitas Islam Riau on 2026-08-18	<1%
215	Student papers	Universitas Jambi on 2025-05-19	<1%
216	Student papers	Universitas Jember on 2026-06-21	<1%
217	Student papers	Universitas Jember on 2026-06-25	<1%
218	Student papers	Universitas Muhammadiyah Palembang on 2026-04-29	<1%
219	Student papers	Universitas Pancasila on 2025-08-10	<1%
220	Student papers	Universitas Pendidikan Indonesia on 2025-03-13	<1%
221	Student papers	Universitas Sumatera Utara on 2024-12-24	<1%

222

Publication

Yulia Fatma, Rahmad Gunawan, Nurkhairi Fitri, Rahmad Firdaus, Regiolina Haya...

<1%

OPTIMASI MODEL HYBRID CNN-SVM UNTUK KLASIFIKASI KEMATANGAN BUAH NANAS

SKRIPSI TUGAS AKHIR



Disusun oleh :

FANISHA JULIANANDA PUTRI

403221010046

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

**OPTIMASI MODEL HYBRID CNN-SVM UNTUK KLASIFIKASI
KEMATANGAN BUAH NANAS**

**OPTIMIZATION OF A HYBRID CNN AND SVM MODEL FOR
PINEAPPLE RIPENESS CLASSIFICATION**

Diajukan untuk memenuhi salah satu syarat
memperoleh derajat Sarjana S1



Disusun oleh :

FANISHA JULIANANDA PUTRI
403221010046

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

PERSETUJUAN

OPTIMASI MODEL HYBRID CNN-SVM UNTUK KLASIFIKASI KEMATANGAN BUAH NANAS

Yang dipersiapkan dan disusun oleh

FANISHA JULIANANDA PUTRI

403221010046

Telah disetujui oleh Dosen Pembimbing
pada tanggal 18 Desember 2025

Pembimbing Utama

Pembimbing Pendamping

Muh. Rasyid Ridha, S.SI., M.Kom
NIDN. 1013089001

Fitri Yunita, S.SI., M.Kom
NIDN. 1012089001

Dekan Fakultas Teknik dan Ilmu Komputer

Dr. Bayu Rianto, S.SI., M.Kom
NIPY. 1691 09 321

PENGESAHAN**OPTIMASI MODEL HYBRID CNN-SVM UNTUK KLASIFIKASI
KEMATANGAN BUAH NANAS**

Dipersiapkan dan disusun oleh

FANISHA JULIANANDA PUTRI
403221010046

Telah Diuji dan Dipertahankan di depan Dewan Penguji
pada Tanggal 21 Juli 2026

Susunan Dewan Penguji

Pembimbing Utama

Dewan Penguji I

Muh. Rasyid Ridha, S.SI., M.Kom
NIDN. 1013089001

Ilyas, S.Kom., M.Kom
NIDN. 1024097402

Pembimbing Pendamping

Dewan Penguji II

Fitri Yunita, S.SI., M.Kom
NIDN. 1012089001

Usman, ST., M.Kom
NIDN. 1017078301

Dewan Penguji III

Samsudin, S.Kom., M.Kom
NIDN. 1009098501

Tugas Akhir ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Sarjana Komputer

Dekan Fakultas Teknik dan Ilmu Komputer

Ka. Prodi Sistem Informasi

Dr. Bayu Rianto, S.SI., M.Kom
NIPY. 1691 09 321

Fitri Yunita, S.SI., M.Kom
NIPY. 1590 10 293

1

SURAT PERNYATAAN
PERNYATAAN

Yang bertanda tangan dibawah ini :

Nama Mahasiswa : **FANISHA JULIANANDA PUTRI**
NIM : 403221010046
Program Studi : Sistem Informasi

Menyatakan bahwa skripsi sbb:

Judul bahasa Indonesia :

OPTIMASI MODEL HYBRID CNN-SVM UNTUK KLASIFIKASI KEMATANGAN
BUAH NANAS

Judul bahasa Inggris :

*OPTIMIZATION OF A HYBRID CNN AND SVM MODEL FOR PINEAPPLE RIPENESS
CLASSIFICATION*

Pembimbing Utama : Muh. Rasyid Ridha, S.SI.,M.Kom

Pembimbing Pendamping : Fitri Yunita, S.SI.,M.Kom

1. Laporan Tugas Akhir ini adalah benar-benar ASLI dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas Islam Indragiri maupun di perguruan tinggi lainnya;
2. Laporan Tugas Akhir ini merupakan gagasan, rumusan dan pemikiran SAYA sendiri, tanpa bantuan pihak lain kecuali arahan Tim Dosen Pembimbing;
3. Dalam laporan Tugas Akhir ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada laporan ini;
4. Perangkat lunak yang digunakan dalam Tugas Akhir ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas Islam Indragiri;
5. Pernyataan ini SAYA buat dengan sesungguhnya apabila di kemudian hari terdapat penyimpangan dan ketidak benaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku diperguruan tinggi.

Tembilahan, 21 Juli 2026

Yang Menyatakan,

Materai
Rp.10.000

FANISHA JULIANANDA PUTRI

84

1

1

KATA PENGANTAR

Puji syukur ke hadirat Allah SWT atas rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan proposal penelitian berjudul “Optimasi Model *Hybrid* CNN–SVM untuk Klasifikasi Kematangan Buah Nanas” sebagai salah satu syarat pelaksanaan skripsi pada Program Studi Teknik Informatika, Fakultas Teknik dan Komputer, Universitas Islam Indragiri. Penulis mengucapkan terima kasih kepada:

1. Bapak Dr. H Najamuddin, Lc, MA Selaku Rektor Universitas Islam Indragiri.
2. Dr.Bayu Riyanto,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 dan Dosen Pembimbng Pendamping yang telah membantu mengarahkan didalam penuisan tugas akhir ini.
4. Bapak Muh. Rasyid Ridha, S.SI.,M.Kom Selaku Pembimbing utama yang telah meluangkan waktu dengan memberikan saran, masukan serta bimbingan selama penyusunan tugas akhir ini.
5. 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.
6. Keluarga tercinta terutama kedua orang tua, yang selalu memberikan doa, motivasi, dan dukungan moril maupun materil kepada penulis,sehingga dapat menyelesaikan tugas akhir ni dengan tepat waktu.

14 Penulis berharap proposal ini dapat memberikan manfaat dalam pengembangan ilmukhususnya di bidang pengolahan citra dan kecerdasan buatan.

27 Kritik dan saran sangat diharapkan demi kesempurnaan penelitian selanjutnya. Akhir kata, semoga Allah SWT senantiasa memberikan keberkahan dan kelancaran dalam penelitian ini. Aamiin.

Tembilahan, 21 juli 2026

FANISHA JULIANANDA PUTRI

NIM.40322101046

1

DAFTAR ISI

PERSETUJUAN	ii
PENGESAHAN	iii
PERNYATAAN	iv
KATA PENGANTAR.....	v
DAFTAR ISI	vii
DAFTAR TABEL	viii
DAFTAR GAMBAR	ix
INTISARI.....	x
BAB I PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	3
1.3 Tujuan Penelitian	3
1.4 Batasan Penelitian	4
1.5 Manfaat Penelitian	4
1.6 Sistematis Penulisan.....	5
BAB II TINJAUAN LITERATUR	8
2.1 Convolutional Neural Networks (CNN).....	8
2.2 Support Vector Machine (SVM).....	9
2.3 Model <i>Hybrid</i> CNN-SVM.....	10
BAB III METODE PENELITIAN	28
3.1 Kerangka Penelitian	28
BAB IV HASIL DAN PEMBAHASAN	38
4.1 Hasil Penelitian	38
4.1.1 Pengumpulan Dataset	38
4.1.2 Preprocessing Data dan Augmentasi Data	42
4.1.3 Pengembangan Model <i>Hybrid</i> CNN-SVM.....	46
4.2 Pembahasan	58
4.2.1 Ablasi Study.....	58
4.2.2 Uji Perbandingan Model	60
BAB V KESIMPULAN DAN SARAN	64
DAFTAR PUSTAKA.....	66

148

35

21

DAFTAR TABEL

Tabel 2. 1 Optimasi Model Pada Berbagai Penelitian	11
Tabel 2. 2 Penggunaan Model Hybrid CNN berbagai Objek Penelitian	14
Tabel 2. 3 Penggunaan Model Hybrid CNN-SVM berbagai penelitian.....	16
Tabel 2. 4 Penelitian objek buah nanas dengan berbagai metode	18
Tabel 2. 5 Akurasi Peneliti Objek Buah Nanas dengan Berbagai Metode	20
Tabel 2. 6 Akurasi Penggunaan Model Hybrid CNN-SVM dari Berbagai Penelitian	23
Tabel 2. 7 Dataset Peneltian Objek Buah Nanas dari Berbagai Penelitian	23
Tabel 2. 8 Tabel Posisi Penelitian yang dilakukan	26
Tabel 3. 1 Aspek penilaian tingkat kematangan buah Nanas.....	30
Tabel 3. 2 Range Tingkat Keasaman pada Buah Nanas.....	33

27

DAFTAR GAMBAR

Gambar 2. 1 Arsitektur metode Convolutional Neural Network(CNN)	9
Gambar 2. 2 Arsitektur Model Super Vector Machine (SVM)	10
Gambar 3. 1 Kerangka Penelitian.....	28
Gambar 3. 2 Posisi model hybrid yang dilakukan (Hybrid CNN-SVM).....	35
Gambar 4. 1 Pengembangan Model hybrid CNN-SVM	46
Gambar 4. 2 Grafik Akurasi dan Loss	51
Gambar 4. 3 Confusion Matrix	53
Gambar 4. 4 Kurva ROC dan Nilai AUC	55
Gambar 4. 5 Prediksi Kematangan Model	57

147

199

122

INTISARI

Penentuan tingkat kematangan buah nanas masih banyak dilakukan secara manual berdasarkan pengamatan warna dan kondisi fisik buah, sehingga hasil yang diperoleh sering bersifat subjektif dan kurang konsisten. Penelitian ini bertujuan untuk mengembangkan model hybrid Convolutional Neural Network (CNN) dan Support Vector Machine (SVM) dalam mengklasifikasikan tingkat kematangan buah nanas berdasarkan citra digital. Dataset yang digunakan terdiri dari lima kelas kematangan, yaitu mentah, mengkal, setengah matang, matang, dan busuk. Tahapan penelitian meliputi pengumpulan dataset, preprocessing, augmentasi data, pengembangan model CNN sebagai ekstraktor fitur, serta SVM sebagai classifier. Hasil pengujian menunjukkan bahwa model hybrid CNN-SVM mampu mengenali dan mengklasifikasikan tingkat kematangan buah nanas dengan performa yang baik berdasarkan metrik accuracy, precision, recall, dan F1-score. Penelitian ini memberikan implikasi berupa sistem klasifikasi yang lebih objektif, cepat, dan efisien dibandingkan metode manual. Dengan demikian, model hybrid CNN-SVM dapat menjadi solusi yang efektif dalam membantu proses sortasi dan penentuan kualitas buah nanas.

Kata Kunci: CNN, SVM, Klasifikasi Citra, Kematangan Nanas, Hybrid CNN-SVM.

ABSTRAC

Determining the maturity level of pineapples is still commonly performed manually based on visual observation of fruit color and physical characteristics, resulting in subjective and inconsistent outcomes. This study aims to develop a hybrid Convolutional Neural Network (CNN) and Support Vector Machine (SVM) model for classifying pineapple maturity levels using digital images. The dataset consists of five maturity classes, namely unripe, pre-ripe, half-ripe, ripe, and overripe. The research stages include dataset collection, preprocessing, data augmentation, CNN model development as a feature extractor, and SVM implementation as a classifier. The experimental results show that the hybrid CNN-SVM model is capable of recognizing and classifying pineapple maturity levels with good performance based on accuracy, precision, recall, and F1-score metrics. The findings provide practical implications in the form of a more objective, faster, and efficient classification system compared to conventional manual methods. Therefore, the hybrid CNN-SVM model can serve as an effective solution for supporting pineapple sorting and quality assessment processes.

Keywords: CNN, SVM, Image Classification, Pineapple Maturity, Hybrid CNN-SVM.

95

BAB I

PENDAHULUAN

1.1 Latar Belakang

Buah nanas merupakan salah satu komoditas tropis unggulan yang banyak dibudidayakan di Kabupaten Indragiri Hilir. Kualitas dan tingkat kematangan nanas sangat menentukan nilai jual, rasa, serta daya tahan saat distribusi. Namun, proses penentuan kematangan buah nanas di lapangan masih banyak dilakukan secara manual berdasarkan pengamatan warna kulit, bentuk, dan aroma. Cara ini bersifat subjektif dan sangat bergantung pada pengalaman petani, sehingga menghasilkan ketidakkonsistenan dalam klasifikasi kematangan[1].

Metode manual tersebut juga tidak efisien untuk penanganan jumlah buah yang besar dan dapat menurunkan akurasi sortasi. Penelitian sebelumnya menunjukkan bahwa ketidaktepatan dalam menentukan kematangan buah dapat menyebabkan kesalahan sortasi hingga lebih dari 20 % [2]. Hal ini menunjukkan perlunya sistem otomatis berbasis teknologi pengolahan citra untuk membantu proses klasifikasi kematangan secara lebih objektif dan konsisten.

Perkembangan teknologi computer vision dan machine learning telah memungkinkan penerapan metode otomatis untuk mengenali pola visual dari citra buah. Salah satu pendekatan yang paling banyak digunakan adalah Convolutional Neural Network (CNN), yang memiliki kemampuan kuat dalam mengekstraksi fitur warna, tekstur, dan bentuk dari citra tanpa perlu proses manual [3]. CNN telah digunakan secara luas pada berbagai penelitian klasifikasi buah, termasuk pada kasus kematangan tomat dan nanas, dengan tingkat akurasi yang tinggi. Misalnya, penelitian Liandaputra dan Zahra [3] melaporkan akurasi 93 % menggunakan

15

121

67

7

11

176

193

216

MobileNetV2 untuk klasifikasi tingkat kematangan nanas. Namun, model CNN murni sering kali menghasilkan overfitting pada dataset terbatas dan mengalami penurunan akurasi pada tahap klasifikasi akhir. Di sisi lain, algoritma Support Vector Machine (SVM) dikenal memiliki kemampuan yang baik dalam memisahkan kelas dengan margin maksimum dan bekerja efektif pada ruang fitur berdimensi tinggi [4]. Penelitian Sutisna dan Chairulloh [4] menunjukkan bahwa SVM mampu mengklasifikasikan kematangan nanas berdasarkan fitur tekstur dengan akurasi mencapai 86 %, meskipun masih bergantung pada metode ekstraksi manual.

Sejumlah penelitian terbaru mencoba menggabungkan kekuatan CNN dan SVM untuk meningkatkan performa klasifikasi. Pendekatan hybrid ini memanfaatkan CNN untuk ekstraksi fitur otomatis, sementara SVM digunakan sebagai pengklasifikasi akhir yang lebih stabil [5]. Studi oleh Hermana et al. [5] menunjukkan bahwa kombinasi CNN–SVM dapat meningkatkan akurasi 5–10 % dibandingkan CNN tunggal. Meskipun demikian, penerapan dan optimasi model hybrid ini khusus untuk buah nanas masih jarang dilakukan dan belum dibahas secara mendalam.

Meskipun berbagai penelitian telah dilakukan dalam klasifikasi kematangan buah nanas, sebagian besar masih memiliki keterbatasan pada jumlah kelaskematangan yang digunakan, ukuran dataset yang relatif kecil, serta belum optimalnya kombinasi metode dalam meningkatkan akurasi klasifikasi. Selain itu, penerapan model hybrid CNN–SVM pada objek buah nanas dengan jumlah kelas yang lebih rinci masih jarang dilakukan. Oleh karena itu, diperlukan penelitian yang tidak hanya menggabungkan keunggulan CNN dan SVM, tetapi juga melakukan

optimasi parameter serta menggunakan dataset yang lebih besar dan representatif untuk meningkatkan akurasi dan stabilitas klasifikasi tingkat kematangan buah nanas. Oleh karena itu, penelitian ini berfokus pada “optimasi model hybrid CNN dan SVM untuk klasifikasi tingkat kematangan buah nanas”. Optimasi dilakukan dengan menyesuaikan parameter arsitektur CNN (lapisan konvolusi, ukuran kernel, fungsi aktivasi) serta fungsi kernel SVM untuk mendapatkan kombinasi paling akurat. Hasil penelitian diharapkan dapat membantu petani, pengepul, dan pelaku industri pertanian dalam menentukan waktu panen dan standarisasi mutu buah secara objektif dan efisien.

1.2 Rumusan Masalah

Berdasarkan latar belakang di atas, adapun rumusan masalah nya adalah:

1. Mengembangkan model *hybrid* CNN untuk mengklasifikasikan tingkat kematangan buah nanas berdasarkan citra digital.
2. Meningkatkan parameter arsitektur CNN dan kernel SVM untuk memperoleh akurasi tertinggi dalam mengenali lima kategori kematangan nanas, yaitu mentah,,mengkal, setengah matang, matang,dan busuk.
3. Mengevaluasi model hybrid CNN–SVM untuk mengklasifikasikaTingkat kematangan buah nanas erdasarkan cita digital.

1.3 Tujuan Penelitian

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

1. Merancang dan mengembangkan model *hybrid* CNN–SVM yang mampu mendeteksi dan mengklasifikasikan tingkat kematangan buah nanas berdasarkan citra digital secara otomatis.
2. Melakukan optimasi parameter arsitektur CNN dan kernel SVM untuk

memperoleh kombinasi terbaik yang menghasilkan akurasi tertinggi dalam mengenali empat kategori kematangan buah nanas, yaitu mentah, setengah matang, matang, dan busuk.

3. Melakukan evaluasi model *hybrid CNN-SVM* dalam mengklasifikasikan tingkat kematangan buah nanas berdasarkan citra digital untuk mengetahui tingkat keakuratan classifier yang sesuai.

1.4 Batasan Penelitian

Adapun batasan masalah dalam penelitian ini adalah, sebagai berikut:

1. Objek penelitian adalah buah nanas yang diklasifikasikan berdasarkan tingkat kematangan kulit buah.
2. Kelas kematangan dibatasi menjadi empat kategori, yaitu: mentah, setengah matang, matang, dan busuk.
3. Model yang dikembangkan merupakan gabungan antara CNN dan SVM, di mana CNN digunakan untuk ekstraksi fitur citra dan SVM sebagai pengklasifikasi akhir.
4. Data yang digunakan berupa citra digital buah nanas yang diambil
5. menggunakan kamera smartphone dengan pencahayaan alami.
6. Implementasi hasil penelitian diwujudkan dalam aplikasi Android yang mampu mengenali tingkat kematangan buah nanas melalui foto.

1.5 Manfaat Penelitian

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

1. Penelitian ini memperluas kajian di bidang kecerdasan buatan dan pengolahan citra digital, khususnya dalam Model Hybrid CNN-SVM.
2. Melalui proses optimasi parameter CNN dan kernel SVM, penelitian ini

46

menghasilkan model yang mampu mengenali tingkat kematangan buah nanas dengan akurasi lebih tinggi. Hal ini membantu mengurangi kesalahan penilaian manual dan meningkatkan efisiensi dalam penentuan kualitas buah.

3. Implementasi model hybrid CNN-SVM ke dalam aplikasi mobile/web memberikan solusi praktis bagi petani, pengepul, dan pelaku usaha buah untuk mendeteksi tingkat kematangan nanas secara cepat, objektif.

1

1.6 Sistematis 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

35

Bab ini berisi uraian mengenai latar belakang penelitian, rumusan masalah, tujuan penelitian, manfaat penelitian, batasan masalah, serta sistematika penulisan. Bab ini menjelaskan alasan dilakukannya penelitian dan arah pengembangannya.

BAB II TIJAUAN LITERATUR

45

Bab ini berisi teori-teori dari penelitian berbagai buku, jurnal, dan terbitan-terbitan lain yang berkaitan dengan topik penelitian, untuk menghasilkan satu tulisan berkenaan dengan satu topik atau isu tertentu. Pada bab ini akan menguraikan studi-studi literatur yang berkaitan dengan topik penelitian.

27

BAB III METODOLOGI PENELITIAN

Bab ini mencakup jenis dan pendekatan penelitian, metode yang digunakan, alur penelitian, data yang digunakan, tahapan pelaksanaan penelitian, serta teknik evaluasi kinerja model. Selain itu, pada bagian akhir dijelaskan pula proses implementasi model hasil penelitian ke dalam aplikasi berbasis mobile/web sebagai bentuk penerapan sistem yang diusulkan.

BAB IV HASIL DAN PEMBAHASAN

Bab ini berisi hasil penelitian dan pembahasan mengenai pengembangan model *Hybrid CNN-SVM* untuk klasifikasi tingkat kematangan buah nanas. Pembahasan dimulai dari hasil pengumpulan dataset, proses *preprocessing* dan augmentasi data, pengembangan model, serta evaluasi performa model. Evaluasi dilakukan menggunakan beberapa metrik, seperti *accuracy*, *precision*, *recall*, *F1-score*, *confusion matrix*, dan kurva ROC-AUC. Selain itu, bab ini juga membahas hasil perbandingan model *Hybrid CNN-SVM* dengan model lain, seperti CNN murni, SVM, KNN, dan Random Forest, untuk mengetahui model yang memiliki performa terbaik.

BAB V KESIMPULAN DAN SARAN

Bab ini berisi kesimpulan dari hasil penelitian yang telah dilakukan berdasarkan tujuan penelitian dan hasil pengujian model. Kesimpulan menjelaskan tingkat keberhasilan model *Hybrid CNN-SVM* dalam mengklasifikasikan kematangan buah nanas serta performa model berdasarkan hasil evaluasi. Selain itu, bab ini juga memuat saran untuk pengembangan penelitian selanjutnya, seperti penambahan jumlah dataset, peningkatan variasi citra, atau peningkatan agar model lebih baik

1

BAB II

TINJAUAN LITERATUR

Bab ini menguraikan teori-teori, konsep dasar, dan hasil penelitian terdahulu yang relevan dengan pengembangan model hybrid CNN–SVM untuk klasifikasi tingkat kematangan buah nanas. Tinjauan literatur ini bertujuan untuk memberikan landasan ilmiah serta memperlihatkan posisi penelitian ini di antara penelitian sebelumnya.

46

3

2.1 Convolutional Neural Networks (CNN)

Convolutional Neural Network (CNN) merupakan salah satu model deep learning yang paling banyak digunakan dalam pengolahan citra karena kemampuannya mengekstraksi fitur visual secara otomatis melalui lapisan konvolusi dan pooling. CNN bekerja dengan mengenali pola penting pada gambar seperti bentuk, warna, tepi, dan tekstur sehingga model mampu melakukan klasifikasi secara lebih akurat. Berbagai penelitian telah menunjukkan bahwa performa CNN dapat meningkat secara signifikan melalui proses optimasi. Sebagai contoh, penggunaan optimizer ADAM pada CNN terbukti mampu meningkatkan akurasi hingga 98,50% dalam klasifikasi citra daging sapi setelah dilakukan penyesuaian terhadap parameter learning rate[6]


13

12

Selain itu, sejumlah penelitian mengembangkan bentuk arsitektur CNN baru yang dirancang untuk meningkatkan performa pada objek citra tertentu. Misalnya, modifikasi struktur CNN pada penelitian FD-CNN menunjukkan bahwa model dapat meningkatkan ketajaman ekstraksi fitur pada citra daun herbal sehingga menghasilkan klasifikasi yang lebih akurat [7] CNN juga diterapkan secara luas pada berbagai bidang seperti kesehatan, pertanian, dan identifikasi objek. Bahkan

210

integrasi CNN dengan jaringan berurutan seperti RNN telah digunakan untuk pendeteksian COVID-19, di mana CNN mengekstraksi fitur visual sebelum diproses oleh RNN [8]. Dengan kemampuannya mempelajari representasi yang kompleks, CNN menjadi metode yang sangat unggul dalam klasifikasi citra termasuk dalam analisis kematangan buah, yang memiliki variasi warna dan tekstur cukup signifikan.



Gambar 2. 1 Arsitektur metode Convolutional Neutral Network(CNN)

3


2.2 Support Vector Machine (SVM)

Support Vector Machine (SVM) adalah algoritma klasifikasi yang bekerja dengan mencari *hyperplane* yang memisahkan kelas data secara optimal melalui margin yang paling lebar. Menurut Huang (2023), SVM memiliki “kemampuan klasifikasi non-linear yang kuat dan robust terhadap data yang bising”, terutama ketika menggunakan kernel seperti Radial Basis Function (RBF) untuk memetakan data ke ruang dimensi lebih tinggi[9]. Pada penelitian tersebut SVM dikombinasikan dengan PCA untuk mengurangi dimensi fitur da mampu mencapai akurasi 90%

91

pada klasifikasi citra buah, menunjukkan bahwa SVM bekerja optimal ketika fitur yang digunakan lebih sederhana dan informatif.

Selain itu, penelitian Sutisna et al. (2024) menunjukkan bahwa performa SVM sangat bergantung pada fitur yang dipilih, di mana penggunaan metode seleksi fitur RFE meningkatkan akurasi klasifikasi tanaman rimpang hingga 81% [10]. Berbagai studi lain juga menunjukkan bahwa SVM sering digunakan dalam kombinasi dengan model ekstraksi fitur seperti CNN untuk meningkatkan akurasi. Misalnya, penelitian terkait optimasi model *hybrid* CNN–SVM pada objek buah tertentu berhasil mencapai akurasi hingga 99,12%, menunjukkan bahwa SVM sangat efektif sebagai classifier akhir pada data visual berdimensi tinggi [11].



Gambar 2. 2 Arsitektur Model Support Vector Machine (SVM)

2.3 Model *Hybrid* CNN-SVM

Penelitian ini menggunakan kombinasi Convolutional Neural Network (CNN) dan Support Vector Machine (SVM) karena kedua metode memiliki keunggulan yang saling melengkapi dalam klasifikasi citra. CNN berfungsi mengekstraksi fitur visual secara otomatis, seperti warna, tekstur, dan bentuk objek, sedangkan SVM digunakan sebagai classifier karena mampu membentuk

hyperplane optimal (*maximum margin*) sehingga dapat memisahkan kelas dengan karakteristik visual yang berdekatan secara lebih baik. Kombinasi CNN sebagai *feature extractor* dan SVM sebagai *classifier* diharapkan menghasilkan model yang lebih stabil serta memiliki kemampuan generalisasi yang lebih baik dibandingkan penggunaan CNN dengan lapisan Softmax saja.

Hal tersebut didukung oleh penelitian [25] yang menunjukkan bahwa model Hybrid CNN-SVM mampu memberikan performa klasifikasi yang baik pada citra buah, dengan CNN sebagai pengekstraksi fitur dan SVM sebagai algoritma klasifikasi akhir. Berdasarkan penelitian tersebut, penggunaan Hybrid CNN-SVM pada penelitian ini tidak hanya bertujuan memperoleh akurasi yang tinggi, tetapi juga memanfaatkan peran masing-masing algoritma yang saling melengkapi dalam mengklasifikasikan lima tingkat kematangan buah nanas. Beberapa penelitian sebelumnya juga telah melakukan optimasi berbagai model pembelajaran mesin dan *deep learning* untuk meningkatkan performa klasifikasi melalui penyesuaian parameter maupun penggunaan algoritma tertentu [26]. Ringkasan penelitian terkait optimasi model disajikan pada tabel berikut.

Tabel 2. 1 Optimasi Model Pada Berbagai Penelitian

Model Utama	Metode Optimasi	Parameter	Akurasi	Objek	Ref.
CNN	ADAM	<i>Learning rate</i>	98,50%	Daging sapi	[6]
SVM	RFE	Fitur	81,00%	Tanaman rimpang	[10]
SVM	<i>Metaheuristic & Statistical Techniques</i>	Regularisasi, <i>gamma</i>	91,69%	Tutupan lahan	[12]
Hybrid CNN-SVM	GA & NSGA-II	Filter CNN, kernel SVM	99,12%	Buah	[9]

SVM	<i>Grid Search</i>	Kernel, <i>cost</i> , <i>gamma</i>	98,00%	Buah kopi	[13]
KNN	<i>Backward Elimination</i>	Fitur	97,60%	Penyakit diabetes	[11]

Tabel 2.1 menampilkan berbagai penelitian yang berfokus pada optimasi model pembelajaran mesin dan deep learning dalam meningkatkan akurasi klasifikasi citra. Berdasarkan tabel tersebut, terlihat bahwa setiap metode optimasi berkontribusi secara signifikan terhadap peningkatan performa model. Misalnya, penggunaan algoritma ADAM pada model CNN terbukti mampu menghasilkan akurasi yang sangat tinggi, yaitu 98,50% pada objek daging sapi, menunjukkan bahwa optimasi parameter seperti *learning rate* berpengaruh besar terhadap stabilitas proses pelatihan jaringan saraf konvolusional [6].

Sementara itu, penelitian lainnya menunjukkan bahwa Support Vector Machine (SVM) juga sangat bergantung pada pemilihan fitur dan parameter regulasi. Metode seperti Recursive Feature Elimination (RFE) digunakan untuk memilih fitur yang paling relevan sehingga meningkatkan akurasi menjadi 81% pada objek tanaman rimpang [10]. Temuan tersebut diperkuat oleh penelitian yang menerapkan teknik metaheuristik dan statistik pada SVM, yang berhasil mengoptimalkan parameter regularization dan gamma sehingga mencapai akurasi 91,69% dalam klasifikasi tutupan lahan [12].

Model *hybrid* CNN–SVM menjadi salah satu pendekatan paling menjanjikan dalam tabel ini. Penelitian yang menggabungkan Genetic Algorithm (GA) dan NSGA-II untuk mengoptimalkan filter CNN dan kernel SVM berhasil melaporkan akurasi mencapai 99,12% pada objek buah, yang merupakan nilai tertinggi pada tabel [9]. Hasil ini menunjukkan bahwa

67 optimasi berbasis algoritma evolusioner sangat efektif dalam meningkatkan
kinerja model *hybrid* pada data citra kompleks. Selain itu, metode optimasi
berbasis grid search pada SVM juga menunjukkan hasil yang baik pada
202 klasifikasi buah kopi, dengan akurasi mencapai 98% [13]. Tidak hanya pada
SVM atau CNN, pendekatan optimasi fitur juga efektif diterapkan pada
algoritma lain seperti K-Nearest Neighbor (KNN). Penelitian yang
menggunakan metode Backward Elimination pada KNN menunjukkan
peningkatan akurasi menjadi 97,60% dalam klasifikasi penyakit diabetes [11].
5 Hal ini menegaskan bahwa pemilihan fitur yang tepat memainkan peran penting
dalam kinerja berbagai algoritma klasifikasi.

5 Dengan melihat tingginya efektivitas berbagai metode optimasi pada
Tabel 2.1, dapat disimpulkan bahwa peningkatan performa model sangat
dipengaruhi oleh pemilihan strategi optimasi yang tepat. Namun, selain
optimasi parameter, perkembangan model berbasis *deep learning* juga
menunjukkan arah baru dalam meningkatkan kualitas klasifikasi citra,
43 khususnya melalui pendekatan *hybrid*. Oleh karena itu, untuk memberikan
gambaran yang lebih komprehensif mengenai evolusi model CNN dalam
berbagai penelitian, 8 Seiring dengan meningkatnya kebutuhan akan metode
klasifikasi citra yang lebih akurat dan efisien, berbagai penelitian mulai
mengembangkan model berbasis CNN yang dikombinasikan dengan algoritma
lain untuk membentuk arsitektur *hybrid*. Pendekatan ini muncul dari
keterbatasan CNN yang meskipun unggul dalam ekstraksi fitur visual, namun
masih membutuhkan *csflassifier* yang lebih kuat untuk meningkatkan ketepatan
keputusan akhir. Oleh karena itu, integrasi CNN dengan berbagai

algoritma seperti SVM, RNN, maupun LSTM menjadi tren baru dalam penelitian klasifikasi citra modern.

Tabel 2.2 berikut menyajikan beberapa contoh penerapan model hybrid CNN pada berbagai objek penelitian, yang menunjukkan bagaimana kombinasi metode ini dapat meningkatkan akurasi, stabilitas, dan performa keseluruhan sistem klasifikasi. Penerapan model hybrid ini membuktikan bahwa penggabungan kemampuan ekstraksi fitur CNN dengan kemampuan pengklasifikasian model lain dapat menghasilkan kinerja yang lebih unggul dibandingkan penggunaan metode tunggal.

Tabel 2. 2 Penggunaan Model Hybrid CNN berbagai Objek Penelitian

Model Hybrid	Tujuan	Objek	No Ref
FD-CNN	Meningkatkan akurasi klasifikasi	Daun herbal	[7]
CNN- SVM	mMeningkatkan akurasi klasifikasi	gulma(weed)	[14]
CNN- RNN	Implementasi deep learning	COVID-19	[8]
Hybrid CNN- LSTM	Deteksi	NSL-KDD, KDDCup99, CIC- IDS2018, ISCX2012	[15]

Dari hasil yang ditampilkan pada Tabel 2.2, terlihat bahwa penerapan model hybrid CNN pada berbagai objek penelitian memberikan kontribusi signifikan dalam peningkatan performa klasifikasi. Penelitian mengenai FD-CNN menunjukkan bahwa modifikasi struktur CNN mampu meningkatkan akurasi identifikasi daun herbal secara substansial, terutama karena fitur-fitur penting dapat diekstraksi dengan lebih tajam dibandingkan metode konvensional[7]. Hal ini menandakan bahwa pengembangan arsitektur CNN

terus berevolusi untuk menyesuaikan kebutuhan analisis citra yang semakin kompleks.

Pada penelitian lain, integrasi CNN–SVM terbukti memberikan performa yang lebih optimal untuk klasifikasi objek seperti gulma. CNN digunakan sebagai pengambil fitur visual mendalam, sementara SVM mengoptimalkan proses pengambilan keputusan melalui margin klasifikasi yang lebih stabil [14]. Kombinasi ini menunjukkan bahwa menggabungkan kekuatan ekstraksi fitur CNN dengan efisiensi pengklasifikasian SVM dapat menghasilkan sistem klasifikasi yang lebih akurat dan robust pada data dengan tekstur tidak teratur.

Sementara itu, model *hybrid* CNN–RNN banyak dimanfaatkan pada bidang medis, seperti pendeteksian COVID-19. CNN bekerja mengekstraksi pola visual dari citra medis, sedangkan RNN mengolah hubungan temporal atau pola berurutan yang muncul dalam data, sehingga memberikan hasil klasifikasi yang lebih akurat dan sensitif terhadap variasi data [8]. Studi ini menegaskan peran penting metode *hybrid* dalam domain diagnosis penyakit yang membutuhkan analisis citra tingkat lanjut.

Model *hybrid* CNN–LSTM juga memiliki peran strategis dalam penelitian berbasis data sekuensial, khususnya pada sistem deteksi serangan siber. CNN memproses fitur spasial dari data trafik jaringan, sementara LSTM mampu menangkap pola temporal yang berkesinambungan sehingga meningkatkan akurasi dalam deteksi berbagai jenis serangan [15]. Hasil penelitian tersebut menunjukkan bahwa penggabungan metode ini sangat efektif untuk aplikasi yang membutuhkan analisis dinamis dalam data berurutan.

Secara keseluruhan, penelitian-penelitian pada Tabel 2.2 memperlihatkan bahwa model *hybrid* CNN merupakan solusi yang adaptif dan efisien untuk permasalahan klasifikasi citra pada berbagai domain. Kombinasi CNN dengan teknik lain terbukti memperluas kemampuan model dalam memahami variasi data yang kompleks, sekaligus meningkatkan performa sistem secara keseluruhan.

Melihat berbagai hasil penelitian pada Tabel 2.2, tampak bahwa pendekatan *hybrid* CNN memiliki potensi besar dalam meningkatkan performa sistem klasifikasi di berbagai domain, baik pada pengolahan citra medis, identifikasi objek, maupun deteksi pola sekuensial yang kompleks. Keunggulan ini terutama karena kemampuan CNN dalam menghasilkan representasi fitur visual yang kuat, yang kemudian dipadukan dengan algoritma lain untuk memperkuat proses pengambilan keputusan akhir.

Salah satu kombinasi yang paling menonjol dan banyak digunakan adalah *hybrid* CNN–SVM, yang mengintegrasikan keunggulan CNN dalam mengekstraksi fitur dengan stabilitas SVM dalam melakukan klasifikasi non-linear. Untuk memberikan gambaran lebih komprehensif mengenai efektivitas penerapan model ini, Tabel 2.3 berikut merangkum berbagai penelitian yang menggunakan *hybrid* CNN–SVM pada beragam objek dan konteks penelitian.

Tabel 2. 3 Penggunaan Model Hybrid CNN-SVM berbagai penelitian

Tujuan penelitian	Objek	Akurasi	No Ref
Klasifikasi	Lukisan	93,28%	[16]
Kalsifikasi	Penyakit Tumor	98.92%	[17]
Klasifikasi	Biji kako	98,32%	[18]
Prediksi	Tebu	89,53%	[19]

177 Berdasarkan hasil yang tersaji pada Tabel 2.3, terlihat bahwa pendekatan *hybrid* CNN–SVM terus menunjukkan performa unggul dalam berbagai bidang penerapan, khususnya pada klasifikasi citra dan analisis data semi-terstruktur. Penelitian pada klasifikasi biji kakao, misalnya, membuktikan bahwa penggunaan CNN sebagai *feature extractor* dan SVM sebagai *final classifier* menghasilkan akurasi yang lebih tinggi dibandingkan penggunaan CNN atau SVM secara tunggal [16]. Hal ini disebabkan oleh kemampuan CNN dalam mengekstraksi fitur citra yang lebih dalam dan representatif, sementara SVM memberikan batas keputusan yang lebih optimal pada ruang fitur berdimensi tinggi.

42 Selain itu, pada penelitian lain di bidang pertanian presisi, model *hybrid* CNN–SVM digunakan untuk memproses data pertanian semi-terstruktur dan memprediksi parameter lingkungan penting seperti kelembapan tanah. Dengan menggabungkan kekuatan CNN dalam analisis pola visual dan keandalan SVM dalam klasifikasi non-linear, penelitian tersebut berhasil meningkatkan akurasi prediksi hingga melampaui model-model sebelumnya [17]. Hasil ini menegaskan bahwa *hybrid* model tidak hanya relevan pada pengolahan citra, tetapi juga pada data sensor dan data berbasis waktu. Dalam bidang perkebunan, model *hybrid* juga dimanfaatkan untuk meningkatkan efektivitas klasifikasi hasil panen dan data agrikultur dengan memadukan CNN untuk identifikasi ciri-ciri visual serta SVM untuk klasifikasi. Hasil akhir studi-studi tersebut menunjukkan bahwa pendekatan *hybrid* mampu memberikan kinerja yang lebih stabil dalam kondisi data yang bervariasi dan tidak terstruktur [18]. Keunggulan ini menjadi alasan utama mengapa kombinasi CNN–SVM terus

Lebih lanjut, penelitian mengenai prakiraan produksi tanaman tebu juga mengonfirmasi efektivitas penggabungan CNN dan SVM. Dengan memanfaatkan CNN untuk mengekstraksi pola pada data pertanian dan SVM untuk memproses hasil ekstraksi tersebut, model *hybrid* terbukti menghasilkan tingkat akurasi yang lebih baik dibandingkan model prediksi konvensional lainnya [19]. Hal ini menunjukkan bahwa pendekatan *hybrid* mampu mengatasi keterbatasan model tunggal, terutama dalam mengolah data beragam dan kompleks.

Secara keseluruhan, temuan-temuan dalam Tabel 2.3 memperlihatkan bahwa model hybrid CNN–SVM menjadi solusi komputasi yang efisien dan adaptif pada beragam konteks penelitian. Kekuatan utamanya terletak pada kombinasi antara kemampuan CNN dalam membangun representasi fitur mendalam dan keandalan SVM dalam menghasilkan klasifikasi yang presisi. Hasil-hasil tersebut menjadi dasar kuat untuk melanjutkan pembahasan menuju model hybrid lainnya yang akan diuraikan pada tabel berikutnya.

Tabel 2. 4 Penelitian objek buah nanas dengan berbagai metode

Tujuan Penelitian	Metode	Akurasi	Kelas	No Ref
Mendeteksi	YOLOv2 berbasis CNN	99.27%	4	[20]
Klasifikasi	CNN	86%	2	[21]
Klasifikasi	deep learning berbasis CNN	86,75	4	[22]
Ekstrasi Fitur	RGB	86,05%	3	[23]
Klasifikasi	SVM	65,59%	3	[24]

Hasil perbandingan beberapa penelitian pada Tabel 2.4 menunjukkan bahwa pendekatan klasifikasi tingkat kematangan buah nanas terus

146

berkembang, baik melalui metode berbasis computer vision, machine learning, maupun deep learning. Setiap penelitian memiliki fokus dan kontribusi yang berbeda, mulai dari pengolahan citra sederhana hingga penerapan model berbasis jaringan saraf yang lebih kompleks.

Penelitian oleh Liandaputra dan Zahra [20] menunjukkan bahwa penggunaan arsitektur CNN modern seperti MobileNetV2 mampu mencapai akurasi tinggi hingga 93% untuk empat kelas kematangan buah nanas. Hal ini menegaskan bahwa model ringan (lightweight) berbasis transfer learning tetap efektif dalam lingkungan data terbatas, khususnya pada komoditas hortikultura. Pendekatan ini memperkuat bahwa fitur visual seperti warna dan tekstur kulit nanas dapat ditangkap secara optimal oleh jaringan dalam, dibandingkan proses manual yang sering tidak konsisten.

Sementara itu, Wang dan Chai [21] mengusulkan metode ekstraksi ciri berbasis warna menggunakan jalur diagonal untuk mengatasi distribusi warna nanas yang tidak merata. Metode ini menghasilkan akurasi hingga 86% untuk klasifikasi tiga kelas kematangan. Pendekatan berbasis warna ini masih relevan pada kondisi pencahayaan terkontrol dan memberikan efisiensi tinggi karena tidak memerlukan komputasi berat seperti model deep learning. Temuan ini menunjukkan bahwa metode berbasis RGB thresholding tetap kompetitif pada kasus tertentu, terutama ketika pemrosesan real-time menjadi prioritas.

191

Selain itu, penelitian Vernanda et al. [22] menerapkan metode Support Vector Machine (SVM) sebagai model klasifikasi berdasarkan nilai histogram citra. Dengan memanfaatkan parameter statistik seperti mean, variance, skewness, dan entropy, penelitian tersebut memperoleh akurasi sekitar 65,59%.

180

Meskipun lebih rendah dibandingkan pendekatan CNN, metode ini tetap memiliki keunggulan pada kompleksitas model yang lebih rendah dan implementasi yang lebih cepat, sehingga cocok digunakan untuk aplikasi sederhana atau perangkat terbatas.

Kemudian, studi lain menunjukkan keberagaman metodologi. Misalnya, pendekatan berbasis fuzzy logic ataupun model berbasis kombinasi beberapa fitur warna juga ditemukan efektif pada konteks tertentu. Hal ini tercermin pada penelitian-penelitian lanjutan dalam referensi [23] dan [24], yang menekankan pentingnya pemilihan fitur relevan serta preprocessing yang tepat untuk meningkatkan performa klasifikasi.

Tabel 2. 5 Akurasi Penilitia Objek Buah Nanas dengan Berbagai Metode

Metode	Tujuan	Kelas	Akurasi	R	S	P	f1-score	No Ref
YOLOv2 berbasis CNN	Klasifikasi	4	99.27%	99%	99%	99%	99%	[20]
deep learning berbasis CNN	Deteksi	4	90.49%	91%	91%	91%	91%	[22]
CNN	Klasifikasi	2	86%	86%	86%	86%	86%	[21]
RGB	Ekstraksi fitur	3	86,05%	90,3	93%	90,7	90%	[23]
SVM	Klasi fikasi	3	65.59%	66.25%	80%	65.99%	66.11%	[24]

Tabel 2.5 merangkum secara komprehensif berbagai metode klasifikasi kematangan nanas yang digunakan pada sejumlah penelitian, lengkap dengan tingkat akurasi, jenis fitur yang digunakan, serta jumlah kelas kematangan yang dianalisis. Pada penelitian pertama yang tercantum dalam tabel, Liandaputra dan Zahra [20] menerapkan arsitektur deep learning MobileNetV2 untuk mengidentifikasi empat kelas kematangan nanas. Model ini mencapai akurasi

yang sangat tinggi, yaitu 93%, karena memanfaatkan keunggulan transfer learning untuk mengekstraksi fitur warna dan tekstur kulit nanas secara mendalam. Tingginya akurasi tersebut membuktikan bahwa CNN modern sangat efektif untuk mendeteksi pola visual kompleks, sehingga cocok diterapkan pada citra buah yang bervariasi dalam tekstur dan warna.

Kemudian, penelitian yang dilakukan oleh Wang dan Chai [21] berfokus pada pengukuran proporsi piksel kuning dengan menerapkan enam garis diagonal pada citra buah. Penelitian ini menghasilkan akurasi 86%, yang didapat dari pengukuran langsung perubahan warna kulit nanas pada tiga kelas kematangan: unripe, ripe, dan fully ripe. Pendekatan ini sederhana namun efektif, terlebih pada citra yang memiliki keseragaman pencahayaan. Teknik ekstraksi warna berbasis RGB thresholding ini sesuai bagi aplikasi ringan atau real-time karena tidak memerlukan komputasi intensif seperti CNN.

Sementara itu, penelitian Vernanda et al. [22] memberikan pendekatan berbeda dengan memanfaatkan fitur statistik orde pertama dari histogram RGB, seperti mean, variance, skewness, kurtosis, dan entropy. Penelitian ini hanya mencapai akurasi 65,59%, tetapi hal tersebut sangat dipengaruhi oleh variasi pencahayaan, perbedaan permukaan buah, serta kompleksitas tekstur kulit nanas. Meskipun akurasinya lebih rendah, SVM tetap memiliki kelebihan dari sisi kestabilan klasifikasi dan kompleksitas komputasi yang rendah. Pendekatan ini cocok diterapkan jika sistem ditujukan untuk proses yang cepat dan tidak memerlukan model besar.

Adapun dalam penelitian lain yang disebutkan pada tabel, metode pemrosesan citra seperti segmentasi Otsu, pemisahan objek dengan hresholding,

atau pengambilan fitur struktural telah terbukti meningkatkan kualitas fitur sebelum tahap klasifikasi. Penelitian pada referensi [23] menegaskan bahwa segmentasi yang akurat dapat meminimalkan noise sehingga model klasifikasi menerima fitur yang lebih bersih. Hal ini penting karena kualitas fitur sangat berpengaruh terhadap hasil akhir akurasi model, terutama dalam citra yang diambil di lingkungan tidak terkontrol.

Sementara itu, penelitian pada [24] menunjukkan bahwa fitur statistik seperti entropi dan skewness memiliki hubungan yang kuat dengan perubahan tekstur kulit nanas selama pematangan. Fitur-fitur tersebut efektif untuk mendeskripsikan pola distribusi warna dan ketajaman tekstur pada kulit buah. Oleh karena itu, meskipun tidak menghasilkan akurasi setinggi CNN, metode statistik tetap relevan untuk aplikasi tertentu yang mengutamakan kecepatan, kesederhanaan, dan kemudahan implementasi.

Secara keseluruhan, Tabel 2.5 memperlihatkan bahwa metode CNN memberikan akurasi tertinggi, diikuti oleh pendekatan ekstraksi warna berbasis diagonal, sedangkan metode berbasis histogram dan SVM menghasilkan performa yang paling rendah namun tetap stabil. Dari hasil tersebut dapat disimpulkan bahwa pemilihan metode sangat bergantung pada kebutuhan sistem, seperti ketelitian yang diinginkan, jenis fitur yang tersedia, serta kemampuan komputasi perangkat yang digunakan. Kombinasi antara fitur visual yang tepat dan metode klasifikasi yang sesuai menjadi kunci dalam membangun model klasifikasi tingkat kematangan buah nanas yang efektif.

Tabel 2. 6 Akurasi Penggunaan Model Hybrid CNN-SVM dari Berbagai Penelitian

Objek	Akurasi	Recall	Specifity	Precision	f1-score	No Ref
Lukisan	93.28%	93%	93%	93%	93%	[16]
Tumor	98.92%	98.92%	98.92%	98.92%	98.92%	[17]
Biji kakoa	98.32 %	98.32 %	98.32 %	98.32 %	98.32 %	[18]
Tebu	86.97%	87%	87%	87%	87%	[19]

Dari hasil pada tabel dapat dilihat bahwa seluruh model hybrid CNN–SVM menunjukkan performa tinggi di berbagai objek penelitian. Akurasi tertinggi mencapai 98,92% pada klasifikasi tumor dengan metode ADAM, sedangkan model lain seperti RBF dan GPM juga menunjukkan hasil konsisten di atas 85%. Nilai precision, recall, dan F1-score yang seimbang menandakan stabilitas model dalam mengenali pola citra yang beragam. Ini memperkuat dasar teoritis penggunaan CNN–SVM dalam penelitian klasifikasi kematangan buah nanas. Keberagaman dataset juga memengaruhi hasil klasifikasi tingkat kematangan nanas. Penelitian terdahulu menggunakan jumlah dataset dan jumlah kelas yang berbeda, yang turut berpengaruh terhadap kompleksitas model dan akurasi yang dihasilkan. Rangkuman dataset yang digunakan disajikan pada tabel berikut.

Tabel 2. 7 Dataset Peneltian Objek Buah Nanas dari Berbagai Penelitian

Metode	Jumlah Dataset	Kelas	No Ref	
YOLOv2 berbasis CNN	8.852	4	[20]	
CNN	100	2	[21]	
mobilNetV2+GAP+dense layer	400	4	[22]	
RGB	86	3	[23]	
SVM	299	3	[24]	

136 Berdasarkan tabel, terlihat bahwa jumlah dataset yang besar seperti pada metode YOLOv2 dengan 8.852 citra menghasilkan akurasi tertinggi, yaitu 99,27% dengan empat kelas kematangan. Sebaliknya, jumlah dataset yang kecil seperti pada metode CNN dengan 100 citra menghasilkan akurasi yang relatif lebih rendah. Oleh karena itu, dalam penelitian ini jumlah dan variasi data menjadi pertimbangan penting untuk memastikan model hybrid CNN–SVM dapat belajar secara optimal terhadap ciri visual dari setiap tingkat kematangan buah nanas.

75 Berdasarkan hasil kajian penelitian terdahulu, dapat disimpulkan bahwa optimasi pada model deep learning, khususnya Convolutional Neural Network (CNN), berperan penting dalam meningkatkan akurasi klasifikasi citra. 81 Berbagai metode optimasi seperti ADAM, Grid Search, dan Genetic Algorithm (GA) telah terbukti mampu memperbaiki parameter model sehingga performanya meningkat signifikan. Model hybrid CNN–SVM menjadi pendekatan yang banyak digunakan karena menggabungkan keunggulan CNN dalam mengekstraksi fitur dan SVM dalam melakukan klasifikasi non-linear. 145 Berbagai penelitian menunjukkan bahwa model ini menghasilkan akurasi tinggi, bahkan mencapai lebih dari 99% pada objek citra buah, biji kakao, maupun penyakit. 154

Pada penelitian klasifikasi kematangan buah nanas, metode berbasis CNN mampu memberikan hasil akurasi tinggi hingga 86%, sedangkan SVM masih terbatas pada sekitar 65%. Hal ini menunjukkan bahwa penggabungan kedua metode dapat menjadi solusi untuk meningkatkan kestabilan dan akurasi klasifikasi tingkat kematangan nanas.

Selain itu, jumlah dataset berpengaruh besar terhadap hasil klasifikasi. Dataset yang besar dan beragam, seperti pada penelitian dengan metode YOLOv2, menghasilkan akurasi lebih tinggi dibanding dataset kecil. Oleh karena itu, penelitian ini menekankan pentingnya penggunaan data yang cukup dan representatif agar model hybrid CNN–SVM dapat bekerja secara optimal. Secara keseluruhan, hasil kajian literatur menunjukkan bahwa optimasi model hybrid CNN–SVM merupakan pendekatan yang relevan dan potensial untuk meningkatkan akurasi, stabilitas, serta efisiensi klasifikasi tingkat kematangan buah nanas.

Berdasarkan hasil kajian literatur yang telah disajikan pada Tabel 2.1 hingga Tabel 2.7, terlihat bahwa penelitian terkait klasifikasi kematangan buah nanas masih menghadapi beberapa keterbatasan, terutama dalam hal jumlah kelas yang digunakan, teknik ekstraksi fitur, serta ukuran dataset yang relatif kecil. Sebagian besar penelitian terdahulu hanya menggunakan 2–4 kelas kematangan, sementara model yang digunakan pun beragam, mulai dari metode berbasis warna, teknik statistik, SVM, hingga arsitektur CNN. Meskipun menunjukkan capaian yang cukup baik, metode-metode tersebut belum sepenuhnya mampu menangani variasi tekstur dan warna yang kompleks pada kulit nanas.

Untuk menggambarkan secara jelas posisi penelitian yang akan dilakukan dibandingkan penelitian sebelumnya, maka diperlukan sebuah tabel perbandingan yang menunjukkan perbedaan signifikan dari aspek metode, jumlah kelas kematangan, serta jumlah dataset yang digunakan. Tabel posisi penelitian ini berfungsi untuk mempertegas kontribusi dan kebaruan (novelty) penelitian yang

dikembangkan, yaitu penerapan model hybrid CNN–SVM dengan lima kelas kematangan serta dataset yang jauh lebih besar dibandingkan penelitian terdahulu. Dengan demikian, tabel berikut memberikan gambaran jelas mengenai celah penelitian yang berhasil dijawab melalui penelitian ini.

Tabel 2. 8 Tabel Posisi Penelitian yang dilakukan

Metode	Jumlah Kelas	Dataset	Objek	Akurasi	No ref
SVM	3	299 citra	Nanas	65.59%	[22]
Ekstraksi warna(RGB)	3	86 citra	Nanas	86.05%	[21]
CNN	4	1000 citra	Nanas	93%	[20]
Hybrid CNN-SVM	3	1500 citra	Lukisan	93.28%	[16]
Hybrid CNN-SVM	5	5000	Nanas	-	-

Berdasarkan perbandingan pada tabel 2.6 dapat dilihat bahwa setiap metode dalam penelitian terdahulu memiliki keunggulan sekaligus keterbatasan masing-masing. Metode SVM murni memang sederhana dan cepat, namun akurasi masih rendah karena fitur yang digunakan masih terbatas pada warna dan histogram. Pendekatan ekstraksi warna GB mampu menangkap perubahan warna kulit nanas, tetapi sangat dipengaruhi oleh kondisi pencahayaan dan kualitas gambar. Sementara CNN tunggal memberikan akurasi yang tinggi berkat kemampuannya mengekstraksi fitur yang lebih dalam, namun tetap memiliki keterbatasan dalam proses klasifikasi akhirnya.

Pada saat yang sama, penelitian hybrid CNN-SVM pada objek lain menunjukkan bahwa kombinasi metode ini mampu mengoptimalkan kedua peran, dimana CNN berfungsi sebagai feature extractor yang kuat, sedangkan

SVM memberika pemisahan kelas yang lebih tegas. Namun penelitian-penelitian tersebut umunya belum iterapkan pada sebuah nanas dan masih terbatas pada jumlah kelas yang sedikit dan dataset yang kecil

Melihat keseluruhan pola tersebut, keputusan untuk menggunakan Hybrid CNN–SVM dengan 5 kelas kematangan dan 5000 dataset pada penelitian ini adalah langkah yang sangat tepat dan memiliki landasan ilmiah yang kuat. Pendekatan ini secara langsung menjawab kekurangan penelitian sebelumnya, yaitu keterbatasan jumlah kelas, keterbatasan dataset, dan penggunaan metode tunggal yang tidak cukup merepresentasikan kompleksitas tekstur serta warna kulit nanas pada tiap tahap kematangan.

Oleh karena itu, pemilihan metode penelitian ini dapat dinyatakan sangat layak untuk dikembangkan, karena tidak hanya memperluas cakupan penelitian terdahulu, tetapi juga memberikan kontribusi baru dalam bentuk model klasifikasi tingkat kematangan nanas yang lebih rinci, lebih informatif, serta memiliki potensi kinerja yang lebih unggul pada dataset besar dan beragam


BAB III

METODE PENELITIAN

Bab ini menyajikan penjabaran secara rinci mengenai pendekatan yang digunakan dalam penelitian, mulai dari desain penelitian, tahapan pengumpulan dan pengolahan data, perancangan arsitektur model, hingga teknik evaluasi yang.

3.1 Kerangka Penelitian

Kerangka penelitian ini dirancang untuk menggambarkan alur sistematis dalam pengembangan aplikasi klasifikasi tingkat kematangan buah nanas menggunakan model Hybrid CNN-SVM



Gambar 3. 1 Kerangka Penelitian

Gambar 3.1 di atas merupakan kerangka penelitian yang akan menjelaskan mengenai tahapan-tahapan yang dilakukan dalam pengembangan model *Hybrid* CNN–SVM untuk klasifikasi kematangan buah nanas berdasarkan warna kulit.

1. Studi Literatur dan Analisis Pra Penelitian

a. Studi Literatur

Penelitian ini diawali dengan kegiatan studi literatur yang bertujuan untuk memahami berbagai konsep dasar, metode, serta penelitian-penelitian terdahulu yang berkaitan dengan klasifikasi citra, pengolahan citra buah, dan penerapan Convolutional Neural Network (CNN) maupun model *hybrid* pada domain pertanian. Studi literatur dilakukan dengan meninjau jurnal dan penelitian yang telah membahas proses deteksi, identifikasi, serta klasifikasi tingkat kematangan buah menggunakan teknik deep learning. Berdasarkan telaah literatur tersebut, ditemukan bahwa CNN merupakan metode yang paling banyak digunakan karena kemampuannya dalam mengekstraksi fitur visual secara otomatis dan akurat.

b. Analisis Pra Penelitian

Analisis Pra-Penelitian merupakan tahap penting untuk memastikan keberhasilan penelitian. Langkah pertama adalah identifikasi masalah, yaitu rendahnya tingkat akurasi dan konsistensi dalam mengenali tingkat kematangan buah nanas secara cepat dan tepat. Penentuan tingkat kematangan nanas secara manual oleh petani maupun pengepul sering kali bergantung pada pengalaman subjektif, sehingga menimbulkan kesalahan dalam pengambilan Keputusan, dan dapat berdampak pada penurunan kualitas produk, dan ketidaksamaan standar pasar.

Solusi yang ditawarkan dalam penelitian ini adalah membangun model klasifikasi tingkat kematangan nanas berbasis pendekatan *hybrid* CNN-SVM. Pada tahap awal CNN digunakan sebagai ekstraktor fitur otomatis dari citra

digital, sedangkan SVM berperan sebagai classifier untuk meningkatkan ketepatan keputusan. Pendekatan ini diambil karena CNN unggul dalam mengenali pola visual kompleks, sementara SVM dikenal memiliki performa tinggi dalam pemisahan kelas pada ruang fitur berdimensi tinggi.

2. Pengumpulan Dataset dan Augmentasi Data

a. Pengumpulan Dataset

Pada tahap ini, jenis data yang diperlukan adalah gambar buah Nanas yang telah terklasifikasikan kedalam beberapa kategori yaitu Unripe, Pre-ripe, Half-ripe, Fully-ripe, dan over ripe, yang mengikuti acuan ciri ciri kematangan berikut

Tabel 3. 1 Aspek penilaian tingkat kematangan buah Nanas

Aspek Pemeriksaan	Mentah	Mengkal	Setengah Matang	Matang	Busuk
Warna Kulit (Pangkal-Puncak)	Hijau seluruhnya	Hijau kekuningan ($\frac{1}{4}$ Bagian bawah mulai kuning)	Hijau dan Kuning ($\frac{1}{3}$ bawah)	Kuning ($\frac{2}{3}$ sampai seluruh buah)	Kuning gelap atau bercak coklat
Perbandingan warna (hijau:kuning)	100% hijau	$\pm 70\%$ hijau : 30% kuning	50% hijau : 50% kuning	$\pm 20\%$ hijau: 80% kuning	<10% hijau, bercak coklat muncul
Tekstur Kulit	Sangat keras	Masih keras tapi sedikit Lentur	Agak keras	Sedikit lunak saat ditekan	Lembek/b erlendir

Aroma Buah	Tidak beraroma	Hampir tidakada aroma, kadang samar di pangkal	Sedikit manis dipangkal	Manis kuat segar	Asam/fermentasi
Daun(Mahkota)	Hijau kaku	Hijaukaku tapi agak lentur di Ujung	Hijau segar	Agak entur mudah ditarik	Layu,berjamur
Mata (eyes)	Menonjol	Masih agak menonjol	Sedikit rata	Rata/cekungan	Rusak/busuk

Setelah diketahui beberapa kelas dan juga ciri ciri aspek yang akan diambil sampelnya,berikut contoh dalam sampel nanas yang disesuaikan pada kategori aspek kematangan buah nanas. Data dikumpulkan langsung dilapangan di beberapa tempat seperti pasar,pedagang nanas yang ada ditepi jalan,dan juga di beberapa kebun nanas.gambar diambil menggunakan handphone merk OPPO A60 dengan rasio kamera 1:1 diambil dari berbagai sudut buah,dan menghasilkan gambar sebanyak 5000 foto nanas



(a)



(b)



(c)



(d)



(e)

Keterangan: (a)Mentah,(b)Mengkal,(c)Setengah Matang,(d)Matang,(e)Busuk

Dalam penelitian ini, pembagian dataset citra buah nanas dilakukan melalui pendekatan stratified split, yaitu metode yang memastikan setiap kelas tingkat kematangan tetap memiliki proporsi yang seimbang pada seluruh subset data. Meskipun proses pemisahan ini didukung oleh teknik stratifikasi, monitoring manual tetap dilakukan untuk memastikan tidak terjadi ketidakseimbangan jumlah sampel antar kelas sehingga representasi data tetap terjaga. Dari total 5.000 sampel, dataset dibagi menjadi tiga bagian utama dengan persentase 70% untuk data training, 15% untuk data validasi, dan 15% untuk data testing. Skema ini dipilih untuk memberikan variasi data yang cukup pada tahap pelatihan sekaligus menyediakan data validasi dan testing yang independen guna mengevaluasi performa model hybrid CNN-SVM secara objektif.

Setelah sampel diambil,lalu saya juga melakukan pengukuran keasaman menggunakan alat digital PH meter,untuk menentukan kadar asam pada setiap tingkat kematangan buah nanas. Hasil yang didapat pada 5 tingkat kematangan buah nanas tersebut sebagai berikut.

Tabel 3. 2 Range Tingkat Keasaman pada Buah Nanas

Tingkat Kematangan	Range
Mentah	4.03 – 4.26 pH
Mengkal	4.09 – 4.48 pH
Setengah Matang	4.03 – 4.26 pH
Matang	4.37 – 4.49 pH
Busuk	4.25 – 4.15 pH

Pada buah nanas, perubahan nilai pH menunjukkan perubahan tingkat keasaman selama proses pematangan. Pada tahap awal (unripe), nilai pH relatif lebih rendah, yang menandakan buah masih lebih asam. Seiring bertambahnya tingkat kematangan menuju half-ripe dan fully ripe, nilai pH meningkat, sehingga tingkat keasaman menurun dan rasa buah menjadi lebih manis. Namun, pada tahap over ripe, nilai pH dapat kembali menurun, yang menunjukkan buah menjadi lebih asam kembali akibat proses fermentasi dan pembusukan.

b. Augmentasi Data

Augmentasi data pada penelitian ini difokuskan pada penerapan teknik rotasi dan pembalikan (flip) untuk menambah keragaman citra nanas pada setiap tingkat kematangan. Teknik rotasi digunakan untuk memutar citra nanas pada sudut tertentu, sehingga model mampu mengenali buah dalam berbagai orientasi yang mungkin terjadi saat pengambilan gambar

1. Teknik Rotasi(diputar 90°)

Rotasi adalah teknik augmentasi data yang dilakukan dengan memutar citra pada sudut 180°, sehingga posisi objek dalam gambar berubah. Tujuan rotasi

adalah agar model dapat mengenali objek meskipun orientasinya berbeda, sehingga meningkatkan kemampuan model dalam memahami variasi posisi objek.

2. Teknik Pembalikan (flip kiri-kanan)

Flip adalah teknik augmentasi yang dilakukan dengan membalik citra, baik secara horizontal (kiri ke kanan) maupun vertikal (atas ke bawah). Teknik ini bertujuan untuk menambah variasi data dan membuat model tidak bergantung pada arah tertentu dari objek dalam gambar.

3. Zoom Out

Zoom Out adalah teknik augmentasi yang dilakukan dengan memperkecil tampilan objek dalam citra sehingga terlihat lebih jauh. Tujuannya adalah agar model mampu mengenali objek dalam berbagai ukuran dan jarak, sehingga lebih adaptif terhadap kondisi nyata saat pengambilan gambar.

4. Darkness


Darkness adalah teknik augmentasi dengan mengurangi tingkat kecerahan citra sehingga gambar terlihat lebih gelap. Teknik ini digunakan untuk mensimulasikan kondisi pencahayaan rendah, sehingga model tetap dapat mengenali objek meskipun dalam kondisi cahaya minim.

5. Brightness

Brightness adalah teknik augmentasi dengan meningkatkan tingkat kecerahan citra sehingga gambar terlihat lebih terang. Tujuannya adalah agar model dapat mengenali objek dengan baik pada kondisi pencahayaan tinggi atau terang, sehingga tidak terpengaruh oleh perubahan intensitas Cahaya.

3. Pengembangan Model

Pada tahap pengembangan model, penelitian ini mengimplementasikan pendekatan hybrid CNN–SVM yang menggabungkan keunggulan kedua metode untuk memperoleh performa klasifikasi yang lebih akurat dan stabil. CNN digunakan sebagai komponen utama dalam ekstraksi fitur citra karena kemampuannya mempelajari pola visual kompleks seperti warna, tekstur, dan kontur kulit buah nanas. Proses ini dilakukan melalui beberapa lapisan konvolusi dan pooling hingga menghasilkan representasi fitur berdimensi tinggi. Namun, alih-alih menggunakan lapisan fully connected sebagai pengklasifikasi, penelitian ini memanfaatkan algoritma SVM sebagai classifier akhir. Pemilihan SVM didasarkan pada kemampuannya memisahkan kelas secara optimal dengan margin yang maksimal, sehingga meningkatkan akurasi pada tahap klasifikasi kematangan buah nanas. Ilustrasi lengkap alur proses hybrid CNN–SVM ditampilkan pada Gambar 3.3 berikut.



Gambar 3. 2 Posisi model hybrid yang dilakukan (Hybrid CNN-SVM)

2 Berdasarkan diagram pada Gambar 3.2. Tahap pertama yaitu memuat dataset yang akan digunakan pada proses pemuatan model yang dibedakan menjadi tiga pada tahap pra-proses yaitu data latih, data validasi, dan data tes. Dataset yang termasuk data latih dan data validasi dan telah dilakukan tahapan pra proses akan masuk ke dalam arsitektur CNN dengan model . Data akan melalui proses konvolusi dengan parameter-parameter yang ditentukan. Data nantinya akan masuk ke fully connected layer setelah menyelesaikan pooling layer terakhir dan menghasilkan output feature berupa vektor fitur dari pooling akhir berdasarkan epoch yang telah ditentukan. Setelah parameter tersimpan, vektor fitur akan menjadi nilai input dan dilatih menggunakan metode SVM untuk proses klasifikasi biner dari model hybrid. Hasil output akan berupa hasil performa dari akurasi, presisi, recall, dan F1-Score. Untuk testing dataset, data akan langsung masuk ke proses klasifikasi menggunakan SVM berdasarkan hasil model CNN yang sudah dilatih dan output feature yang telah didapatkan. Hasil akhir pada testing dataset berupa hasil perrforma dari akurasi, presisi, recall, dan f1-score.

4. Evaluasi

33 Evaluasi model dilakukan untuk mengukur kemampuan model hybrid CNN– SVM dalam mengklasifikasi tingkat kematangan buah nanas secara akurat. 93 Proses evaluasi dilakukan dengan menggunakan data testing yang telah dipisahkan sebelumnya dan tidak terlibat dalam proses pelatihan maupun validasi, sehingga hasil evaluasi dapat mencerminkan performa model secara objektif. 4 Metode evaluasi yang digunakan meliputi perhitungan accuracy, precision, recall, dan F1-score, yang secara komplementer memberikan

gambaran menyeluruh mengenai kualitas prediksi model pada setiap kelas kematangan. Selain itu, confusion matrix juga digunakan untuk memvisualisasikan distribusi prediksi benar dan salah sehingga dapat dianalisis pola kesalahan yang muncul. Evaluasi ini membantu menilai sejauh mana model CNN bertugas mengekstraksi fitur dan SVM melakukan klasifikasi secara efektif, serta menjadi dasar dalam menentukan apakah model yang diperoleh sudah cukup optimal atau masih memerlukan penyesuaian lebih lanjut.

5. Uji Coba

Tahap uji coba ini dilakukan dengan menjalankan model pada data yang sebelumnya tidak pernah dilihat oleh model, sehingga hasil yang diperoleh benar-benar mencerminkan kemampuan generalisasi model. Selama proses ini, setiap citra dalam dataset testing diproses melalui jaringan CNN untuk mengekstraksi fitur, kemudian hasil ekstraksi tersebut diklasifikasikan oleh SVM untuk menentukan kategori tingkat kematangan buah nanas. Fase uji coba ini juga mencakup pengamatan terhadap tingkat akurasi prediksi, identifikasi jenis kesalahan klasifikasi, serta analisis stabilitas model ketika menghadapi variasi bentuk, warna, dan kondisi pencahayaan pada citra. Selain itu, seluruh output uji coba digunakan sebagai dasar untuk menghitung metrik evaluasi seperti accuracy, precision, recall, F1-score, dan confusion matrix. Hasil uji coba ini menjadi indikator utama keberhasilan model dalam melakukan klasifikasi secara konsisten dan akurat, sekaligus menjadi bahan pertimbangan apabila diperlukan optimasi lanjutan pada model.

86

BAB IV

HASIL DAN PEMBAHASAN

125

3

18

Bab ini menyajikan hasil yang diperoleh dari proses perancangan, pelatihan, dan pengujian model klasifikasi tingkat kematangan buah nanas menggunakan pendekatan *hybrid Convolutional Neural Network - Support Vector Machine* (CNN-SVM). Model yang dikembangkan bertujuan untuk meningkatkan akurasi klasifikasi dengan memanfaatkan kemampuan CNN dalam ekstraksi fitur citra serta SVM dalam proses klasifikasi yang optimal.

143

70

Tahapan analisis dilakukan secara sistematis mulai dari proses preprocessing data, ekstraksi fitur menggunakan CNN, hingga klasifikasi menggunakan SVM. Evaluasi kinerja model dilakukan dengan menggunakan berbagai metrik seperti akurasi, *loss*, *precision*, *recall*, dan *F1-score* guna memberikan gambaran menyeluruh terhadap performa model yang diusulkan.

48

4.1 Hasil Penelitian

25

Pada bagian ini disajikan hasil penelitian yang meliputi proses pengumpulan dataset, preprocessing dan augmentasi data, serta pengembangan model *hybrid* CNN-SVM. Data citra buah nanas diolah dan digunakan untuk membangun model, di mana CNN berfungsi sebagai ekstraksi fitur dan SVM sebagai *classifier* dalam menentukan tingkat kematangan buah nanas.

31

4.1.1 Pengumpulan Dataset

Dataset pada penelitian ini bertujuan memperoleh citra buah nanas yang representatif sebagai data masukan bagi model klasifikasi. Dataset dikumpulkan dengan memperhatikan variasi visual dan pembagian kelas tingkat kematangan agar

data yang digunakan mampu merepresentasikan kondisi nyata serta mendukung proses pelatihan dan pengujian model secara optimal. Penentuan tingkat kematangan buah nanas mengacu pada indikator agronomi yang umum digunakan, yaitu perubahan warna kulit buah dari hijau kekuningan sebagai penanda kematangan. Buah mentah didominasi warna hijau, buah setengah matang menunjukkan kombinasi warna hijau dan kuning, sedangkan buah matang memiliki dominasi warna kuning keemasan pada permukaan kulit. Oleh karena itu, pengambilan citra difokuskan untuk menangkap variasi warna kulit buah nanas sebagai dasar pelabelan kelas kematangan, yaitu mentah, setengah matang, dan matang, sesuai dengan standar maturity indices pasca panen buah. Data diambil langsung dilapangan di beberapa tempat seperti perkebunan nanas dan juga pasar yang ada di kabupaten Indragiri Hilir. data diambil menggunakan kamera handphone A60 dengan rasio penangkapan citra buah nanas 1:1 dengan berbagai sudut dan pencahayaan alami langsung dilapangan. dan juga dilakukan tes uji keasaman menggunakan alat pH digital keasaman di setiap tingkat kematangan buah Nanas.

Tabel 4. 1 Dataset Kematangan Nanas

Gambar	Ciri-Ciri	Tingkat Kematangan
	- Nanas terlihat berwarna hijau secara keseluruhan. - Mahkota bunga dari nanas terlihat kokoh dan segar - Batang nanas masih terlihat tegak dan tidak layu. - Tingkat keasaman : 4.03-4.26 pH	Mentah

Lanjutan Tabe 4.1 Dataset kematangan

Gambar	Ciri-Ciri	Tingkat Kematangan
	• Nanas terlihat sudah mulai berwarna kuning sekitar 20% dari seluruh warna nanas. • Mahkota bunga mulai tidak tegak sempurna • Batang terlihat tegak dan menguning • Tingkat keasaman : 4.09-4.48 ph	Mengkal
	• Nanas terlihat sudah mulai berwarna kuning sekitar 70% dari kematangan sebelumnya. • Mahkota daun mulai melunak • Batang daun juga sudah mulai melunak • Tingkat keasaman : 4.03-4.26 ph	Setengah Matang
	• Nanas terlihat kuning sudaah berwarna kuning 100% • Mahkota daun sudah mulai layu dan tidak terlalu kaku • Batang lebih lunak dari sebelumnya • Tingkat keasaman : 4.37-4.49 ph	Matang
	• Nanas sudah terlihat mulai terdapat warna kecoklatan dari bawah keatas. • Mahkota daun mulai melayu dan beerwarna coklat,dan juga sedikit berair • Batang nanas layu dan tidak berwwarna hijau lagi. • Tingkat keasaman : 4.25-4.15 ph	Busuk

Dataset dalam penelitian ini berjumlah 3.745 citra buah nanas. Data tersebut dibagi menjadi data pelatihan (*training*), data validasi (*validation*), dan data uji (*testing*) untuk memastikan proses pelatihan dan evaluasi model berjalan secara objektif. Pembagian data dilakukan dengan perbandingan 70,15% 15% . Rincian pembagian dataset disajikan pada tabel berikut.

Tabel 4. 2 Jumlah Dataset perkelas

Kelas	Jumlah Citra
Mentah	749
Mengkal	749
Setengah Matang	749
Matang	749
Busuk	749
Total	3.745

Selanjutnya, dataset yang telah diperoleh dibagi menjadi beberapa bagian, yaitu data pelatihan, data validasi, dan data uji. Pembagian ini bertujuan untuk memastikan proses pelatihan dan evaluasi model dilakukan secara objektif. Rincian pembagian dataset disajikan pada Tabel 4.3

Tabel 4. 3 Pembagian Dataset

Jenis Data	Presentase	Jumlah Citra
Data Training	70%	2.621
Data Validasi	15%	562
Data Uji	15%	562
Total	100%	3.745

Pembagian dataset dilakukan untuk memastikan bahwa proses pelatihan dan evaluasi model berjalan secara optimal dan objektif. Data dibagi menjadi tiga bagian utama, yaitu data training, data validasi, dan data uji. Data training digunakan untuk melatih model agar dapat mengenali pola dari citra yang diberikan. Selanjutnya, data validasi digunakan untuk mengevaluasi performa model selama proses pelatihan serta membantu dalam penyesuaian parameter agar tidak terjadi *overfitting*. Sementara itu, data uji digunakan sebagai tahap akhir untuk mengukur kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya. Proporsi pembagian dataset sebesar 70% untuk training, 15% untuk validasi, dan 15% untuk pengujian agar model stabil.

4.1.2 Preprocessing Data dan Augmentasi Data

Pada tahap ini dilakukan proses preprocessing dan augmentasi data untuk mempersiapkan dataset agar dapat digunakan secara optimal dalam pelatihan model. Tahapan ini bertujuan untuk meningkatkan kualitas data, mengurangi noise, serta menambah variasi citra sehingga model mampu belajar dengan lebih baik dan memiliki kemampuan generalisasi yang tinggi. Oleh karena itu, sebelum proses pelatihan dilakukan, data citra terlebih dahulu melalui tahap preprocessing sebagai langkah awal dalam pengolahan data.

a. Preprocessing Data

Pada tahap preprocessing, dilakukan pengolahan awal terhadap dataset citra untuk memastikan data siap digunakan dalam proses pelatihan model. Proses ini meliputi penyesuaian ukuran citra menjadi 160×160 piksel, pembagian dataset menjadi data training, validasi, dan testing, serta pengaturan parameter pelatihan seperti *batch size* dan *learning rate*. Selain itu, diterapkan beberapa konfigurasi tambahan untuk meningkatkan kinerja model, seperti penggunaan dropout dan label smoothing guna mengurangi *overfitting*. Optimalisasi proses pemuatan data juga dilakukan dengan memanfaatkan fitur *autotune* dari *TensorFlow*. Tahap processing dilakukan agar data citra yang digunakan dalam pelatihan memiliki kualitas dan format yang seragam, sehingga model dapat mempelajari pola dari setiap citra lebih optimal. Rincian parameter yang digunakan pada tahap preprocessing dan pelatihan disajikan pada Tabel 4.4 berikut.

Tabel 4. 4 Parameter Preprocessing dan Pelatihan Model

No	Parameter	Nilai
1.	Seed	42
2.	Img size	192
3.	Batch size	16
4.	Train split	0.70
5.	Val split	0.15
6.	Test split	0.15
7.	Epochs Head	30
8.	Epochs Finetune	12
9.	SVM kernel	RBF
10.	LR Head	0.0003
11.	LR Finetune	0.000005
12.	Dropuout Rate	0.45
13.	Label Smoothing	0.03
14.	Valid ext	Jpg, jpeg, png, bmp

Berdasarkan Tabel 4.4, parameter yang digunakan pada tahap preprocessing dan pelatihan model telah disesuaikan untuk mendukung proses pembelajaran yang optimal. Pengaturan ukuran citra, pembagian dataset, serta pemilihan nilai *batch size* dan *learning rate* dilakukan untuk menjaga keseimbangan antara kecepatan pelatihan dan akurasi model. Selain itu, penerapan teknik seperti dropout dan label smoothing bertujuan untuk mengurangi risiko *overfitting* sehingga model berkerja dengan baik

b. **Augmentasi Data**

Pada tahap augmentasi data, dilakukan penambahan variasi citra untuk meningkatkan jumlah dan keberagaman dataset sehingga model dapat melakukan generalisasi dengan lebih baik. Teknik augmentasi yang digunakan meliputi transformasi geometris dan perubahan pencahayaan tanpa mengubah label asli data.

Proses ini bertujuan untuk mengurangi *overfitting* serta meningkatkan performa model dalam mengenali berbagai kondisi citra di dunia nyata. Adapun jenis augmentasi yang diterapkan dijelaskan pada bagian berikut.

Tabel 4. 5 Proses Augmentasi Dataset

No	Gambar	Jenis Augmentasi	Keterangan
1.		Normal	Gambar Nanas normal sebelum proses Augmentasi dengan rasio kamera 1:1.dengan pengambilan gambar secara tegak lurus
2		Rotasi	Gambar Nanas dari normal lalu dilakukan tahap augmentasi Rotasi,yang diputar sebesar 90° dari gambar nanas yang normal.
3		Flip	Gambar dilakukan tahap augmentasi flip dengan cara membalik kan gambar dari kiri-kanan,atau sebaliknya dari gambar normal nanas.
4		Zoom out	Gambar nanas melakukan augmentasi zoom out,dimana gambar nomal dizoom lebih terlihat jelas ke gambar dari gambar normal


Lanjutan Tabel 4.5 Proses Augmentasi Dataset

No	Gambar	Jenis Augmentasi	Keterangan
5		Brightness	Gambar nanas melakukan tahap augmentasi brightness dengan menaikkan cahaya dari cahaya normal yang didapat, untuk mempelajari pencahayaan di lapangan
6		Darkness	Gambar nanas melakukan tahap augmentasi darkness yaitu penurunan cahaya untuk mempelajari objek di dalam ruangan gelap, atau malam hari

Berdasarkan Tabel 4.4, proses augmentasi data dilakukan untuk meningkatkan variasi citra buah nanas sehingga model dapat mengenali objek dalam berbagai kondisi pengambilan gambar. Jenis augmentasi yang digunakan meliputi citra normal, rotasi, flip, zoom out, brightness, dan darkness. Setiap teknik augmentasi memiliki peran penting dalam membantu model memahami perubahan orientasi, posisi, ukuran, serta kondisi pencahayaan pada citra. Dengan adanya augmentasi ini, dataset menjadi lebih beragam dan model tidak hanya bergantung pada satu kondisi gambar tertentu. Oleh karena itu, proses augmentasi diharapkan mampu mengurangi risiko *overfitting* serta meningkatkan kemampuan generalisasi model dalam mengklasifikasikan tingkat kematangan buah nanas pada kondisi nyata di lapangan.

4.1.3 Pengembangan Model Hybrid CNN-SVM

Pengembangan model *hybrid* CNN-SVM pada penelitian ini dilakukan dengan menggabungkan kemampuan CNN sebagai ekstraktor fitur dan SVM sebagai *classifier* akhir. CNN digunakan untuk mempelajari karakteristik visual citra buah nanas, seperti warna kulit, tekstur permukaan, bentuk, dan pola kematangan melalui proses konvolusi dan pooling. Hasil ekstraksi fitur dari CNN kemudian diubah menjadi *feature vector* yang selanjutnya digunakan sebagai masukan pada algoritma SVM. SVM berperan dalam memisahkan setiap kelas kematangan buah nanas dengan margin terbaik sehingga proses klasifikasi menjadi lebih optimal. Melalui kombinasi ini, model diharapkan mampu menghasilkan klasifikasi tingkat kematangan buah nanas yang lebih akurat, stabil, dan efektif dibandingkan penggunaan model tunggal



Gambar 4. 1 Pengembangan Model hybrid CNN-SVM

Untuk memperjelas fungsi setiap tahapan pada proses tersebut, penjelasan lebih rinci disajikan dalam bentuk tabel pada bagian berikut.

Tabel 4. 6 Komponen Hybrid CNN-SVM

Tahapan	Komponen	Fungsi
Input Data	Data Latih, Data Validasi, Data Uji	Membagi dataset citra buah nanas menjadi data pelatihan, validasi, dan pengujian untuk membangun dan mengevaluasi model.
Preprocessing	Augmentasi (Rotasi, flip, dll)	Meningkatkan variasi data citra sehingga model lebih robust terhadap perubahan posisi dan orientasi objek
Ekstraksi Fitur (CNN)	Convolution Layer	Mengekstraksi fitur visual seperti warna, tekstur, dan pola permukaan kulit nanas
	Pooling Layer	Mengurangi dimensi data serta mempertahankan fitur penting hasil ekstraksi
Training CNN	Epoch dan Parameter CNN	Melatih model CNN agar mampu mengenali pola kematangan buah secara optimal
Feature Representation	Fully Connected Layer / Feature Vector	Mengubah hasil ekstraksi fitur menjadi bentuk vektor numerik yang siap digunakan untuk klasifikasi
Model Hybrid	Integrasi CNN-SVM	Menggabungkan CNN sebagai feature extractor dan SVM sebagai classifier
Klasifikasi	Support Vector Machine (SVM)	Mengklasifikasikan tingkat kematangan buah nanas berdasarkan feature vector dengan margin pemisah optimal
Training Model	CNN-SVM	Melatih model hybrid menggunakan data latih agar menghasilkan model yang akurat
Pengujian	Data Testing	Menguji model menggunakan data baru yang tidak digunakan saat pelatihan
Evaluasi	Accuracy, Precision, Recall, F1-score, Confusion Matrix	Accuracy, Precision, Recall, F1-score, Confusion Matrix
Output	Hasil Klasifikasi	Menentukan kategori kematangan buah nanas (unripe, pre-ripe, half-ripe, fully ripe, over ripe)

Model *hybrid CNN-SVM* yang digunakan dalam penelitian ini memiliki alur proses yang sistematis dan saling terintegrasi antara tahap ekstraksi fitur dan klasifikasi. CNN berperan sebagai *feature extractor* yang mampu menangkap karakteristik visual penting dari citra buah nanas, seperti warna, tekstur, dan pola permukaan, sedangkan SVM berfungsi sebagai *classifier* yang mengoptimalkan pemisahan kelas berdasarkan *feature vector* yang dihasilkan. Output dari model ini berupa hasil klasifikasi tingkat kematangan buah nanas, seperti mentah, mengkal, setengah matang, matang, dan busuk. Dengan menggabungkan kemampuan CNN dalam ekstraksi fitur dan SVM dalam klasifikasi, model *hybrid* ini diharapkan mampu menghasilkan akurasi yang lebih baik.

Berdasarkan alur pengembangan model *hybrid CNN-SVM* pada Gambar 4.1, proses klasifikasi tingkat kematangan buah nanas diawali dari citra input yang telah melalui tahap *preprocessing* dan *augmentasi*, kemudian diproses oleh CNN untuk mengekstraksi fitur visual seperti warna, tekstur, bentuk, dan pola permukaan kulit nanas. Setiap citra disesuaikan dengan parameter pada Tabel 4.4, yaitu ukuran gambar 192×192 , *batch size* 16, pembagian data training 70%, validasi 15%, testing 15%, dropout rate 0,45, serta penggunaan kernel SVM RBF. Hasil ekstraksi fitur dari CNN selanjutnya diubah menjadi *feature vector* yang digunakan sebagai masukan bagi SVM untuk melakukan klasifikasi akhir ke dalam lima kelas kematangan, yaitu mentah, mengkal, setengah matang, matang, dan busuk. Oleh karena itu, penyajian bentuk tensor diperlukan untuk memperjelas perubahan dimensi data pada setiap tahapan model, mulai dari input citra, proses konvolusi dan pooling, pembentukan *feature vector*, hingga output klasifikasi model *hybrid CNN-SVM* berupa vector, hingga output klasifikasi model *hybrid CNN-SVM*.


Tabel 4.7 Bentuk Tensor Proses Model Hybrid CNN-SVM

Tahapan	Proses	Bentuk Tensor	Hyperparameter/ Keterangan
Input	Data latih, data validasi, dan data uji	$X_{train} \in R^{(2621 \times 192 \times 192 \times 3)}$, $X_{val} \in R^{(562 \times 192 \times 192 \times 3)}$, $X_{test} \in R^{(562 \times 192 \times 192 \times 3)}$	Split data : 70% training, 15% validasi, dan 15% testing
Preprocessing	Resize citra dan validasi format	$X \in R^{(16 \times 192 \times 192 \times 3)}$	Ukuran citra 192×192, batch size 16, format valid jpg, jpeg, png, bmp
Augmentasi Data	Rotasi, flip, zoom out, brightness, darkness	$X_{aug} \in R^{(16 \times 192 \times 192 \times 3)}$	Augmentasi menambah variasi citra, tetapi tidak mengubah ukuran tensor
Ekstraksi Fitur CNN	Convolution Layer dan fungsi aktivasi ReLU	$F_{conv} \in R^{(16 \times H \times W \times K)}$	CNN mengekstraksi fitur warna, tekstur, bentuk, dan pola permukaan kulit nanas
Pooling Layer	Max Pooling	$F_{pool} \in R^{(16 \times H' \times W' \times K)}$	Pooling mengurangi dimensi spasial dan mempertahankan fitur penting
Training CNN	Pelatihan CNN menggunakan epoch dan parameter pelatihan	$F_{cnn} \in R^{(16 \times H' \times W' \times K)}$	Epoch head 30, epoch finetune 12, learning rate head 0,0003, learning rate finetune 0,000005
Feature Representation	Flatten / Fully Connected Layer	$v \in R^{(16 \times d)}$	Feature map CNN diubah menjadi feature vector sebagai input SVM
Model Hybrid CNN-SVM	Integrasi CNN sebagai feature extractor dan SVM sebagai classifier	$X_{svm} \in R^{(n \times d)}$	CNN menghasilkan vektor fitur, kemudian fitur tersebut diproses oleh SVM
Klasifikasi SVM	SVM dengan kernel RBF	$\hat{y} \in R^{(n)}$	SVM menentukan kelas kematangan berdasarkan feature vector
Pengujian	Pengujian menggunakan data testing	$\hat{y}_{test} \in R^{(562)}$	Data testing berjumlah 562 citra
Output	Hasil klasifikasi tingkat kematangan nanas	$\hat{y} \in \{\text{Mentah, Mengkal, Setengah Matang, Matang, Busuk}\}$	Output akhir berupa kelas kematangan buah nanas

Berdasarkan tabel bentuk tensor tersebut, dapat dilihat bahwa setiap tahapan pada model *hybrid* CNN-SVM menghasilkan perubahan bentuk data yang berbeda, mulai dari citra masukan berukuran $192 \times 192 \times 3$, proses preprocessing dan augmentasi, ekstraksi fitur menggunakan CNN, pembentukan *feature vector*, hingga proses klasifikasi menggunakan SVM. Perubahan bentuk tensor ini menunjukkan bahwa CNN berperan dalam mengubah citra menjadi representasi fitur numerik yang lebih informatif, sedangkan SVM memanfaatkan *feature vector* tersebut untuk menentukan kelas kematangan buah nanas. Dengan demikian, tabel bentuk tensor ini memperjelas alur komputasi model pada Gambar 4.1 dan mendukung pemahaman terhadap hubungan antara parameter pelatihan pada Tabel 4.4 dengan proses klasifikasi tingkat kematangan buah nanas.

a. Performa Model *Hybrid* CNN-SVM

Pada tahap pelatihan model dilakukan proses training untuk mengetahui kemampuan model dalam mempelajari pola dari dataset citra buah nanas. Evaluasi kinerja model selama proses pelatihan dilakukan dengan mengamati nilai akurasi dan loss pada setiap *epoch*. Grafik akurasi dan loss digunakan untuk melihat perkembangan performa model serta mendeteksi kemungkinan terjadinya *overfitting* atau *underfitting* selama proses training. Hasil pelatihan model ditampilkan pada Gambar 4.2 berikut.



Gambar 4. 2 Grafik Akurasi dan Loss

Berdasarkan Gambar 4.2, grafik akurasi dan loss menunjukkan pola pembelajaran model selama proses training. Pada grafik akurasi, terlihat bahwa nilai akurasi training mengalami peningkatan yang signifikan dari sekitar 0,33 pada epoch ke-1 menjadi 0,56 pada epoch ke-3, kemudian meningkat menjadi 0,68 pada epoch ke-6, dan terus meningkat secara lebih stabil hingga mencapai sekitar 0,84 pada epoch ke-30. Hal ini menunjukkan bahwa model secara bertahap mampu mempelajari fitur-fitur penting dari citra buah nanas. Akurasi validasi juga menunjukkan tren peningkatan yang sejalan dengan akurasi training, yaitu dari sekitar 0,48 pada epoch ke-1 menjadi 0,65 pada epoch ke-4, kemudian meningkat menjadi sekitar 0,75 pada epoch ke-10, dan mencapai sekitar 0,84 pada epoch ke-30, meskipun terdapat fluktuasi kecil pada beberapa epoch.

Fluktuasi ini menunjukkan adanya variasi performa model terhadap data validasi, namun masih dalam batas wajar dan tidak menunjukkan penyimpangan yang signifikan. Pada grafik loss, terlihat bahwa nilai loss training menurun secara konsisten dari sekitar 2,05 pada epoch ke-1 menjadi 1,25 pada epoch ke-3, kemudian turun menjadi sekitar 0,90 pada epoch ke-7, dan mencapai sekitar 0,58

pada epoch ke-30, yang menandakan bahwa kesalahan prediksi model terhadap data training semakin berkurang. Loss validasi juga menunjukkan tren penurunan dari sekitar 1,35 pada epoch ke-1 menjadi 0,95 pada epoch ke-5, kemudian turun menjadi sekitar 0,72 pada epoch ke-12, dan mencapai sekitar 0,58 pada epoch ke-30, meskipun pada beberapa titik mengalami kenaikan sementara.


Berdasarkan perubahan nilai akurasi dan loss pada setiap epoch, dapat diketahui bahwa model mengalami proses pembelajaran yang baik selama tahap training. Peningkatan akurasi training dan validasi menunjukkan bahwa model mampu mengenali pola serta fitur penting dari citra buah nanas secara bertahap. Selain itu, penurunan nilai loss pada data training dan validasi menunjukkan bahwa tingkat kesalahan prediksi model semakin berkurang seiring bertambahnya epoch. Kondisi ini menandakan bahwa model semakin stabil dalam mempelajari data dan mampu menghasilkan performa yang lebih baik pada akhir proses pelatihan

Jika dibandingkan antara kurva training dan validasi, tidak terlihat adanya gap yang terlalu besar baik pada akurasi maupun loss. Hal ini menunjukkan bahwa model tidak mengalami overfitting secara signifikan. dapat disimpulkan bahwa proses pelatihan model berjalan dengan baik, model mampu belajar secara efektif, serta memiliki kemampuan generalisasi yang cukup baik terhadap data yang belum pernah dilihat sebelumnya.

b. Confusion Matrix

Setelah proses pelatihan model selesai, dilakukan tahap pengujian menggunakan data uji untuk mengevaluasi kemampuan model dalam mengklasifikasikan citra yang belum pernah dilihat sebelumnya. Salah satu metode evaluasi yang digunakan adalah *confusion matrix*, yang memberikan informasi

detail mengenai jumlah prediksi benar dan salah pada setiap kelas. Confusion matrix hasil pengujian model ditampilkan pada Gambar 4.3.



Gambar 4. 3 Confusion Matrix

Berdasarkan Gambar 4.3, *confusion matrix* menunjukkan hasil klasifikasi model *hybrid* CNN-SVM terhadap lima kelas, yaitu busuk, matang, mengkal, mentah, dan setengah matang. Nilai pada diagonal utama menunjukkan jumlah prediksi yang benar untuk setiap kelas.

Pada kelas busuk, seluruh data sebanyak 113 citra berhasil diklasifikasikan dengan benar tanpa adanya kesalahan, Pada kelas matang, terdapat 105 citra yang diklasifikasikan dengan benar, namun masih terdapat kesalahan. Pada kelas mentah, terdapat 107 citra yang berhasil diklasifikasikan dengan benar, , pada kelas setengah matang, model mampu mengklasifikasikan dengan benar sebanyak 100 citra, namun masih terdapat kesalahan yaitu 2 citra diprediksi sebagai busuk, 2 citra sebagai matang, 7 citra sebagai mengkal, dan 1 citra sebagai mentah.

Secara keseluruhan, terlihat bahwa prediksi benar mendominasi pada setiap kelas, terutama pada kelas busuk dan mentah yang memiliki tingkat akurasi tinggi. Kesalahan klasifikasi paling banyak terjadi pada kelas mengkal dan setengah matang, yang disebabkan oleh kemiripan karakteristik visual antar tingkat kematangan. Hal ini menunjukkan bahwa model *hybrid CNN-SVM* sudah memiliki performa yang sangat baik, namun masih menghadapi tantangan dalam membedakan kelas dengan perbedaan visual yang tipis.

c. Classification Report

Selain menggunakan *confusion matrix*, evaluasi performa model juga dilakukan menggunakan *classification report*. Metode ini memberikan informasi yang lebih rinci mengenai nilai *precision*, *recall*, dan *f1-score* untuk setiap kelas, sehingga dapat diketahui performa model secara lebih mendalam. Hasil *classification report* dari pengujian model ditampilkan pada Tabel 4.9 berikut.

Tabel 4. 8 Clasification Report Hybrid CNN-SVM


Kelas Kematangan	Precision	Recall	F1-Score	Support
Busuk	0.93	1.00	0.96	113
Matang	0.98	0.93	0.95	112
Mengkal	0.87	0.84	0.85	112
Mentah	0.93	0.94	0.94	113
Setengah Matang	0.90	0.89	0.89	112
Accuray			0.92	562
Macro avg	0.92	0.92	0.92	562
Weighted avg	0.92	0.92	0.92	562

classification report menunjukkan bahwa model *hybrid CNN-SVM* memiliki performa yang sangat baik dengan nilai akurasi sebesar 0,9253 (92,53%). Dilihat dari setiap kelas, kelas busuk memiliki performa terbaik dengan nilai *recall* sebesar 1,0000 dan *f1-score* 0,9658, yang menunjukkan bahwa seluruh data busuk berhasil

dikenali dengan sempurna. Kelas matang juga menunjukkan performa tinggi dengan *precision* 0,9813, *recall* 0,9375, dan *f1-score* 0,9589. Selain itu, kelas mentah memiliki performa yang stabil dengan *f1-score* 0,9427, yang menandakan model cukup konsisten dalam mengenali kelas ini.

Sementara itu, performa yang sedikit lebih rendah terlihat pada kelas mengkal dan setengah matang, dengan *f1-score* masing-masing sebesar 0,8597 dan 0,8969. Nilai ini menunjukkan bahwa model masih mengalami kesulitan dalam membedakan kelas dengan tingkat kematangan yang berdekatan. Meskipun demikian, nilai *macro average f1-score* sebesar 0,9248 dan *weighted average* sebesar 0,9249 menunjukkan bahwa secara keseluruhan model memiliki performa yang sangat baik dan seimbang pada seluruh kelas. Hal ini membuktikan bahwa model *hybrid* CNN-SVM efektif dalam mengklasifikasikan tingkat kematangan buah.

d. Kurva ROC dan Nilai AUC



Gambar 4. 4 Kurva ROC dan Nilai AUC

Untuk mengevaluasi performa model secara lebih komprehensif, digunakan kurva *Receiver Operating Characteristic* (ROC) dan nilai *Area Under Curve* (AUC). Kurva ROC menggambarkan hubungan antara *True Positive Rate* (TPR) dan *False Positive Rate* (FPR) pada berbagai threshold klasifikasi.

Berdasarkan Gambar 4.X, terlihat bahwa seluruh kurva ROC berada jauh di atas garis diagonal (random), yang menunjukkan bahwa model memiliki kemampuan klasifikasi yang sangat baik. Nilai AUC untuk masing-masing kelas juga menunjukkan hasil yang tinggi, yaitu busuk (1.000), matang (0.997), mengkal (0.976), mentah (0.992), dan setengah matang (0.984). Nilai AUC yang mendekati 1 menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam membedakan antar kelas. Dengan demikian, hasil ini memperkuat bahwa model *Hybrid CNN-SVM* memiliki performa yang sangat baik dan konsisten dalam klasifikasi tingkat kematangan buah nanas.

e. Prediksi Model *Hybrid CNN-SVM*

Setelah proses pelatihan dan pengujian model selesai, dilakukan tahap visualisasi hasil prediksi untuk melihat secara langsung kemampuan model *hybrid CNN-SVM* dalam mengklasifikasikan citra buah nanas. Pada tahap ini, beberapa sampel citra dari dataset ditampilkan beserta label hasil prediksi yang diberikan oleh model. Visualisasi ini bertujuan untuk memberikan gambaran nyata mengenai performa model dalam mengenali tingkat kematangan buah nanas berdasarkan karakteristik visualnya. Pada Gambar yang telah dipilih untuk tahap ini akan ditentukan kelas kematangannya sesuai visualisasi nanas dari sampel yang sudah dipelajari. Proses ini juga untuk mengetahui seberapa optimal model *Hybrid CNN-SVM* yang dipelajari dalam menentukan tingkat kematangan buah nanas.



Gambar 4. 5 Prediksi Kematangan Model

Pada Gambar 4.5, terlihat bahwa model mampu mengklasifikasikan sebagian besar citra dengan baik sesuai dengan tingkat kematangannya. Citra dengan label mentah umumnya dikenali dengan dominasi warna hijau, sedangkan setengah matang menunjukkan kombinasi warna hijau dan kuning, dan matang cenderung memiliki warna kuning yang lebih dominan. Sementara itu, kelas busuk ditandai dengan perubahan warna yang lebih gelap serta tekstur yang tidak normal, yang juga berhasil dikenali oleh model.

Meskipun sebagian prediksi sudah sesuai, masih terdapat beberapa potensi kesalahan pada, terutama antara kelas mengkal dan setengah matang atau mentah dan mengkal. Hal ini menunjukkan bahwa model masih menghadapi tantangan dalam membedakan tingkat kematangan yang berdekatan. Namun secara keseluruhan, hasil ini memperkuat bahwa model hybrid CNN-SVM memiliki kemampuan yang baik dalam melakukan klasifikasi citra buah nanas secara akurat dan konsisten

4.2 Pembahasan

Pada bagian pembahasan ini dijelaskan analisis hasil pengujian beberapa model, yaitu CNN murni, SVM, *hybrid* CNN–SVM, KNN, dan *Random Forest*. Pembahasan dilakukan untuk membandingkan performa setiap model berdasarkan *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*, sehingga dapat diketahui model yang paling efektif dalam mengklasifikasikan tingkat kematangan buah nanas.

4.2.1 Ablasi Study

Pada tahap ablasi study, dilakukan pengujian terhadap model baseline yaitu CNN murni dan SVM murni untuk mengetahui kontribusi masing-masing metode dalam proses klasifikasi tingkat kematangan buah nanas. Pengujian ini bertujuan untuk membandingkan performa kedua model sebelum dilakukan penggabungan dalam model *hybrid* CNN–SVM. Evaluasi dilakukan menggunakan metrik *precision*, *recall*, dan *F1-score* yang disajikan dalam bentuk *classification report* sebagai hasil akhir model.

a. Hasil Clasification Report Model CNN Murni,SVM,dan Hybrid CNN-SVM

Tabel 4. 9 Clasification Report CNN dan SVM

Model	A	P	R	F1	Model Size(MB)	Parameter
CNN	0.87	0.88	0.87	0.88	16.36	4.288
SVM	0.71	0.70	0.72	0.71	2.45	12.50
Hybrid CNN-SVM	0.92	0.92	0.92	0.92	8.66	2.269

Berdasarkan Tabel 4.9, dapat dilihat bahwa model *Hybrid* CNN-SVM memperoleh hasil performa terbaik dibandingkan model CNN murni dan SVM. Model *Hybrid* CNN-SVM menghasilkan nilai *accuracy*(A), *precision*(P), *recall*(R), dan *F1-score*(F1) masing-masing sebesar 0,92. Hasil ini menunjukkan bahwa

penggabungan CNN sebagai ekstraktor fitur dan SVM sebagai metode klasifikasi mampu meningkatkan kemampuan model dalam mengenali tingkat kematangan buah nanas. Model CNN murni memperoleh accuracy sebesar 0,87, precision sebesar 0,88, recall sebesar 0,87, dan F1-score sebesar 0,88. Nilai tersebut menunjukkan bahwa CNN sudah mampu melakukan klasifikasi dengan cukup baik, namun performanya masih berada di bawah model Hybrid CNN-SVM. Model CNN memiliki ukuran model sebesar 16,36 MB dengan jumlah parameter sebesar 4,288, sehingga model ini memiliki kompleksitas yang lebih besar dibandingkan model Hybrid CNN-SVM.

Sementara itu, model SVM memperoleh nilai accuracy sebesar 0,71, precision sebesar 0,70, recall sebesar 0,72, dan F1-score sebesar 0,71. Nilai ini menunjukkan bahwa performa SVM masih lebih rendah dibandingkan CNN dan Hybrid CNN-SVM. Hal ini dapat terjadi karena SVM bekerja berdasarkan fitur yang diberikan, sehingga kemampuan klasifikasinya sangat bergantung pada kualitas fitur yang digunakan. Model SVM memiliki ukuran model sebesar 2,45 MB dengan parameter sebesar 12.500, yang merepresentasikan kompleksitas model dalam proses klasifikasi.

Secara keseluruhan, hasil pada tabel menunjukkan bahwa model Hybrid CNN-SVM merupakan model dengan performa paling optimal. Model ini tidak hanya menghasilkan nilai evaluasi tertinggi, tetapi juga memiliki ukuran model yang lebih kecil dibandingkan CNN murni, yaitu sebesar 8,66 MB dengan jumlah parameter sebesar 2,269. Dengan demikian, pendekatan Hybrid CNN-SVM dapat dikatakan lebih efektif dalam meningkatkan akurasi klasifikasi tingkat kematangan buah nanas.

4.2.2 Uji Perbandingan Model

Pada subbab ini dilakukan uji perbandingan terhadap beberapa model klasifikasi, yaitu CNN murni, SVM (baseline), *Hybrid CNN-SVM*, *K-Nearest Neighbor* (KNN), dan Random Forest. Tujuan dari pengujian ini adalah untuk mengetahui model dengan performa terbaik dalam mengklasifikasikan tingkat kematangan buah nanas berdasarkan citra digital. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*.

a. Hasil Model *K-Nearest Neighbor* (KNN) dan *Random Forest*

K-Nearest Neighbor (KNN) merupakan salah satu algoritma klasifikasi berbasis instance yang bekerja dengan cara menentukan kelas suatu data berdasarkan kedekatan jarak dengan data lain yang berada di sekitarnya. Prinsip utama KNN adalah bahwa data yang memiliki kemiripan akan cenderung berada dalam kelas yang sama. Pada proses klasifikasi, KNN akan menghitung jarak antara data uji dengan seluruh data latih, kemudian memilih sejumlah tetangga terdekat (k) dan menentukan kelas berdasarkan mayoritas dari tetangga tersebut.

Dan juga *Random Forest* merupakan salah satu algoritma *machine learning* berbasis ensemble yang bekerja dengan menggabungkan banyak pohon keputusan (*decision tree*) untuk meningkatkan akurasi dan stabilitas prediksi. Setiap pohon dibangun menggunakan subset data dan fitur yang berbeda, sehingga menghasilkan model yang lebih robust terhadap variasi data. Dalam proses klasifikasi, setiap pohon keputusan akan memberikan hasil prediksi, kemudian hasil akhir ditentukan berdasarkan voting mayoritas dari seluruh pohon. Metode ini mampu mengurangi risiko *overfitting* yang sering terjadi pada *decision tree* tunggal serta meningkatkan kemampuan generalisasi model.

Tabel 4.10 Hasil Clasification Report Perbandingan Model

Model	Accuray	Precision	Recall	F1-Score	Model Size(MB)
Random Forest	0.84	0.87	0.85	0.86	3.85
KNN	0.86	0.87	0.85	0.86	2.10
Hybrid CNN-SVM	0.92	0.92	0.92	0.92	8.66

Berdasarkan Tabel 4.10, dapat dilihat bahwa model *Hybrid* CNN-SVM memperoleh hasil terbaik dibandingkan model *Random Forest* dan *K-Nearest Neighbor* (KNN). Model *Hybrid* CNN-SVM menghasilkan nilai accuracy, precision, recall, dan F1-score masing-masing sebesar 0,92. Hasil ini menunjukkan bahwa penggabungan CNN sebagai ekstraktor fitur dan SVM sebagai metode klasifikasi mampu memberikan performa klasifikasi yang lebih optimal dalam mengenali tingkat kematangan buah nanas.

Model *Random Forest* memperoleh accuracy sebesar 0,84, precision sebesar 0,87, recall sebesar 0,85, dan F1-score sebesar 0,86. Model ini memiliki ukuran sebesar 3,85 MB dengan parameter berupa 100 trees. Parameter pada *Random Forest* dinyatakan dalam bentuk jumlah trees karena *Random Forest* merupakan algoritma berbasis kumpulan pohon keputusan. Setiap pohon keputusan akan melakukan proses klasifikasi, kemudian hasil akhir ditentukan berdasarkan voting mayoritas dari seluruh pohon. Oleh karena itu, jumlah trees menunjukkan banyaknya pohon keputusan yang digunakan dalam model dan menjadi salah satu faktor yang memengaruhi kompleksitas serta kemampuan prediksi model.

Sementara itu, model KNN memperoleh accuracy sebesar 0,86, precision sebesar 0,87, recall sebesar 0,85, dan F1-score sebesar 0,86. Model KNN memiliki ukuran sebesar 2,10 MB dengan parameter berupa 627 samples. Parameter pada KNN dinyatakan dalam bentuk jumlah samples karena KNN termasuk algoritma

instance-based learning atau *lazy learning*, yaitu model tidak membentuk parameter bobot seperti neural network. KNN melakukan klasifikasi dengan menyimpan data latih, kemudian membandingkan data uji dengan sampel-sampel tersebut berdasarkan kedekatan jarak. Oleh karena itu, jumlah *samples* menunjukkan banyaknya data yang digunakan sebagai acuan dalam proses klasifikasi.

Secara keseluruhan, hasil pengujian menunjukkan bahwa model *Hybrid CNN-SVM* merupakan model dengan performa paling unggul. Model ini memperoleh nilai evaluasi tertinggi pada seluruh metrik, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. Selain itu, model *Hybrid CNN-SVM* memiliki ukuran model sebesar 8,66 MB dengan jumlah parameter sebesar 2,269 juta. Dengan demikian, model *Hybrid CNN-SVM* dapat dikatakan lebih efektif dibandingkan *Random Forest* dan KNN dalam proses klasifikasi tingkat kematangan buah nanas berdasarkan citra digital.

4.2.3 Rangkuman

Berdasarkan hasil penelitian dan pengujian yang telah dilakukan, penelitian ini telah berhasil mengembangkan model klasifikasi tingkat kematangan buah nanas menggunakan metode *Hybrid CNN-SVM*. Tahapan penelitian dimulai dari pengumpulan dataset, preprocessing, augmentasi data, pelatihan model, hingga evaluasi menggunakan *accuracy*, *precision*, *recall*, *F1-score*, *confusion matrix*, dan *ROC-AUC*. Dataset yang digunakan terdiri dari lima kelas kematangan, yaitu mentah, mengkal, setengah matang, matang, dan busuk.

Hasil pengujian menunjukkan bahwa model *Hybrid CNN-SVM* memperoleh performa terbaik dibandingkan model CNN murni, SVM, *Random Forest*, dan KNN. Model *Hybrid CNN-SVM* menghasilkan nilai *accuracy*, *precision*, *recall*, dan F1-score sebesar 0,92. Nilai ini lebih tinggi dibandingkan CNN murni dengan *accuracy* 0,87, SVM sebesar 0,71, *Random Forest* sebesar 0,84, dan KNN sebesar 0,86. Hal ini menunjukkan bahwa penggabungan CNN sebagai ekstraktor fitur dan SVM sebagai *classifier* mampu meningkatkan akurasi klasifikasi tingkat kematangan buah nanas.

Kelebihan dari model *Hybrid CNN-SVM* adalah mampu mengenali fitur visual buah nanas seperti warna, tekstur, dan pola kulit dengan lebih baik. Selain itu, model ini memiliki performa yang stabil pada sebagian besar kelas dan ukuran model yang lebih kecil dibandingkan CNN murni, yaitu 8,66 MB dengan parameter sebesar 2,269 juta. Namun, model masih memiliki kekurangan, terutama dalam membedakan kelas yang memiliki kemiripan visual, seperti mengkal dan setengah matang. Kesalahan ini terjadi karena perubahan warna dan tekstur pada kelas tersebut tidak terlalu berbeda secara signifikan.

Berdasarkan hasil tersebut, model *Hybrid CNN-SVM* dapat dikatakan sebagai model yang paling efektif dalam penelitian ini. Rekomendasi untuk penelitian selanjutnya adalah menggunakan dataset yang lebih banyak dan lebih bervariasi, terutama pada kelas yang memiliki kemiripan visual tinggi. Selain itu, penelitian berikutnya dapat mencoba optimasi parameter, penggunaan arsitektur CNN yang lebih ringan.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian dan pengembangan yang telah dilakukan dapat diambil hasil Kesimpulan sebagai berikut :

1. Penelitian ini berhasil mengembangkan model Hybrid CNN-SVM untuk mengklasifikasikan tingkat kematangan buah nanas berdasarkan citra digital. Model ini menggunakan CNN sebagai ekstraktor fitur dan SVM sebagai classifier akhir untuk menentukan kelas kematangan buah.
2. Dataset yang digunakan terdiri dari lima kelas kematangan buah nanas, yaitu mentah, mengkal, setengah matang, matang, dan busuk. Proses preprocessing dan augmentasi data dilakukan untuk meningkatkan variasi citra agar model dapat mengenali buah nanas dalam berbagai kondisi.
3. Berdasarkan hasil pengujian, model Hybrid CNN-SVM memperoleh nilai accuracy, precision, recall, dan F1-score sebesar 0,92. Hasil ini menunjukkan bahwa model memiliki performa lebih baik dibandingkan CNN murni, SVM, KNN, dan Random Forest.

5.2 Saran

Adapun saran yang dapat diberikan untuk pengembangan lebih lanjut dari penelitian ini adalah :

1. Penelitian selanjutnya disarankan menggunakan dataset yang lebih banyak dan bervariasi, terutama dari segi pencahayaan, sudut

33

52

pengambilan gambar, latar belakang, dan kondisi buah. Hal ini bertujuan agar model dapat mengenali citra buah nanas dengan lebih baik pada kondisi nyata.

4

2. Perlu dilakukan penambahan data pada kelas yang memiliki kemiripan visual tinggi, terutama kelas mengkal dan setengah matang. Penambahan data tersebut diharapkan dapat mengurangi kesalahan klasifikasi pada kelas yang memiliki ciri warna dan tekstur hampir sama.

22

140

3. Penelitian selanjutnya disarankan untuk mencoba metode atau arsitektur model lain sebagai pembanding, seperti MobileNet, EfficientNet, atau model deep learning ringan lainnya. Hal ini bertujuan untuk mengetahui apakah terdapat metode yang dapat menghasilkan akurasi lebih tinggi dengan ukuran model yang lebih efisien.

161

DAFTAR PUSTAKA

- [1] J. G. M. Sanu, "Identifikasi Kematangan Buah Nanas Menggunakan Citra Digital Dengan Metode K-Nearest Neighbor (K-Nn) Dan Support Vector Machine (Svm)," *HOAQ (High Educ. Organ. Arch. Qual. J. Teknol. Inf.*, vol. 16, no. 1, pp. 35–48, 2025, doi: 10.52972/hoaq.vol16no1.p35-48.
- [2] H. H. Wang and S. Y. Chai, "Novel Feature Extraction for Pineapple Ripeness Classification," *J. Telecommun. Inf. Technol.*, vol. 2022, no. 1, pp. 14–22, 2022, doi: 10.26636/jtit.2022.156021.
- [3] D. Liandaputra and A. Zahra, "Klasifikasi Tingkat Kematangan Buah Nanas Menggunakan Metode Deep Learning," *G-Tech J. Teknol. Terap.*, vol. 8, no. 2, pp. 1091–1103, 2024, doi: 10.33379/gtech.v8i2.4122.
- [4] B. Nanas, S. V. Machine, S. V. Machine, B. Hasil, K. Kunci, and B. Nanas, "1, 2 1,2," vol. 4, no. 4, pp. 296–301, 2022.
- [5] A. N. Hermana, D. Rosmala, and M. G. Husada, "Classification of Fruit Ripeness with Model Descriptor Using Vgg 16 Architecture," *J. Educ.*, vol. 05, no. 03, pp. 5587–5596, 2023.
- [6] C. N. 1 Sahera and Y. Rahmawati, "Universitas Muhammadiyah Sidoarjo Optimasi Penerapan Algoritma Convolution Neural Network Dalam Klasifikasi Tingkat Kesegaran Daging Sapi Oleh," 2024.
- [7] S. P. 7 Backar, P. Purnawansyah, H. Darwis, and W. Astuti, "Hybrid Fourier Descriptor Naïve Bayes dan CNN pada Klasifikasi Daun Herbal," *J. Inform. J. Pengemb. IT*, vol. 8, no. 2, pp. 126–133, 2023, doi: 10.30591/jpit.v8i2.5186.
- [8] N. 9 Uly, H. Hendry, and A. Iriani, "CNN-RNN Hybrid Model for Diagnosis

- of COVID-19 on X-Ray Imagery,” *Digit. Zo. J. Teknol. Inf. dan Komun.*, vol.14, no.1, pp. 57–67, 2023, doi: 10.31849/digitalzone.v14i1.13668.
- [9] Q. 4 Huang, “Classification of Fruits Based on CNN, SVM and PCA,” no. Daml 2023, pp. 465–473, 2024, doi: 10.5220/0012815000003885.
- [10] N. 2 Sulistianingsih, F. Astutik, and A. Rahman, “Optimasi Seleksi Fitur Untuk Perbaikan Akurasi Support Vector Machine Classifier Pada Klasifikasi Citra Tanaman Rimpang,” *J. Fasilkom*, vol. 14, no. 2, pp. 526–532, 2024, doi: 10.37859/jf.v14i2.7566.
- [11] M. A. 6 Wiratama And W. M. Pradnya, “Optimasi Algoritma Data Mining Menggunakan Backward Elimination Untuk Klasifikasi Penyakit Diabetes Jurnal Nasional Pendidikan Teknik Informatika : JANAPATI | 2,” vol. 11, pp. 1–12, 2022.
- [12] L. W. 3 Rizkallah, “Optimizing SVM hyperparameters for satellite imagery classification using metaheuristic and statistical techniques,” *Int. J. Data Sci. Anal.*, vol. 20, no. 5, pp. 4945–4962, 2025, doi: 10.1007/s41060-025-00762-7.
- [13] J. 5 Rusman, B. Z. Haryati, and A. Michael, “Optimisasi Hiperparameter Tuning pada Metode Support Vector Machine untuk Klasifikasi Tingkat Kematangan Buah Kopi,” *J. Komput. dan Inform.*, vol. 11, no. 2, pp. 195–202, 2023, doi: 10.35508/jicon.v11i2.12571.
- [14] Y. 8 Wu, Y. He, and Y. Wang, “Multi-Class Weed Recognition Using Hybrid CNN-SVM Classifier,” *Sensors*, vol. 23, no. 16, 2023, doi: 10.3390/s23167153.

- [15] A. 10 Sahgal, “Penerapan Metode Hybrid Cnn-Lstm Dalam Sistem Deteksi Multi Classification Cyber Attack,” vol. 4, no. 1, pp. 9–15, 2024.
- [16] Y. 11 Yohannes, D. Udjulawa, and F. Febbiola, “Klasifikasi Lukisan Karya Van Gogh Menggunakan Convolutional Neural Network-Support Vector Machine,” *J. Tek. Inform. dan Sist. Inf.*, vol. 7, no. 1, pp. 192–205, 2021, doi: 10.28932/jutisi.v7i1.3399.
- [17] T. S. 12 Nabila and A. Salam, “Classification of Brain Tumors by Using a Hybrid CNN-SVM Model,” *J. Appl. Informatics Comput.*, vol. 8, no. 2, pp. 241–247, 2024, doi: 10.30871/jaic.v8i2.8277.
- [18] A. K. 13 Jean, M. Diarra, B. A. Bakary, G. Pierre, and A. K. Jérôme, “Application based on Hybrid CNN-SVM and PCA-SVM Approaches for Classification of Cocoa Beans,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 9, pp. 231–238, 2022, doi: 10.14569/IJACSA.2022.0130927.
- [19] D. 14 Bhattacharyya, E. S. N. Joshua, N. T. Rao, and T. H. Kim, “Hybrid CNN- SVM Classifier Approaches to Process Semi-Structured Data in Sugarcane Yield Forecasting Production,” *Agronomy*, vol. 13, no. 4, pp. 1–16, 2023, doi: 10.3390/agronomy13041169.
- [20] C. Y. 15 Chang, C. S. Kuan, H. Y. Tseng, P. H. Lee, S. H. Tsai, and S. J. Chen, “Using deep learning to identify maturity and 3D distance in pineapple fields,” *Sci. Rep.*, vol. 12, no. 1, pp. 1–8, 2022, doi: 10.1038/s41598-022-12096-6.
- [21] W. O. 16 Mardiana, N. A., & Windari, “G-Tech : Jurnal Teknologi Terapan,” *G- Tech J. Teknol. Terap.*, vol. 8, no. 1, pp. 186–195, 2024.

- [22] W. O. 17 Mardiana, N. A., & Windari, “G-Tech : Jurnal Teknologi Terapan,” *G- Tech J. Teknol. Terap.*, vol. 8, no. 1, pp. 186–195, 2024.
- [23] H. H. 18 Wang and S. Y. Chai, “Novel Feature Extraction for Pineapple Ripeness Classification,” *J. Telecommun. Inf. Technol.*, vol. 2022, no. 1, pp. 14–22, 2022, doi: 10.26636/jtit.2022.156021.
- [24] D. 19 Vernanda, N. N. Purnawan, and T. H. Apandi, “Analisis Data Untuk Klasifikasi Tingkat,” vol. 4, no. September, pp. 8–17, 2022, doi: 10.31962/jiitr.vvii.67.
- [25] L. S. Arzeti, J. L. Putra, T. Setiyorini, P. Studi, I. Fakultas, and K. J. Pusat, “MODEL HYBRID CNN-SVM UNTUK KLASIFIKASI KESEGARAN BUAH PARE BERDASARKAN CITRA Luica,” vol. 9, no. 4, pp. 439–445, 2025.
- [26] F. P. A. Shintyadhita Wirawan Putri, Anggraini Puspita Sari, “Identifikasi penyakit daun dan batang tanaman jagung menggunakan vgg16-svm,” vol. 11, no. 2, pp. 794–802, 2026.

LAMPIRAN



