

SURAT KETERANGAN BEBAS PLAGIARISME



Universitas Nusantara PGRI Kediri
UPT. PERPUSTAKAAN, PUBLIKASI DAN INOVASI
Alamat: Kampus 1, Jl. KH. Ahmad Dahlan No.76 Kota Kediri 64112
Telp. (0354) 771576, (0354) 771503, (0354) 771495, Fax. (0354) 771576
Website: <http://ppi.unpkediri.ac.id/> Email: perpustakaan@unpkediri.ac.id

SURAT KETERANGAN BEBAS SIMILARITY

Ketua UPT Perpustakaan, Publikasi dan Inovasi Universitas Nusantara PGRI Kediri menerangkan bahwa mahasiswa dengan identitas berikut:

Nama Mahasiswa : Muhammad Qoyyum
NPM : 2213020031
Program Studi : S1-Teknik Informatika

Judul Karya Ilmiah:

“Deteksi tingkat kematangan pisang Kepok berbasis Computer Vision menggunakan Arsitektur VGG16”

Dinyatakan sudah memenuhi syarat batas maksimal 30% *similarity* sesuai dengan ketentuan yang berlaku pada setiap subbab naskah Laporan **Tugas Akhir/Skripsi/Tesis** yang disusun.

Demikian Surat Keterangan ini kami berikan untuk dapat dipergunakan seperlunya.



Kediri, 25 Juni 2026
Ka UPT PPI,



Dr. Abdul Aziz Hunaifi, M.A

Turnitin LLCC

2213020031_Muhammad Qoyyum-2

 TI-15

Document Details

Submission ID

trn:oid::2945:395585568

Submission Date

Jun 25, 2026, 2:13 PM GMT+7

Download Date

Jun 25, 2026, 2:18 PM GMT+7

File Name

2213020031_Muhammad Qoyyum-2.pdf

File Size

3.0 MB

73 Pages

14,759 Words

95,040 Characters

17% Overall Similarity

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

Filtered from the Report

- Bibliography

Top Sources

- 8%  Internet sources
- 7%  Publications
- 16%  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

- 8% Internet sources
- 7% Publications
- 16% Submitted works (Student Papers)

Top Sources

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

1	Student papers	Universitas Muslim Indonesia on 2025-08-16	<1%
2	Student papers	Universitas Islam Riau on 2026-04-30	<1%
3	Student papers	Sriwijaya University on 2026-05-04	<1%
4	Student papers	Politeknik Pariwisata NHI Bandung on 2026-04-28	<1%
5	Internet	repository.ub.ac.id	<1%
6	Student papers	Universitas Khairun on 2026-05-20	<1%
7	Internet	ejournal.catursakti.ac.id	<1%
8	Student papers	Universitas Muhammadiyah Sukabumi on 2026-06-06	<1%
9	Student papers	Universitas Tarumanagara on 2025-12-12	<1%
10	Student papers	Universitas Pamulang on 2026-05-04	<1%
11	Student papers	Universitas Dinamika on 2026-06-11	<1%

12	Student papers	Universitas Khairun on 2026-05-05	<1%
13	Internet	123dok.com	<1%
14	Student papers	UPN Veteran Yogyakarta on 2026-04-28	<1%
15	Student papers	Universitas Hayam Wuruk Perbanas on 2026-06-11	<1%
16	Student papers	Universitas Islam Riau on 2026-06-11	<1%
17	Student papers	Universitas Negeri Medan on 2026-06-17	<1%
18	Internet	widuri.raharja.info	<1%
19	Student papers	Forum Perpustakaan Perguruan Tinggi Indonesia Jawa Timur on 2025-07-08	<1%
20	Publication	Santowi Azis, Bambang irawan -. "EVALUASI KLASIFIKASI PENYAKIT DAUN TEH M...	<1%
21	Student papers	Universitas Jember on 2026-06-21	<1%
22	Student papers	Universitas Tarumanagara on 2025-12-19	<1%
23	Internet	macoupinctygenealogy.org	<1%
24	Student papers	Academic Library Consortium on 2026-01-25	<1%
25	Student papers	Universitas Malikussaleh on 2026-01-12	<1%

26	Student papers	Politeknik Negeri Lhokseumawe Turnitin on 2026-01-07	<1%
27	Publication	Tyler, Jeramey. "Spatial Location of Binaural Signals Using Cepstral Analysis", Ren...	<1%
28	Student papers	Universitas Muslim Indonesia on 2024-08-16	<1%
29	Internet	ejurnal.seminar-id.com	<1%
30	Internet	repository2.unw.ac.id	<1%
31	Publication	Muhammad Ilham Manzis Nur Jamal. "IMPLEMENTASI MACHINE LEARNING BERB...	<1%
32	Student papers	UPN Veteran Yogyakarta on 2025-10-01	<1%
33	Student papers	Universitas Islam Riau on 2025-12-08	<1%
34	Student papers	Universitas Islam Riau on 2026-06-02	<1%
35	Student papers	Universitas Muhammadiyah Sukabumi on 2025-07-16	<1%
36	Student papers	Universitas Tarumanagara on 2025-12-18	<1%
37	Internet	openlibrarypublications.telkomuniversity.ac.id	<1%
38	Internet	repository.narotama.ac.id	<1%
39	Student papers	LL DIKTI IX Turnitin Consortium Part II on 2024-12-06	<1%

40	Student papers	Universitas Islam Sumatera Utara on 2026-04-20	<1%
41	Student papers	Universitas Muhammadiyah Palembang on 2026-06-10	<1%
42	Student papers	Universitas Tarumanagara on 2025-12-15	<1%
43	Internet	journal.aptika.org	<1%
44	Student papers	Politeknik Negeri Bandung on 2017-06-19	<1%
45	Student papers	Universitas Islam Indonesia on 2026-06-15	<1%
46	Internet	eprints.umpo.ac.id	<1%
47	Internet	repository.uin-suska.ac.id	<1%
48	Internet	www.scribd.com	<1%
49	Internet	doku.pub	<1%
50	Internet	ejournal.ikmi.ac.id	<1%
51	Publication	Habil Putra Arianda, T. Yudi Hadiwandura. "Implementasi Deep Learning Untuk Kl..."	<1%
52	Student papers	Sekolah Teknik Elektro & Informatika on 2025-07-31	<1%
53	Student papers	Udayana University on 2015-03-16	<1%

54	Student papers	Universitas Muhammadiyah Sukabumi on 2025-08-03	<1%
55	Student papers	Universitas Pamulang on 2026-06-08	<1%
56	Student papers	Universitas Pancasila on 2026-02-23	<1%
57	Internet	repository.itpln.ac.id	<1%
58	Publication	Adi Suryadi, Suhirman Suhirman. "Model Convolutional Neural Network berbasis ...	<1%
59	Student papers	Fakultas Teknik on 2026-04-07	<1%
60	Publication	Indah Sartika, Imam Saputra. "Analisis Sentimen Masyarakat Terhadap Pembatas...	<1%
61	Student papers	Universitas Khairun on 2026-06-08	<1%
62	Student papers	Universitas Pamulang on 2026-05-11	<1%
63	Student papers	Universitas Sumatera Utara on 2024-12-23	<1%
64	Student papers	Universitas Sumatera Utara on 2026-06-04	<1%
65	Internet	www.researchgate.net	<1%
66	Student papers	Institut Bisnis dan Teknologi Indonesia (INSTIKI) on 2025-05-30	<1%
67	Student papers	UPN Veteran Yogyakarta on 2026-04-30	<1%

68	Student papers	Universitas Islam Riau on 2025-07-18	<1%
69	Student papers	Universitas Pendidikan Ganesha on 2025-08-05	<1%
70	Student papers	Universitas Putera Batam on 2026-02-02	<1%
71	Student papers	Universitas Sumatera Utara on 2026-05-18	<1%
72	Publication	Fannisa Salsabila Pratiwi, Mula Agung Barata, Aprillia Dwi Ardianti. "IMPLEMENT...	<1%
73	Student papers	Forum Perpustakaan Perguruan Tinggi Indonesia Jawa Tengah on 2026-01-29	<1%
74	Publication	Rengga Hanif Habib Pradipta, Otong Saiful Bachri, Nur Ariesanto Ramdhan. "PEN...	<1%
75	Student papers	Universitas Airlangga-1 on 2025-12-15	<1%
76	Student papers	Universitas Gunadarma on 2025-10-14	<1%
77	Student papers	Universitas Muria Kudus on 2018-08-27	<1%
78	Internet	digilibadmin.unismuh.ac.id	<1%
79	Internet	informatika.unpkediri.ac.id	<1%
80	Internet	repository.uinsaizu.ac.id	<1%
81	Student papers	Abdullah Gul University on 2025-11-20	<1%

82	Student papers	Institut Bisnis dan Teknologi Indonesia (INSTIKI) on 2025-09-16	<1%
83	Student papers	Institut Teknologi Sumatera on 2025-09-22	<1%
84	Student papers	STIKOM Surabaya on 2013-11-19	<1%
85	Student papers	Universitas Budi Luhur on 2026-01-24	<1%
86	Publication	Widyawati Widyawati, Rafli Sidik, Ely Nuryani, Persis Haryo Winasis. "RANCANG B...	<1%
87	Internet	ejurnal.undipa.ac.id	<1%
88	Internet	ijppr.umsida.ac.id	<1%
89	Internet	repositori.unwira.ac.id	<1%
90	Internet	repository.uksw.edu	<1%
91	Publication	Anggita Aprilla, Willy Prihartono, Cep Lukman Rohmat. "OPTIMASI MODEL KLASIF...	<1%
92	Student papers	Fakultas Ekonomi Universitas Indonesia on 2015-11-23	<1%
93	Publication	Maharani, Cheka Putri. "Sistem Pakar Untuk Deteksi Kerusakan Inkubator Bayi D...	<1%
94	Publication	Muhamad Rizvi Roshan, Hafiz Irsyad. "Klasifikasi Kerusakan Uang Rupiah Mengg...	<1%
95	Student papers	Perpustakaan on 2025-08-06	<1%

96	Publication	Rahandya Cahyo, Alda Cendekia Siregar, Barry Ceasar Octariadi. "Implementasi A...	<1%
97	Student papers	Universitas Brawijaya on 2016-07-08	<1%
98	Student papers	Universitas Islam Riau on 2025-10-08	<1%
99	Student papers	Universitas Islam Riau on 2025-10-31	<1%
100	Student papers	Universitas Putera Batam on 2026-01-29	<1%
101	Internet	adam-aprilian.blogspot.com	<1%
102	Internet	ejournal.publine.or.id	<1%
103	Internet	eprints.uny.ac.id	<1%
104	Internet	jurnal.unimed.ac.id	<1%
105	Internet	lantip.respati.ac.id	<1%
106	Internet	repository.ittelkom-pwt.ac.id	<1%
107	Internet	repository.umy.ac.id	<1%
108	Internet	repository.unissula.ac.id	<1%
109	Internet	repository.unpkediri.ac.id	<1%

110	Internet	text-id.123dok.com	<1%
111	Internet	www.ijraset.com	<1%
112	Internet	yopiindrabb.blogspot.com	<1%
113	Publication	Alif Chandra Wijaya, Arditya Baskara Mahbubi, Miftah Fauzi Januarta, Tasya Syabi...	<1%
114	Publication	Ihbal, Ahmad. "Pengaruh Struktur Dewan Terhadap Kinerja Keuangan: Peran Me...	<1%
115	Student papers	Politeknik Negeri Bandung on 2019-08-08	<1%
116	Student papers	UPN Veteran Jakarta on 2026-04-29	<1%
117	Student papers	UPN Veteran Yogyakarta on 2026-05-04	<1%
118	Student papers	Universitas Brawijaya on 2018-12-18	<1%
119	Student papers	Universitas Islam Riau on 2025-12-17	<1%
120	Student papers	Universitas Muhammadiyah Purwokerto on 2025-01-13	<1%
121	Student papers	Universitas Negeri Medan on 2021-06-16	<1%
122	Student papers	Universitas Negeri Semarang on 2023-02-28	<1%
123	Student papers	Universitas Pendidikan Ganesha on 2025-02-18	<1%

124	Student papers	Universitas Sebelas Maret on 2022-02-03	<1%
125	Student papers	Universitas Tarumanagara on 2025-12-21	<1%
126	Internet	elib.pdii.lipi.go.id	<1%
127	Internet	eprints.umg.ac.id	<1%
128	Internet	jurnal.kdi.or.id	<1%
129	Internet	ojs.stiami.ac.id	<1%
130	Internet	repository.unpas.ac.id	<1%
131	Internet	staff.uny.ac.id	<1%
132	Internet	www.digilib.its.ac.id	<1%
133	Publication	Edo Ranov Anjasmara, Farniwati Fattah, Andi Widya Mufila Gaffar. "Implementasi...	<1%
134	Student papers	FAKULTAS ILMU KOMPUTER on 2026-01-08	<1%
135	Publication	Muhammad Ichfan Askar, Askar Taliang, Muhammad Qadri, Muh.Riyaldi Pratama...	<1%
136	Student papers	Perpustakaan on 2025-08-26	<1%
137	Student papers	Politeknik Negeri Lhokseumawe Turnitin on 2026-01-07	<1%

138	Student papers	Politeknik Negeri Lhokseumawe Turnitin on 2026-01-11	<1%
139	Publication	Ridwan Ridwan, Hanny Hikmayanti Handayani, Santi Arum Puspita Lestari, Yana ...	<1%
140	Student papers	Sriwijaya University on 2023-01-09	<1%
141	Student papers	Tarumanagara University on 2026-06-20	<1%
142	Student papers	Transylvania University on 2024-07-25	<1%
143	Student papers	UPN Veteran Yogyakarta on 2026-01-06	<1%
144	Student papers	Universitas Brawijaya on 2018-05-27	<1%
145	Student papers	Universitas Brawijaya on 2019-01-03	<1%
146	Student papers	Universitas Budi Luhur on 2026-01-31	<1%
147	Student papers	Universitas Dinamika on 2026-06-15	<1%
148	Student papers	Universitas Islam Indonesia on 2026-05-12	<1%
149	Student papers	Universitas Islam Riau on 2025-07-17	<1%
150	Student papers	Universitas Islam Riau on 2025-09-10	<1%
151	Student papers	Universitas Islam Riau on 2025-10-08	<1%

152	Student papers	Universitas Islam Riau on 2026-06-15	<1%
153	Student papers	Universitas Muhammadiyah Makassar on 2026-06-25	<1%
154	Student papers	Universitas Muhammadiyah Palembang on 2026-04-23	<1%
155	Student papers	Universitas Pamulang on 2026-05-12	<1%
156	Student papers	Universitas Pamulang on 2026-06-06	<1%
157	Student papers	Universitas Pamulang on 2026-06-22	<1%
158	Student papers	Universitas Pamulang on 2026-06-25	<1%
159	Student papers	Universitas Pendidikan Indonesia on 2025-02-19	<1%
160	Student papers	Universitas Sumatera Utara on 2026-06-05	<1%
161	Student papers	Universitas Tarumanagara on 2025-12-23	<1%
162	Student papers	Universiti Tun Hussein Onn Malaysia on 2026-06-15	<1%
163	Student papers	University of Nairobi on 2025-10-08	<1%
164	Internet	docobook.com	<1%
165	Internet	docplayer.info	<1%

166	Internet	e-journal.uajy.ac.id	<1%
167	Internet	ejournal.um-sorong.ac.id	<1%
168	Internet	ejurnal.mikroskil.ac.id	<1%
169	Internet	id.123dok.com	<1%
170	Internet	jicrs.icros.org	<1%
171	Internet	jurnal.buddhidharma.ac.id	<1%
172	Internet	pustakanet.wordpress.com	<1%
173	Internet	srimulyo-bantul.desa.id	<1%
174	Internet	wiseata.blogspot.com	<1%
175	Student papers	Fakultas Teknik on 2026-05-25	<1%
176	Publication	Gema Umara Muhammad, Erna Zuni Astuti. "Implementation of Convolutional N...	<1%
177	Publication	Saikin Saikin, Mohammad Taufan Asri Zaen, Sofiansyah Fadli, Hairul Fahmi. "Pene...	<1%
178	Student papers	UPN Veteran Yogyakarta on 2026-06-04	<1%
179	Student papers	UPN Veteran Yogyakarta on 2026-06-04	<1%

180	Student papers	Universitas Brawijaya on 2018-03-01	<1%
181	Student papers	Universitas Brawijaya on 2018-03-19	<1%
182	Student papers	Universitas Mulawarman on 2026-04-21	<1%
183	Student papers	Universitas Muria Kudus on 2017-09-15	<1%
184	Student papers	Universitas Muria Kudus on 2019-03-13	<1%
185	Student papers	fpptijateng on 2023-09-25	<1%
186	Student papers	Boston University on 2026-05-13	<1%
187	Student papers	Telkom University on 2025-07-07	<1%
188	Student papers	UPN Veteran Yogyakarta on 2026-03-31	<1%
189	Student papers	Universitas Budi Luhur on 2025-07-10	<1%
190	Student papers	Universitas Jember on 2026-04-06	<1%
191	Student papers	Universitas Muria Kudus on 2016-08-11	<1%
192	Student papers	Universitas Pancasila on 2025-08-25	<1%
193	Student papers	Universitas Sumatera Utara on 2024-12-23	<1%

A. Latar Belakang

Pisang merupakan salah satu komoditas buah yang paling banyak dikonsumsi secara global dan menempati peringkat keempat dalam hal produksi pangan dunia (Upadhyay dkk., 2022). Di antara jenis pisang olah, pisang kepok (*Musa acuminata* × *balbisiana*) memegang peranan vital di Asia Tenggara, khususnya di Indonesia. Pisang ini umumnya diolah menjadi produk pangan seperti keripik atau tepung, dengan karakteristik kulit tebal, tekstur padat, dan rasa kurang manis sebelum dimasak. Nilai ekonominya yang tinggi sebagai bahan baku industri mengharuskan adanya kontrol kualitas yang ketat.

Permasalahan utama dalam penanganan pascapanen pisang kepok adalah sifatnya sebagai buah klimaterik, yang mengalami laju respirasi tinggi setelah dipanen (Prasetyo & Silvia, 2024). Hal ini menyebabkan pisang kepok memiliki karakteristik gampang matang dalam waktu singkat, yang secara langsung memperpendek umur simpan (*shelf life*) buah. Selain itu, penentuan tingkat kematangan pisang kepok masih dilakukan secara manual melalui pengamatan visual yang bergantung pada persepsi individu. Subjektivitas ini menyebabkan ketidakkonsistenan penilaian kualitas dan berpotensi menurunkan efisiensi proses penyortiran (S & Kathirvelan, 2025).

Perkembangan terbaru dalam algoritma *Deep Learning (DL)* dan teknologi *Computer Vision (CV)* menghadirkan beberapa pendekatan (S & Kathirvelan, 2025). Dengan memanfaatkan analisis citra dan model berbasis data, peneliti sedang mengembangkan teknik baru untuk evaluasi kualitas buah yang objektif dan otomatis. Dalam ranah ini, *Convolutional Neural Network (CNN)* telah menjadi alat yang sangat kompetitif (Upadhyay dkk., 2022). CNN adalah jaringan saraf tiruan yang dirancang khusus untuk memproses data pixel secara efektif, memungkinkannya mengekstraksi fitur (*feature extraction*) langsung dari gambar secara otomatis tanpa

intervensi manusia (Gill & Khehra, 2021). Selain itu *Convolutional Neural Network* (CNN) telah banyak digunakan dalam penelitian deteksi kematangan buah karena kemampuannya mengenali pola visual secara otomatis. CNN terbukti efektif pada buah pepaya melalui aplikasi berbasis Android dengan hasil klasifikasi akurat (Sembiring dkk., 2022). Metode serupa juga diterapkan pada buah nanas menggunakan mikrokontroler untuk menentukan tingkat kematangan secara efisien (Jenis dkk., 2021). Selain itu, CNN berhasil digunakan untuk klasifikasi tingkat kematangan mangga Badami melalui pengolahan citra digital (Bili dkk., 2022). Keberhasilan ini menunjukkan potensi CNN yang tinggi untuk diterapkan dalam deteksi kematangan pisang kepok secara objektif dan otomatis.

Berdasarkan hasil penerapan metode *Convolutional Neural Network* (CNN) pada berbagai klasifikasi tingkat kematangan buah, penelitian ini mengimplementasikan arsitektur VGG16 untuk mengklasifikasikan tingkat kematangan pisang kepok berdasarkan citra digital. Model VGG16 digunakan karena memiliki kemampuan yang baik dalam mengekstraksi fitur visual seperti warna, tekstur, dan pola permukaan buah secara otomatis. Sistem yang dikembangkan mampu mengidentifikasi tingkat kematangan pisang kepok secara objektif, cepat, dan akurat sehingga dapat mengurangi kesalahan penilaian yang umumnya terjadi pada proses pengamatan manual. Penerapan sistem ini diharapkan dapat membantu proses penyortiran buah secara otomatis serta meningkatkan efisiensi, konsistensi, dan kualitas pengendalian mutu pada industri pengolahan pisang kepok.

B. Identifikasi Masalah

Berdasarkan latar belakang yang telah dijelaskan, dapat diidentifikasi beberapa permasalahan utama yang menjadi dasar penelitian ini, yaitu:

1. Proses penentuan tingkat kematangan pisang kepok masih dilakukan secara manual sehingga hasilnya bersifat subjektif dan tidak konsisten.
2. Tidak adanya sistem otomatis yang dapat membantu dalam penyortiran kualitas pisang kepok secara cepat dan akurat.

3. Diperlukan metode berbasis pengolahan citra yang mampu mendeteksi tingkat kematangan buah berdasarkan fitur visual seperti warna, tekstur, dan pola bintik pada kulit pisang.

C. Rumusan Masalah

Berdasarkan identifikasi masalah di atas, maka rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana cara menerapkan metode *Convolutional Neural Network* (CNN), khususnya arsitektur VGG16, untuk mendeteksi tingkat kematangan buah pisang kepok berdasarkan grade A (Matang), grade B (Terlalu Matang), dan Grade C (Mentah)?.
2. Bagaimana performa model CNN VGG16 dalam mengklasifikasikan kematangan buah pisang kepok berdasarkan citra digital?.

D. Batasan Masalah

Agar penelitian ini lebih terarah dan fokus, maka ruang lingkup permasalahan dibatasi sebagai berikut:

1. Penelitian hanya difokuskan pada pisang kepok (*Musa acuminata* × *balbisiana*).
2. Data yang digunakan berupa gambar (citra digital) pisang kepok dengan tiga kategori grade kematangan, yaitu Grade A (Matang), Grade B (Terlalu Matang), dan Grade C (Mentah), yang diidentifikasi berdasarkan karakteristik visual kulit pisang.
3. Metode yang digunakan terbatas pada *Convolutional Neural Network* (CNN) dengan arsitektur VGG16.
4. Sistem dibangun untuk tujuan klasifikasi citra, bukan deteksi objek atau prediksi waktu kematangan.
5. Pengujian model dilakukan menggunakan dataset citra pisang dalam kondisi pencahayaan dan latar belakang yang berbeda agar memudahkan para penjual atau pembeli.

89 6. Penelitian ini menggunakan *confusion matrix* sebagai model evaluasi kinerja sistem seperti *Akurasi, Presisi, Recall, dan F1-Score*.

7. Proses *modelling* dilakukan menggunakan tools *Google Coollab*, sedangkan untuk Visualisasi menggunakan Aplikasi *Android Studio*.

E. Tujuan Penelitian

1 Tujuan dari penelitian ini adalah:

1. Menerapkan sistem berbasis CNN VGG16 untuk mendeteksi tingkat kematangan buah pisang kepok ke dalam grade A (Matang), grade B (Terlalu Matang), dan Grade C (Mentah).
2. Menganalisis performa model CNN dalam mengklasifikasikan tingkat kematangan pisang berdasarkan citra digital.

F. Manfaat Penelitian

17 Penelitian ini diharapkan memberikan kontribusi yang signifikan, baik dalam bidang akademik maupun penerapannya secara langsung di dunia industri. Dengan pengembangan sistem klasifikasi kematangan pisang kepok berbasis CNN VGG16, hasil penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

- 15 1. Manfaat Akademik
 - a. Memberikan kontribusi ilmiah dalam penerapan teknik *Deep Learning* untuk bidang pertanian, khususnya dalam klasifikasi kematangan buah.
 - b. Menjadi referensi bagi penelitian selanjutnya yang berkaitan dengan pengolahan citra dan penerapan CNN pada produk hortikultura.
2. Manfaat Praktis
 - a. Membantu petani, pengepul, dan industri pengolahan pisang dalam melakukan penyortiran buah secara otomatis dengan hasil yang lebih objektif.
 - b. Mengurangi tingkat kesalahan manusia (*human error*) dalam menilai kematangan buah, sehingga meningkatkan efisiensi dan kualitas distribusi hasil panen.

3. Manfaat Ekonomis dan Industri

- a. Meningkatkan nilai tambah dan daya saing produk pisang lokal melalui sistem kontrol kualitas berbasis teknologi.
- b. Mendukung pengembangan industri pertanian cerdas (*smart agriculture*) di Indonesia dengan penerapan teknologi visi komputer.

A. Teori dan Penelitian Terdahulu

1. Landasan Teori

a. Pengolahan Citra Digital

Pengolahan citra digital merupakan prosedur sistematis yang mencakup tahapan *akuisisi*, *preprocessing*, *segmentasi*, ekstraksi fitur, hingga klasifikasi untuk menganalisis dan memodifikasi citra demi memperoleh informasi vital. Dalam studi deteksi kematangan buah, teknologi ini mengandalkan indikator visual seperti pergeseran warna, tekstur, dan pola piksel. Penggunaan ruang warna HSV (*Hue*, *Saturation*, *Value*) sering kali lebih diunggulkan dibandingkan RGB karena stabilitasnya yang lebih baik dalam menghadapi variasi intensitas pencahayaan, sehingga efektif untuk membedakan tingkat kematangan, seperti pada pisang Cavendish. Lebih lanjut, penelitian oleh (Megah Sari & Rafli, n.d.) dan (Mulia et al., 2024) menegaskan bahwa ekstraksi fitur statistik meliputi *mean*, *variance*, dan *standard deviation* pada kanal warna dapat merepresentasikan transisi warna kulit pisang dari hijau, kuning, hingga cokelat sebagai penanda utama tingkat kematangan.

b. Kematangan Buah


Kematangan buah merupakan proses fisiologis alami yang ditandai dengan perubahan karakteristik fisik dan kimia seiring perkembangan buah menuju fase siap konsumsi. Pada tahap ini, buah mengalami transformasi warna akibat degradasi klorofil dan peningkatan pigmen seperti karotenoid atau antosianin. Selain perubahan warna, tekstur buah juga mengalami pelunakan karena aktivitas enzim pektinase dan selulase yang memecah dinding sel. Aroma menjadi lebih kuat akibat meningkatnya senyawa volatil, sementara rasa menjadi lebih manis seiring konversi pati menjadi gula

23 sederhana seperti glukosa, fruktosa, dan sukrosa. Pada buah klimaterik seperti pisang, proses kematangan berlangsung cepat karena lonjakan respirasi dan produksi etilen, sehingga perubahan fisik menjadi indikator penting untuk menentukan tingkat kematangan (Hakim dkk., 2022).

66 Dalam praktik industri hortikultura, tingkat kematangan buah umumnya direpresentasikan dalam bentuk grade kualitas, seperti Grade A (Mentah), Grade B (Matang), dan Grade C (Terlalu Matang), untuk memudahkan proses penyortiran dan penentuan standar pasar. Penentuan grade ini didasarkan pada karakteristik visual buah, terutama warna kulit dan tekstur permukaan yang berubah seiring proses pematangan. Pada komoditas pisang, sistem grading terbukti lebih aplikatif dibandingkan klasifikasi kematangan konvensional karena selaras dengan kebutuhan pasar modern. Penerapan teknologi *computer vision* memungkinkan proses penentuan grade dilakukan secara objektif dan konsisten berdasarkan citra digital, sehingga mengurangi subjektivitas penilaian manual (Fatahna dkk, 2025)

176 c. Convolutional Neural Network (CNN)

55 CNN adalah arsitektur *deep learning* yang dirancang untuk mengenali pola visual melalui lapisan konvolusi dan *pooling*. CNN dapat mempelajari fitur visual seperti tekstur, warna, dan bentuk tanpa perlu perhitungan manual. Studi dalam JICOM (Universitas Samudra) menunjukkan efektivitas CNN dalam klasifikasi objek berbasis citra, termasuk komoditas pertanian, karena kemampuannya mengekstraksi pola visual secara akurat meskipun pada data bercampur tekstur dan warna kompleks (Effendi & Hermawan, 2021). Pada penelitian terbaru, CNN terbukti mampu mencapai akurasi tinggi pada klasifikasi tingkat kematangan pisang dalam empat kelas menggunakan dataset real dan sintetik (Chuquimarca dkk., 2025) serta mendukung aplikasi pada sistem deteksi kontaminasi kimia melalui dataset *Ripen Banana* (Alam dkk., 2025). Berikut gambar Arsitektur CNN :




Gambar 2.1 Arsitektur CNN

Gambar 2.1 tersebut menunjukkan alur kerja sebuah *Convolutional Neural Network* (CNN) yang dimulai dari data input, kemudian diproses melalui beberapa lapisan konvolusi. Pada setiap lapisan konvolusi (Conv-1, Conv-2, Conv-3), CNN menggunakan kernel berukuran tertentu ($k_1 \times k_1$, $k_2 \times k_2$, $k_3 \times k_3$) dengan same padding untuk menghasilkan serangkaian feature maps (n_1 , n_2 , n_3 channels). Setiap lapisan bertugas mengekstraksi fitur visual secara bertahap, mulai dari pola sederhana hingga pola yang lebih kompleks. Setelah proses konvolusi selesai, output diratakan melalui proses flatten, kemudian diteruskan ke *fully connected layers* yang menghubungkan semua neuron untuk melakukan proses klasifikasi. Bagian paling kanan menunjukkan beberapa kelas output (misalnya *Alpha*, *Beta*, *Delta*, *Gamma*, *Omicron*) yang diprediksi menggunakan fungsi aktivasi seperti softmax. Secara ringkas, gambar ini menggambarkan bagaimana CNN mengekstraksi fitur dari input hingga menghasilkan keputusan akhir klasifikasi.

d. Convolutional Neural Network (CNN) VGG16

VGG16 merupakan salah satu arsitektur CNN yang paling banyak digunakan untuk klasifikasi citra karena memiliki struktur yang sederhana namun sangat efektif. Model ini diperkenalkan oleh (Arge & Mage, 2015) dalam penelitian berjudul “*Very Deep Convolutional Networks for Large-Scale Image Recognition*”. Berikut gambar arsitektur CNN VGG16:



Gambar 2. 2 Arsitektur CNN VGG16

Gambar 2.2 tersebut menunjukkan arsitektur VGG16, yaitu jaringan CNN dengan 16 lapisan utama yang terdiri dari beberapa blok konvolusi dan max-pooling. Setiap blok konvolusi menggunakan kernel 3×3 secara berulang, dimulai dari kedalaman 64 filter, lalu meningkat menjadi 128, 256, dan 512 pada blok berikutnya. Setelah setiap blok konvolusi, digunakan maxpool untuk mengurangi dimensi fitur namun tetap mempertahankan informasi penting. Setelah seluruh proses ekstraksi fitur selesai, output jaringan diteruskan ke tiga lapisan *fully connected* (FC1 dan FC2 berukuran 4096 neuron, serta FC3 dengan 1000 *neuron*) yang menghasilkan output klasifikasi melalui fungsi *softmax*. Secara ringkas, gambar tersebut memperlihatkan bagaimana VGG16 mengekstraksi fitur visual secara bertahap dari level sederhana hingga kompleks sebelum membuat keputusan klasifikasi akhir.

Penelitian VGG16 dalam klasifikasi buah telah terbukti efektif. (Chuquimarca dkk., 2025) menunjukkan bahwa VGG16 berhasil mengklasifikasikan tingkat kematangan pisang *Cavendish* dengan akurasi tinggi menggunakan kombinasi citra nyata dan sintetis. Sementara itu, (Alam dkk., 2025) memanfaatkan arsitektur serupa dalam dataset *Ripen Banana* untuk mendeteksi kondisi buah terkontaminasi kimia, menunjukkan bahwa VGG16 robust terhadap variasi pencahayaan dan tekstur kompleks.

e. Metode Evaluasi

Evaluasi kinerja model klasifikasi citra dilakukan menggunakan metrik yang berasal dari *confusion matrix*, yang terdiri dari nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Menurut (Bagaskara & Suryanegara, 2021), metrik-metrik evaluasi seperti *akurasi*, *presisi*, *recall*, dan *F1-score* menjadi indikator utama untuk menilai performa model dalam kasus klasifikasi citra pertanian. Akurasi digunakan untuk mengukur proporsi prediksi yang benar terhadap keseluruhan data dengan rumus:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \dots \dots \dots (2.1)$$

Presisi mengukur ketepatan prediksi untuk kelas positif dan dirumuskan sebagai:

$$Precision = \frac{TP}{TP + FP} \dots \dots \dots (2.2)$$

Sementara itu, recall atau sensitivitas menunjukkan kemampuan model dalam mengenali seluruh data positif yang benar dengan rumus:

$$Recall = \frac{TP}{TP + FN} \dots \dots \dots (2.3)$$

F1-score digunakan untuk menyeimbangkan presisi dan recall, terutama pada dataset dengan distribusi kelas tidak seimbang, melalui persamaan:

$$F1 = 2 \times \frac{Precision \cdot Recall}{Precision + Recall} \dots \dots \dots (2.4)$$

Penjelasan Evaluasi model yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). TP dan TN menggambarkan prediksi yang benar, sedangkan FP dan FN menunjukkan kesalahan prediksi, baik ketika model salah menganggap data negatif sebagai positif (FP) maupun gagal mengenali data positif (FN). Dari keempat nilai ini, *accuracy* digunakan untuk melihat seberapa banyak prediksi yang benar secara keseluruhan, sementara *precision* mengukur ketepatan model dalam memprediksi kelas positif. *Recall* menunjukkan kemampuan model dalam menangkap seluruh

data positif sebenarnya. Karena *precision* dan *recall* sering tidak seimbang, *F1-score* digunakan sebagai rata-rata harmonik keduanya, dan faktor $2\times$ pada rumus F1-score berfungsi memastikan bahwa kedua metrik tersebut memiliki bobot yang sama. Dengan demikian, metrik evaluasi ini memberikan gambaran lebih komprehensif tentang kinerja model, terutama pada dataset dengan distribusi kelas yang tidak merata.

Penelitian (Ikasari dkk., 2025) menunjukkan bahwa penggunaan metrik-metrik ini memberikan gambaran mendalam mengenai performa CNN dalam mendeteksi cacat buah. Hal yang sama juga diterapkan oleh (Alam, Islam, Raka, dkk., 2025) dalam evaluasi klasifikasi tingkat kematangan pisang, yang menunjukkan bahwa metrik berbasis confusion *matrix* sangat efektif untuk menilai kualitas model CNN yang bekerja pada citra buah dengan variasi warna yang berdekatan.

f. Cross-Validation

Cross-validation merupakan metode penting dalam proses pelatihan CNN untuk memastikan model mampu melakukan generalisasi dengan baik dan tidak mengalami overfitting. Teknik *K-Fold Cross-Validation* menjadi salah satu metode yang paling banyak digunakan. Pada metode ini, dataset dibagi menjadi K bagian (*fold*), kemudian model dilatih dan diuji sebanyak k kali. Setiap fold akan berperan sebagai data uji satu kali. (Widodo dkk., 2022) menyatakan bahwa teknik ini meningkatkan stabilitas performa model, terutama pada dataset citra pertanian dengan jumlah terbatas. Nilai performa rata-rata K-Fold dihitung menggunakan rumus:

$$CV_{score} = \frac{1}{k} \sum_{i=1}^k S_i \dots \dots \dots (2.5)$$

Dalam rumus validasi, variabel k (disebut k-fold) berfungsi untuk menentukan berapa kali pengujian harus diulang dengan pembagian data yang berbeda-beda agar pengujian adil dan tidak bias. Variabel S_i berfungsi sebagai penampung nilai skor kinerja (seperti akurasi) yang diperoleh dari setiap satu putaran pengujian tersebut (skor ke-1, skor ke-2, dst). Terakhir, CV_{score}

berfungsi sebagai nilai rata-rata final dari penjumlahan seluruh skor S_i yang dibagi dengan jumlah k . Fungsi utama CV_{score} adalah menyimpulkan kestabilan model secara keseluruhan, memastikan bahwa angka performa yang Anda laporkan adalah hasil yang konsisten (*robust*), bukan sekadar kebetulan tinggi karena faktor keberuntungan saat membagi data latih.

2. Kajian Pustaka

Di dunia pertanian global, pisang memegang peranan krusial sebagai salah satu produk hortikultura unggulan dengan tingkat konsumsi yang masif. Pentingnya posisi komoditas ini dalam rantai pasok pangan dunia ditegaskan oleh (Upadhyay dkk., 2022), yang mencatat bahwa pisang menempati urutan keempat dalam skala produksi global. Secara spesifik di Indonesia, varietas pisang kepok (*Musa acuminata* × *balbisiana*) menjadi primadona bagi sektor industri pengolahan makanan. Karakteristik fisiknya yang khas meliputi kulit yang tebal, tekstur daging buah yang padat, serta profil rasa yang lebih optimal setelah melalui proses pemasakan menjadikannya bahan baku ideal untuk produksi keripik, tepung, maupun aneka panganan lainnya. Sejalan dengan hal tersebut, (Md Hasanul Ferdaus a, 2024) menggarisbawahi bahwa besarnya potensi ekonomi pada varietas pisang olahan seperti kepok ini menuntut penerapan metode analisis kualitas dan penyortiran yang lebih objektif serta konsisten demi menjaga standar mutu.

Sebagai buah klimakterik, pisang kepok mengalami peningkatan aktivitas respirasi yang signifikan setelah dipanen. Proses fisiologis ini mempercepat pematangan dan secara drastis mengurangi umur simpan buah. (Prasetyo & Silvia, 2024) menambahkan bahwa perubahan kadar air, produksi etilen, serta peningkatan suhu jaringan turut mempercepat deteriorasi pascapanen. Kondisi tersebut mengakibatkan pisang cepat berubah warna, mengalami kerusakan tekstur, hingga rentan mengalami pembusukan. Tantangan ini semakin besar ketika teknik penilaian kualitas masih dilakukan secara manual melalui inspeksi visual, yang sangat dipengaruhi pengalaman dan persepsi subjektif setiap pekerja.

Metode penilaian visual manual terbukti memiliki tingkat ketidakstabilan yang tinggi. Menurut (S & Kathirvelan, 2025), perbedaan persepsi warna antaroperator dapat menyebabkan hasil penilaian kematangan yang tidak konsisten, berdampak pada kesalahan klasifikasi dan kerugian ekonomi dalam proses penyortiran. Subjektivitas juga menyebabkan ketidakpastian pada tahap distribusi, karena buah yang terlalu matang atau kurang matang sering kali tercampur dan menurunkan kualitas produk akhir. Penelitian (Chen dkk., 2025) menunjukkan bahwa sistem berbasis pengamatan manusia memiliki akurasi jauh lebih rendah dibandingkan sistem berbasis visi komputer dan *deep learning*.

Seiring perkembangan teknologi, pemanfaatan *Deep Learning* dan *Computer Vision* mulai menggantikan metode manual dalam identifikasi kualitas buah. *Deep learning* memungkinkan analisis citra secara otomatis melalui ekstraksi fitur spasial yang stabil. Menurut (Gill dkk., 2022), CNN mampu mempelajari pola visual seperti warna, tekstur, bentuk, hingga noda pada kulit buah tanpa intervensi manusia. Selain itu, CNN memberikan performa yang lebih stabil pada dataset kompleks, termasuk citra buah dengan variasi pencahayaan dan latar belakang yang berbeda. Hal ini dibuktikan oleh penelitian (Bagaskara & Suryanegara, 2021) yang menunjukkan bahwa CNN mengungguli model tradisional seperti KNN dan SVM dalam mendeteksi kualitas buah pada kondisi pencahayaan tidak seragam.


Penggunaan CNN dalam penelitian kualitas buah telah banyak dilaporkan. (Sembiring dkk., 2022) berhasil menggunakan CNN untuk membuat aplikasi deteksi kematangan pepaya berbasis Android dengan akurasi tinggi. Penelitian (Salamah dkk., 2023) menerapkan CNN pada *mikrokontroler* untuk mendeteksi kematangan nanas secara real time dengan tingkat keandalan meningkat. Studi lain oleh (Soekarta dkk., 2023) menggunakan CNN untuk klasifikasi tomat matang dan tidak matang, menunjukkan kinerja model yang robust terhadap variasi warna dan tekstur. Pada buah tropis lainnya, (Rusli, 2024) menerapkan CNN pada klasifikasi kematangan apel dan melaporkan peningkatan akurasi hingga 25% dibandingkan metode tradisional.

11
21
Penelitian terkait pisang juga semakin berkembang. (Chuquimarca dkk., 2025) menunjukkan bahwa CNN berbasis arsitektur VGG16 dan *ResNet* mampu membedakan tingkat kematangan pisang *Cavendish* dengan akurasi lebih dari 95%. (Alam, Islam, Zahan, dkk., 2025) memperkenalkan *Ripen Banana Dataset*, yang menjadi salah satu dataset pisang olahan paling komprehensif dan menunjukkan bahwa CNN tetap stabil meski citra memiliki pencahayaan bervariasi. Selain itu, penelitian (Puteri dkk., 2025) menggunakan CNN untuk mendeteksi cacat internal pisang, membuktikan bahwa *deep learning* tidak hanya mampu mengenali kematangan, tetapi juga cacat struktural.

153
Arsitektur VGG16, yang diperkenalkan oleh (Kualitas dkk., 2021), menjadi salah satu model CNN yang paling banyak digunakan untuk tugas klasifikasi karena struktur jaringan yang dalam namun tetap stabil. VGG16 mengekstraksi fitur secara bertahap mulai dari tepi sederhana hingga pola kompleks, menjadikannya cocok untuk analisis warna dan tekstur pada kulit pisang. (Hermawan dkk., n.d.) menyatakan bahwa VGG16 menghasilkan akurasi lebih tinggi dibandingkan model yang lebih ringan seperti *MobileNet* jika digunakan pada dataset yang memiliki variasi warna sangat dekat, seperti tingkat kematangan buah.

Berdasarkan berbagai penelitian tersebut, dapat disimpulkan bahwa penggunaan CNN khususnya arsitektur VGG16 sangat potensial untuk diterapkan pada klasifikasi kematangan pisang kepok. Selain mengurangi subjektivitas dalam penilaian manual, CNN mampu bekerja secara cepat, akurat, dan konsisten pada berbagai kondisi pencahayaan. Keberhasilan metode ini pada berbagai jenis buah seperti pepaya, nanas, apel, mangga, dan pisang *Cavendish* menunjukkan bahwa penerapan CNN pada pisang kepok merupakan langkah yang tepat untuk meningkatkan efisiensi penyortiran dan kualitas produk industri pengolahan pisang di Indonesia.

B. Kerangka Berpikir



Gambar 2. 3 Kerangka Berpikir

Penelitian tersebut berangkat dari permasalahan bahwa penilaian tingkat kematangan pisang kepok masih dilakukan secara manual, sehingga rentan terhadap subjektivitas dan inkonsistensi. Faktor perubahan fisik buah yang cepat serta kualitas citra yang dipengaruhi pencahayaan juga membuat metode tradisional kurang efektif. Berdasarkan teori pengolahan citra digital, kualitas pencahayaan, dan konsep CNN khususnya arsitektur VGG16 diketahui bahwa model deep learning mampu mengekstraksi pola warna dan tekstur secara otomatis dengan akurasi tinggi.

Kajian penelitian terdahulu menunjukkan bahwa CNN telah berhasil diterapkan pada berbagai buah seperti pepaya, nanas, mangga, dan pisang dengan hasil klasifikasi yang lebih akurat dibandingkan metode tradisional. Oleh karena itu, penelitian ini mengimplementasikan CNN VGG16 untuk membangun sistem

klasifikasi kematangan pisang kepok yang objektif dan efisien. Sistem yang dihasilkan telah terbukti mampu meningkatkan konsistensi penilaian dan mendukung proses penyortiran otomatis dalam industri pengolahan pisang.

BAB III

METODE PENELITIAN

A. Desain Penelitian

Penelitian ini menggunakan Desain Penelitian Pengembangan (*Development Research*), yaitu pendekatan penelitian yang berfokus pada proses perancangan, pengembangan, dan evaluasi suatu produk atau sistem untuk menghasilkan solusi terhadap permasalahan tertentu. Dalam konteks penelitian ini, produk yang dikembangkan adalah sistem klasifikasi tingkat kematangan buah pisang kepok berbasis *Convolutional Neural Network* (CNN) dengan arsitektur VGG16. Desain penelitian pengembangan dipilih karena penelitian ini tidak hanya bertujuan untuk menganalisis fenomena, tetapi juga menghasilkan sistem yang dapat berfungsi secara nyata, mulai dari tahap analisis kebutuhan, perancangan sistem, implementasi model CNN, hingga pengujian dan evaluasi kinerja sistem. Setiap tahapan pengembangan dilakukan secara sistematis untuk memastikan bahwa sistem yang dibangun mampu mengklasifikasikan tingkat kematangan pisang kepok secara objektif, akurat, dan konsisten.

1. Jenis Penelitian (*Research Type*)

Jenis penelitian yang digunakan adalah penelitian pengembangan sistem (*development research*) dengan pendekatan eksperimental berbasis komputasi. Penelitian ini berfokus pada pengembangan dan pengujian model deep learning CNN VGG16 untuk klasifikasi citra pisang kepok ke dalam tiga kelas grade A sebagai Matang, grade B sebagai Terlalu Matang, dan grade C sebagai Mentah. Dalam penelitian ini, proses pengembangan sistem mencakup pengumpulan data citra secara langsung, *preprocessing* data, pelatihan model CNN, serta evaluasi performa menggunakan metrik berbasis *confusion matrix* dan *cross-validation*. Seluruh pengujian dilakukan dalam lingkungan komputasi terkontrol untuk menilai efektivitas sistem yang dikembangkan. Dengan pendekatan ini, penelitian

tidak hanya menghasilkan analisis kinerja model, tetapi juga produk sistem klasifikasi

kematangan buah yang siap digunakan dan dikembangkan lebih lanjut pada skala aplikasi nyata.

a. Pengembangan Algoritma

Pengembangan algoritma dalam penelitian ini merupakan tahapan penting yang bertujuan untuk merancang dan mengimplementasikan metode klasifikasi citra yang sesuai dengan permasalahan deteksi kematangan buah pisang kepok. Algoritma yang dikembangkan harus mampu mengekstraksi fitur visual secara optimal serta menghasilkan performa klasifikasi yang akurat dan konsisten. Oleh karena itu, penelitian ini memfokuskan pengembangan algoritma berbasis deep learning menggunakan arsitektur *Convolutional Neural Network* (CNN) VGG16, yang kemudian diuji dan dievaluasi melalui proses simulasi komputasi.

1. Studi Kasus

Studi kasus pada penelitian ini adalah pengembangan algoritma klasifikasi citra untuk mendeteksi tingkat kematangan buah pisang kepok berdasarkan karakteristik visual kulit buah. Permasalahan yang diangkat adalah bagaimana sistem dapat mengklasifikasikan citra pisang kepok ke dalam tiga grade kematangan, yaitu Grade A (Matang), Grade B (Terlalu Matang), dan Grade C (Mentah), secara otomatis dan objektif. Studi kasus ini berada pada bidang *computer vision*, khususnya klasifikasi citra menggunakan metode *deep learning*.

2. Tahap Pengembangan Algoritma

Tahapan pengembangan algoritma dimulai dengan formulasi masalah klasifikasi kematangan buah pisang kepok berbasis citra digital. Selanjutnya dilakukan pemilihan algoritma *Convolutional Neural Network* (CNN) dengan arsitektur VGG16 sebagai model utama. Model kemudian diimplementasikan menggunakan bahasa pemrograman *Python* dan *framework deep learning*. Tahap berikutnya adalah pelatihan dan

pengujian model menggunakan dataset citra pisang yang telah dikumpulkan, disertai proses evaluasi kinerja menggunakan metrik *akurasi*, *precision*, *recall*, dan *F1-score*. Untuk meningkatkan keandalan hasil, pengujian dilakukan menggunakan teknik *cross validation* dan hasilnya dianalisis secara menyeluruh.

3. Contoh Penerapan

Sebagai contoh penerapan, algoritma CNN VGG16 yang dikembangkan digunakan untuk mengklasifikasikan citra pisang kepok hasil pemotretan langsung dari pasar tradisional. Setiap citra diproses melalui tahap *preprocessing*, diekstraksi fiturnya oleh jaringan CNN, kemudian diklasifikasikan ke dalam kelas kematangan yang sesuai. Hasil klasifikasi ini dapat dimanfaatkan sebagai dasar sistem penyortiran buah secara otomatis pada proses pascapanen.

b. Variabel Penelitian

Variabel penelitian merupakan komponen penting yang digunakan untuk menggambarkan faktor-faktor yang terlibat dalam proses pengembangan dan evaluasi sistem klasifikasi kematangan pisang kepok. Penetapan variabel dilakukan untuk memastikan bahwa penelitian berjalan secara terstruktur, terukur, dan objektif, serta untuk mengetahui hubungan sebab-akibat antara parameter yang diatur dalam model dengan hasil kinerja yang diperoleh. Dalam penelitian ini, variabel penelitian dikelompokkan menjadi variabel independen, variabel dependen, dan variabel kontrol agar proses analisis dapat dilakukan secara sistematis dan valid.

1. Variabel Independen

Dalam penelitian ini Variabel Independen merupakan faktor-faktor yang dimanipulasi untuk melihat pengaruhnya terhadap kinerja model klasifikasi kematangan pisang kepok berbasis CNN VGG16. Variabel tersebut meliputi jumlah *epoch* pelatihan model, ukuran *batch* (*batch size*), nilai learning rate serta jenis *optimizer* yang digunakan, jenis augmentasi data seperti *flip*, *rotation*, *zoom*, dan *brightness*, pembagian

ukuran dataset latih dan uji, serta konfigurasi *fine-tuning* pada arsitektur VGG16. Variasi pada parameter-parameter ini dilakukan untuk memperoleh konfigurasi model yang paling optimal dalam proses pembelajaran.

2. Variabel Dependen

Variabel dependen dalam penelitian ini adalah hasil atau respon yang dihasilkan oleh model akibat perubahan pada variabel independen. Variabel dependen tersebut meliputi tingkat *akurasi* model dalam mengklasifikasikan kematangan pisang kepok, nilai *precision*, *recall*, dan *F1-score* sebagai indikator performa klasifikasi, nilai loss pada data pelatihan dan validasi untuk melihat proses konvergensi model, serta *confusion matrix* yang digunakan untuk mengevaluasi kemampuan model dalam mengklasifikasikan setiap kelas kematangan secara detail.

3. Variabel Kontrol

Sementara itu, variabel kontrol adalah variabel yang dijaga tetap konstan selama penelitian agar hasil yang diperoleh tetap valid dan dapat dibandingkan secara objektif. Variabel kontrol dalam penelitian ini meliputi resolusi citra input yang diseragamkan, struktur dasar arsitektur VGG16 yang digunakan sebagai model utama, spesifikasi perangkat keras yang digunakan selama pelatihan dan pengujian model, lingkungan komputasi berupa bahasa pemrograman *Python* dan *framework TensorFlow*, serta jenis dataset yang terbatas pada citra buah pisang kepok.

2. Metode Pengumpulan Data

Data dalam penelitian ini diperoleh secara langsung melalui proses pengambilan gambar buah pisang kepok di lapangan tanpa menggunakan dataset dari Kaggle ataupun sumber lain. Peneliti melakukan observasi pada buah pisang dengan berbagai tingkat kematangan, kemudian mendokumentasikannya menggunakan kamera smartphone dalam kondisi pencahayaan yang dijaga stabil agar kualitas citra seragam. Setiap gambar diambil dari beberapa sudut dan jarak

untuk menghasilkan variasi yang representatif. Selain data primer berupa citra pisang, peneliti juga mengumpulkan data sekunder melalui studi literatur dari jurnal dan penelitian terdahulu yang mendukung proses perancangan model dan analisis sistem. Kedua jenis data ini digunakan sebagai dasar untuk membangun dan mengevaluasi sistem klasifikasi kematangan pisang yang dikembangkan.

B. Instrumen Penelitian

1. Perangkat Keras

Perangkat keras yang digunakan dalam penelitian ini berupa sebuah laptop yang berfungsi sebagai media utama untuk pengolahan data, pelatihan model, dan evaluasi hasil. Laptop tersebut memiliki spesifikasi prosesor minimal Intel Core i5 atau AMD Ryzen, dengan kapasitas RAM antara 8 hingga 16 GB untuk mendukung proses komputasi deep learning. Selain itu, digunakan media penyimpanan berupa SSD dengan kapasitas minimal 256 GB agar proses pembacaan data dan pelatihan model dapat berjalan lebih cepat dan stabil.

2. Perangkat Lunak

Perangkat lunak yang digunakan dalam penelitian ini meliputi sistem operasi Windows 11 sebagai platform utama. Bahasa pemrograman yang digunakan adalah Python versi 3.10 atau lebih tinggi. Untuk pengembangan dan pelatihan model CNN VGG16 digunakan *library TensorFlow* dan Keras, sedangkan NumPy dan Pandas digunakan untuk pengolahan data. Evaluasi model dilakukan dengan bantuan *Scikit-Learn*, serta visualisasi hasil menggunakan *Matplotlib* dan *Seaborn*. Proses *preprocessing* citra dilakukan menggunakan *OpenCV*. Lingkungan pengembangan yang digunakan meliputi *Jupyter Notebook*, *Visual Studio Code (VSCode)*, dan *Google Colab* untuk mendukung fleksibilitas dalam eksperimen dan pelatihan model. Selain itu, pengembangan aplikasi mobile dilakukan menggunakan Android Studio sebagai IDE utama untuk membangun dan mengintegrasikan model ke dalam platform Android.

3. Dataset

Dataset dalam penelitian ini dikumpulkan secara mandiri dengan mengambil gambar pisang kepok menggunakan kamera smartphone dalam kondisi pencahayaan yang seragam. Setiap gambar diambil dengan latar belakang polos agar fitur visual seperti warna dan tekstur dapat terekstraksi dengan jelas. Proses pengambilan dilakukan pada tiga kategori kematangan yaitu Grade A (Matang), Grade B (Terlalu Matang), dan Grade C (Mentah) dengan jumlah sekitar 625 gambar secara keseluruhan. Setelah dikumpulkan, seluruh citra melalui tahap *preprocessing*, termasuk *resize* piksel, normalisasi nilai piksel, serta pembersihan gambar yang tidak layak seperti buram atau gelap. Selanjutnya, dataset dibagi menjadi data training sebanyak 500 citra dan data testing sebanyak 125 citra untuk pengujian agar proses pelatihan model CNN VGG16 berjalan seimbang dan menghasilkan evaluasi performa yang objektif.

4. Analisis Hasil

Setelah dataset dikumpulkan dan diproses, penelitian ini menggunakan beberapa instrumen analisis hasil untuk mengevaluasi performa sistem klasifikasi. Pengujian fungsional dilakukan melalui metode *White Box Testing* untuk memastikan alur logika program, fungsi *preprocessing*, dan proses prediksi model berjalan sesuai yang dirancang, sedangkan *Black Box Testing* digunakan untuk menguji keluaran sistem berdasarkan input tanpa melihat struktur internal kode. Pada sisi non-fungsional, penelitian memanfaatkan Confusion Matrix untuk menghitung *akurasi*, *precision*, *recall*, dan *F1-score*, serta menggunakan *Mean Absolute Error (MAE)* untuk melihat tingkat kesalahan prediksi secara rata-rata pada output model. Instrumen evaluasi ini memastikan sistem bekerja stabil dan sesuai dengan tujuan penelitian.

Perangkat lunak yang digunakan, seperti Python dengan library *TensorFlow/Keras*, dikonfigurasi untuk menjalankan proses pelatihan dan evaluasi model secara optimal. Lingkungan komputasi disiapkan dengan GPU *support* untuk mempercepat training, sementara struktur folder dataset dibagi menjadi data latih dan data uji untuk menjaga keseimbangan proses pembelajaran

model. Selain itu, beberapa tools pendukung seperti *Google Colab*, *Jupyter Notebook*, atau *Visual Studio Code* digunakan untuk menjalankan kode, mengelola eksperimen, serta memvisualisasikan hasil evaluasi. Dengan demikian, seluruh instrumen tersebut bekerja secara terintegrasi untuk mendukung proses analisis dan memperoleh hasil yang akurat serta dapat dipertanggungjawabkan.

C. Tempat dan Jadwal Penelitian

Penelitian ini dilakukan di Pasar Ngaglik yang terletak di Desa Dandangan Kecamatan Kota , Kota Kediri. Pemilihan lokasi ini dinilai sesuai karena memiliki pasokan buah Pisang yang melimpah. Rencana Kegiatan yang dilakukan selama proses penelitian tertera pada Tabel Berikut :

Tabel 3. 1 Rencana Kegiatan Penelitian

No	Uraian Kegiatan	Bulan 1	Bulan 2	Bulan 3	Bulan 4	Bulan 5	Bulan 6
1	Studi Literatur						
2	Pegumpulan Data						
3	Analisis Sistem						
4	Desain Sistem						
5	Implementasi Model						
6	Uji Coba dan Analisis Hasil						
7	Penyusunan Laporan						

D. Objek Penelitian/ Subjek Penelitian

1. Analisis Kebutuhan Sistem

Analisis kebutuhan sistem dilakukan untuk memastikan bahwa sistem klasifikasi tingkat kematangan pisang kepok berbasis CNN VGG16 dapat berjalan sesuai tujuan penelitian. Sistem ini diharapkan mampu menerima input berupa citra pisang, melakukan *preprocessing*, mengekstraksi fitur, dan

152
70
172
3

menghasilkan prediksi tingkat kematangan secara otomatis. Dari sisi kebutuhan fungsional, sistem harus mampu memuat citra dalam format JPG, melakukan *resizing* dan normalisasi, menjalankan proses ekstraksi fitur melalui model VGG16, serta mengeluarkan hasil klasifikasi lengkap dengan nilai akurasi. Kebutuhan non-fungsional meliputi tuntutan performa yang cepat, stabilitas hasil prediksi, kemudahan penggunaan, portabilitas, dan keamanan data pengguna.

Secara bisnis dan operasional, sistem ini ditujukan untuk membantu petani, pengepul, atau industri kecil dalam mempercepat proses penyortiran pisang kepok secara objektif, mengurangi kesalahan manusia, dan meningkatkan kualitas rantai pasok. Dari sisi pengguna, sistem harus ringkas, mudah dioperasikan, memberikan hasil klasifikasi yang jelas, dan dapat dijalankan tanpa memerlukan pemahaman teknis mendalam. Kebutuhan data penelitian juga ditetapkan secara spesifik, meliputi penggunaan citra non-struktural (gambar) ada 200 gambar atau lebih per label kategori kematangan, dilengkapi variasi kondisi pencahayaan dan sudut pengambilan. Data analitik seperti akurasi, loss, dan confusion matrix digunakan untuk menilai performa model. Struktur kebutuhan ini menjadi dasar utama dalam merancang alur sistem yang akurat, efisien, dan relevan dengan konteks penelitian.

2. Objek Penelitian

1
138

Objek penelitian ini adalah model klasifikasi citra berbasis *Convolutional Neural Network* (CNN) dengan arsitektur VGG16 yang digunakan untuk mendeteksi tingkat kematangan pisang kepok. Pemilihan objek ini dilatarbelakangi oleh permasalahan utama dalam penentuan kematangan pisang kepok yang hingga saat ini masih banyak dilakukan secara manual berdasarkan pengamatan visual, sehingga bersifat subjektif dan tidak konsisten. Kondisi tersebut berpotensi menimbulkan kesalahan dalam proses penyortiran dan penurunan kualitas hasil panen. Arsitektur VGG16 dipilih karena telah terbukti efektif dalam mengekstraksi fitur visual seperti warna dan tekstur, yang merupakan indikator utama tingkat kematangan pisang. Selain model CNN VGG16, dataset citra pisang kepok yang digunakan sebagai input model juga

menjadi bagian dari objek penelitian, termasuk seluruh tahapan preprocessing, pelatihan, validasi, dan pengujian. Pemilihan objek penelitian ini relevan dengan tujuan penelitian, yaitu membangun sistem klasifikasi kematangan pisang kepok yang objektif, konsisten, dan akurat untuk mendukung proses penyortiran secara otomatis.


3. Subjek Penelitian

Subjek penelitian adalah pihak atau sumber data yang berkontribusi dalam penyediaan informasi untuk keperluan penelitian. Dalam penelitian ini, subjek utama adalah citra pisang kepok hasil dokumentasi lapangan yang dikumpulkan secara langsung, karena seluruh proses analisis, pelatihan, dan evaluasi model klasifikasi bergantung pada data citra tersebut. Selain itu, literatur ilmiah berupa jurnal, prosiding, dan laporan penelitian terdahulu digunakan sebagai subjek sekunder untuk memperkuat landasan teori, pemilihan metode, dan perancangan sistem. Adapun pengguna (*user*) dari sistem yang dikembangkan dalam penelitian ini ditujukan kepada pihak yang berkepentingan dalam proses penyortiran dan pengendalian kualitas pisang, seperti petani, pengepul, atau pelaku industri pengolahan pisang, yang berperan sebagai pengguna akhir sistem klasifikasi. Meskipun demikian, penelitian ini tidak melibatkan responden manusia secara langsung, karena seluruh pengujian dilakukan melalui implementasi komputasi.

E. Prosedur Penelitian

Prosedur penelitian pada pengembangan sistem klasifikasi kematangan pisang kepok ini menggunakan metode *Waterfall*, yaitu model pengembangan perangkat lunak yang dilakukan secara bertahap dan sistematis. Metode *Waterfall* dipilih karena memiliki alur kerja yang terstruktur dan jelas, sehingga setiap tahapan pengembangan dapat dilakukan secara berurutan mulai dari analisis kebutuhan hingga pengujian dan dokumentasi. Pendekatan ini sesuai untuk penelitian pengembangan sistem berbasis deep learning karena kebutuhan sistem telah terdefinisi dengan baik sejak awal dan perubahan selama proses pengembangan relatif minimal. Dengan menggunakan

metode *Waterfall*, proses penelitian diharapkan dapat berjalan lebih terkontrol, terdokumentasi dengan baik, serta menghasilkan sistem klasifikasi yang stabil dan sesuai dengan tujuan penelitian. Berikut Grafik Metode *Waterfall* :



Gambar 3. 1 Grafik Metode Waterfall

1. Studi Literatur

Mengumpulkan dan mempelajari berbagai sumber ilmiah seperti buku, jurnal, artikel penelitian, serta referensi terkait *computer vision* dan *deep learning*, khususnya metode CNN dan arsitektur VGG16. Studi literatur ini bertujuan untuk memahami teori dasar, perkembangan penelitian sebelumnya, serta menentukan pendekatan metodologis yang paling relevan untuk penelitian.

2. Pengumpulan Data

Proses Pengumpulan Data dilakukan dengan mengunjungi pasar tradisional atau pusat penjualan buah untuk memperoleh objek penelitian berupa pisang kepok. Setiap sampel pisang difoto menggunakan kamera smartphone dengan latar belakang dan pencahayaan yang dibuat se-seragam mungkin agar hasil citra berkualitas baik. Seluruh gambar kemudian disortir dan diberikan label kematangan grade A sebagai Matang, grade B sebagai Terlalu Matang, dan grade C sebagai Mentah sebagai dasar untuk proses pelatihan model.

3. Analisis Sistem

Berdasarkan Tinjauan Literatur menganalisis kebutuhan penelitian meliputi kebutuhan data, kebutuhan fungsional sistem, serta identifikasi komponen utama yang diperlukan dalam proses klasifikasi citra. Analisis dilakukan untuk menetapkan alur kerja mulai dari *preprocessing* citra, pemrosesan model, hingga evaluasi keluaran model. Hasil analisis ini menjadi dasar untuk menentukan rancangan sistem yang akan dibangun.

4. Desain Sistem

Proses penyusunan rancangan arsitektur pemodelan yang meliputi desain alur *preprocessing*, struktur modul pelatihan model, mekanisme prediksi, serta rancangan alur evaluasi dan Pengiriman Data ke modul klasifikasi. Pada tahap ini juga dirancang konfigurasi arsitektur CNN VGG16 yang akan digunakan, termasuk ukuran input, layer yang *freeze* atau *di-train* ulang, serta skema pembagian dataset. Desain sistem ini memastikan bahwa proses implementasi berjalan sesuai rencana.

5. Implementasi Model

proses membangun dan menjalankan Algoritma *Python* dengan model CNN VGG16 menggunakan *framework* seperti *TensorFlow* atau *Keras*. Proses ini mencakup *preprocessing* citra, pelatihan model, fine-tuning parameter, penyimpanan model, serta integrasi model ke *pipeline* pengujian. Implementasi dilakukan secara bertahap untuk mendapatkan model dengan performa optimal.

6. Uji Coba dan Analisis Hasil

Untuk Mengevaluasi kelayakan logika dan fungsionalitas setiap komponen yang diimplementasikan, maka dilakukan pengujian sistem yang bertujuan untuk menguji model menggunakan data uji dan mengevaluasi performanya menggunakan metrik seperti *akurasi*, *precision*, *recall*, *F1-score*, serta *confusion matrix*. Analisis hasil dilakukan untuk mengidentifikasi tingkat keberhasilan model dalam membedakan tingkat kematangan pisang serta mengevaluasi faktor-faktor yang memengaruhi kesalahan prediksi.

7. Penyusunan Laporan

Semua tahap penelitian dirangkum untuk menyusun laporan ini. Pada tahap ini mencakup pendahuluan, landasan teori, metode penelitian, hasil percobaan, pembahasan, dan kesimpulan. Laporan disusun secara sistematis sebagai bentuk pertanggungjawaban penelitian dan sebagai keluaran akhir dari keseluruhan proses penelitian.


F. Teknik Analisis Data

1. Desain Sistem

a. Arsitektur Sistem (System Architecture)

Pada penelitian ini digunakan pendekatan OOAD (*Object-Oriented Analysis and Design*) untuk menggambarkan alur interaksi pengguna dengan sistem klasifikasi kematangan pisang. Sistem dipandang sebagai kumpulan objek yang saling berinteraksi dalam proses input citra, pemrosesan model CNN VGG16, dan menghasilkan output klasifikasi.


1. Use Case Diagram



Gambar 3. 2 Use Case Diagram

Gambar 3.2 *Use Case Diagram* tersebut menggambarkan interaksi antara pengguna dan sistem. Pada sistem ini, pengguna berperan sebagai aktor utama yang memulai seluruh proses. Pertama, pengguna mengunggah gambar pisang ke dalam sistem. Sistem kemudian memproses gambar tersebut melalui proses preprocessing, seperti *resizing* dan normalisasi. Setelah itu, sistem menjalankan model CNN VGG16 untuk menganalisis citra dan menghasilkan klasifikasi tingkat kematangan. Hasil klasifikasi ditampilkan kepada pengguna dalam bentuk label (Grade A, Grade B, atau Grade C) beserta probabilitas prediksinya. Pengguna juga memiliki opsi untuk menyimpan hasil klasifikasi ke dalam penyimpanan sebagai arsip. Alur ini menunjukkan bahwa seluruh proses dipicu oleh pengguna, sementara sistem menyediakan fungsionalitas otomatis untuk analisis dan penyajian hasil.


2. Activity Diagram



Gambar 3. 3 Activity Diagram

Gambar 3.3 *Activity Diagram* tersebut menjelaskan urutan aktivitas yang dilakukan sistem secara operasional. Proses dimulai ketika pengguna membuka sistem dan mengunggah gambar pisang. Setelah gambar diterima, sistem menjalankan tahapan *preprocessing*, yang meliputi *resizing* citra, normalisasi nilai piksel, atau augmentasi jika diperlukan. Ketika gambar sudah siap, sistem memuat model CNN VGG16 dan kemudian menggunakan model tersebut untuk melakukan prediksi tingkat kematangan. Hasil prediksi yang diperoleh kemudian diproses dan ditampilkan kepada pengguna. Jika diinginkan, sistem dapat menyimpan hasil tersebut ke dalam basis data. Diagram ini memperlihatkan bahwa sistem berjalan secara berurutan dan otomatis, dari input hingga keluarannya, tanpa memerlukan intervensi manual dalam setiap tahap pemrosesan.

3. *Sequence Diagram*




Gambar 3.4 *Sequence Diagram*

Gambar 3.4 *Sequence Diagram* tersebut menunjukkan interaksi antar objek dan modul dalam sistem secara lebih detail. Proses dimulai ketika pengguna mengunggah citra melalui antarmuka pengguna. UI

kemudian mengirimkan citra tersebut kepada modul *preprocessing*. Modul ini melakukan penyesuaian citra, seperti *resize* dan normalisasi, dan kemudian mengirimkan hasil citra yang telah diproses ke model CNN VGG16. Model menjalankan proses inferensi dan menghasilkan prediksi tingkat kematangan. Prediksi tersebut kemudian dikirim ke modul hasil (*Result Processor*) untuk diformat menjadi output yang mudah dipahami. Selanjutnya, hasil akhir dikirim kembali ke UI untuk ditampilkan kepada pengguna. Diagram ini memperlihatkan alur komunikasi antar modul secara runtut, serta bagaimana setiap komponen saling bekerja sama untuk menghasilkan hasil klasifikasi yang akurat.

b. Desain Database (*Database Design*)



Gambar 3. 5 Class Diagram

Gambar 3.5 *Class* diagram ini menunjukkan bahwa sistem terdiri dari beberapa kelas utama yang saling berinteraksi. *User* berperan sebagai aktor yang mengunggah citra pisang melalui kelas *ImageHandler*, yang bertugas

memuat dan memvalidasi citra. Citra kemudian dikirim ke *PreprocessingModule* untuk melalui tahapan seperti *resize*, normalisasi, dan augmentasi. Setelah diproses, citra diteruskan ke VGG16 Model, yang memuat arsitektur VGG16 dan bobotnya untuk melakukan klasifikasi tingkat kematangan. Hasil prediksi kemudian diolah oleh *ResultProcessor*, yang memformat label kematangan serta probabilitas. Jika diperlukan, hasil juga dapat disimpan ke database melalui *DatabaseManager*. Diagram ini menampilkan hubungan uses dan calls yang menggambarkan urutan proses dalam sistem berbasis CNN VGG16.

c. Desain Antarmuka Pengguna (UI/UX Design)



Gambar 3. 6 Desain Antarmuka

Desain UI/UX Banana pada Gambar 3.6 tersebut berfungsi sebagai antarmuka sederhana untuk menghubungkan pengguna dengan sistem klasifikasi kematangan pisang. Bagian *Input* Gambar digunakan untuk mengunggah foto pisang yang akan dianalisis, sedangkan tombol Deteksi

Kualitas berfungsi untuk menjalankan proses klasifikasi oleh sistem. Bagian Hasil Deteksi & Analisis menampilkan keluaran berupa hasil prediksi tingkat kematangan pisang setelah proses selesai. Desain ini dibuat intuitif agar mudah digunakan dan bersifat contoh (*prototype*), sehingga tampilannya masih dapat berubah atau dikembangkan tanpa mengubah fungsi utama sistem.

2. Proses Penyelesaian Masalah

a. Data Input

Data input dalam penelitian ini berupa citra buah pisang kepok yang dikumpulkan melalui proses pemotretan langsung di pasar tradisional. Setiap gambar diambil menggunakan kamera *smartphone* dengan pencahayaan yang cukup dan latar belakang sederhana agar mengurangi *noise* visual yang dapat mengganggu proses ekstraksi fitur. Dataset terdiri dari tiga label kematangan, yaitu grade A sebagai Matang, grade B sebagai Terlalu Matang, dan grade C sebagai Mentah, dengan masing-masing label berjumlah sekitar 200 citra, sehingga total dataset mencapai 625 citra. Setiap citra direkam dalam format JPG dengan resolusi bervariasi sebelum dilakukan penyesuaian. Seluruh gambar kemudian melalui tahap prapemrosesan, seperti *cropping* area objek buah, *resizing* ke untuk mengubah ukuran piksel sesuai standar arsitektur CNN VGG16, serta normalisasi nilai piksel untuk menstabilkan proses pembacaan model. Dengan tahapan ini, semua data benar-benar berada dalam kondisi optimal untuk diproses pada tahap pengolahan data berikutnya.

b. Proses Pengolahan Data

Dataset total ada 625 gambar/citra yang terdiri dari 3 label yaitu grade A sebagai Matang, grade B sebagai Terlalu Matang, dan grade C sebagai Mentah. Masing-masing 200 gambar atau lebih. Akan dilakukan 8-fold *cross-validation* ($k = 8$).

Data Latih = 500 citra

Data Uji = 125 citra

1. Pra-pemrosesan Data (*Preprocessing*)

Seluruh citra masukan diproses melalui beberapa tahapan pra-pemrosesan untuk memastikan kesesuaian data dengan kebutuhan model serta menjaga konsistensi kualitas citra sebelum masuk ke tahap pelatihan. Seluruh citra masukan diproses melalui tahapan berikut:

a. *Resize* citra

Ukuran citra masukan pada penelitian ini masih berada pada tahap pengujian dan disesuaikan dengan kebutuhan arsitektur model CNN yang digunakan. Dalam proses eksperimen, citra diubah ukurannya hingga mendekati ukuran input standar VGG16, agar model dapat menerima citra dengan dimensi yang seragam. Penyesuaian ukuran ini bertujuan untuk mengurangi kompleksitas komputasi sekaligus memastikan kompatibilitas antara data citra dan lapisan input jaringan saraf.

b. Normalisasi nilai piksel

Nilai piksel citra digital yang digunakan berasal dari format citra RGB 8-bit, di mana setiap kanal warna (*Red, Green, Blue*) memiliki rentang nilai 0 hingga 255. Rentang ini berasal dari representasi standar citra digital, di mana nilai 0 menunjukkan intensitas terendah (hitam) dan 255 menunjukkan intensitas tertinggi (putih). Untuk meningkatkan stabilitas proses pelatihan dan mempercepat konvergensi model, dilakukan normalisasi dengan membagi setiap nilai piksel dengan 255 sehingga rentang nilai berubah menjadi 0–1. Pelabelan kelas Setiap citra diberi label numerik:

1. Grade A = Matang
2. Grade B = Terlalu Matang
3. Grade C = Mentah

2. Proses Pelatihan Model (*Training*)

Model yang digunakan adalah CNN VGG16 dengan pendekatan *fine-tuning*, di mana bobot awal berasal dari model *pretrained ImageNet*, kemudian disesuaikan dengan dataset pisang kepok.

a. Inisialisasi Parameter

Pada tahap awal pelatihan model, parameter-parameter ditentukan sebagai parameter awal (*initial setting*) yang selanjutnya akan diuji dan dievaluasi pengaruhnya terhadap kinerja model. Pemilihan nilai ini tidak bersifat final, melainkan digunakan sebagai dasar untuk mengamati perilaku model selama proses pelatihan dan menentukan konfigurasi yang paling optimal. Berikut parameternya :

1. Jumlah Epoch 30 digunakan sebagai nilai percobaan untuk mengamati proses pembelajaran model CNN VGG16. Nilai ini dipilih agar model memiliki kesempatan yang cukup untuk mempelajari pola visual citra pisang kepok, sekaligus memungkinkan peneliti mengevaluasi apakah model mengalami *underfitting* atau mulai menunjukkan gejala *overfitting* sebelum dilakukan penyesuaian lebih lanjut
2. *Batch size* sebesar 8 digunakan sebagai nilai awal pengujian karena mampu memberikan keseimbangan antara efisiensi komputasi dan kestabilan proses pelatihan. Nilai ini memudahkan pengamatan perubahan loss dan akurasi pada setiap iterasi, sehingga dapat dibandingkan dengan konfigurasi batch size lain pada tahap eksperimen berikutnya.
3. Optimizer Adam dipilih sebagai optimizer awal karena memiliki mekanisme penyesuaian learning rate secara adaptif. Penggunaan Adam pada tahap pengujian awal bertujuan untuk memastikan proses pelatihan berjalan stabil, sehingga perubahan kinerja model yang terjadi lebih dipengaruhi oleh variasi parameter lain yang diuji.

4. *Learning rate* 0,0001 digunakan sebagai nilai awal untuk menjaga proses pembaruan bobot berlangsung secara bertahap. Nilai ini dipilih agar model tidak mengalami perubahan bobot yang terlalu drastis pada tahap awal pengujian, sehingga hasil pelatihan dapat dianalisis dengan lebih terkontrol sebelum dilakukan eksperimen dengan nilai *learning rate* yang berbeda.

b. Perhitungan Manual Iterasi Training

Pada setiap fold, jumlah data latih adalah 500 citra. Dengan batch size 8, maka Jumlah batch per epoch = $500 \div 8 = 63$ batch.

Jika jumlah epoch = 30, maka Total iterasi training per fold = $63 \times 30 = 1.890$ iterasi.

Artinya, model melakukan proses forward dan backward propagation sebanyak 1.890 kali untuk setiap fold.

3. Proses Pengujian dan Evaluasi Model

Setelah pelatihan selesai pada setiap *fold*, model diuji menggunakan 120 citra uji. Hasil prediksi dibandingkan dengan label aktual dan disusun ke dalam confusion matrix.

Contoh *Confusion Matrix* (Fold ke-1)

Tabel 3. 2 Confusion Matrix

Actual	Grade A	Grade B	Grade C	Total
Grade A	48	1	0	49
Grade B	5	33	0	38
Grade C	0	0	38	38
Total				125

Jumlah prediksi benar = $48 + 33 + 38 = 119$

Perhitungan Akurasi :

$$Accuracy = \frac{48 + 33 + 38}{125} = \frac{119}{125} = 0,952 = 95,20\%$$

Perhitungan *Precision*, *Recall*, dan *F1-Score*

Perhitungan dilakukan untuk setiap kelas menggunakan nilai TP, FP, dan FN dari *confusion matrix*, kemudian dirata-ratakan menggunakan macro average untuk memperoleh performa keseluruhan model.

4. Perhitungan *Cross-Validation*

Nilai akurasi dari kelima fold dihitung dan dirata-ratakan sebagai berikut:

Tabel 3. 3 Cross-Validation

Fold	Akurasi
1	1.0000
2	1.0000
3	0.9841
4	1.0000
5	1.0000
6	1.0000
7	1.0000
8	1.0000
Rata-Rata	0.9980 (99.80%)

Pada proses 8-fold *cross-validation*, dataset yang digunakan dalam penelitian ini dibagi menjadi 8 bagian (*fold*) secara proporsional. Dengan total data training sebanyak 501 citra, maka setiap *fold* berisi sekitar 62–63 citra. Pada setiap iterasi, satu fold digunakan sebagai data validasi, sedangkan tujuh fold lainnya digunakan sebagai data *training*. Proses ini dilakukan sebanyak 8 kali sehingga setiap bagian data berkesempatan menjadi data validasi.

Model CNN VGG16 dilatih dan diuji pada setiap *fold*, kemudian menghasilkan nilai akurasi yang berbeda-beda.

Kemudian semuanya dijumlahkan dengan Rumus berikut :

$$CV_{score} = \frac{1 + 1 + 0.9841 + 1 + 1 + 1 + 1 + 1}{8}$$

$$CV_{score} = 0.9980 = 99.80\%$$

Hasil ini menunjukkan bahwa model CNN VGG16 memiliki performa yang stabil dan konsisten dalam mendeteksi tingkat kematangan pisang kepok.

c. Data output dan evaluasi

Output utama dari simulasi ini adalah hasil klasifikasi tingkat kematangan pisang kepok beserta nilai probabilitas untuk setiap kelas. Output ditampilkan dalam bentuk label grade A sebagai Mentah, grade B sebagai Matang, dan grade C sebagai Terlalu Matang bersamaan dengan *confidence score* dari model. Untuk mengevaluasi performa model, beberapa metrik evaluasi digunakan, antara lain *akurasi*, *precision*, *recall*, dan *F1-score* yang dihitung melalui *confusion matrix*. *Confusion matrix* memberikan gambaran detail mengenai jumlah prediksi benar dan salah untuk masing-masing kelas. Selain itu, performa model juga dianalisis melalui grafik *training* dan *validation loss* untuk melihat stabilitas proses pembelajaran. Dari tahap evaluasi ini dapat disimpulkan sejauh mana model mampu melakukan klasifikasi secara akurat serta mengidentifikasi potensi bias atau *error* yang muncul. Evaluasi ini menjadi dasar analisis keberhasilan simulasi dan validitas model dalam mendeteksi kematangan pisang secara otomatis.

A. Hasil Penelitian

1. Implementasi Desain Sistem

Bagian ini memaparkan hasil implementasi perancangan sistem yang telah dirancang pada Bab III. Implementasi mencakup dua modul utama, yaitu modul Antarmuka Pengguna (*UI*) dan modul Kecerdasan Buatan (*Artificial Intelligence*), serta keterkaitan antar kedua modul tersebut dalam membentuk alur kerja aplikasi secara keseluruhan:

a. Implementasi Lembar kerja

Bagian Implementasi lembar kerja pada sistem ini terbagi menjadi dua modul utama, yaitu Modul Antarmuka Pengguna (*UI*) dan Modul Kecerdasan Buatan. Berikut penjelasan masing-masing modul beserta fungsi dan tujuannya.

1. Modul Antarmuka Pengguna (UI)

Modul Antarmuka Pengguna merupakan komponen yang berinteraksi langsung dengan pengguna. Modul ini terdiri dari empat halaman (*activity*) yang masing-masing memiliki fungsi dan tujuan tersendiri, yaitu:

a. Halaman Utama

Halaman Utama merupakan tampilan awal (*splash/welcome screen*) saat pengguna pertama kali membuka aplikasi. Antarmuka halaman ini didesain minimalis dengan latar belakang gelap yang memuat logo *visual* buah pisang serta judul aplikasi "Deteksi Tingkat Kematangan Pisang Kepok Berbasis Computer Vision menggunakan arsitektur VGG16". Pada halaman ini, terdapat satu komponen interaktif utama berupa tombol "Mulai". Tombol tersebut berfungsi

sebagai pintu masuk (*trigger*) navigasi yang akan mengarahkan pengguna menuju Halaman Menu.




Gambar 4. 1 Halaman Utama

Berdasarkan Gambar 4.1, tampilan Halaman Utama menampilkan desain yang bersih dan terfokus. Ikon pisang tiga dimensi ditempatkan di bagian tengah atas layar sebagai elemen visual utama yang langsung mengkomunikasikan fungsi aplikasi kepada pengguna. Judul aplikasi ditampilkan dengan tipografi tegas di bawah ikon, diikuti oleh tombol "Mulai" berwarna ungu yang menonjol. Desain minimalis ini bertujuan agar pengguna dapat segera memahami tujuan aplikasi dan langsung memulai proses deteksi tanpa hambatan navigasi yang tidak perlu.

b. Halaman Menu

Halaman Menu berfungsi sebagai hub navigasi utama aplikasi yang menjembatani pengguna setelah melewati halaman awal. Pada aspek estetika antarmuka, visualisasi ikon 3D buah pisang tetap dipertahankan di bagian tengah layar guna menjaga konsistensi skema

desain visual (*design consistency*) di seluruh halaman aplikasi. Halaman menu ini mengimplementasikan tata letak yang berpusat pada pengguna (*user-centered layout*) dengan menyediakan dua komponen interaktif berupa tombol struktural. Pertama, terdapat tombol Deteksi yang bertindak sebagai kendali utama untuk mengarahkan pengguna masuk ke fitur pemindaian pada Halaman Kamera. Kedua, terdapat tombol Kembali yang dirancang secara ergonomis untuk memfasilitasi alur kerja pengguna (*user workflow*) apabila ingin membatalkan aksi dan melakukan navigasi mundur ke Halaman Utama.




Gambar 4. 2 Halaman Menu

Berdasarkan Gambar 4.2, Halaman Menu menampilkan dua tombol navigasi utama yang tersusun secara vertikal di bagian tengah layar. Penempatan tombol yang simetris dan konsisten secara warna dengan halaman sebelumnya memberikan pengalaman navigasi yang nyaman dan intuitif. Tombol "Deteksi" diposisikan di atas sebagai aksi utama yang mendorong pengguna untuk segera memulai proses

deteksi, sementara tombol "Kembali" ditempatkan di bawahnya sebagai opsi sekunder. Konsistensi penggunaan elemen ikon pisang dan palet warna gelap di seluruh halaman memperkuat identitas visual aplikasi.

c. Halaman Kamera

Halaman Kamera merupakan implementasi teknis dari subsistem akuisisi data citra yang berfungsi sebagai penangkap masukan (*input*) utama ke dalam sistem. Antarmuka pada halaman ini dirancang untuk mengintegrasikan fungsionalitas kamera bawaan perangkat Android secara langsung, sehingga dapat melakukan pemindaian objek buah pisang kepok secara real-time. Di dalam visualisasi halaman ini, terdapat sebuah bingkai pembatas berbentuk persegi panjang (*bounding box*) berwarna biru yang ditempatkan secara presisi di area tengah layar. Bingkai pembatas ini berfungsi sebagai panduan visual (*visual guide*) bagi pengguna agar dapat memosisikan objek buah pisang kepok secara optimal, sehingga fokus lensa kamera dan intensitas cahaya dapat terjaga guna menghasilkan kualitas citra yang stabil. Selain mengandalkan pemindaian otomatis, halaman ini juga dilengkapi dengan komponen interaktif berupa tombol "Ambil Gambar" yang ditempatkan di bagian bawah bingkai kamera. Kehadiran tombol ini berfungsi sebagai fungsi alternatif atau mekanisme cadangan (*fallback mechanism*) untuk menangkap citra secara manual (*capture*). Fitur manual ini sangat krusial untuk mengantisipasi kondisi di lapangan, seperti ketika fitur deteksi otomatis secara real-time mengalami kendala akibat fluktuasi pencahayaan, latar belakang yang terlalu bising (*cluttered background*), atau pergerakan perangkat yang tidak stabil. Melalui kombinasi pemindaian real-time dan pengambilan gambar manual ini, sistem dapat memastikan ketersediaan data citra berkualitas tinggi sebelum diteruskan ke tahap pemrosesan klasifikasi.




Gambar 4. 3 Halaman Kamera

Berdasarkan Gambar 4.3, Halaman Kamera menampilkan area pratinjau kamera yang luas dan mendominasi layar, dibatasi oleh bingkai berwarna biru sebagai panduan penempatan objek. Tombol "Ambil Gambar" ditempatkan di bagian bawah layar dengan posisi yang mudah dijangkau oleh ibu jari pengguna, mengikuti prinsip ergonomi desain mobile. Kombinasi antara fitur pemindaian real-time dan tombol pengambilan gambar manual memastikan sistem dapat memperoleh citra berkualitas tinggi pada berbagai kondisi pencahayaan dan lingkungan pengambilan gambar.

d. Halaman Hasil

Halaman Hasil berfungsi sebagai antarmuka luaran untuk menyajikan informasi dari proses klasifikasi berbasis *Deep Learning* yang telah dilakukan. Antarmuka pada halaman ini dirancang untuk menampilkan kembali citra buah pisang kepok yang telah ditangkap sebagai bentuk validasi objek. Tepat di bawah citra tersebut, sistem menampilkan informasi tekstual berupa hasil grade kematangan serta

nilai akurasi (*confidence score*) model yang direpresentasikan dalam satuan persen. Pada bagian bawah halaman, terdapat tombol "Kembali" yang berfungsi untuk mengarahkan pengguna menuju ke Halaman Utama, sehingga pengguna dapat langsung memulai proses pemindaian objek yang baru.



Gambar 4. 4 Halaman Hasil

Berdasarkan Gambar 4.4, Halaman Hasil menampilkan area besar di tengah layar yang diperuntukkan bagi citra pisang yang telah dianalisis, sehingga pengguna dapat memvalidasi secara visual bahwa gambar yang diproses adalah benar. Di bawah area gambar, sistem menampilkan teks hasil klasifikasi yang mencakup grade kematangan dan nilai *confidence score*. Desain yang bersih dan terfokus ini memudahkan pengguna membaca hasil deteksi dengan cepat tanpa distraksi dari elemen antarmuka yang tidak relevan.

2. Modul Kecerdasan Buatan (*Artificial Intelligence*)

Modul Kecerdasan Buatan merupakan inti dari sistem deteksi yang mengolah citra masukan dan menghasilkan prediksi kelas kematangan

pisang kepok. Modul ini dibangun menggunakan metode *Convolutional Neural Network (CNN)* dan diintegrasikan ke dalam aplikasi *Android*. Tahapan yang dilakukan dalam modul ini adalah sebagai berikut:

a. Tahap Input Citra

1. Mekanisme Kerja

Modul AI/Kecerdasan Buatan menerima kiriman berkas mentah berupa citra digital buah pisang kepok yang dikirimkan oleh Modul UI (baik hasil tangkapan langsung dari *Layout Kamera Deteksi* maupun unggahan berkas gambar dari galeri *smartphone*).

2. Karakteristik Data

Citra yang diterima pada tahap ini masih memiliki karakteristik yang sangat beragam, seperti ukuran resolusi yang tidak seragam (tergantung spesifikasi kamera pengguna), format ekstensi berkas yang berbeda (JPEG, PNG), serta tingkat pencahayaan latar belakang (*background*) yang bervariasi. Citra mentah ini belum bisa langsung diolah oleh jaringan saraf tiruan dan harus dialirkan ke tahap berikutnya.

b. Tahap Pra-pemrosesan Citra (*Image Preprocessing*)

Sebelum citra dianalisis oleh arsitektur VGG16, citra mentah harus melewati fase standardisasi dan pembersihan agar model dapat bekerja dengan efisien dan akurat. Tahap ini terdiri dari beberapa sub-proses:

1. Pengubahan Ukuran (*Resizing*)

Gambar mentah dipotong dan diubah dimensinya secara otomatis disesuaikan dengan skenario pengujian ukuran yang digunakan, meliputi pengujian ukuran A (89x89 piksel), ukuran B (128x128 piksel), ukuran C (224x224 piksel), dan ukuran D (512x512 piksel) dengan aspek rasio 3 saluran warna (RGB). Variasi dimensi input ini diterapkan untuk menguji fleksibilitas dan performa arsitektur jaringan saraf konvolusional VGG16

terhadap resolusi citra yang berbeda sebelum ditentukan ukuran yang paling ideal.

2. Normalisasi Nilai Piksel

Nilai asli piksel warna citra yang berkisar antara 0 hingga 255 dikonversi ke dalam skala numerik antara 0 dan 1 (atau rentang -1 hingga 1). Proses matematika ini bertujuan untuk mempercepat waktu konvergensi saat model melakukan komputasi dan mencegah terjadinya komputasi ekstrem (*exploding gradients*) di dalam jaringan saraf.

c. Tahap Ekstraksi Fitur & Klasifikasi (Arsitektur VGG16)

1. Ekstraksi Fitur (*Feature Extraction*)

Karakteristik visual dari citra masukan masih akan diuji nantinya melalui tahapan simulasi dengan melewatkannya secara bertahap ke dalam 16 lapisan konvolusi (*convolutional layers*) dan lapisan penalaran maksimum (*max-pooling layers*). Melalui pengujian ini, performa model dalam mendeteksi fitur visual dasar seperti garis tepi, sudut, gradasi warna, hingga fitur kompleks yang spesifik seperti tekstur bercak kematangan pada kulit pisang kepok akan dievaluasi secara mendalam.

2. Klasifikasi (*Classification Layer*)

Setelah fitur-fitur visual berhasil diringkas ke dalam bentuk vektor padat, data tersebut diteruskan ke bagian akhir VGG16, yaitu 3 lapisan terkoneksi penuh (*fully connected layers* atau *Dense Layers*). Di sini, fitur visual dikorelasikan secara matematis untuk menghitung kecenderungan karakteristik objek pisang tersebut lebih condong ke arah kelas kematangan yang mana.

d. Tahap *Output* Hasil Klasifikasi

Fase ini merupakan tahapan akhir dari lembar kerja AI yang menerjemahkan perhitungan matematis di latar belakang menjadi informasi yang siap konsumsi.

1. Mekanisme Kerja

Pada lapisan terakhir (*output layer*), sistem menerapkan fungsi aktivasi *Softmax*. Fungsi ini bertugas mengubah nilai bobot numerik mentah dari *fully connected layer* menjadi nilai probabilitas atau persentase peluang (antara 0% hingga 100%) untuk masing-masing kelas kematangan.

2. Pengiriman Data

Modul AI akan memilih satu kelas dengan nilai probabilitas tertinggi sebagai keputusan akhir (misalnya: "Grade A" dengan *confidence score* 95,20%). Label *string* dan nilai persentase ini kemudian dikemas kembali menjadi data output digital untuk dikirimkan secara instan ke Modul UI, sehingga dapat ditampilkan di *Layout Hasil* untuk dibaca oleh pengguna.

b. Keterkaitan Antar Lembar Kerja

Keterkaitan antar lembar kerja menggambarkan hubungan fungsional dan integrasi aliran data (*data flow*) antara Modul Antarmuka Pengguna (*User Interface*) dan Modul Kecerdasan Buatan (*Artificial Intelligence*). Kedua modul ini tidak berdiri sendiri, melainkan saling bertukar data secara sinkron untuk menjalankan fungsi aplikasi secara utuh. Berikut adalah poin-poin keterkaitan erat antar lembar kerja dalam aplikasi:

1. Keterkaitan pada Proses Akuisisi Citra (UI Aplikasi ke Masukan AI)

Proses interaksi sistem dimulai secara langsung pada lembar kerja antarmuka pengguna, tepatnya melalui *Layout Kamera Deteksi*. Ketika pengguna menekan tombol tangkap kamera atau memilih berkas dari galeri, lembar kerja UI bertindak sebagai gerbang pertama pengumpul data mentah. Berkas citra buah pisang kepok yang berhasil diambil oleh UI ini kemudian dikirimkan secara instan ke *back-end* sistem untuk dijadikan sebagai data masukan (*input*) utama bagi lembar kerja kecerdasan buatan. Tanpa adanya input berkas yang dikirimkan oleh

komponen UI ini, lembar kerja kecerdasan buatan tidak akan terpicu untuk memulai siklus komputasinya.

2. Keterkaitan pada Tahap Pra-pemrosesan Citra (*Preprocessing* di Sisi AI)

Setelah lembar kerja kecerdasan buatan menerima kiriman berkas gambar dari komponen UI, modul AI akan melakukan fungsi penyaringan dan standardisasi melalui tahap *image preprocessing*. Pada alur sistem ini, proses input citra dari UI ke AI akan dikonfigurasi secara adaptif berdasarkan hasil performa terbaik pada uji *input size* yang telah dieksperimenkan. Keterkaitan pada tahap ini memastikan bahwa variasi spesifikasi perangkat keras kamera pada UI dapat diselaraskan secara optimal melalui penyesuaian dimensi resolusi yang terbukti menghasilkan performa model paling tinggi.

3. Keterkaitan pada Proses Klasifikasi dan Analisis Fitur (VGG16 di Sisi AI)

Lembar kerja kecerdasan buatan memegang kendali penuh pada tahap ini dengan mengeksekusi citra hasil standardisasi dimensi input menggunakan arsitektur jaringan saraf konvolusional CNN VGG16. Algoritma AI bekerja di latar belakang (*background process*) untuk mengeksplorasi nilai piksel, mengekstraksi fitur warna kulit buah, serta mendeteksi tekstur bercak kematangan pada pisang kepok. Hasil komputasi dari proses ini adalah keputusan matematis berupa label kelas kematangan beserta tingkat kepercayaan prediksi (*confidence score*). Lembar kerja AI kemudian mengemas hasil analisis ini menjadi format data digital terstruktur yang siap dibaca kembali oleh komponen antarmuka pengguna.

4. Keterkaitan pada Tahap Visualisasi Informasi (Keluaran AI ke Tampilan Akhir UI)

Hubungan timbal balik antara kedua modul ini diakhiri dengan pengiriman data hasil prediksi dari lembar kerja kecerdasan buatan kembali ke lapisan antarmuka pengguna. Data string berupa label kematangan (misalnya "Grade A") beserta nilai akurasi prediksi yang

dihasilkan oleh modul AI ditangkap oleh komponen *front-end* aplikasi. UI aplikasi kemudian memetakan data tersebut dan menampilkannya secara informatif pada *Layout* Hasil. Melalui keterkaitan akhir ini, pengguna dapat membaca hasil klasifikasi cerdas secara visual, lengkap dengan gambar pisang yang diuji di dalam satu halaman antarmuka.

2. Pengujian Fungsional

Pengujian fungsional dilakukan menggunakan metode pengujian *blackbox*. Metode ini menguji perilaku aplikasi dari sisi pengguna dengan memberikan masukan tertentu dan mengamati keluaran yang dihasilkan, tanpa memperhatikan proses internal kode program. Pengujian dilakukan pada empat modul utama aplikasi secara terpisah untuk memastikan setiap fungsi berjalan sesuai spesifikasi yang dirancang pada Bab III.

a. Pengujian Modul Halaman Utama

Untuk menguji tingkat kesiapan elemen pada halaman awal aplikasi saat pertama kali dijalankan oleh pengguna, dilakukan skenario pengujian fungsional yang tertera pada tabel di bawah ini.

Tabel 4. 1 Pengujian Fungsional Modul Halaman Utama

No	Nama Pengujian	Deskripsi Pengujian	Hasil yang Diharapkan
1	Tampilan Halaman Utama	Membuka aplikasi untuk pertama kali	Halaman utama ditampilkan dengan judul aplikasi, gambar pisang, dan tombol Mulai
2	Fungsi Tombol Mulai	Pengguna menekan tombol Mulai pada halaman utama	Sistem berpindah ke Halaman Menu

Berdasarkan Tabel 4.1, kedua skenario pengujian pada Modul Halaman Utama menghasilkan status Berhasil. Halaman utama berhasil ditampilkan

dengan seluruh elemen yang dirancang dan fungsi navigasi tombol Mulai bekerja dengan benar mengarahkan pengguna ke Halaman Menu.

b. Pengujian Modul Halaman Menu

Navigasi lanjutan yang berfungsi sebagai penghubung fitur utama aplikasi diuji fungsionalitasnya melalui serangkaian tindakan pengguna sebagaimana dijabarkan pada tabel berikut.

Tabel 4. 2 Pengujian Fungsional Modul Halaman Menu

No	Nama Pengujian	Deskripsi Pengujian	Hasil yang Diharapkan
1	Tampilan Halaman Menu	Pengguna masuk ke halaman menu setelah menekan tombol Mulai	Halaman menu ditampilkan dengan tombol Deteksi dan tombol Kembali
2	Fungsi Tombol Deteksi	Pengguna menekan tombol Deteksi pada halaman menu	Sistem berpindah ke Halaman <i>Camera</i> untuk memulai proses deteksi
3	Fungsi Tombol Kembali	Pengguna menekan tombol Kembali pada halaman menu	Sistem berpindah kembali ke Halaman Utama

Berdasarkan Tabel 4.2, seluruh tiga skenario pengujian pada Modul Halaman Menu menghasilkan status Berhasil. Halaman Menu ditampilkan dengan lengkap, tombol "Deteksi" berhasil mengarahkan pengguna ke Halaman *Camera*, dan tombol "Kembali" berhasil mengembalikan pengguna ke Halaman Utama.

c. Pengujian Modul Halaman *Camera*

Fungsionalitas pengambilan data citra melalui sensor kamera gawai serta pengiriman data gambar ke dalam sistem diuji secara intensif menggunakan parameter uji pada tabel di bawah ini.

Tabel 4. 3 Pengujian Fungsional Modul Halaman *Camera*

No	Nama Pengujian	Deskripsi Pengujian	Hasil yang Diharapkan
1	Tampilan Pratinjau Kamera	Pengguna masuk ke halaman kamera dari halaman menu	Pratinjau kamera real-time ditampilkan pada komponen <i>PreviewView</i> berukuran 300x300 dp
2	Fungsi Tombol Ambil Gambar	Pengguna menekan tombol Ambil Gambar	Kamera mengambil gambar melalui intent <i>ACTION_IMAGE_CAPTURE</i> , data bitmap dikirim ke <i>Activity</i> Hasil
3	Transfer Data Bitmap	Setelah gambar diambil, data dikirim ke halaman hasil	Bitmap gambar pisang berhasil diterima Halaman Hasil melalui <i>Intent.putExtra</i>

Berdasarkan Tabel 4.3, ketiga skenario pada Modul Halaman *Camera* berhasil dieksekusi. Pratinjau real-time tampil sesuai spesifikasi, pengambilan gambar berjalan normal, dan transfer data bitmap ke Halaman Hasil berhasil tanpa kehilangan data.

d. Pengujian Modul Halaman Hasil

Sebagai gerbang akhir pemrosesan, bagian visualisasi kelas kematangan dan skor kepercayaan model diuji akurasi penampilannya lewat rancangan pengujian pada tabel berikut.

Tabel 4. 4 Pengujian Fungsional Modul Halaman Hasil

No	Nama Pengujian	Deskripsi Pengujian	Hasil yang Diharapkan
1	Tampilan Gambar Hasil	Halaman Hasil menerima bitmap gambar dari Halaman Camera	Gambar pisang yang difoto ditampilkan pada <i>ImageView</i> di halaman hasil
2	Proses Klasifikasi CNN	Sistem menjalankan model TFLite (model_pisang.tflite)	Model <i>Classifier</i> memproses <i>bitmap</i> 224x224 dan menghasilkan prediksi kelas beserta persentase akurasi
3	Tampilan Hasil Kualitas	Model selesai melakukan inferensi terhadap gambar pisang	Hasil klasifikasi (Grade A/Grade B/Grade C) dan tingkat akurasi ditampilkan pada <i>TextView</i>
4	Fungsi Tombol Kembali	Pengguna menekan tombol Kembali pada halaman hasil	Sistem berpindah langsung ke halaman utama

Penjelasan Tabel 4.4, Skenario uji fungsional akhir pada Modul Halaman Hasil membuktikan bahwa komponen *ImageView* sukses menampilkan kembali foto pisang yang diambil sebelumnya. Secara simultan, di latar belakang sistem sukses memicu berkas model_pisang.tflite untuk melakukan komputasi inferensi dan berhasil memetakan hasil klasifikasi (Grade A, B, atau C) serta skor kepercayaan ke dalam *TextView* secara akurat. Tombol navigasi akhir menuju Halaman Utama juga berhasil tereksekusi dengan baik.

3. Pengujian Non-Fungsional

Pengujian non-fungsional dilakukan untuk mengukur performa dan kualitas model CNN yang diintegrasikan ke dalam aplikasi. Pengujian ini mencakup empat tahap: (a) uji arsitektur model CNN, (b) uji ukuran input citra, (c) uji performa menggunakan K-Fold Cross Validation, dan (d) uji akurasi model final menggunakan confusion matrix dan metrik evaluasi. Hasil *Confusion Matrix – Fold Representatif*. Hasil *Confusion matrix* berikut merupakan hasil pengujian pada salah satu fold representatif (Fold ke-1) dengan jumlah data uji sebanyak 125 citra:

a. Uji Arsitektur Model VGG16

Uji arsitektur dilakukan untuk memastikan bahwa arsitektur model VGG16 yang diterapkan telah sesuai dengan kebutuhan sistem klasifikasi kematangan pisang. Model VGG16 yang digunakan merupakan arsitektur *deep learning* dengan 16 lapisan berbobot, terdiri dari 13 lapisan konvolusi dan 3 lapisan *fully connected*. Pada penelitian ini, teknik *transfer learning* diterapkan dengan menggunakan bobot *pretrained* dari dataset *ImageNet*, di mana lapisan *fully connected* pada bagian atas digantikan dengan lapisan klasifikasi baru yang disesuaikan dengan jumlah kelas kematangan pisang yang dideteksi.

Arsitektur model yang diimplementasikan telah berhasil dikompilasi dan dapat berjalan dengan baik pada lingkungan pengembangan yang digunakan. Pengujian arsitektur memastikan model dapat menerima input berupa gambar dengan dimensi yang telah ditentukan, memproses fitur melalui lapisan-lapisan konvolusi, dan menghasilkan output berupa probabilitas masing-masing kelas kematangan pisang.

Tabel 4. 5 Spesifikasi Arsitektur Model VGG16

Komponen Arsitektur	Keterangan
Base Model	VGG16 (pretrained ImageNet)

Lapisan Konvolusi	13 lapisan konvolusi
Lapisan <i>Fully Connected</i>	3 lapisan (2 <i>pretrained</i> + 1 <i>custom</i>)
<i>Activation Function</i>	<i>ReLU (konvolusi), Softmax (output)</i>
<i>Optimizer</i>	Adam
<i>Loss Function</i>	<i>Categorical Crossentropy</i>
Jumlah Kelas Output	Sesuai kelas kematangan pisang
Teknik	<i>Transfer Learning + Fine-tuning</i>

Berdasarkan Tabel 4.5, arsitektur VGG16 yang diimplementasikan menggunakan base model pretrained dari ImageNet dengan *optimizer Adam* dan fungsi loss *Categorical Crossentropy*. Arsitektur model yang diimplementasikan telah berhasil dikompilasi dan dapat berjalan dengan baik pada lingkungan pengembangan yang digunakan.

b. Uji Ukuran Input Citra

Uji performa non-fungsional dilakukan melalui skenario eksperimen dengan membandingkan hasil akurasi validasi model pada empat variasi kelompok, yaitu pengujian ukuran A (89x89 piksel), pengujian ukuran B (128x128 piksel), pengujian ukuran C (224x224 piksel), dan pengujian ukuran D (512x512 piksel). Eksperimen ini bertujuan untuk menganalisis secara empiris batas limitasi dimensi masukan yang paling optimal bagi arsitektur model pada dataset kematangan pisang kepok yang digunakan.

Tabel 4. 6 Hasil Uji Performa Variasi Ukuran Input

Ukuran Input	Val Akurasi
89 x 89	0,7661
128 x 128	0,8387
224 x 224	0,9032
512 x 512	Error

Berdasarkan hasil uji, ukuran 224×224 piksel menghasilkan validasi akurasi tertinggi sebesar 90,32% sehingga ditetapkan sebagai ukuran input standar untuk seluruh tahapan eksperimen berikutnya. Ukuran 512×512 tidak dapat diuji karena perangkat mengalami *error Out-of-Memory* (OOM) akibat keterbatasan kapasitas RAM dan GPU laptop yang digunakan.

c. Uji Performa – K-Fold Cross Validation

Setelah diperoleh ukuran input terbaik (224x224), dilakukan pengujian K-Fold *Cross Validation* dengan variasi jumlah fold, yaitu K=3, K=5, dan K=8. Pengujian ini bertujuan untuk menentukan jumlah fold yang menghasilkan kinerja model paling optimal sebelum dilakukan proses training akhir.

Tabel 4. 7 Rekapitulasi Hasil K-Fold Cross Validation

Model	K=3	K=5	K=8
Model A	99,20%	99,00%	99,80%
Model B	97,00%	80,40%	98,61%
Model C	98,00%	98,80%	99,01%

Hasil eksperimen menunjukkan bahwa Model A dengan $K=8$ menghasilkan rata-rata validasi akurasi tertinggi sebesar 99,80%, sehingga ditetapkan sebagai konfigurasi terbaik. Konfigurasi ini selanjutnya digunakan sebagai dasar pelatihan model final.

d. Uji Akurasi Model Final – *Confusion Matrix* dan Metrik Evaluasi


Setelah ditentukan konfigurasi terbaik (ukuran input 224×224 , $K=8$, Model A), dilakukan proses training akhir menggunakan seluruh data latih untuk menghasilkan model final yang akan digunakan pada sistem aplikasi. Hasil *training* akhir menunjukkan akurasi sebesar 95,20%. Evaluasi akhir dilakukan menggunakan *Confusion Matrix* untuk menganalisis distribusi hasil prediksi pada setiap kelas kematangan pisang. *Confusion Matrix* memberikan gambaran rinci mengenai jumlah prediksi yang tepat (*True Positive*) maupun yang salah diklasifikasikan (*False Positive* dan *False Negative*) untuk setiap kelas.

Tabel 4. 8 Rekapitulasi Hasil Pengujian Non Fungsional

Jenis Pengujian	Parameter	Hasil
Uji Ukuran Input	Ukuran 224×224	Val Akurasi 90,32%
K-Fold Validation	$K=8$, Model A	Akurasi 98,80%
Training Akhir	$K=8$, size 224	Akurasi 95,20%

Berdasarkan Tabel 4.8, di atas menyimplifikasi parameter-parameter terbaik yang berhasil disaring dari seluruh rangkaian fase eksperimen non-fungsional. Parameter komputasi terpilih ini kemudian dijadikan landasan mutlak untuk melakukan proses pelatihan akhir (*final training*) model kecerdasan buatan secara menyeluruh menggunakan keseluruhan alokasi dataset buah pisang kepok yang tersedia. Model final kemudian diuji terhadap

125 data uji. Hasil pengujian divisualisasikan melalui *confusion matrix* berikut.



Gambar 4. 5 *Confusion Matrix* – Model Final

Gambar di atas menyajikan grafik *Confusion Matrix* yang merepresentasikan perbandingan antara kelas yang sebenarnya (*True Class/Actual*) dengan kelas yang diprediksi oleh model (*Predicted Class*). Berdasarkan sebaran data pada matriks tersebut, model CNN VGG16 menunjukkan performa klasifikasi yang sangat kuat dan presisi. Dari total 125 data sampel yang diuji, model berhasil mengklasifikasikan buah pisang kepok secara tepat ke dalam tiga kelas utama. Keberhasilan mutlak diraih pada kelas Grade C (Mentah), di mana seluruh 38 sampel data uji berhasil ditebak dengan benar tanpa ada satu pun sampel yang meleset atau tertukar dengan kelas lain (*True Positive* sempurna).

Sementara itu, pada kelas Grade A (Matang), sistem mampu mendeteksi secara akurat sebanyak 48 sampel data dari total 49 sampel yang tersedia, dengan hanya 1 sampel yang salah diprediksi. Tantangan visual terkonsentrasi pada kelas Grade B (Terlalu Matang), di mana terdapat 5 sampel data yang salah diidentifikasi oleh model sebagai Grade A (Matang), sehingga jumlah *True Positive* yang terdata untuk Grade B adalah sebanyak 33 sampel dari

total 38 data uji. (Analisis mendalam mengenai fenomena kemiripan visual dan penyebab bias prediksi antar-kelas ini akan dibahas secara ekspansif pada bagian Pembahasan).

Tabel 4. 9 Metrik Evaluasi Model CNN pada Data Uji

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Grade A	0,91	0,98	0,94	49
Grade B	0,97	0,87	0,92	38
Grade C	1,00	1,00	1,00	38
<i>Accuracy</i>			0,95	125
<i>Macro Avg</i>	0,96	0,95	0,95	125
<i>Weighted Avg</i>	0,95	0,95	0,95	125

Tabel metrik evaluasi di atas menunjukkan performa kuantitatif model final CNN VGG16 pada 125 sampel data uji independen yang sangat andal dan seimbang di setiap kelas. Capaian sempurna diraih oleh kelas Grade C (Mentah) dengan nilai *Precision*, *Recall*, dan *F1-Score* sebesar 1,00 (100%) karena karakteristik pigmen warna hijau klorofil yang sangat homogen dan mudah dikenali model. Kelas Grade A (Matang) juga menunjukkan kinerja yang kokoh dengan nilai *Precision* 0,91 dan *Recall* 0,98 (berhasil menebak 48 dari 49 data), menghasilkan nilai *F1-Score* sebesar 0,94. Sementara itu, kelas Grade B (Terlalu Matang) mencatatkan *Precision* tinggi sebesar 0,97, meskipun nilai *Recall* berada di angka 0,87 akibat adanya 5 sampel data matang yang mengalami bias visual karena kemiripan bercak coklat transisi awal kematangan. Secara akumulatif, model final ini berhasil memperoleh tingkat Akurasi Total sebesar 0,95 (95,20%) serta rata-rata *makro* sebesar

0,95, yang membuktikan bahwa arsitektur kecerdasan buatan yang dibangun terbebas dari masalah ketidakseimbangan data (*class imbalance*) dan sangat presisi untuk diimplementasikan ke dalam aplikasi Android.

B. Pembahasan

Bagian pembahasan ini menyajikan analisis mendalam terhadap seluruh hasil penelitian yang telah dipaparkan pada sub-bab sebelumnya, Analisis difokuskan pada temuan-temuan eksperimental yang diperoleh selama proses pengembangan dan pengujian sistem, mencakup pengaruh berbagai parameter terhadap performa model, interpretasi hasil pengujian fungsional dan non fungsional, evaluasi terhadap capaian keseluruhan system.

1. Implementasi Sistem dan Pengujian

Hasil Implementasi kedua modul sistem, yaitu Modul Antarmuka Pengguna (UI) dan Modul Kecerdasan Buatan, telah berhasil dilakukan sesuai dengan perancangan yang didefinisikan pada Bab III. Dari sisi Modul UI, keempat halaman aplikasi berhasil diimplementasikan dengan tampilan yang konsisten dan intuitif. Skema desain visual yang seragam menggunakan palet warna gelap, ikon pisang tiga dimensi yang konsisten di setiap halaman, dan tata letak tombol yang ergonomis memberikan pengalaman pengguna yang terpadu dan mudah dipahami. Keunggulan utama modul *UI* terletak pada desainnya yang sederhana namun informatif, memungkinkan pengguna dari berbagai latar belakang dan tingkat melek teknologi untuk mengoperasikan aplikasi tanpa memerlukan panduan khusus atau pelatihan terlebih dahulu.

Dari sisi Modul Kecerdasan Buatan, seluruh tahapan alur kerja yang dirancang berhasil diimplementasikan dengan baik, mulai dari penerimaan citra, *preprocessing*, inferensi model VGG16, hingga pengiriman hasil kembali ke antarmuka pengguna. Integrasi model melalui format *TensorFlow Lite (TFLite)* memungkinkan proses inferensi berjalan langsung di perangkat (*on-device inference*) tanpa memerlukan koneksi internet, sehingga sistem dapat digunakan di berbagai kondisi lapangan termasuk area pertanian yang minim akses jaringan.

Keterkaitan antara kedua modul berjalan secara sinkron dan *seamless*, di mana data bitmap gambar pisang berhasil diteruskan ke model *TFLite* dan hasilnya dikembalikan ke Halaman Hasil tanpa gangguan maupun kehilangan data.

Keberhasilan implementasi dikonfirmasi secara empiris melalui pengujian fungsional *Black Box Testing* pada keempat modul *Activity*. Dari total 12 skenario pengujian yang mencakup seluruh fitur utama sistem (tampilan halaman, fungsi navigasi, pengambilan gambar, *transfer data bitmap*, inferensi model, tampilan hasil, dan navigasi kembali), seluruhnya menghasilkan status Berhasil tanpa satupun kegagalan fungsi. Hal ini merupakan bukti nyata bahwa implementasi teknis sistem telah dilakukan dengan benar dan seluruh komponen fungsional bekerja sesuai rancangan. Tidak ditemukannya bug maupun ketidaksesuaian antara perilaku aktual sistem dengan hasil yang diharapkan menunjukkan kematangan implementasi kode dan kehandalan integrasi antar komponen. Keberhasilan pengujian *Black Box Testing* ini sekaligus memvalidasi bahwa alur kerja end-to-end dari pengambilan gambar hingga penampilan hasil klasifikasi telah berjalan secara fungsional dengan sempurna.

2. Pengaruh Ukuran Input Citra terhadap Performa Model

Dari Eksperimen perbandingan ukuran input citra merupakan salah satu tahapan paling krusial dalam penelitian ini karena pemilihan ukuran input yang tepat secara langsung menentukan kualitas fitur yang dapat diekstraksi oleh jaringan konvolusi VGG16. Hasil eksperimen menunjukkan pola yang sangat jelas dan konsisten: semakin besar resolusi input gambar yang digunakan, semakin tinggi pula akurasi validasi yang dicapai oleh model, dengan pengecualian pada ukuran 512×512 yang justru gagal dieksekusi akibat keterbatasan kapasitas memori perangkat.

Pada ukuran input terkecil yaitu 89×89 piksel, model menghasilkan nilai akurasi terendah sebesar 76,61% (0,7661). Nilai ini tergolong rendah dan belum memenuhi standar yang diharapkan untuk sistem deteksi kematangan buah yang akan digunakan secara praktis. Rendahnya akurasi pada ukuran ini dapat dijelaskan dari perspektif pemrosesan citra digital: ketika gambar pisang


dikompresi secara agresif menjadi hanya 89×89 piksel, terjadi hilangnya informasi detail (*aliasing dan pixelation*) yang sangat signifikan. Fitur-fitur visual pembeda antar grade kematangan pisang, seperti gradasi perubahan warna dari hijau ke kuning, tekstur halus bercak kecokelatan, dan pola distribusi warna pada permukaan kulit pisang, mengalami degradasi kualitas yang parah. Akibatnya, lapisan konvolusi VGG16 tidak dapat mendeteksi dan mengekstraksi pola-pola tersebut secara akurat, sehingga representasi fitur yang dihasilkan tidak cukup diskriminatif untuk membedakan Grade A, Grade B, dan Grade C dengan tingkat keyakinan yang tinggi.

Ketika ukuran input ditingkatkan menjadi 128×128 piksel, model berhasil mencapai peningkatan *akurasi* yang cukup signifikan sebesar 7,26 poin persentase, dari 76,61% menjadi 83,87% (0,8387). Peningkatan ini mengkonfirmasi bahwa penambahan resolusi memberikan manfaat nyata bagi kemampuan model dalam mengekstraksi fitur visual kematangan. Pada resolusi 128×128 , detail tekstur kulit pisang mulai dapat direpresentasikan dengan lebih baik oleh jaringan konvolusi. Namun demikian, akurasi 83,87% ini masih belum optimal karena sebagian informasi tekstur halus yang membedakan antar kelas kematangan masih hilang akibat proses *downsampling* dari resolusi asli ke dimensi 128×128 piksel.

Ukuran input 224×224 piksel menghasilkan performa terbaik dengan *val akurasi* sebesar 90,32% (0,9032), meningkat 6,45 poin dari ukuran 128×128 . Pencapaian ini bukan kebetulan, melainkan konsekuensi langsung dari fakta bahwa 224×224 adalah ukuran *input default* dan optimal yang telah dirancang secara spesifik untuk arsitektur VGG16 sejak model ini pertama kali dikembangkan dan diujikan pada dataset *ImageNet*. Pada resolusi ini, seluruh 13 lapisan konvolusi VGG16 bekerja pada titik keseimbangan optimal antara kedalaman representasi fitur dan efisiensi komputasi. Fitur-fitur visual penting seperti gradasi warna kulit pisang dari hijau kekuningan (Grade A), kuning cerah (Grade B), dan kuning kecokelatan (Grade C) dapat direpresentasikan secara penuh dan akurat. Lapisan konvolusi awal mendeteksi tepi dan batas warna

dengan presisi tinggi, sementara lapisan yang lebih dalam berhasil mengkodekan pola kompleks seperti distribusi bercak coklat dan densitas perubahan pigmen. Dengan demikian, ukuran 224×224 ditetapkan sebagai ukuran input standar untuk seluruh tahapan eksperimen berikutnya.

Sementara itu, ukuran 512×512 piksel sama sekali tidak dapat diuji karena perangkat selalu mengalami error *Out-of-Memory (OOM)*. Peningkatan ukuran dari 224×224 ke 512×512 berarti jumlah piksel yang harus diproses meningkat lebih dari 5,2 kali lipat (dari 50.176 menjadi 262.144 piksel per gambar). Selama proses training deep learning, setiap gambar dalam mini-batch membutuhkan memori untuk menyimpan nilai piksel input, intermediate *activation* maps di setiap lapisan konvolusi, bobot gradien untuk *backpropagation*, serta *state optimizer Adam*. Kebutuhan memori yang melonjak drastis ini melampaui kapasitas RAM dan VRAM GPU laptop yang tersedia, sehingga sistem operasi terpaksa menghentikan proses. Kegagalan ini mempertegas bahwa ukuran 224×224 bukan hanya pilihan terbaik dari sisi akurasi, tetapi juga batas atas praktis dari kemampuan komputasi perangkat. Secara keseluruhan, urutan performa dari terbaik ke terburuk adalah 224×224 (90,32%) > 128×128 (83,87%) > 89×89 (76,61%), dengan 512×512 tidak dapat dievaluasi.



Gambar 4. 6 Grafik Perbandingan Validasi Akurasi

Berdasarkan Gambar 4.6 di atas, grafik batang secara visual memperlihatkan tren kenaikan akurasi validasi yang konsisten seiring bertambahnya resolusi input. Batang grafik untuk ukuran 89×89 berada pada nilai 0,7661, kemudian meningkat pada 128×128 ke nilai 0,8387, dan mencapai puncaknya pada 224×224 dengan nilai 0,9032. Batang untuk ukuran 512×512 tidak muncul atau ditandai sebagai *Error (OOM)* yang menunjukkan ketidakmampuan perangkat memproses resolusi tersebut. Visualisasi ini secara tegas mengkonfirmasi bahwa peningkatan resolusi input memberikan dampak positif yang nyata terhadap kualitas representasi fitur yang dipelajari model, dengan ukuran 224×224 sebagai titik optimal yang tidak hanya menghasilkan akurasi tertinggi tetapi juga masih dapat dieksekusi dalam batas kemampuan perangkat yang tersedia.

3. Pengaruh Jumlah *K-Fold* dan Pemilihan Model terhadap Akurasi Validasi


Dalam Setelah ukuran input optimal ditetapkan pada 224×224 piksel, tahap berikutnya adalah menentukan konfigurasi *K-Fold Cross Validation* yang paling efektif. Eksperimen ini dilakukan dengan menguji tiga variasi nilai K ($K=3$, $K=5$, $K=8$) pada tiga arsitektur model yang berbeda (Model A, Model B, Model C), menghasilkan sembilan kombinasi konfigurasi yang dapat dibandingkan secara komprehensif. Pendekatan *K-Fold Cross Validation* dipilih karena memberikan evaluasi performa yang jauh lebih objektif dibandingkan pembagian data *train/test* sekali saja, sehingga akurasi yang dihasilkan lebih mencerminkan kemampuan generalisasi model yang sesungguhnya.

Dari perspektif pengaruh nilai K, hasil eksperimen menunjukkan bahwa secara umum penggunaan nilai K yang lebih besar menghasilkan evaluasi yang lebih stabil. Pada $K=3$, setiap fold menggunakan sekitar 66,7% data untuk training dan 33,3% untuk validasi. Evaluasi dengan tiga fold ini relatif cepat secara komputasi, namun estimasi akurasinya memiliki varians yang lebih tinggi karena setiap *fold* validasi mencakup porsi data yang besar, sehingga satu *fold* yang kebetulan berisi sampel tidak representatif dapat mempengaruhi hasil evaluasi secara signifikan. Pada konfigurasi ini, Model A memimpin dengan akurasi 99,20%, disusul Model C (98,00%) dan Model B (97,00%).

Pada $K=5$, pembagian data menjadi lebih merata dengan rasio 80%/20% untuk *training/validasi per fold*. Temuan paling mengejutkan pada konfigurasi ini adalah performa Model B yang anjlok drastis dari 97,00% ($K=3$) menjadi hanya 80,40% ($K=5$), sebuah penurunan sebesar 16,6 poin persentase yang sangat signifikan. Penurunan ini merupakan indikasi kuat bahwa Model B sangat sensitif terhadap cara pembagian data. Kemungkinan besar, salah satu fold pada $K=5$ secara kebetulan mengandung sampel-sampel dengan karakteristik visual yang sulit atau berada di wilayah batas kelas (*decision boundary*) yang ambigu, sehingga Model B gagal mengklasifikasikannya. Ketidakstabilan Model B ini menjadi faktor pembeda yang signifikan. Sementara itu, Model A tetap konsisten dengan akurasi 99,00% dan Model C mencapai 98,80%.

Pada $K=8$, yang merupakan nilai K terbesar dalam eksperimen ini, setiap iterasi menggunakan sekitar 87,5% data untuk training dan hanya 12,5% untuk validasi. Pembagian yang lebih granular ini memungkinkan model mendapatkan lebih banyak data pelatihan di setiap iterasi, sekaligus memastikan set validasi yang lebih representatif terhadap keseluruhan distribusi dataset. Hasilnya sangat signifikan: Model A mencapai akurasi tertinggi sebesar 99,80%, Model C memperoleh 99,01%, dan bahkan Model B yang sebelumnya tidak stabil berhasil pulih ke performa 98,61%. Konsistensi yang jauh lebih baik pada $K=8$ mengkonfirmasi teori statistik bahwa nilai K yang lebih besar menghasilkan estimasi bias yang lebih rendah dan varians evaluasi yang lebih kecil.

Dari sisi perbandingan antar model, Model A secara konsisten mengungguli Model B dan Model C di seluruh variasi nilai K . Konsistensi performa Model A yang superior di seluruh kondisi menunjukkan bahwa konfigurasi arsitekturnya memang lebih optimal untuk tugas klasifikasi kematangan pisang kepok dibandingkan kedua model lainnya. Berdasarkan keseluruhan hasil eksperimen ini, konfigurasi Model A dengan $K=8$ yang menghasilkan akurasi validasi 99,80% ditetapkan sebagai konfigurasi terbaik untuk proses training model final.



Gambar 4. 7 Grafik Perbandingan Rata-rata Validasi Akurasi *K-Fold*


Berdasarkan Gambar 4.7, grafik kelompok batang (*grouped bar chart*) memperlihatkan perbandingan akurasi validasi untuk ketiga model (Model A, B, C) di setiap konfigurasi K (K=3, K=5, K=8). Secara visual, dominasi Model A terlihat jelas di seluruh kelompok batang, di mana batang Model A konsisten berada di posisi tertinggi pada setiap variasi nilai K. Anomali penurunan performa Model B pada K=5 (80,40%) sangat mencolok pada grafik ini dibandingkan batang-batang lainnya yang seluruhnya berada di atas 97%. Hal ini secara visual menegaskan ketidakstabilan Model B dan mengapa konfigurasi tersebut tidak dipilih sebagai model terbaik. Pada kelompok K=8, ketiga batang model berada di rentang yang paling tinggi dan paling merata, dengan batang Model A (99,80%) yang ditandai sebagai nilai terbaik secara keseluruhan. Grafik ini secara komprehensif memperkuat keputusan pemilihan Model A dengan K=8 sebagai konfigurasi optimal untuk tahap training akhir.

4. Pengaruh *Epoch* dan Hasil *Training Model Final*

Setelah konfigurasi terbaik ditetapkan (ukuran input 224×224, K=8, Model A), proses training akhir dilakukan menggunakan seluruh data latih yang tersedia untuk menghasilkan model final yang akan diintegrasikan ke dalam aplikasi Android. Proses *training* dijalankan selama 30 *epoch* dengan *optimizer Adam* dan

fungsi loss *Categorical Crossentropy*. Hasil *training* akhir menunjukkan bahwa model final berhasil mencapai akurasi sebesar 95,20% pada 125 data uji yang sepenuhnya terpisah dan belum pernah dilihat model selama proses *training*.


Pada fase awal *training* (*epoch* 1–5), baik *training accuracy* maupun *validation accuracy* sama-sama meningkat sangat tajam dari titik awal sekitar 60–65% menuju lebih dari 90%. Laju pembelajaran yang sangat cepat di fase ini merupakan manfaat langsung dari teknik *transfer learning* yang diterapkan: bobot *pretrained* dari *dataset ImageNet* menjadi titik awal yang jauh lebih baik dibandingkan inisialisasi acak, sehingga model tidak perlu memulai dari nol dan dapat langsung memanfaatkan representasi fitur visual tingkat rendah (tepi, tekstur, gradasi warna) yang sudah tertanam dalam bobot-bobot tersebut. Tanpa *transfer learning*, dibutuhkan jauh lebih banyak *epoch* dan data untuk mencapai tingkat konvergensi yang sama.



Gambar 4. 8 Grafik *Training* dan *Validation Accuracy* – Model Final

Berdasarkan Gambar 4.8, grafik *Training* dan *Validation Accuracy* menampilkan pola pembelajaran yang sehat dan stabil sepanjang 30 epoch. Setelah kenaikan tajam pada epoch 1–5, memasuki fase tengah (*epoch* 6–15), *training accuracy* terus meningkat secara bertahap menuju kisaran 95–98%, sementara *validation accuracy* mulai menunjukkan pola yang lebih fluktuatif

namun tetap dalam tren yang meningkat di kisaran 90–95%. Gap yang relatif kecil antara *training accuracy* dan *validation accuracy* pada fase ini merupakan indikator penting bahwa model tidak mengalami *overfitting* yang parah; model tidak hanya menghafalkan data latih tetapi memang belajar mengenali pola visual yang dapat digeneralisasi ke data baru. Pada fase akhir *training* (*epoch* 16–30), *training accuracy* stabil di atas 97% sementara *validation accuracy* bergerak di sekitar 92–95% dengan *fluktuasi* yang semakin mengecil, menandakan konvergensi yang baik. Garis putus-putus yang menunjukkan *Test Accuracy* = 0,952 berada dalam rentang yang konsisten dengan *tren validation accuracy* akhir, mengkonfirmasi akurasi akhir 95,20% bukanlah hasil *overfitting*.



Gambar 4. 9 Grafik *Training Loss* dan *Validation Loss* – Model Final

Berdasarkan Gambar 4.9, grafik *Training Loss* dan *Validation Loss* menunjukkan tren penurunan yang konsisten dan paralel antara keduanya hingga mendekati nilai 0,1–0,2 pada *epoch-epoch* akhir. Tidak terdapat divergensi loss di mana training loss turun sementara *validation loss* justru naik, yang merupakan tanda klasik *overfitting*. Terdapat sedikit spike atau lonjakan sementara pada sekitar epoch 13–14 pada validation loss, namun segera kembali ke tren penurunan normal. Fenomena ini lazim terjadi dalam training *deep learning* dan biasanya disebabkan oleh karakteristik mini-batch yang secara kebetulan berisi

sampel-sampel sulit. Secara keseluruhan, pola grafik loss ini membuktikan bahwa konfigurasi hyperparameter (*optimizer Adam, learning rate default, 30 epoch*) sudah sangat efektif menghasilkan konvergensi yang baik tanpa *overfitting* signifikan.

Hasil akurasi model final sebesar 95,20% menunjukkan penurunan yang wajar sebesar 4,6 poin dibandingkan akurasi *K-Fold* terbaik (99,80%). Perbedaan ini merupakan fenomena yang normal: pada *K-Fold Cross Validation*, model dievaluasi terhadap data yang berasal dari pool yang sama dengan data latih (dirotasi), sehingga cenderung menghasilkan estimasi yang lebih optimis. Pada training akhir, model diuji terhadap 125 data uji yang benar-benar terpisah dan belum pernah dilihat model, sehingga akurasi 95,20% lebih mencerminkan kemampuan generalisasi model dalam kondisi penggunaan nyata. Dengan demikian, 95,20% adalah estimasi performa yang lebih konservatif dan lebih dapat dipercaya.


5. Pengaruh Warna dan Fitur Visual terhadap Akurasi Klasifikasi Per Kelas

Analisis mendalam terhadap *Confusion Matrix* model final memberikan wawasan yang sangat berharga mengenai bagaimana karakteristik warna dan fitur visual kematangan pisang mempengaruhi kemampuan klasifikasi model secara per kelas. Pemahaman terhadap pola kesalahan dan keberhasilan klasifikasi ini penting untuk mengidentifikasi kekuatan dan kelemahan sistem serta memberikan arah pengembangan yang tepat di masa mendatang.

Dari 49 sampel Grade A yang diuji, model berhasil mengklasifikasikan 48 sampel dengan benar dan hanya 1 sampel yang salah diklasifikasikan sebagai Grade B. Hal ini menghasilkan nilai *recall* yang sangat tinggi sebesar 0,98 untuk Grade A. Namun, *precision* Grade A yang lebih rendah (0,91) menunjukkan bahwa ada 5 sampel dari kelas lain (semuanya dari Grade B) yang salah diprediksi sebagai Grade A. Tingginya *recall* Grade A memiliki implikasi praktis yang penting: sistem sangat jarang melewatkan pisang yang benar-benar masuk kategori Grade A, sehingga risiko salah mengklasifikasikan pisang Grade A sebagai kelas lain sangat kecil.

Dari 38 sampel Grade B, model berhasil mengklasifikasikan 33 sampel dengan benar sementara 5 sampel salah diklasifikasikan sebagai Grade A. *Recall* Grade B sebesar 0,87 merupakan yang terendah di antara ketiga kelas, menunjukkan bahwa Grade B adalah kelas yang paling menantang untuk diklasifikasikan. Pola kesalahan ini sangat dapat dipahami dari perspektif karakteristik visual pisang: Grade A (pisang matang optimal, kuning cerah) dan Grade B (pisang setengah matang, warna transisi kuning-hijau atau kuning muda) memiliki transisi warna yang gradual dan tidak memiliki batas visual yang tegas. Pada kondisi pencahayaan tertentu atau sudut pengambilan gambar yang berbeda, perbedaan warna antara kedua kelas ini dapat menjadi sangat subtle sehingga bahkan penilai manusia pun dapat mengalami kesulitan membedakannya secara konsisten. Yang penting, kesalahan klasifikasi terpusat hanya di antara Grade A dan Grade B tanpa satupun misklasifikasi lintas Grade A–C atau B–C, yang justru mengkonfirmasi bahwa model telah berhasil mempelajari hierarki kematangan yang benar.

Temuan paling luar biasa adalah performa sempurna model pada kelas Grade C: seluruh 38 sampel Grade C berhasil diklasifikasikan dengan benar tanpa satupun kesalahan (*precision*=1,00, *recall*=1,00, *F1-score*=1,00). Pencapaian ini dapat dijelaskan oleh karakteristik visual Grade C (pisang terlalu matang) yang memiliki dominasi warna coklat tua pada permukaan kulit yang sangat kontras dan mudah dibedakan dari kelas lainnya. Warna coklat tua yang khas merupakan fitur visual yang sangat diskriminatif dan unik, sehingga model tidak mengalami ambiguitas dalam mengidentifikasi kelas ini. Tidak adanya sampel Grade A atau Grade B yang salah diklasifikasikan sebagai Grade C juga menunjukkan bahwa batas keputusan antara Grade C dengan kelas lainnya sudah terbentuk dengan sangat baik di dalam ruang fitur model.



Gambar 4. 10 Grafik Metrik Evaluasi Model CNN

Berdasarkan Gambar 4.10, grafik metrik evaluasi menampilkan nilai *Precision*, *Recall*, dan *F1-Score* untuk masing-masing kelas (Grade A, Grade B, Grade C) beserta nilai rata-rata keseluruhan (*Macro Average* dan *Weighted Average*). Secara visual, batang grafik untuk Grade C tampak paling menonjol dengan ketiga metrik bernilai sempurna 1,00, mencerminkan kemudahan model dalam membedakan karakteristik warna coklat tua kelas ini. Sebaliknya, batang *Recall* untuk Grade B (0,87) tampak sebagai titik terendah di seluruh grafik, secara visual menegaskan bahwa Grade B adalah kelas yang paling menantang akibat kemiripan visualnya dengan Grade A. Garis putus-putus pada grafik yang menunjukkan *Overall Accuracy* = 0,952 memberikan referensi visual yang jelas mengenai di mana performa per kelas berada relatif terhadap akurasi keseluruhan. Nilai *macro average F1-score* sebesar 0,95 yang merata di seluruh kelas mengkonfirmasi bahwa model tidak mengalami bias signifikan terhadap kelas tertentu, sehingga hasil prediksi dapat diandalkan secara merata untuk ketiga grade kematangan pisang kepok.

6. Kesimpulan Pembahasan

Berdasarkan seluruh rangkaian analisis mendalam yang telah dipaparkan, dapat ditarik kesimpulan yang komprehensif mengenai capaian penelitian secara keseluruhan. Pengembangan aplikasi mobile deteksi kematangan pisang kepok berbasis *Deep Learning CNN VGG16* dengan teknik *transfer learning* telah berhasil dilaksanakan dan memenuhi seluruh parameter keberhasilan yang direncanakan pada Bab I. Sistem terbukti mampu mentransformasikan proses identifikasi kematangan buah yang sebelumnya manual dan rentan inkonsistensi menjadi sistem deteksi otomatis yang cepat, objektif, dan terstandarisasi.

Setiap tahapan eksperimental memberikan kontribusi nyata terhadap kualitas akhir sistem. Eksperimen ukuran input membuktikan resolusi 224×224 sebagai pilihan optimal (90,32%), melampaui 89×89 (76,61%) dan 128×128 (83,87%). Eksperimen *K-Fold* mengidentifikasi Model A $K=8$ (99,80%) sebagai konfigurasi terbaik dari sembilan kombinasi yang diuji. *Training* akhir menghasilkan akurasi model final 95,20% pada data uji independen, didukung metrik evaluasi yang seimbang di seluruh kelas (*macro avg F1-score* 0,95) dan performa sempurna pada Grade C (*precision, recall, F1-score* = 1,00). Seluruh 12 skenario *Black Box Testing* menghasilkan status Berhasil. Dengan demikian, tujuan penelitian yang dirumuskan pada Bab I telah sepenuhnya tercapai, dan sistem yang dikembangkan memiliki kesiapan teknis yang matang untuk diterapkan secara praktis guna membantu petani, pedagang, dan pelaku industri dalam memantau kualitas komoditas pisang kepok secara cerdas dan terstandarisasi.

Bab penutup ini menyajikan rangkuman menyeluruh dari seluruh rangkaian penelitian yang telah dilaksanakan. Bagian ini memuat kesimpulan akhir berdasarkan hasil analisis data dan pembahasan pada bab sebelumnya, serta merumuskan saran untuk pengembangan penelitian sejenis di masa yang akan datang.

A. Kesimpulan

Proses penentuan tingkat kematangan pada komoditas buah pisang kepok selama ini masih didominasi oleh metode konvensional yang mengandalkan pengamatan visual manual secara langsung. Pendekatan manual seperti ini memiliki kelemahan mendasar karena sangat bergantung pada subjektivitas penguji, membutuhkan waktu pengerjaan yang relatif lama, serta rentan menghasilkan tingkat inkonsistensi yang tinggi antara satu penilai dengan penilai lainnya sehingga menghambat standardisasi kualitas komoditas di pasar.

Sebagai solusi atas permasalahan tersebut, dalam penelitian ini telah dirancang dan dibangun sebuah sistem aplikasi klasifikasi kualitas buah pisang kepok berbasis mobile Android dengan mengintegrasikan metode *Deep Learning* menggunakan arsitektur *Convolutional Neural Network* (CNN) VGG16. Sistem ini mengklasifikasikan buah ke dalam tiga tingkatan kualitas visual, yaitu Grade A, Grade B, dan Grade C. Aplikasi ini mengintegrasikan Modul Antarmuka Pengguna (UI) untuk akuisisi citra secara *real-time* dan Modul Kecerdasan Buatan (AI) lokal berbasis *TensorFlow Lite* (model_pisang.tflite) dengan kuantisasi int8 , sehingga mampu menyediakan fungsi deteksi grade objek yang objektif, otomatis, dan dapat berjalan sepenuhnya secara offline di lapangan.

Rangkaian pengujian membuktikan bahwa solusi yang diimplementasikan memiliki kesiapan teknis yang sangat matang, dibuktikan dengan hasil uji fungsional *Black-Box Testing* yang sukses mencapai kelulusan 100% dari total 12 skenario uji. Pada pengujian non-fungsional model AI, konfigurasi Model A dengan skema *K-Fold*

Cross Validation nilai $K=8$ dan variasi resolusi input optimal 224×224 piksel terpilih sebagai model terbaik dengan rata-rata akurasi validasi sebesar 99,80%. Pada pengujian final menggunakan 125 data uji independen, model sukses memperoleh tingkat *Akurasi Total* sebesar 95,20%, dengan performa sempurna (*Precision*, *Recall*, dan *F1-Score* sebesar 1,00) diraih pada pengenalan kelas Grade C (Mentah).

B. Saran

Untuk pengembangan penelitian selanjutnya, peneliti diharapkan dapat memperluas cakupan dan kuantitas dataset melalui penambahan variasi kondisi lingkungan di lapangan, seperti sudut kamera ekstrem, latar belakang bising, fluktuasi pencahayaan, serta penambahan sampel citra pada fase transisi demi meminimalkan bias visual antara Grade A dan Grade B. Di samping itu, disarankan untuk mengeksplorasi dan membandingkan arsitektur jaringan saraf tiruan yang lebih ringan untuk perangkat *mobile*, seperti varian *MobileNet*, *ShuffleNet*, atau *EfficientNet-Lite*. Terakhir, fungsionalitas sistem dapat ditingkatkan dengan mengimplementasikan fitur pemindaian video secara langsung (*real-time video object detection*), integrasi basis data berbasis cloud untuk merekam riwayat panen, serta penambahan fitur rekomendasi pemanfaatan produk kuliner berdasarkan grade kualitas yang terdeteksi.