

Turnitin LLCC

2213030128_Moch. Raffi Dwi Saktya Rahman.docx (1)

 SI-01

Document Details

Submission ID

trn:oid::2945:391890234

Submission Date

Jun 8, 2026, 11:43 AM GMT+7

Download Date

Jun 8, 2026, 11:46 AM GMT+7

File Name

2213030128_Moch. Raffi Dwi Saktya Rahman.docx (1).pdf

File Size

2.8 MB

52 Pages

10,620 Words

68,446 Characters

15% Overall Similarity

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

Filtered from the Report

- Bibliography

Top Sources

- 10%  Internet sources
- 5%  Publications
- 11%  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

- 10% Internet sources
- 5% Publications
- 11% Submitted works (Student Papers)

Top Sources

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

1	Internet	e-journals2.unmul.ac.id	<1%
2	Publication	Marina Adriana Mercioni, Stefan Holban. "P-Swish: Activation Function with Lear...	<1%
3	Internet	journal.uui.ac.id	<1%
4	Internet	repository.itpln.ac.id	<1%
5	Student papers	Sriwijaya University on 2026-05-04	<1%
6	Student papers	Universitas Pamulang on 2026-05-04	<1%
7	Internet	journal.arteli.or.id	<1%
8	Student papers	Perpustakaan on 2025-08-06	<1%
9	Internet	ejournal.catursakti.ac.id	<1%
10	Internet	ejournal.uigm.ac.id	<1%
11	Internet	dergipark.org.tr	<1%

12	Internet	jurnal.unw.ac.id	<1%
13	Internet	repository.uinsaizu.ac.id	<1%
14	Student papers	UPN Veteran Yogyakarta on 2026-05-04	<1%
15	Student papers	Universitas Islam Riau on 2026-04-28	<1%
16	Student papers	Universitas Sumatera Utara on 2026-06-04	<1%
17	Student papers	Universitas Muhammadiyah Sukabumi on 2026-06-06	<1%
18	Publication	Ferry Khusnil Arief, Nurul Kholidiah, Rifki Mistahul Munir, Rahma Yunita. "Compa...	<1%
19	Publication	Ines Heidiani Ikasari, Perani Rosyani, Resti Amalia. "Klasifikasi Jenis Buah Mengg...	<1%
20	Internet	digilib.unila.ac.id	<1%
21	Internet	journal.aptii.or.id	<1%
22	Internet	proceeding.unisayogya.ac.id	<1%
23	Internet	repository.unissula.ac.id	<1%
24	Internet	jurnal.stkipppgritulungagung.ac.id	<1%
25	Internet	you-gonever.icu	<1%

26	Internet	docplayer.info	<1%
27	Internet	ejournal.iainbengkulu.ac.id	<1%
28	Internet	www.lembagakita.org	<1%
29	Internet	123dok.com	<1%
30	Student papers	UIN Syarif Hidayatullah Jakarta on 2024-12-11	<1%
31	Publication	Aprilian Gevindo, Syafri Arlis. "Smoker Detection Using the You Only Look Once (Y...	<1%
32	Student papers	Politeknik Ilmu Pelayaran Semarang on 2026-05-18	<1%
33	Student papers	Universitas Islam Riau on 2025-07-17	<1%
34	Student papers	Universitas Tarumanagara on 2025-12-24	<1%
35	Internet	dspace.uui.ac.id	<1%
36	Student papers	Perpustakaan on 2025-08-08	<1%
37	Internet	pt.scribd.com	<1%
38	Publication	I Gusti Agung Putu Mahendra, Afis Julianto, Agus Tedyana. "Klasifikasi Citra Top...	<1%
39	Publication	Muhammad Mauladi, Dedy Hermanto. "Klasifikasi Motif Kain Jumputan Palemba...	<1%

40	Student papers	Universitas Mercu Buana on 2022-05-18	<1%
41	Student papers	Universitas Maritim Raja Ali Haji on 2024-12-20	<1%
42	Internet	journal.unismuh.ac.id	<1%
43	Internet	mc.ai	<1%
44	Student papers	UPN Veteran Yogyakarta on 2026-05-05	<1%
45	Student papers	Universitas Muslim Indonesia on 2025-08-13	<1%
46	Student papers	Universitas Brawijaya on 2021-04-13	<1%
47	Student papers	Universitas Islam Riau on 2025-12-08	<1%
48	Internet	repository.unj.ac.id	<1%
49	Internet	widuri.raharja.info	<1%
50	Internet	eprints.amikom.ac.id	<1%
51	Internet	journal.jisti.unipol.ac.id	<1%
52	Internet	repository.upi.edu	<1%
53	Internet	www.acarindex.com	<1%

54	Student papers	University of Hertfordshire on 2024-09-02	<1%
55	Internet	documents.mx	<1%
56	Internet	downloadptkptssdsmpsma.blogspot.com	<1%
57	Internet	es.scribd.com	<1%
58	Internet	ml.scribd.com	<1%
59	Internet	repositori.unwira.ac.id	<1%
60	Publication	Muhammad Fawzan, Daniel Udjulawa. "Optimasi Hyperparameter CNN dengan A...	<1%
61	Student papers	Universitas Pamulang on 2022-11-04	<1%
62	Student papers	Universitas Pendidikan Ganesha on 2025-04-17	<1%
63	Student papers	Universitas Tarumanagara on 2025-12-12	<1%
64	Internet	blinkphotos.co.uk	<1%
65	Internet	docobook.com	<1%
66	Internet	ejurnal.lkparyaprima.id	<1%
67	Internet	ejurnal.stmik-budidarma.ac.id	<1%

68	Internet	gitea.communitydata.science	<1%
69	Internet	kc.umn.ac.id	<1%
70	Internet	lib.unnes.ac.id	<1%
71	Internet	repository.unhas.ac.id	<1%
72	Internet	repository.unja.ac.id	<1%
73	Internet	vbook.pub	<1%
74	Internet	www.scribd.com	<1%
75	Publication	I Kadek Prasta Yudhantara, Ni Ketut Kertiasih, I Nyoman Saputra Wahyu Wijaya. ...	<1%
76	Publication	Jenny Rahma Hidayat, Jemakmum. "Implementasi Klasifikasi Citra Berbasis Tenso...	<1%
77	Student papers	Politeknik Negeri Bandung on 2019-07-29	<1%
78	Student papers	Universitas Atma Jaya Yogyakarta on 2018-01-09	<1%
79	Student papers	Universitas Diponegoro on 2023-07-05	<1%
80	Student papers	Universitas Khairun on 2026-05-04	<1%
81	Student papers	Universitas Merdeka Malang on 2020-03-23	<1%

82	Student papers	Universitas Putera Batam on 2026-02-03	<1%
83	Student papers	Universitas Tarumanagara on 2025-12-11	<1%
84	Student papers	Universitas Tarumanagara on 2025-12-11	<1%
85	Internet	adoc.pub	<1%
86	Internet	digilib.uinsby.ac.id	<1%
87	Internet	eprints.walisongo.ac.id	<1%
88	Internet	ind.acousticbiotech.com	<1%
89	Internet	www.mdpi.com	<1%
90	Publication	Miftakhul Rahman, Mantri Kromo Fandith Fili, Wardianto. "Analisis Hasil Rekapit...	<1%
91	Student papers	UPN Veteran Yogyakarta on 2026-05-29	<1%
92	Student papers	Universitas Esa Unggul on 2025-07-23	<1%
93	Student papers	Universitas Pancasila on 2026-03-05	<1%
94	Student papers	Universitas Sumatera Utara on 2026-06-05	<1%
95	Internet	anitafantastikaaa.wordpress.com	<1%

96	Publication	Erfian Junianto, Mila Puspitasari, Salman Ilyas Zakaria, Toni Arifin, Ignatius Wiset...	<1%
97	Student papers	Institut Teknologi PLN on 2025-09-02	<1%
98	Student papers	Universitas Islam Riau on 2025-11-27	<1%
99	Student papers	Universitas Maritim Raja Ali Haji on 2025-04-21	<1%
100	Student papers	Universitas Tarumanagara on 2025-12-24	<1%

26

BAB I

PENDAHULUAN

A. Latar Belakang

74

Pada abad ini, sektor pertanian menjadi aspek yang paling signifikan dalam pembangunan suatu negara dalam hal dukungan ekonomi. Seiring berjalannya waktu, persaingan di sektor pertanian akan semakin intens, yang ditandai dengan produksi yang lebih besar, kualitas yang lebih baik, dan efisiensi bisnis yang lebih tinggi. Inovasi pertanian baru semakin dibutuhkan untuk membantu proses produksi sehingga kualitas dan kuantitas yang dihasilkan dapat dimaksimalkan dan bersaing dengan yang lain (Lisda et al., 2023) (Trihardianingsih L. & Permatasari H., 2025).

25

Pistachio merupakan salah satu komoditas pertanian yang memerlukan inovasi dalam proses pengelolaannya. *Pistachio* adalah jenis tanaman penghasil biji-bijian yang umumnya dikenal sebagai kacang *Pistachio*, yang tumbuh dengan baik di iklim kering dengan tanah yang kurang subur, seperti Iran, Turkmenistan, dan Azerbaijan bagian barat. Biji berwarna hijau cerah dari tanaman *Pistachio* biasanya digunakan untuk menghias hidangan atau dalam berbagai olahan makanan lezat seperti es krim. *Pistachio* adalah jenis kacang-kacangan yang memiliki nutrisi tinggi karena mengandung protein, serat, asam lemak tak jenuh tunggal, mineral, vitamin, karotenoid, asam fenolik, flavonoid, dan antosianin (Lisda et al., 2023) (Trihardianingsih L. & Permatasari H., 2025).

95

55

Pistachio dipilih sebagai objek penelitian karena merupakan salah satu komoditas pertanian dengan nilai jual tinggi yang permintaannya terus meningkat di pasar global, namun proses klasifikasi pasca panennya masih dilakukan secara manual dan konvensional sehingga rentan terhadap kesalahan Singh et al., (2022) Uzer, (2025). Dibandingkan komoditas pertanian lainnya, *Pistachio* memiliki tantangan klasifikasi yang lebih kompleks karena perbedaan morfologi antar varietasnya sangat halus dan sulit dibedakan secara kasat mata, menjadikannya objek yang relevan dan menantang untuk dikaji menggunakan pendekatan *computer vision* berbasis *deep learning* (Lisda et al., 2023).

Adapun pemilihan varietas *Kirmizi* dan *Siirt* secara spesifik didasarkan pada tiga alasan utama. Pertama, kedua varietas ini merupakan jenis *Pistachio* yang paling banyak diperdagangkan dan memiliki nilai ekonomi tertinggi dibandingkan varietas lainnya, sehingga akurasi klasifikasi keduanya berdampak langsung pada nilai transaksi perdagangan AVUÇLU, (2023) Özkan et al., (2021). Kedua, meskipun ditujukan untuk segmen pasar yang berbeda. *Kirmizi* untuk industri permen dan kue manis, serta *Siirt* untuk camilan, keduanya memiliki kemiripan bentuk fisik yang sangat tinggi sehingga menjadi tantangan klasifikasi yang signifikan Lisda et al., (2023; Trihardianingsih L. & Permatasari H., (2025). Ketiga, tersedianya dataset publik yang telah tervalidasi untuk kedua varietas ini di Kaggle memungkinkan penelitian dilakukan secara terstruktur dan hasil penelitian dapat dibandingkan secara langsung dengan penelitian-penelitian sebelumnya yang menggunakan dataset yang sama (Lisda et al., 2023) (Avuçlu, 2023).

Amerika Serikat, Iran, Turki, dan Suriah sebagai produsen global utama *Pistachio* menyumbang hampir 90% dari total produksi di seluruh dunia (Singh et al., (2022) Avuçlu, (2023) Uzer, (2025). Namun demikian, proses yang digunakan untuk memisahkan kacang *Pistachio* masih dilakukan secara manual dengan pengetahuan dasar. Karena hal ini, terdapat potensi tinggi untuk terjadinya kesalahan dalam proses klasifikasi mengingat setiap varietas kacang *Pistachio* memiliki bentuk yang hampir identik Lisda et al., (2023) Trihardianingsih L. & Permatasari H., (2025). Kesalahan klasifikasi ini dapat menyebabkan kerugian ekonomi yang signifikan karena produk dapat tercampur dan dijual dengan harga yang tidak sesuai dengan jenisnya (Singh et al., 2022) (Uzer, 2025).

Oleh karena itu, inovasi diperlukan untuk mengenali jenis kacang *Pistachio* secara otomatis sehingga proses pengemasan untuk penjualan dapat tepat sasaran Lisda et al., (2023) Trihardianingsih L. & Permatasari H., (2025). Untuk meningkatkan nilai pasar *Pistachio*, diperlukan pemisahan dan klasifikasi otomatis untuk berbagai jenis produk yang berasal dari pemasok yang berbeda AVUÇLU, (2023) Özkan et al., (2021). Oleh karena itu, teknik dan teknologi baru harus digunakan untuk meningkatkan metode yang

digunakan dalam proses mekanisasi pasca panen *Pistachio* dan untuk meningkatkan hasil dari produk yang memiliki nilai ekonomi tinggi (Avuçlu, 2023) (Uzer, 2025).

Perkembangan teknologi *computer vision* dan pemrosesan citra dalam beberapa tahun terakhir telah membuka peluang untuk mengotomatisasi proses klasifikasi produk pertanian. Teknologi berbasis *deep learning*, khususnya *Convolutional Neural Network (CNN)*, telah terbukti mampu mengekstraksi fitur visual secara hierarkis dan otomatis dari citra tanpa memerlukan rekayasa fitur manual. Hal ini menjadikan *CNN* sebagai salah satu pendekatan yang paling menjanjikan untuk diterapkan dalam klasifikasi *Pistachio* yang memiliki kemiripan bentuk visual antar varietas (Lisda et al., 2023) (Trihardianingsih L. & Permatasari H., 2025).

Selain potensi teknologi yang besar, terdapat juga tantangan praktis yang perlu diatasi, yaitu keterbatasan jumlah data citra *Pistachio* yang tersedia untuk melatih model *deep learning* secara optimal. Dataset yang terbatas berpotensi menyebabkan model mengalami *overfitting*, yakni kondisi di mana model hanya mampu menghafal data latih tetapi gagal menggeneralisasi pada data baru. Hal ini memperkuat urgensi penerapan teknik *data augmentation* sebagai solusi untuk memperbanyak variasi data latih tanpa harus mengumpulkan data baru secara fisik (Lisda et al., 2023).

Berbagai penelitian terdahulu telah dilakukan untuk mengklasifikasikan kacang *Pistachio* menggunakan metode *machine learning* dan *deep learning*. Penelitian oleh Farazi et al. menggunakan arsitektur *machine learning* dan *deep learning* untuk mengklasifikasikan *Pistachio* ke dalam 3 kelas yaitu *Pistachio* cangkang terbuka, *Pistachio* cangkang busuk, dan sampah atau serpihan kayu, dengan menggunakan 1000 citra yang diekstraksi menggunakan arsitektur AlexNet dan GoogleNet dan memperoleh akurasi secara berturut-turut sebesar 98% dan 99% Trihardianingsih L. & Permatasari H., (2025). Penelitian lain oleh Omid et al. menggunakan pengolahan citra dengan *machine learning* untuk proses klasifikasi jenis *Pistachio* yang sudah mengalami proses pengupasan, dengan membagi *Pistachio* yang sudah dikupas menjadi 5 kelas menggunakan *Artificial Neural Networks (ANN)* dan

Support Vector Machine (SVM), dan hasil klasifikasi dengan menggunakan *ANN* dan *SVM* secara berturut-turut adalah 99,4% dan 99,8% (Trihardianingsih L. & Permatasari H., 2025).

Penelitian yang mengklasifikasikan spesies *Pistachio* menggunakan pendekatan *Transfer Learning* dengan arsitektur *AlexNet*, *VGG16*, dan *VGG19* menggunakan 2148 foto yang terdiri dari 916 jenis *Siirt* dan 1232 jenis *Kirmizi*, dibagi dengan rasio 80:20 untuk data *training* dan *testing*, menghasilkan akurasi masing-masing 94,42%, 98,84%, dan 98,14%. *VGG16* mencapai tingkat keberhasilan klasifikasi terbesar sebesar 98,84% Lisda et al., (2023) Trihardianingsih L. & Permatasari H., (2025). Penelitian lain menggunakan metode *KNN* untuk melakukan klasifikasi *Pistachio* menjadi dua kelas yaitu *Kirmizi* dan *Siirt*, dengan tiga skenario yaitu *KNN*, *Weighted KNN*, dan *PCA based k-NN*, memperoleh hasil secara berturut-turut 83%, 87%, dan 94%, di mana keberhasilan klasifikasi tertinggi dicapai menggunakan *PCA* dengan akurasi 94% (Özkan et al., 2021) (Trihardianingsih L. & Permatasari H., 2025).

Penelitian menggunakan arsitektur *Resnet* untuk klasifikasi *Pistachio* dengan dataset 2148 gambar dan 2 kelas menunjukkan bahwa akurasi tertinggi diperoleh sebesar 88,58% pada *fold-1* dengan rata-rata akurasi klasifikasi *5-fold* sebesar 86,16% Avuçlu, (2023) Uzer, (2025). Studi lain menggunakan dataset 958 *Pistachio* dengan kondisi cacat dan sempurna untuk klasifikasi, di mana *GoogleNet*, *VGG16*, dan *Resnet models* mencapai akurasi klasifikasi masing-masing sebesar 95,8%, 95,83%, dan 97,2% Uzer, (2025). Studi komparatif tentang evaluasi berbagai jaringan berbasis *CNN* untuk klasifikasi juga menunjukkan bahwa arsitektur *Resnet101* memiliki potensi untuk memberikan hasil yang lebih baik dalam tugas klasifikasi citra dibandingkan *VGG16*, *VGG19*, *GoogleNet*, dan *InceptionV3* ketika diimplementasikan dengan parameter yang sama (Goceri & Karakas, 2020).

Meskipun penelitian sebelumnya telah menunjukkan hasil yang menjanjikan, terdapat beberapa *research gap* yang perlu diperhatikan. Pertama, penelitian-penelitian terdahulu belum mengujicobakan arsitektur *Resnet101* secara spesifik pada dataset *Pistachio* varietas *Kirmizi* dan *Siirt*.

32

Kedua, sebagian besar penelitian tidak menerapkan teknik *data augmentation* untuk meningkatkan variasi data *training*, padahal jumlah foto dalam dataset dapat mempengaruhi akurasi kategorisasi dari berbagai model. Ketiga, penelitian menggunakan *Resnet* pada dataset yang sama menunjukkan terjadinya *overfitting* parah yang ditandai oleh *gap* besar antara *training accuracy* (98%) dan *validation accuracy* (20%) pada arsitektur *Resnet50*, yang menandakan perlunya strategi penanganan *overfitting* yang lebih baik Lisda et al., (2023). Keempat, ketidakseimbangan distribusi data antara kelas *Kirmizi* (1232 sampel) dan *Siirt* (916 sampel) belum ditangani secara eksplisit melalui teknik *class weighting* dalam penelitian-penelitian sebelumnya.

Selain itu, beberapa studi melaporkan hasil dari *single experimental runs* atau performa terbaik yang dipilih, yang kurang memiliki validasi statistik yang tepat. Praktik ini dapat menyebabkan klaim performa yang terlalu optimis dan reproduktibilitas yang buruk ketika metode diterapkan dalam pengaturan dunia nyata Hoots et al., (2025). Hal ini menunjukkan pentingnya metodologi yang lebih ketat dan transparan dalam penelitian klasifikasi *Pistachio* ke depannya.

Berdasarkan hasil perbandingan berbagai arsitektur *CNN* yang telah dilakukan oleh Goceri & Karakas, (2020) dan saran yang diberikan oleh peneliti Lisda et al., (2023), penelitian ini bertujuan untuk mengimplementasikan arsitektur *Resnet101* yang belum pernah diuji pada dataset *Pistachio* varietas *Kirmizi* dan *Siirt*. Penerapan teknik *data augmentation*, meliputi *rescale*, *rotation*, *horizontal flip*, *width shift range*, *height shift range*, *fill mode*, dan *validation split*, diharapkan dapat meningkatkan variasi data *training* sesuai dengan rekomendasi bahwa jumlah foto dalam dataset dapat mempengaruhi akurasi model (Lisda et al., 2023).

Penerapan *data augmentation* diharapkan dapat mengatasi keterbatasan jumlah dataset dan meningkatkan kemampuan generalisasi model dalam mengklasifikasikan kedua jenis *Pistachio*. Selain itu, penelitian ini juga akan menerapkan *class weighting* untuk mengoptimalkan performa model sekaligus mencegah terjadinya *overfitting* dan bias model terhadap kelas mayoritas. Dengan menggunakan metodologi yang konsisten dengan

2

penelitian sebelumnya dalam hal pembagian dataset, *batch size* 32, dan *epoch* hingga 100 Lisda et al., (2023), serta dengan memperhatikan pentingnya validasi statistik yang tepat untuk menghindari klaim performa yang terlalu optimis Hoots et al., (2025), penelitian ini diharapkan dapat memberikan kontribusi berupa peningkatan akurasi klasifikasi yang melampaui *baseline* Inception-V3 sebesar 96% (Lisda et al., 2023).

Penelitian ini juga akan memberikan analisis komprehensif mengenai performa *Resnet101* pada dataset *Pistachio*, termasuk evaluasi menggunakan berbagai metrik seperti *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix* Lisda et al., (2023) Uzer, (2025), sehingga dapat memberikan gambaran yang lebih lengkap dan valid tentang kemampuan model dalam mengklasifikasikan kedua jenis *Pistachio* tersebut. Hasil penelitian ini diharapkan pula dapat membantu petani dalam meningkatkan efisiensi proses pasca panen dengan mengklasifikasikan berbagai jenis kacang *Pistachio* secara cepat, akurat, dan efisien, serta menangani kebutuhan pasar dengan lebih tepat sasaran (Lisda et al., 2023) (Özkan et al., 2021) (Trihardianingsih L. & Permatasari H., 2025).

B. Batasan Masalah

Agar penelitian ini lebih terarah dan tidak melebar dari tujuan utama, maka ditetapkan batasan masalah sebagai berikut:

1. Penelitian hanya berfokus pada klasifikasi dua varietas kacang *Pistachio*, yaitu *Kirmizi* dan *Siirt*, sebagaimana terdapat pada dataset *Pistachio* publik dari kaggle yang digunakan dalam penelitian sebelumnya.
2. Model deep learning yang dikembangkan hanya menggunakan arsitektur *Resnet101*, sebagai bentuk eksplorasi arsitektur alternatif dari penelitian terdahulu yang menggunakan *Inception-V3*, dan *Resnet50*. Penelitian ini tidak melakukan eksperimen pada arsitektur lain di luar *Resnet101*.
3. Penambahan jumlah data hanya dilakukan melalui teknik data Augmentation, seperti (*rescale*, *rotation*, *horizontal_flip*, *width_shift_range*, *height_shift_range*, *fill_mode*, dan *validation_split*). Penelitian ini tidak menambah data melalui pengambilan gambar baru ataupun sumber dataset eksternal.

4. Penanganan ketidakseimbangan kelas (imbalance class) hanya dilakukan menggunakan teknik *class weighting* pada proses *training*. Penelitian ini tidak membahas metode balancing lain seperti *SMOTE*, *oversampling*, *undersampling*, ataupun *focal loss*.
5. Cakupan evaluasi model terbatas pada metrik klasifikasi standar, yaitu *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Evaluasi yang bersifat deployment juga termasuk dalam ruang lingkup ini.

C. Rumusan Masalah

Berdasarkan identifikasi dan batasan masalah yang telah ditetapkan, maka rumusan masalah dalam penelitian ini adalah sebagai berikut :

1. Seberapa efektif penerapan teknik data Augmentation pada arsitektur *Resnet101* dalam meningkatkan akurasi klasifikasi dan mencegah overfitting pada kacang *Pistachio* varietas *Kirmizi* dan *Siirt* dibandingkan dengan model tanpa data Augmentation?
2. Seberapa akurat tingkat akurasi, *precision*, *recall*, dan *F1-score* yang dicapai oleh model *CNN Resnet101* dengan data *Augmentation* dibandingkan dengan penelitian sebelumnya yang menggunakan baseline *Inception-V3* (96%) dan *Resnet50* (86%)?
3. Bagaimana pengaruh penerapan *class weighting* terhadap keseimbangan performa klasifikasi antara kelas *Kirmizi* dan *Siirt* yang memiliki distribusi data tidak seimbang?

D. Tujuan Penelitian

Tujuan dari penelitian ini adalah sebagai berikut :

1. Meningkatkan variasi data *training* dan mencegah overfitting melalui implementasi teknik data Augmentation (*rescale*, *rotation*, *horizontal_flip*, *width_shift_range*, *height_shift_range*, *fill_mode*, dan *validation_split*) pada arsitektur *Resnet101* untuk mengatasi keterbatasan jumlah dataset dan meningkatkan kemampuan generalisasi model, yang ditunjukkan melalui pengurangan gap yang signifikan antara *training* dan *validation accuracy* dibandingkan dengan hasil penelitian sebelumnya pada *Resnet50* yang mengalami overfitting parah (gap 78%).

2. Meningkatkan akurasi klasifikasi *Pistachio* dengan mengimplementasikan arsitektur *Resnet101* yang lebih dalam dibandingkan *Resnet50*, untuk mencapai akurasi minimal melampaui baseline Inception-V3 (96%) dan *Resnet50* (86%) dari penelitian sebelumnya.
3. Menyeimbangkan kemampuan model dalam mengenali kedua jenis *Pistachio* (*Kirmizi* dan *Siirt*) dengan menggunakan teknik class weighting, sehingga model tidak lebih pintar mengenali jenis yang datanya lebih banyak (*Kirmizi*) dan mengabaikan jenis yang datanya lebih sedikit (*Siirt*).

E. Manfaat Penelitian

1. Manfaat Teoritis

- a. Memberikan kontribusi dalam pengembangan ilmu *computer vision* dan *deep learning* untuk aplikasi klasifikasi produk pertanian dengan karakteristik visual yang serupa.
- b. Menjadi referensi akademis mengenai implementasi arsitektur *Resnet101* pada klasifikasi *Pistachio* yang dapat dijadikan acuan untuk penelitian sejenis di masa mendatang.
- c. Memberikan pemahaman yang lebih mendalam mengenai efektivitas teknik data *Augmentation* dan *class weighting* dalam mengatasi permasalahan dataset terbatas dan tidak seimbang.
- d. Memudahkan peneliti lain untuk mengulangi penelitian ini karena melalui transparansi metodologi yang lengkap, termasuk dokumentasi *hyperparameter* dan strategi *training*.

2. Manfaat Praktis

- a. Bagi petani dan pelaku usaha *Pistachio*, hasil penelitian dapat menjadi dasar pengembangan sistem klasifikasi otomatis yang meningkatkan efisiensi proses pasca panen, sehingga menghemat biaya tenaga kerja dan meningkatkan keuntungan karena produk dijual sesuai dengan jenisnya.
- b. Bagi industri pengolahan makanan, sistem klasifikasi ini dapat membantu memastikan kualitas bahan baku yang digunakan selalu konsisten dan tidak tercampur antar jenis.
- c. Bagi pengembang teknologi pertanian, penelitian ini dapat menjadi bukti nyata bahwa teknologi klasifikasi otomatis bisa diterapkan untuk

pengembangan aplikasi mobile yang dapat diimplementasikan secara *real-time*.

- d. Bagi peneliti selanjutnya, metodologi yang terdokumentasi dengan baik dalam penelitian ini dapat menjadi baseline yang solid untuk penelitian lanjutan dalam klasifikasi *Pistachio* maupun produk pertanian lainnya.

3. Harapan/kontribusi

Secara keseluruhan, penelitian ini diharapkan dapat memberikan kontribusi yang berarti dalam pengembangan model klasifikasi kacang *Pistachio* berbasis arsitektur *CNN Resnet101*, khususnya dalam membuktikan efektivitas kombinasi teknik *data augmentation* dan *class weighting* untuk meningkatkan akurasi dan keseimbangan klasifikasi varietas *Kirmizi* dan *Siirt*. Selain itu, penelitian ini diharapkan dapat menjadi solusi praktis bagi para pelaku industri *Pistachio* dalam meningkatkan efisiensi dan akurasi proses klasifikasi pasca panen secara otomatis, sehingga setiap varietas dapat dipisahkan dan dipasarkan sesuai dengan nilai ekonominya masing-masing.

BAB II

KAJIAN PUSTAKA

A. Kajian Teori

1. *Pistachio* (Kacang *Pistachio*)

Pistachio merupakan salah satu komoditas pertanian yang memerlukan inovasi dalam proses penanganan pasca panen. Tanaman *Pistachio* merupakan jenis penghasil biji-bijian yang dikenal sebagai kacang *Pistachio*. Dari segi nutrisi, *Pistachio* tergolong kacang-kacangan bernutrisi tinggi karena mengandung protein, serat, asam lemak tak jenuh tunggal, mineral, vitamin, karotenoid, asam fenolik, flavonoid, dan antosianin Lisda et al., (2023). Terdapat berbagai varietas *Pistachio* dengan karakteristik dan segmen pasar yang berbeda. Dalam penelitian ini, dua varietas utama menjadi fokus klasifikasi, yaitu:

a. *Pistachio Kirmizi*

Varietas *Kirmizi* memiliki karakteristik warna hijau tua, rasa dan aroma yang khas, sehingga banyak digunakan oleh industri permen dan kue-kue manis (Trihardianingsih L. & Permatasari H., 2025).



Gambar 2.1 *Pistachio Kirmizi*

b. *Pistachio Siirt*

Varietas *Siirt* lebih disukai sebagai makanan ringan karena memiliki tingkat retak yang tinggi. Kultivar *Siirt* memiliki persentase pembelahan yang

tinggi, bentuk oval dan besar dengan biji berwarna kuning. Buah yang panjang lebih disukai di industri untuk permen, es krim, dan produk kembang gula karena warna biji hijau, rasa, dan teksturnya yang khas. Buah berbentuk oval dipasarkan dan dikonsumsi sebagai camilan. Pasar lebih menyukai buah berukuran besar dengan persentase pembelahan tinggi seperti varietas *Siirt* karena rasanya yang luar biasa (Lisda et al., 2023).




Gambar 2.2 *Pistachio Siirt*

2. Convolutional Neural Network (CNN)

Menurut Azmi & Defit, (2023) *CNN* merupakan salah satu jenis arsitektur neural Network yang dirancang khusus untuk memproses data citra (*image*). *CNN* pada dasarnya memiliki struktur yang tidak jauh berbeda dengan neural Network konvensional, namun dioptimalkan untuk menangani data spasial. Arsitektur *CNN* terdiri dari dua komponen utama, yaitu *feature learning* yang mencakup serangkaian lapisan untuk mengidentifikasi fitur-fitur penting dalam citra, dan *classification layer* yang bertanggung jawab dalam pengambilan keputusan berdasarkan fitur yang telah diekstraksi oleh lapisan sebelumnya (Harahap et al., 2024).

Kemampuan *CNN* dalam melakukan ekstraksi fitur yang kompleks dan hierarkis dari citra digital menjadikannya metode yang sangat sesuai untuk meningkatkan performa klasifikasi pada objek pertanian seperti *Pistachio*. *CNN* mampu menangani berbagai variasi visual dalam dataset seperti

perbedaan orientasi objek, variasi kondisi pencahayaan, serta perbedaan morfologi yang halus antara varietas *Kirmizi* dan *Siirt*, sehingga penelitian ini bertujuan menganalisis *Resnet101* dalam melakukan klasifikasi kedua varietas *Pistachio* dengan akurasi yang optimal (Aldiani et al., 2024).



Gambar 2.3 Arsitektur CNN

a. *Komponen - komponen CNN:*

1. *Input Layer*

Menurut Azmi & Defit, (2023) Lapisan *input* berfungsi untuk menampung nilai pixel dari citra yang dimasukkan ke dalam sistem. Citra *Pistachio* yang diinputkan memiliki 3 channel warna RGB (*Red, Green, Blue*) yang merepresentasikan informasi warna dari setiap pixel.

2. *Convolution Layer*

Menurut Nurona Cahya et al., (2021) *Convolutional layer* melakukan operasi konvolusi pada output dari *layer* sebelumnya. Bobot pada *layer* ini menspesifikasikan kernel konvolusi yang dapat dilatih berdasarkan *input* pada *CNN*. Tujuan dari operasi konvolusi terhadap citra adalah untuk mengekstraksi fitur dari citra *input* yang kemudian digunakan untuk proses klasifikasi.

3. *Activation Layer*

Pada lapisan ini terjadi proses transformasi nilai-nilai *feature map* pada rentang tertentu tergantung pada fungsi aktivasi yang digunakan, yaitu fungsi aktivasi *ReLU (Rectified Linear Unit)*. Fungsi *ReLU* melakukan thresholding dari nilai 0 hingga infinity, dan menjadi salah satu fungsi aktivasi yang

populer dalam *deep learning* karena kemampuannya mengatasi masalah *vanishing gradient* (Azmi & Defit, 2023).

4. *Pooling Layer*

Lapisan *Pooling* bekerja pada setiap *feature map* dan melakukan pengurangan dimensi spasial. Umumnya *Pooling layer* menggunakan *filter* berukuran 2×2 yang diaplikasikan dengan *stride* tertentu dan beroperasi pada setiap *slice* dari *input*. *Pooling* berfungsi untuk mengurangi jumlah *parameter* dan komputasi, serta membantu mencegah *overfitting* (Azmi & Defit, 2023).

5. *Fully Connected Layer*

Lapisan ini menghubungkan fitur-fitur yang telah diekstraksi menuju *output* kelas A. Sucipto et al., (2024). *Layer* ini melakukan *high-level reasoning* berdasarkan fitur yang telah diekstraksi (Azmi & Defit, 2023).

6. *Output Layer*

Pada tahap akhir, proses klasifikasi dilakukan dengan bantuan aktivasi *softmax* yang mengklasifikasikan *input* sesuai dengan kategori target, yaitu 2 kelas *Pistachio* yaitu *Kirmizi* dan *Siirt*. Fungsi *softmax* mengkonversi output menjadi distribusi probabilitas untuk setiap kelas (Azmi & Defit, 2023).

3. *Transfer Learning*


Transfer learning merupakan pendekatan yang memanfaatkan model jaringan yang telah melalui proses pelatihan sebelumnya sebagai fondasi awal dalam mempelajari tugas atau masalah baru Solihin et al., (2022). Dengan menggunakan *Transfer Learning*, fitur yang telah dipelajari dapat ditransfer ke tugas baru dengan memanfaatkan dataset yang lebih sedikit selama proses pelatihan, sehingga mempercepat proses *training*. Karena jaringan sudah melalui proses pelatihan sebelumnya dan telah mempelajari cara mengekstraksi berbagai fitur, jaringan yang baru menjadi lebih akurat dalam melakukan tugasnya (Faturrahman et al., 2023).

4. *Resnet101*

Menurut Vierisyah & Maulana Fajri, (2023) *Resnet-101* adalah jaringan saraf *Convolutional* dengan kedalaman 101 lapisan. jaringan yang dilatih di lebih dari satu juta gambar dari database *ImageNet*. Jaringan terlatih dapat mengklasifikasikan gambar ke dalam 1000 kategori objek untuk menangani

15

masalah vanishing gradient pada jaringan yang sangat dalam, sehingga mempercepat dan menstabilkan proses pelatihan (Fathir Rizal Januar et al., (2025) Vierisyah & Maulana Fajri, (2023). Pemilihan arsitektur *Resnet101* dalam penelitian ini didasarkan pada bukti empiris dari studi komparatif yang rigorous oleh Goceri & Karakas, (2020). Dalam penelitian berjudul "*Comparative Evaluations of CNN Based Network for Skin Lesion Classification*", Goceri & Karakas melakukan evaluasi terhadap lima arsitektur CNN yang populer yaitu *VGG16*, *VGG19*, *GoogleNet*, *Inception-V3*, dan *Resnet101* untuk tugas klasifikasi lesi kulit. Hasil penelitian Goceri & Karakas (2020) menunjukkan bahwa arsitektur *Resnet101* mampu mengklasifikasikan citra dengan akurasi tertinggi sebesar 77.72% dibandingkan dengan *VGG16*, *VGG19*, *GoogleNet*, dan *Inception-V3*.



Gambar 2.4 Arsitektur *Resnet-101*

5. *Augmentasi Data*

71

Data augmentation adalah teknik yang digunakan dalam machine learning untuk memperbanyak jumlah data training dengan cara memodifikasi data yang sudah ada, melalui modifikasi terkontrol seperti: *rescale*, *rotation*, *horizontal_flip*, *width_shift_range*, *height_shift_range*, *fill_mode*, dan *validation_split*. Kombinasi teknik *Augmentation* ini dipilih berdasarkan karakteristik data *Pistachio* untuk mencegah *overfitting* dan meningkatkan variasi data tanpa mengubah fitur visual esensial yang membedakan *varietas Kirmizi* dan *Siirt* (Solihin et al., 2022) (Al-Fahrezi, 2025) (Hisyam Pradhana & Daniati, 2025).

2

6. Class weight

Menurut Akbar & Sanjaya, (2023) *Class weight* adalah teknik yang dapat digunakan dalam pembelajaran mesin untuk mengatasi kelas yang tidak seimbang dengan cara memberikan bobot yang lebih tinggi pada sampel dari kelas minoritas. Permasalahan dapat timbul dalam menilai classifier secara adil karena ketidakseimbangan distribusi kelas pada dataset yang tidak seimbang, sehingga menyebabkan terjadinya bias prediksi pada model terhadap kelas mayoritas.

7. Metrik Evaluasi Klasifikasi

Tahap evaluation berfungsi sebagai proses menggambarkan performa model yang telah dikembangkan serta validasi terhadap tingkat kesesuaian dan akurasi data hasil klasifikasi Shelin Sahira et al., (2024). Dalam penelitian ini, evaluasi dilakukan dengan membagi data ke dalam set *training*, *validation*, dan *testing*, serta mengevaluasi model menggunakan metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score*. Selain itu visualisasi hasil menggunakan *confusion matrix* dan juga diperlukan untuk menganalisis lebih lanjut performa model (Adzkie & Arifin, 2025).

a. Accuracy

Accuracy mengukur proporsi data yang berhasil diklasifikasikan secara tepat, digunakan untuk memvalidasi ketepatan hasil prediksi model (Bhakti et al., 2024).

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

b. Precision

Precision yaitu proporsi antara hasil positif yang benar terhadap total prediksi positif (Triwardani et al., 2024).

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

c. Recall

Recall mengukur proporsi kejadian aktual positif yang benar-benar terprediksi positif (Ardiansyah et al., 2024).

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

d. *F1-score*

F1-score adalah harmoni rata-rata dari presisi dan recall, memberikan keseimbangan antara keduanya (Ardyansyah et al., 2024).

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2.4)$$

B. Kajian Hasil Penelitian Terdahulu

1. Penelitian menggunakan CNN

Penelitian oleh Goceri & Karakas, (2020) yang berjudul "*Comparative Evaluations of CNN Based Network for Skin Lesion Classification*" melakukan evaluasi komparatif terhadap lima arsitektur CNN yaitu *VGG16*, *VGG19*, *GoogleNet*, *Inception-V3*, dan *Resnet101* untuk klasifikasi lesi kulit. Penelitian ini mengimplementasikan kelima arsitektur dengan kondisi yang identik, meliputi parameter yang sama, fungsi aktivasi, loss, dan optimasi yang sama, serta dilatih dan diuji dengan dataset yang sama pada komputer dengan konfigurasi hardware yang sama untuk memastikan perbandingan yang fair. Hasil penelitian menunjukkan bahwa arsitektur *Resnet101* mampu mengklasifikasikan citra dengan akurasi tertinggi sebesar 77.72% dibandingkan arsitektur lainnya. Penelitian ini memberikan bukti empiris bahwa *Resnet101 superior* dibandingkan *Inception-V3* dalam tugas klasifikasi citra ketika dilakukan fair comparison, sehingga menjadi landasan kuat pemilihan arsitektur *Resnet101* dalam penelitian yang akan dilakukan. Meskipun domain penelitian berbeda (*medical imaging vs agricultural products*), karakteristik permasalahan memiliki kesamaan yaitu klasifikasi objek dengan perbedaan visual yang *subtle* dan dataset yang terbatas, sehingga hasil studi komparatif ini relevan untuk dijadikan acuan.

2. Penelitian tentang Klasifikasi *Pistachio*

Penelitian tentang klasifikasi *Pistachio* telah dilakukan oleh beberapa peneliti dengan menggunakan berbagai arsitektur deep learning. Lisda et al., (2023) dalam penelitiannya yang berjudul "*Classification of Pistachio Nut*"

Using Convolutional Neural Network" mengklasifikasikan dua varietas Pistachio yaitu Kirmizi dan Siirt menggunakan arsitektur CNN Inception-V3 dan Resnet50 pada dataset sebanyak 2148 gambar yang dibagi dengan rasio 80:10:10 untuk training, validation, dan testing. Hasil eksperimen menunjukkan bahwa Inception-V3 mencapai akurasi testing sebesar 96%, sementara Resnet50 hanya mencapai 86% dengan indikasi overfitting yang parah ditunjukkan oleh gap antara training accuracy (98%) dan validation accuracy (20%) yang mencapai 78%. Penelitian ini tidak menggunakan teknik data augmentation dalam proses training, yang menjadi salah satu penyebab terjadinya overfitting pada model Resnet50.

Selanjutnya, Singh et al., (2022) dalam penelitian berjudul "Classification and Analysis of Pistachio Species with Pre-Trained Deep Learning Models" menggunakan pendekatan Transfer Learning dengan tiga arsitektur CNN yaitu AlexNet, VGG16, dan VGG19 untuk mengklasifikasikan 2148 citra Pistachio Kirmizi dan Siirt yang dibagi dengan rasio 80:20 untuk training dan testing. Hasil klasifikasi menunjukkan tingkat keberhasilan masing-masing sebesar 94.42%, 98.84%, dan 98.14%, dimana VGG16 mencapai akurasi klasifikasi tertinggi sebesar 98.84%. Penelitian ini menggunakan metrik evaluasi berupa sensitivitas, spesifisitas, akurasi, dan skor F-1, serta menggunakan kurva ROC dan nilai AUC dalam evaluasi performa model.

AVUÇLU, (2023) melakukan dua penelitian terpisah tentang klasifikasi Pistachio dengan arsitektur yang berbeda. Penelitian pertama berjudul "Classification of Pistachio Images Using VGG16 and VGG19 Deep Learning Models" mengklasifikasikan dua kelas Pistachio Kirmizi dan Siirt menggunakan arsitektur VGG16 dan VGG19 dengan metode 5-fold cross-validation pada dataset 2148 gambar. Hasil eksperimen menunjukkan bahwa VGG16 menghasilkan rata-rata accuracy sebesar 0.8021 (80.21%) dan F1-measure sebesar 0.8306, sementara VGG19 menghasilkan accuracy dan F1-measure sebesar 0.7794 (77.94%).

Penelitian kedua oleh Avuçlu, (2023) berjudul "Classification of Pistachio Images with The Resnet Deep Learning Model" mengklasifikasikan Pistachio Kirmizi dan Siirt menggunakan arsitektur Resnet dengan 2148 gambar

melalui pendekatan *5-fold cross-validation*. Hasil eksperimen menunjukkan akurasi tertinggi sebesar 88.58% pada *fold-1* dengan rata-rata akurasi *5-fold* sebesar 86.16%, yang menunjukkan konsistensi dengan hasil *Resnet50* pada penelitian (Lisda et al., 2023).

Berdasarkan kajian penelitian-penelitian terdahulu, dapat diidentifikasi bahwa meskipun berbagai arsitektur telah diuji pada dataset *Pistachio* yang sama, masih terdapat beberapa *gap* penelitian. Pertama, *Resnet101* yang terbukti superior dalam studi *komparatif* Goceri & Karakas, (2020) belum pernah diuji pada dataset *Pistachio* ini. Kedua, arsitektur *Resnet* (*Resnet50*) yang mengalami *overfitting* parah (gap 78%) pada penelitian Lisda et al., (2023) tidak menggunakan teknik *data augmentation* untuk meningkatkan variasi data *training* dan mencegah *overfitting*. Ketiga, ketidakseimbangan distribusi data antara kelas *Kirmizi* (1232 sampel) dan *Siirt* (916 sampel) belum ditangani dengan teknik *class weighting* pada penelitian-penelitian sebelumnya, yang dapat menyebabkan bias model terhadap kelas mayoritas. Keempat, beberapa penelitian melaporkan hasil dari *single experimental runs* atau performa terbaik yang dipilih tanpa validasi statistik yang tepat melalui *multiple runs* dengan random seed berbeda, sebagaimana dikritik oleh Hoots et al., (2025) bahwa praktik ini dapat menyebabkan klaim performa yang terlalu optimis dan reproduisibilitas yang buruk.


3. Perbedaan penelitian ini dengan penelitian sebelumnya

Penelitian ini bertujuan untuk mengisi *gap* penelitian yang telah diidentifikasi dengan mengimplementasikan arsitektur *Resnet101* yang belum pernah diuji pada dataset *Pistachio* ini, dikombinasikan dengan teknik data augmentation dan class weighting untuk mengatasi keterbatasan penelitian-penelitian sebelumnya. Berbeda dengan penelitian Lisda et al., (2023) yang menggunakan *Inception-V3* dan *Resnet50* tanpa data augmentation, penelitian ini menerapkan teknik *data augmentation* yang komprehensif meliputi *rescale*, *rotation* ($\pm 8^\circ$), *horizontal flip*, *width shift range* (6%), *height shift range* (6%), *fill mode* (*nearest*), dan *validation split* untuk meningkatkan variasi data *training* dan mencegah *overfitting* yang dialami *Resnet50* dengan *gap* 78% antara *training* dan *validation accuracy*.

Selain itu, penelitian ini juga menerapkan teknik *class weighting* untuk menangani ketidakseimbangan data antara kelas *Kirmizi* (1232 sampel) dan *Siirt* (916 sampel).

C. Kerangka Berpikir

Penelitian ini menggunakan pendekatan kuantitatif dengan jenis penelitian eksperimental yang memanfaatkan komputasi matematis untuk menganalisis data. Proses pembelajaran klasifikasi citra *Pistachio* dilakukan menggunakan arsitektur *Convolutional Neural Network (CNN)* dengan implementasi model *Resnet101* yang dikombinasikan dengan teknik *data Augmentation* dan *class weighting*. Evaluasi hasil pembelajaran dilakukan untuk mengukur tingkat akurasi model dalam mengklasifikasikan citra *Pistachio* varietas *Kirmizi* dan *Siirt*, sehingga dapat diketahui efektivitas model yang dikembangkan berdasarkan metrik evaluasi yang telah ditetapkan.



Gambar 2.5 Alur Kerangka Berpikir

METODE PENELITIAN

21



Kacang *Pistachio* merupakan komoditas pertanian bernilai ekonomi tinggi yang diperdagangkan secara global. Proses klasifikasi varietas *Pistachio* yang saat ini masih dilakukan secara manual menghadapi tantangan signifikan, mengingat varietas *Kirmizi* dan *Siirt* memiliki bentuk morfologi yang hampir identik sehingga sulit dibedakan secara visual oleh tenaga manusia Lisda et al., (2023). Kondisi ini berpotensi menyebabkan kesalahan klasifikasi yang berdampak langsung pada kerugian ekonomi, karena produk dari dua varietas berbeda dapat tercampur dan dijual dengan harga yang tidak sesuai dengan nilai pasar masing-masing varietas (Singh et al., 2022).

47 Dari sudut pandang bisnis, permasalahan ini dapat dirinci menjadi tiga aspek utama. Pertama, aspek efisiensi operasional, di mana proses klasifikasi manual membutuhkan waktu yang lama dan bergantung pada keahlian tenaga kerja yang berpengalaman. Kedua, aspek kualitas produk, di mana tercampurnya dua varietas dalam satu kemasan dapat menurunkan reputasi dan kepercayaan konsumen terhadap produk. Ketiga, aspek ekonomi, di mana varietas *Kirmizi* yang ditujukan untuk industri permen dan kue manis memiliki titik harga yang berbeda dari varietas *Siirt* yang ditujukan sebagai camilan, sehingga kesalahan klasifikasi secara langsung berdampak pada selisih pendapatan yang signifikan (Singh et al., 2022) (Uzer, 2025).

31 Oleh karena itu, dibutuhkan sebuah sistem klasifikasi otomatis berbasis *deep learning* yang mampu membedakan kedua varietas *Pistachio* secara akurat, cepat, dan konsisten untuk menggantikan proses manual yang rentan terhadap kesalahan.

2. Tujuan Bisnis

5 Berdasarkan latar belakang masalah bisnis yang telah diuraikan, tujuan bisnis dari penelitian ini adalah sebagai berikut:

- Mengembangkan model klasifikasi otomatis berbasis *deep learning* untuk membedakan *Pistachio* varietas *Kirmizi* dan *Siirt* dengan akurasi tinggi.
- Mengatasi *overfitting* parah pada *Resnet50* (*gap train-val* 78%) melalui implementasi teknik *data augmentation* (Lisda et al., 2023).
- Menghasilkan performa klasifikasi yang seimbang antar kelas melalui penerapan *class weighting*.
- Menghasilkan model yang terdokumentasi dan tervalidasi sehingga siap diintegrasikan ke dalam sistem pasca panen *Pistachio*.

3. Kriteria Keberhasilan Proyek

Penelitian ini dinyatakan berhasil apabila memenuhi kriteria-kriteria berikut:

- Model mencapai testing accuracy minimal melampaui *baseline Inception-V3* (96%) dan *Resnet50* (86%) (Lisda et al., 2023).
- Gap* antara *training* accuracy dan *validation* accuracy lebih kecil secara signifikan dibandingkan *Resnet50* (*gap* 78%) pada penelitian sebelumnya.

- c. Nilai *precision*, *recall*, dan *F1-score* seimbang antara kelas *Kirmizi* dan *Siirt* tanpa bias yang signifikan terhadap salah satu kelas.
- d. Hasil dievaluasi secara komprehensif dan transparan menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix* (Hoots et al., 2025).

B. Data Understanding

1. Pengumpulan Data

Data yang digunakan adalah *Pistachio Image Dataset* yang bersumber dari platform *Kaggle* dengan *lisensi Public Domain (CC0)*. Dataset ini merupakan dataset yang sama dengan penelitian sebelumnya *Lisda et al., (2023)*, sehingga memungkinkan perbandingan hasil yang valid.

a. Sumber Data :

- *Pistachio Image Dataset* dari *Kaggle* (*Lisda et al., 2023*)
- Lisensi: *Public Domain (CC0)*
- Format: *JPG/PNG*,
- Mode warna: *RGB 3 channels*

2. Deskripsi Data

Dataset terdiri dari 2148 citra yang terbagi ke dalam dua kelas varietas *Pistachio* dengan distribusi sebagai berikut:

- Total *Images*: 2148
- *Kirmizi_Pistachio*: 1232 images (57.4%)
- *Siirt_Pistachio*: 916 images (42.6%)
- *Class Imbalance Ratio*: 1.35:1 (*mild imbalance*)
- *Resolution*: *Varied* (akan di-*resize* ke 224×224)

Terdapat *class imbalance* dengan rasio 1,35:1 yang perlu ditangani menggunakan teknik *class weighting* untuk mencegah bias model terhadap kelas mayoritas.

3. Eksplorasi Data Awal

Berdasarkan eksplorasi data, diperoleh temuan sebagai berikut:

- a. Seluruh citra memiliki latar belakang putih atau netral yang konsisten, sehingga model dapat fokus pada fitur morfologi kacang

- b. Varietas *Kirmizi* berciri warna biji hijau tua dengan bentuk lebih panjang, sedangkan *Siirt* berbentuk lebih oval dengan warna biji kuning kehijauan (Lisda et al., 2023).
- c. Resolusi citra bervariasi sehingga diperlukan *resize* ke ukuran 224×224 piksel sesuai standar input *Resnet101*.

4. Verifikasi Kualitas Data

Hasil verifikasi menunjukkan bahwa seluruh citra dapat terbaca dengan baik, tidak ditemukan citra rusak atau tidak relevan, dan label kelas sudah tersegregasi dengan benar sesuai struktur folder dataset. Dataset dinyatakan layak digunakan tanpa memerlukan proses data cleaning tambahan.

C. Data Preparation

1. Seleksi Data

Seluruh 2148 citra digunakan tanpa pengurangan subset. Dataset dibagi menggunakan strategi stratified split dengan rasio 80:10:10 sesuai penelitian sebelumnya (Lisda et al., 2023).

Tabel 3.1 Pembagian Dataset

Subset	Proporsi	Jumlah Citra
<i>Training</i>	80%	± 1718
Validation	10%	± 193
Testing	10%	237
Total	100%	2148

2. Pembersihan Data

Berdasarkan hasil verifikasi kualitas data, seluruh citra dinyatakan dalam kondisi baik sehingga tidak diperlukan pembersihan data secara khusus. Normalisasi nilai piksel dilakukan dengan *rescaling* ($1./255$) untuk mengubah rentang nilai *piksel* dari $[0-255]$ menjadi $[0-1]$ guna mempercepat *konvergensi* dan menstabilkan *gradien* selama *training*.

3. Transformasi Data

a. Preprocessing

Preprocessing merupakan tahap penting dalam pengolahan data karena data mentah seringkali belum sempurna dan memerlukan penyesuaian sebelum dapat digunakan secara optimal dalam proses pelatihan model (S.

Sucipto et al., 2024). Setiap citra di-resize menjadi 224×224 piksel dan dinormalisasi dengan *rescaling* ($1./255$) sesuai persyaratan input *Resnet101*.

b. Data Augmentation

Data augmentation diterapkan eksklusif pada *training set* dengan parameter berikut:

Tabel 3.2 Parameter *Data Augmentation*

Parameter	Nilai
<i>Rescale</i>	$1./255$
<i>Rotation</i>	$\pm 8^\circ$
<i>Horizontal flip</i>	True
<i>Width/Height Shift Range</i>	6%
<i>Fill Mode</i>	Nearest
<i>Validation Split</i>	0,1111

c. Perhitungan *Class Weights*

Class weight dihitung menggunakan formula *balanced weight* berikut (Adi et al., 2025):

$$Class_weight_i = \frac{N_{total}}{K \times N_i} \quad (3.1)$$

Keterangan :

- $Class_weight_i$ = bobot kelas i
- N_{total} = total sampel **training**
- K = jumlah kelas
- N_i = jumlah sampel kelas i

Berdasarkan formula tersebut, diperoleh nilai *class weight* sebagai berikut:

Tabel 3.3 Nilai *Class Weight*

Kelas	Jumlah Sampel <i>Training</i>	<i>Class Weight</i>
<i>Kirmizi_Pistachio</i>	± 986	0,876
<i>Siirt_Pistachio</i>	± 732	1,165

4. Pembuatan Dataset *Modeling*

Dataset modeling dibuat menggunakan ImageDataGenerator dari TensorFlow/Keras. *Training* generator dikonfigurasi dengan parameter augmentasi lengkap, sedangkan test generator hanya menggunakan *rescaling* tanpa augmentasi. Seluruh generator dikonfigurasi dengan *seed*=42 untuk menjamin reproduktibilitas hasil.

D. Modelling

1. Pemilihan Teknik Model

Model yang digunakan adalah *Resnet101* dengan pendekatan Transfer Learning menggunakan bobot pre-trained ImageNet. Pemilihan ini didasarkan pada studi komparatif Goceri & Karakas, (2020) yang membuktikan *Resnet101* menghasilkan akurasi tertinggi dibandingkan *VGG16*, *VGG19*, *GoogleNet*, dan *InceptionV3* pada kondisi pengujian yang identik. Strategi *fine-tuning* diterapkan dengan membekukan 60% lapisan awal (layer 1–208) dan melatih 40% lapisan akhir (layer 209–346) untuk menyesuaikan fitur dengan karakteristik citra *Pistachio* (Faturrahman et al., 2023).

2. Desain dan Pengujian Model

a. Arsitektur *Classification Head*

Tabel 3.4 Arsitektur *Classification Head Resnet101*

Layer	Konfigurasi
<i>Base Model Resnet101</i>	<i>Pre-trained ImageNet, partial fine-tuning</i>
<i>Global Average Pooling 2D</i>	Mereduksi <i>feature map</i> menjadi vektor
<i>Batch Normalization 1</i>	Normalisasi distribusi aktivasi
<i>Dense 512</i>	ReLU, L2 = 0,0001
<i>Dropout 1</i>	<i>Rate</i> = 0,35
<i>Batch Normalization 2</i>	Normalisasi distribusi aktivasi
<i>Dense 256</i>	ReLU, L2 = 0,0001
<i>Dropout 2</i>	<i>Rate</i> = 0,35
<i>Output Dense 2</i>	<i>Softmax</i> (2 kelas)

b. Konfigurasi *Training*

- *Optimizer* : Adam

- **Learning Rate** : 0,0001
- **Loss Function** : *Categorical Crossentropy* + *Class Weights*
- **Batch Size** : 32
- **Max Epochs** : 100
- **Random Seed** : 42

c. Callbacks

Tabel 3.5 Konfigurasi Callbacks

Callback	Konfigurasi	Fungsi
<i>Early Stopping</i>	patience=20, monitor val_accuracy	Menghentikan <i>training</i> jika tidak ada peningkatan selama 20 <i>epoch</i>
<i>Reduce LR On Plateau</i>	patience=6, factor=0.5	Mengurangi <i>learning rate</i> 50% jika <i>val_loss</i> stagnan
<i>Model Checkpoint</i>	Monitor val_accuracy	Menyimpan bobot model terbaik secara otomatis

3. Evaluasi Parameter Model

Pemilihan nilai parameter didasarkan pada pertimbangan berikut:

- Learning Rate 0,0001** dipilih untuk memastikan *training* yang stabil dan menghindari konvergensi prematur pada *local minimum*, sesuai praktik umum *fine-tuning* pada dataset terbatas.
- Dropout Rate 0,35** diterapkan untuk regularisasi yang seimbang antara pencegahan *overfitting* dan kapasitas belajar model.
- L2 Regularisasi 0,0001** pada lapisan *Dense* untuk membatasi pertumbuhan bobot berlebihan dan meningkatkan generalisasi model.
- Batch Size 32** dipilih sesuai pengaturan penelitian sebelumnya Lisda et al., (2023) untuk memastikan komparabilitas hasil.

4. Evaluasi Parameter Model

Hasil *training* dipantau melalui kurva *learning* yang menampilkan perkembangan *accuracy*, *loss*, *precision*, dan *recall* pada setiap *epoch*. Interpretasi mencakup analisis konvergensi model, efektivitas *learning rate schedule* dari *ReduceLROnPlateau*, serta penentuan model terbaik

berdasarkan *val_accuracy* tertinggi yang tersimpan melalui *ModelCheckpoint*.

E. Evaluation

1. Evaluasi Model Terbaik

Evaluasi dilakukan pada *testing set* (237 citra) yang tidak digunakan selama *training* maupun *validasi*. Metrik yang digunakan meliputi *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix* (Lisda et al., 2023) (Uzer, 2025).

Tabel 3.6 Hasil Evaluasi Model *Resnet101*

Metrik	<i>Kirmizi</i>	<i>Siirt</i>	<i>Weighted Avg</i>
<i>Precision</i>	96,40%	97,96%	97,07%
<i>Recall</i>	98,53%	95,05%	97,05%
<i>F1-Score</i>	97,45%	96,48%	97,04%
<i>Accuracy</i>	-	-	97,05%

Hasil *confusion matrix* menunjukkan dari 136 citra *Kirmizi*, 134 terklasifikasi benar (2 salah), dan dari 101 citra *Siirt*, 96 terklasifikasi benar (5 salah).

2. Validasi Model terhadap Tujuan Bisnis

Tabel 3.7 Validasi Model terhadap Kriteria Keberhasilan

Kriteria	Target	Hasil	Status
<i>Testing accuracy</i>	> 96%	97,05%	Tercapai
<i>Generalisasi model</i>	Gap < 78%	Gap < 5%	Tercapai
Keseimbangan kelas	F1 seimbang	97,45% vs 96,48%	Tercapai
Evaluasi komprehensif	Semua metrik tersedia	Lengkap	Tercapai

3. Tinjauan Ulang Proses *CRISP-DM*

Seluruh tahapan *CRISP-DM* telah berjalan sesuai tujuan penelitian. Hasil evaluasi menunjukkan semua kriteria keberhasilan terpenuhi, sehingga tidak diperlukan iterasi ulang ke tahapan sebelumnya. Model dinyatakan siap untuk dilanjutkan ke tahap *deployment*.

F. Deployment

1. Rencana Penerapan Hasil

Model yang dihasilkan akan diterapkan melalui pengembangan aplikasi berbasis website yang memungkinkan pengguna mengunggah citra kacang *Pistachio* dan memperoleh hasil klasifikasi varietas *Kirmizi* atau *Siirt* secara langsung. Implementasi website ini dapat memanfaatkan model yang telah disimpan dalam format .keras dan diintegrasikan ke dalam back-end menggunakan framework seperti Flask atau FastAPI sebagai REST API, sehingga dapat diakses oleh pengguna melalui antarmuka web tanpa memerlukan instalasi perangkat lunak tambahan (Trihardianingsih L. & Permatasari H., 2025).

2. Implementasi Model

Model terbaik disimpan dalam format .keras secara otomatis melalui *ModelCheckpoint* selama *training*. Model kemudian diuji kemampuannya untuk memuat ulang dan melakukan prediksi pada citra baru. Meskipun implementasi sistem produksi penuh tidak termasuk dalam ruang lingkup penelitian ini, model telah disiapkan dan didokumentasikan sehingga siap diintegrasikan oleh pengembang selanjutnya (Marsheila Islami & Nugroho, 2025).

3. Dokumentasi dan Pelaporan

Dokumentasi penelitian mencakup kode program yang terdokumentasi lengkap di Google Colaboratory, seluruh nilai hyperparameter yang digunakan, serta laporan hasil evaluasi yang komprehensif disertai perbandingan dengan baseline penelitian sebelumnya. Penelitian ini dijalankan menggunakan Google Colaboratory dengan akselerasi GPU dan framework TensorFlow/Keras (Hoots et al., 2025).

BAB IV

HASIL DAN PEMBAHASAN

A. Data Hasil Penelitian


1. Hasil Eksplorasi Data

Dataset yang digunakan dalam penelitian ini adalah *Pistachio Image Dataset* yang bersumber dari Kaggle dengan total 2148 citra yang terbagi ke dalam dua kelas varietas. Berdasarkan hasil eksplorasi data, diperoleh informasi statistik deskriptif sebagai berikut:

Tabel 4.1 Statistik Deskriptif *Dataset Pistachio*

Keterangan	Detail
Total citra	2148
<i>Kirmizi_Pistachio</i>	1232 citra (57,4%)
<i>Siirt_Pistachio</i>	916 citra (42,6%)
Rasio ketidakseimbangan	1,35 : 1
Format citra	JPG / PNG, RGB (3 <i>channel</i>)
Resolusi input model	224 × 224 piksel

Berdasarkan tabel tersebut, terdapat ketidakseimbangan kelas (*class imbalance*) dengan selisih 316 citra antara kelas *Kirmizi* dan *Siirt*. Meskipun rasio 1,35:1 tergolong *mild imbalance*, kondisi ini tetap berpotensi menyebabkan bias model terhadap kelas mayoritas apabila tidak ditangani secara eksplisit.



Gambar 4.1 Distribusi Kelas Dataset *Pistachio*

Gambar 4.1 menyajikan diagram batang yang memvisualisasikan distribusi jumlah citra pada masing-masing kelas. Sumbu horizontal menunjukkan nama kelas (*Kirmizi* dan *Siirt*), sedangkan sumbu vertikal menunjukkan jumlah citra. Dari diagram tersebut terlihat jelas perbedaan jumlah citra antar kelas, di mana kelas *Kirmizi* memiliki 1232 citra (57,4%) dan *Siirt* memiliki 916 citra (42,6%), sehingga ketidakseimbangan kelas dapat teridentifikasi secara visual.

Hasil eksplorasi visual menunjukkan bahwa seluruh citra memiliki latar belakang putih atau netral yang konsisten, sehingga fitur yang diekstraksi model dapat difokuskan pada karakteristik morfologi kacang. Perbedaan visual antara *Kirmizi* (biji hijau tua, bentuk panjang) dan *Siirt* (biji kuning kehijauan, bentuk oval) bersifat halus dan sulit dibedakan secara kasat mata, yang menjadi tantangan utama dalam proses klasifikasi (Lisda et al., 2023)

2. Proses Transformasi Data

Sebelum mendeskripsikan proses transformasi data, perlu dijelaskan terlebih dahulu keempat skenario eksperimen yang digunakan dalam penelitian ini. Penelitian ini merancang empat skenario eksperimen dengan kombinasi teknik yang berbeda untuk menganalisis kontribusi masing-masing teknik secara terpisah maupun kombinasi, sebagaimana dirangkum pada tabel berikut:

Tabel 4.2 Deskripsi Keempat Skenario Eksperimen

Skenario	Data Augmentation	Class Weighting	Keterangan
Skenario 1	Ya	Ya	Kombinasi penuh: augmentasi + <i>class weighting</i>
Skenario 2	Tidak	Ya	Hanya <i>class weighting</i> , tanpa augmentasi
Skenario 3	Ya	Tidak	Hanya augmentasi, tanpa <i>class weighting</i>
Skenario 4	Tidak	Tidak	<i>Baseline</i> murni tanpa teknik tambahan

Penomoran skenario ini akan digunakan secara konsisten pada seluruh pembahasan berikutnya. Ketika disebut "Skenario 1", maka merujuk pada eksperimen dengan kombinasi *augmentation* dan *class weighting*; "Skenario 2" merujuk pada eksperimen dengan *class weighting* saja; "Skenario 3" merujuk pada eksperimen dengan *augmentation* saja; dan "Skenario 4" merujuk pada eksperimen *baseline* tanpa teknik tambahan apapun.

Transformasi data dilakukan melalui dua tahapan utama sebelum data dimasukkan ke dalam model.

a. **Normalisasi (*Rescaling*)**

Seluruh nilai piksel citra dinormalisasi menggunakan operasi *rescaling* dengan nilai $1./255$, sehingga rentang nilai piksel diubah dari $[0, 255]$ menjadi $[0, 1]$. Normalisasi ini bertujuan untuk mempercepat konvergensi model dan menstabilkan proses *backpropagation* selama *training*.

b. **Resize Citra**

Seluruh citra di-*resize* ke ukuran standar 224×224 piksel sesuai persyaratan input arsitektur *Resnet101* yang menggunakan bobot *pre-trained ImageNet*.

c. **Pembagian Dataset**

Dataset dibagi menggunakan strategi *stratified split* dengan rasio 80:10:10 untuk memastikan proporsi kelas yang representatif di setiap subset:

Tabel 4.3 Pembagian Dataset


Subset	Jumlah Citra	Keterangan
<i>Training</i>	± 1718	Digunakan untuk melatih model
<i>Validation</i>	± 193	Digunakan untuk memantau performa selama <i>training</i>
<i>Testing</i>	237	Digunakan untuk evaluasi akhir model

d. **Data Augmentation (Skenario 1 dan 3)**

Pada eksperimen yang menggunakan *data augmentation*, transformasi tambahan diterapkan secara eksklusif pada *training set* dengan parameter: *rotation range* $\pm 8^\circ$, *horizontal flip*, *width/height shift range* 6%, dan *fill mode nearest*. *Data augmentation* tidak diterapkan pada *validation set* maupun *testing set*.

e. Perhitungan *Class Weights* (Skenario 1 dan 2)

Pada skenario yang menggunakan *class weighting*, bobot kelas dihitung menggunakan formula *balanced weight* sehingga diperoleh nilai *Kirmizi*: 0,876 dan *Siirt*: 1,165. Nilai ini diterapkan selama proses *training* untuk memberikan penalti yang lebih besar pada kesalahan prediksi kelas *Siirt* (Bahtiar et al., 2025).



Gambar 4.2 Sampel Citra *Kirmizi* dan *Siirt* 4 Skenario

Pada baris pertama menampilkan sampel dari Skenario 1 dan Skenario 2 yang tidak menerapkan augmentasi visual tambahan (atau menerapkan augmentasi pada Skenario 1), sedangkan baris berikutnya menampilkan sampel yang telah mengalami transformasi augmentasi pada Skenario 3. Dari gambar tersebut terlihat bahwa augmentasi rotasi dan pergeseran menghasilkan variasi posisi dan orientasi kacang yang bersifat realistis, sementara ciri khas morfologi seperti warna dan bentuk tetap dapat dibedakan antara kedua varietas.

3. Hasil Modeling

Penelitian ini melakukan empat eksperimen dengan kombinasi teknik yang berbeda untuk menjawab rumusan masalah secara komprehensif. Seluruh eksperimen menggunakan arsitektur *Resnet101* yang sama dengan konfigurasi *training* identik (Adam, *learning rate* 0,0001, *batch size* 32, *max epoch* 100).

a. Ringkasan Hasil Keempat Eksperimen

Tabel 4.4 Ringkasan Hasil Keempat Eksperimen *Resnet101*

Skenario	Augmentation	Class Weight	Duration (menit)	Test Acc (%)	Val Acc (%)	Gap (%)
1	Ya	Ya	92	97,05	98,73	-1,68
2	Tidak	Ya	23	98,31	98,31	0
3	Ya	Tidak	56	95,78	97,89	-2,11
4	Tidak	Tidak	32	98,31	98,31	0

Keterangan :

- *Test Acc* = *Testing Accuracy*
- *Val Acc* = *Validation Accuracy*
- *Gap* = *Test Acc* – *Val Acc*

Perbandingan komprehensif keempat skenario eksperimen. Dari sisi *testing accuracy*, Skenario 2 dan Skenario 4 menghasilkan performa tertinggi sebesar 98%, sedangkan Skenario 1 menghasilkan 97% dan Skenario 3 menghasilkan 95%. Dari sisi durasi *training*, Skenario 1 membutuhkan waktu paling panjang yaitu 92 menit karena augmentasi memperbesar variasi data yang harus dipelajari model di setiap *epoch*, sementara Skenario 2 menjadi yang paling singkat dengan hanya 23 menit karena tanpa augmentasi model dapat berkonvergensi lebih cepat hingga berhenti di *epoch* ke-21 melalui mekanisme *early stopping*.

Sementara itu nilai *gap* antara *validation accuracy* dan *testing accuracy*, Skenario 2 dan Skenario 4 menunjukkan *gap* sebesar 0%, yang berarti performa model pada data validasi sepenuhnya konsisten dengan performa pada data *testing* yang belum pernah dilihat model sebelumnya. Hal ini mengindikasikan kemampuan generalisasi yang sangat baik pada kedua skenario tersebut. Sebaliknya, Skenario 1 menunjukkan *gap* sebesar -1,68% dan Skenario 3 sebesar -2,11%, yang berarti *validation accuracy* lebih tinggi dibandingkan *testing accuracy* pada kedua skenario ini. *Gap* negatif tersebut

mengindikasikan bahwa penerapan augmentasi selama *training* menyebabkan model terbiasa dengan distribusi data yang telah dimodifikasi, sehingga ketika dihadapkan pada data *testing* asli tanpa augmentasi, terdapat sedikit penurunan performa. Semakin besar nilai *gap* negatif, semakin menunjukkan bahwa augmentasi yang diterapkan kurang sesuai dengan karakteristik data asli pada dataset ini.

b. Detail Hasil Per Kelas — Skenario 1

Skenario 1 menyelesaikan *training* penuh hingga *epoch* ke-100 dengan *val accuracy* sebesar 98,73%.

Tabel 4.5 *Classification Report* Skenario 1

Kelas	Precision	Recall	F1-Score	Support
<i>Kirmizi_Pistachio</i>	99,24%	95,59%	97,38%	136
<i>Siirt_Pistachio</i>	94,34%	99,01%	96,62%	101
<i>Weighted Avg</i>	97,15%	97,05%	97,05%	237
<i>Accuracy</i>	97,05%			

Ditabel tersebut menunjukkan bahwa pada Skenario 1, model memiliki *precision* yang sangat tinggi untuk kelas *Kirmizi* (99,24%), artinya hampir seluruh prediksi *Kirmizi* adalah benar. Namun *recall Kirmizi* (95,59%) lebih rendah dibandingkan *recall Siirt* (99,01%), yang menunjukkan bahwa penerapan *class weighting* berhasil mendorong model untuk lebih sensitif terhadap kelas *Siirt* (minoritas), meskipun dengan sedikit pengorbanan pada *precision Siirt* (94,34%).

c. Detail Hasil Per Kelas — Skenario 2

Model dengan Skenario 2 berhenti pada *epoch* ke-41 (*early stopping*) dengan *validation accuracy* sebesar 98,31%.

Tabel 4.6 *Classification Report* Skenario 2

Kelas	Precision	Recall	F1-Score	Support
<i>Kirmizi_Pistachio</i>	98,53%	98,53%	98,53%	136
<i>Siirt_Pistachio</i>	98,02%	98,02%	98,02%	101
<i>Weighted Avg</i>	98,31%	98,31%	98,31%	237
<i>Accuracy</i>	98,31%			

Menunjukkan hasil yang sangat seimbang antara kedua kelas pada Skenario 2. *Precision*, *recall*, dan *F1-score* pada kelas *Kirmizi* (98,53%) dan *Siirt* (98,02%) memiliki selisih yang sangat kecil (0,51 poin), mengindikasikan bahwa model tidak mengalami bias signifikan terhadap salah satu kelas. Nilai *precision* dan *recall* yang identik pada masing-masing kelas juga menunjukkan bahwa jumlah *false positive* dan *false negative* seimbang.

d. Detail Hasil Per Kelas — Skenario 3

Model Skenario 3 berhenti pada *epoch* ke-85 (*early stopping*) dengan *validation accuracy* sebesar 97,89%.

Tabel 4.7 *Classification Report* Skenario 3

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
<i>Kirmizi_Pistachio</i>	97,01%	95,59%	96,30%	136
<i>Siirt_Pistachio</i>	94,17%	96,04%	95,10%	101
<i>Weighted Avg</i>	95,80%	95,78%	95,79%	237
<i>Accuracy</i>	95,78%			

Menunjukkan bahwa Skenario 3 menghasilkan performa terendah di antara keempat skenario. Tanpa *class weighting*, model memperlihatkan kecenderungan yang lebih jelas terhadap kelas *Kirmizi*, yang terlihat dari *precision Kirmizi* (97,01%) yang lebih tinggi dibandingkan *precision Siirt* (94,17%), dengan selisih *F1-score* antar kelas mencapai 1,20 poin. Hal ini mengkonfirmasi bahwa tanpa penanganan ketidakseimbangan kelas, model cenderung lebih baik dalam memprediksi kelas mayoritas.

e. Detail Hasil Per Kelas — Skenario 4


Model Skenario 4 berhenti pada *epoch* ke-66 (*early stopping*) dengan *validation accuracy* sebesar 98,31%.

Tabel 4.8 *Classification Report* Skenario 4

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
<i>Kirmizi_Pistachio</i>	98,53%	98,53%	98,53%	136
<i>Siirt_Pistachio</i>	98,02%	98,02%	98,02%	101
<i>Weighted Avg</i>	98,31%	98,31%	98,31%	237
<i>Accuracy</i>	98,31%			

Menunjukkan bahwa Skenario 4 menghasilkan performa yang identik dengan Skenario 2 (98,31%). Fakta bahwa *baseline* murni tanpa teknik apapun mampu menghasilkan akurasi setinggi ini menunjukkan kemampuan dasar *Resnet101* dengan bobot ImageNet yang sudah sangat kuat dalam mengekstraksi fitur visual dari citra *Pistachio* yang memiliki latar belakang bersih dan konsisten.


f. Kurva *Training Accuracy* dan *Training Loss*



Gambar 4.3 Kurva *Training Accuracy* Keempat Skenario

Pada Skenario 1 dan Skenario 3 yang menggunakan augmentasi, terlihat bahwa garis oranye (*validation accuracy*) bergerak naik turun secara tidak teratur terutama pada *epoch-epoch* awal. Hal ini terjadi karena setiap *epoch* model menerima data latih yang sudah dimodifikasi secara acak melalui augmentasi seperti rotasi dan pergeseran, sehingga pola yang dipelajari model berubah-ubah dan membutuhkan lebih banyak *epoch* untuk menjadi stabil. Skenario 1 baru mencapai kestabilan di sekitar *epoch* ke-30 dan berjalan hingga *epoch* ke-100, sedangkan Skenario 3 mencapai kestabilan lebih awal dan berhenti di *epoch* ke-85.

Sebaliknya, pada Skenario 2 dan Skenario 4 yang tidak menggunakan augmentasi, garis oranye jauh lebih cepat stabil dan langsung bergerak naik sejak awal *training*. Skenario 2 bahkan sudah mencapai nilai di atas *baseline* 96% pada sekitar *epoch* ke-21 dan berhenti karena *early stopping*, sedangkan Skenario 4 berhenti di *epoch* ke-66. Cepatnya konvergensi ini terjadi karena model menerima data yang sama setiap *epoch* tanpa modifikasi, sehingga lebih mudah dan lebih cepat mempelajari pola visual kacang *Pistachio*. Pada akhir *training*, seluruh skenario berhasil melampaui *baseline* Inception-V3, namun Skenario 2 dan Skenario 4 mencapainya dengan lebih efisien.




Gambar 4.4 Kurva *Training Loss* Keempat Skenario

Pada Skenario 1 dan Skenario 3 yang menggunakan augmentasi, terlihat bahwa garis oranye (*validation loss*) mengalami lonjakan yang sangat tinggi di *epoch-epoch* awal, bahkan pada Skenario 1 dan Skenario 3 sempat mencapai nilai di atas 1,5. Lonjakan ini terjadi karena model menerima data yang sudah dimodifikasi secara acak di setiap *epoch*, sehingga pada saat dievaluasi menggunakan data *validation* yang tidak dimodifikasi, model sempat mengalami kebingungan dan menghasilkan prediksi yang jauh meleset. Namun setelah *epoch* ke-10, kedua garis mulai turun bersama-sama meskipun garis oranye masih sesekali naik turun hingga akhir *training*. Pada

akhir *training*, nilai *loss* keduanya sudah rendah dan berdekatan yang menandakan model sudah belajar dengan baik.

Pada Skenario 2 dan Skenario 4 yang tidak menggunakan augmentasi, lonjakan *validation loss* di awal *training* juga terjadi namun jauh lebih pendek dan cepat mereda. Skenario 2 dan Skenario 4 menunjukkan penurunan *loss* yang lebih mulus dan konsisten sejak awal hingga akhir *training*. Hal ini terjadi karena tanpa augmentasi model menerima data yang sama setiap *epoch* sehingga proses pembelajaran berlangsung lebih lancar. Pada bagian akhir *training*, *training loss* dan *validation loss* pada Skenario 2 dan Skenario 4 sudah berada di nilai yang sangat rendah dan berdekatan, yang merupakan tanda bahwa model berhasil belajar dengan baik tanpa *overfitting*.



Gambar 4.5 *Confusion Matrix* Keempat Skenario

Skenario 2 dan Skenario 4 menunjukkan hasil terbaik dengan kotak diagonal bernilai 134 (*Kirmizi* benar) dan 99 (*Siirt* benar), artinya hanya 4 citra yang salah diklasifikasikan dari total 237 citra *testing*, 2 citra *Kirmizi*

salah diprediksi sebagai *Siirt* dan 2 citra *Siirt* salah diprediksi sebagai *Kirmizi*. Skenario 1 memiliki 7 citra yang salah, yaitu 6 citra *Kirmizi* salah diprediksi sebagai *Siirt* dan 1 citra *Siirt* salah diprediksi sebagai *Kirmizi*. Skenario 3 memiliki kesalahan terbanyak dengan 10 citra yang salah, yaitu 6 citra *Kirmizi* salah diprediksi sebagai *Siirt* dan 4 citra *Siirt* salah diprediksi sebagai *Kirmizi*. Pola kesalahan pada Skenario 3 yang tidak menggunakan *class weighting* ini menunjukkan bahwa model cenderung lebih sering salah pada kelas *Siirt* yang jumlah datanya lebih sedikit, yang mengkonfirmasi pentingnya penerapan *class weighting* untuk menyeimbangkan kemampuan model dalam mengenali kedua kelas.

4. Perbandingan beberapa model

Perbandingan keempat eksperimen dilakukan untuk menganalisis kontribusi masing-masing teknik (*augmentation* dan *class weighting*) terhadap performa klasifikasi secara terpisah maupun kombinasi.

a. Pengaruh *Data Augmentation*

Membandingkan Skenario 1 vs Skenario 2, dan Skenario 3 vs Skenario 4 menunjukkan bahwa penerapan *data augmentation* justru menurunkan *testing accuracy*. Skenario 1 menghasilkan 97,05% dibandingkan Skenario 2 sebesar 98,31%, sedangkan Skenario 3 menghasilkan 95,78% dibandingkan Skenario 4 sebesar 98,31%. Hal ini mengindikasikan bahwa pada dataset *Pistachio* dengan karakteristik latar belakang yang sudah sangat bersih dan konsisten, augmentasi rotasi dan pergeseran justru memperkenalkan variasi yang tidak relevan dan membuat proses konvergensi lebih lambat, yang tercermin dari durasi *training* yang jauh lebih panjang (92 dan 56 menit vs 23 dan 32 menit).

b. Pengaruh *Class Weighting*

Membandingkan Skenario 1 vs Skenario 3, dan Skenario 2 vs Skenario 4 menunjukkan bahwa *class weighting* memberikan pengaruh yang lebih positif terhadap keseimbangan performa per kelas. Pada Skenario 3, selisih F1-score antara *Kirmizi* (96%) dan *Siirt* (95%) mencapai 1,20 poin persentase. Setelah penambahan *class weighting* pada Skenario 1, selisih tersebut mengecil menjadi 0,76 poin persentase (*Kirmizi* 97,38% vs *Siirt* 96,62%). Hal serupa terlihat pada Skenario 4 di mana selisih F1-score *Kirmizi-Siirt* adalah 0,51

poin, sementara Skenario 2 menghasilkan selisih yang lebih kecil yaitu 0,51 poin dengan nilai yang lebih tinggi secara keseluruhan.

c. **Perbandingan dengan *Baseline* Penelitian Sebelumnya**

Tabel 4.9 Perbandingan dengan Penelitian Sebelumnya

Model	Testing Accuracy	Sumber
<i>Resnet50</i>	86%	Lisda et al. (2023)
<i>Inception-V3</i>	96%	Lisda et al. (2023)
<i>Resnet101</i> Skenario 3	95%	Penelitian ini
<i>Resnet101</i> Skenario 1	97%	Penelitian ini
<i>Resnet101</i> Skenario 2	98%	Penelitian ini
<i>Resnet101</i> Skenario 4	98%	Penelitian ini

Seluruh skenario *Resnet101* dalam penelitian ini berhasil melampaui *baseline Resnet50* (86%) dari penelitian sebelumnya. Tiga dari empat Skenario (Skenario 1, 2, dan 4) berhasil melampaui *baseline Inception-V3* (96%), dengan Skenario 2 dan 4 mencapai akurasi tertinggi sebesar 98%.

B. Pembahasan

1. Model yang Paling Optimal

Berdasarkan hasil keempat eksperimen, Skenario 2 dan Skenario 4 sama-sama mencapai performa testing tertinggi dengan *accuracy*, *precision*, *recall*, dan *F1-score* masing-masing sebesar 98%. Namun apabila ditinjau dari perspektif yang lebih komprehensif, Skenario 2 dapat dianggap sebagai model paling optimal karena dua alasan utama.

Pertama, Skenario 2 menghasilkan performa yang setara dengan Skenario 4 (98%) namun dengan keunggulan tambahan berupa penanganan ketidakseimbangan kelas yang eksplisit melalui *class weighting*, sehingga model dilatih dengan mempertimbangkan proporsi kelas secara adil. Kedua, meskipun hasil *testing* pada Skenario 2 dan Skenario 4 identik pada dataset ini, Skenario 2 dinilai lebih siap diterapkan pada kondisi nyata. Hal ini dikarenakan pada lingkungan produksi seperti fasilitas penyortiran *Pistachio*, proporsi antara varietas *Kirmizi* dan *Siirt* pada setiap *batch* produk tidak selalu sama seperti pada dataset penelitian. Dengan adanya *class weighting* yang memberikan bobot lebih tinggi pada kelas *Siirt* (1,165) selama *training*, model telah dilatih untuk tidak mengabaikan kelas dengan jumlah data lebih sedikit, sehingga ketika dihadapkan pada kondisi di mana *Siirt* muncul lebih

jarang dalam satu batch, model tetap dapat mengenalinya dengan baik (Akbar & Sanjaya, 2023).

Adapun Skenario 1 yang semula menjadi konfigurasi utama penelitian menghasilkan *testing accuracy* sebesar 97,05%, yang meskipun masih melampaui *baseline* Inception-V3 (96%), tidak mencapai performa tertinggi dibandingkan skenario lainnya. Hal ini menunjukkan bahwa penambahan *data augmentation* pada dataset *Pistachio* dengan karakteristik visual yang sudah bersih justru tidak memberikan manfaat yang diharapkan.

2. Evaluasi Hasil *Modeling* terhadap Tujuan Bisnis

Mengacu pada tujuan bisnis yang telah ditetapkan pada tahap *Business Understanding*, berikut adalah evaluasi pencapaian masing-masing tujuan:

a. Mengembangkan model klasifikasi otomatis dengan akurasi tinggi

Tujuan ini tercapai. Model *Resnet101* Skenario 2 berhasil mencapai *testing accuracy* sebesar 98,31%, yang berarti model mampu mengklasifikasikan 233 dari 237 citra *testing* dengan benar. Tingkat akurasi ini dinilai sangat memadai untuk diimplementasikan sebagai sistem klasifikasi otomatis dalam proses pasca panen *Pistachio*.

b. Mengatasi *overfitting* yang terjadi pada *Resnet50*

Tujuan ini tercapai secara signifikan. Penelitian sebelumnya melaporkan *overfitting* parah pada *Resnet50* dengan gap *training-validation accuracy* mencapai 78% (Lisda et al., 2023). Pada penelitian ini, seluruh skenario model menunjukkan gap yang jauh lebih kecil, dengan Skenario 2 yang menghasilkan *val accuracy* 98,31% dan *test accuracy* 98,31%, yang menandakan gap yang hampir tidak ada antara performa validasi dan *testing*.

c. Menghasilkan performa yang seimbang antara kelas *Kirmizi* dan *Siirt*

Tujuan ini tercapai, terutama pada Skenario 2. Dengan *F1-score Kirmizi* sebesar 98,53% dan *Siirt* sebesar 98,02%, selisih performa antar kelas hanya 0,51 poin persentase, menunjukkan bahwa model mampu mengenali kedua varietas dengan kemampuan yang relatif seimbang meskipun terdapat perbedaan jumlah data antar kelas.

3. Kesesuaian Hasil dengan *Business Understanding*

Pada tahap *Business Understanding*, target akurasi yang ditetapkan adalah melampaui baseline Inception-V3 sebesar 96%. Hasil penelitian menunjukkan bahwa tiga dari empat skenario eksperimen berhasil melampaui target tersebut, dengan Skenario 2 dan Skenario 4 mencapai 98,31% yang melampaui target sebesar 2,31 poin persentase.

Namun terdapat satu temuan yang tidak sesuai dengan ekspektasi awal, yaitu penerapan *data augmentation* yang semula diharapkan meningkatkan akurasi justru memberikan efek sebaliknya. Skenario 1 menghasilkan 97,05% dan Skenario 3 hanya 95,78%, keduanya di bawah performa model tanpa augmentasi. Hal ini dapat dijelaskan oleh beberapa faktor: pertama, dataset *Pistachio* memiliki karakteristik latar belakang yang sangat homogen (putih/netral) sehingga variasi dari augmentasi seperti rotasi dan pergeseran tidak merepresentasikan kondisi nyata yang lebih bervariasi; kedua, transformasi augmentasi yang diterapkan memperpanjang durasi *training* secara signifikan (hingga 92 menit untuk Skenario 1 tanpa memberikan keuntungan akurasi yang sepadan; ketiga, *Resnet101* dengan bobot *pre-trained ImageNet* yang kaya sudah memiliki kemampuan generalisasi yang cukup baik sehingga augmentasi tambahan tidak diperlukan untuk dataset yang relatif bersih ini (Faturrahman et al., 2023).

Meskipun demikian, hasil keseluruhan penelitian tetap melebihi ekspektasi karena seluruh skenario (termasuk Skenario 3 yang terendah dengan 95,78%) masih melampaui baseline *Resnet50* (86%) dan mendekati atau melampaui Inception-V3 (96%).

4. Validitas dan Generalisasi Hasil

Validitas hasil penelitian ini didukung oleh beberapa aspek metodologis yang diterapkan secara konsisten. Pertama, seluruh eksperimen menggunakan random seed yang sama (*seed=42*) untuk memastikan reproduisibilitas hasil. Kedua, evaluasi dilakukan pada *testing set* yang sepenuhnya terpisah dari *training* dan *validation set*, sehingga hasil evaluasi mencerminkan kemampuan generalisasi model pada data yang belum pernah dilihat sebelumnya. Ketiga, penggunaan metrik evaluasi yang komprehensif

(*accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*) memberikan gambaran yang lebih lengkap dan tidak menyesatkan dibandingkan hanya melaporkan satu metrik saja (Hoots et al., 2025).

Dari perspektif generalisasi, perlu dicatat beberapa keterbatasan. Dataset yang digunakan hanya terdiri dari 2148 citra dengan latar belakang yang sangat terkontrol (putih/netral), sehingga performa model mungkin akan menurun apabila dihadapkan pada citra *Pistachio* yang diambil dalam kondisi pencahayaan yang bervariasi, latar belakang yang kompleks, atau orientasi yang berbeda-beda. Selain itu, penelitian ini hanya mencakup dua varietas *Pistachio* (*Kirmizi* dan *Siirt*), sehingga model tidak dapat digunakan untuk mengklasifikasikan varietas lain tanpa proses *fine-tuning* ulang. Untuk meningkatkan generalisasi model, penelitian lanjutan disarankan untuk menggunakan dataset yang lebih beragam dalam hal kondisi pengambilan citra (Lisda et al., 2023).

5. Rekomendasi Penerapan Model


Berdasarkan hasil penelitian, model yang direkomendasikan untuk diterapkan adalah *Resnet101* Skenario 2 dengan pertimbangan bahwa model ini menghasilkan performa tertinggi (98,31%) sekaligus memberikan keseimbangan klasifikasi antar kelas yang baik, dengan durasi *training* yang relatif singkat (23 menit) sehingga efisien untuk dilatih ulang apabila diperlukan pembaruan model dengan data baru.

Untuk implementasi nyata, model ini direkomendasikan untuk diterapkan melalui pengembangan aplikasi berbasis website yang memungkinkan pengguna mengunggah citra kacang *Pistachio* dan memperoleh hasil klasifikasi varietas *Kirmizi* atau *Siirt* secara langsung. Model yang tersimpan dalam format *.keras* diintegrasikan ke dalam back-end menggunakan *framework Flask* sebagai *REST API*, sehingga dapat diakses melalui antarmuka web tanpa memerlukan instalasi perangkat lunak tambahan (Trihardianingsih & Permatasari, 2025).

Sebagai bentuk realisasi dari rekomendasi tersebut, penelitian ini telah mengimplementasikan model ke dalam sebuah aplikasi website sederhana

bernama Sistem Deteksi Kacang *Pistachio* Cerdas & Akurat. Website ini terdiri dari empat halaman utama yang dijelaskan sebagai berikut:


a. Halaman *Home*



Gambar 4.6 Tampilan Halaman *Home*

Halaman *Home* merupakan tampilan awal yang pertama kali dilihat oleh pengguna ketika mengakses website. Halaman ini menampilkan judul sistem yaitu "Sistem Deteksi Kacang *Pistachio* Cerdas & Akurat" beserta deskripsi singkat mengenai tujuan dan fungsi website. Halaman ini dirancang untuk memberikan gambaran umum kepada pengguna mengenai sistem yang tersedia sebelum melanjutkan ke halaman deteksi.

b. Halaman *About*




Gambar 4.7 Tampilan Halaman *About*

Halaman *About* menyajikan informasi edukatif mengenai dua varietas kacang *Pistachio* yang menjadi objek klasifikasi dalam sistem ini, yaitu

varietas *Kirmizi* dan *Siirt*. Pada halaman ini dijelaskan karakteristik masing-masing varietas secara singkat, di mana *Kirmizi* dikenal dengan warna biji hijau tua dan banyak digunakan di industri permen dan kue manis, sedangkan *Siirt* memiliki bentuk oval dengan persentase pembelahan tinggi dan lebih disukai sebagai camilan (Lisda et al., 2023). Selain informasi varietas, halaman ini juga memuat penjelasan singkat mengenai model yang digunakan yaitu *Resnet101*, termasuk alasan pemilihannya sebagai arsitektur klasifikasi pada sistem ini.


c. Halaman Deteksi



Gambar 4.8 Tampilan Halaman Deteksi

Halaman Deteksi merupakan halaman inti dari aplikasi ini, di mana pengguna dapat mengunggah citra kacang *Pistachio* untuk diklasifikasikan oleh model. Setelah citra diunggah, sistem secara otomatis melakukan proses *preprocessing* meliputi *resize* ke ukuran 224×224 piksel dan normalisasi piksel, kemudian citra dimasukkan ke dalam model *Resnet101* Skenario 2 untuk proses prediksi.

d. Halaman Hasil Prediksi



Gambar 4.8 Tampilan Halaman Hasil Prediksi

Hasil prediksi ditampilkan kepada pengguna berupa label varietas (*Kirmizi* atau *Siirt*) beserta persentase tingkat keberhasilan deteksi (*confidence score*) sehingga pengguna dapat mengetahui seberapa yakin model terhadap hasil klasifikasi yang diberikan.

Meskipun implementasi *website* dalam penelitian ini masih bersifat lokal dan belum dapat diakses secara publik, tahap *deployment* ini membuktikan bahwa model *Resnet101* Skenario 2 yang dikembangkan telah dapat dioperasikan dalam bentuk aplikasi nyata. Pengembangan lebih lanjut seperti pengunggahan ke layanan *hosting* publik, penambahan fitur riwayat prediksi, serta peningkatan antarmuka pengguna agar lebih ramah bagi petani dan pelaku usaha *Pistachio* dapat dilakukan sebagai tindak lanjut dari penelitian ini (Marsheila Islami & Nugroho, 2025).

86

BAB V

PENUTUP

A. Kesimpulan

Penelitian ini telah berhasil mengimplementasikan arsitektur CNN *Resnet101* dengan teknik *class weighting* dan *data augmentation* untuk klasifikasi kacang *Pistachio* varietas *Kirmizi* dan *Siirt*. Berdasarkan seluruh tahapan yang telah dilalui, berikut kesimpulan yang dapat ditarik dari penelitian ini.

1. Penerapan teknik *data augmentation* pada arsitektur *Resnet101* tidak terbukti efektif dalam meningkatkan akurasi klasifikasi kacang *Pistachio* varietas *Kirmizi* dan *Siirt* pada dataset ini. Skenario 1 yang menggabungkan *augmentation* dan *class weighting* menghasilkan *testing accuracy* 97%, lebih rendah dibandingkan Skenario 2 tanpa augmentasi yang mencapai 98%. Demikian pula Skenario 3 yang hanya menggunakan *augmentation* menghasilkan 95%, lebih rendah dibandingkan Skenario 4 baseline murni sebesar 98%. Hal ini disebabkan oleh karakteristik dataset *Pistachio* yang sudah memiliki latar belakang sangat bersih dan homogen sehingga variasi yang dihasilkan oleh augmentasi tidak merepresentasikan kondisi data nyata. Dari sisi pencegahan *overfitting*, Skenario 1 dan Skenario 3 justru menunjukkan *gap negatif* antara *validation accuracy* dan *testing accuracy* masing-masing sebesar -1% dan -2%, menandakan bahwa augmentasi menyebabkan model terbiasa dengan distribusi data yang telah dimodifikasi sehingga sedikit kesulitan menyesuaikan diri dengan data *testing* asli. Sebaliknya, Skenario 2 dan Skenario 4 tanpa augmentasi menunjukkan *gap* sebesar 0% yang mengindikasikan kemampuan generalisasi yang sempurna.
2. Model CNN *Resnet101* dengan *data augmentation* dan *class weighting* (Skenario 1) berhasil mencapai *testing accuracy* 97,05% dengan *precision* 97,15%, *recall* 97,05%, dan *F1-score* 97,05%, melampaui *baseline Inception-V3* (96%) sebesar 1,05 poin dan melampaui *baseline Resnet50* (86%) sebesar 11,05 poin dari penelitian sebelumnya (Lisda et al., 2023). Namun apabila ditinjau dari seluruh skenario, model terbaik yang dihasilkan adalah Skenario 2 tanpa *augmentation* dengan *class weighting* yang mencapai

54

testing accuracy tertinggi sebesar 98,31% dengan *precision*, *recall*, dan *F1-score* masing-masing sebesar 98,31%, melampaui *baseline Inception-V3* sebesar 2,31 poin dan *baseline Resnet50* sebesar 12,31 poin.

3. Penerapan *class weighting* pada kondisi tanpa augmentasi kurang berpengaruh, Skenario 4 (*baseline*) dan Skenario 2 (*class weighting*) menghasilkan performa yang identik dengan *accuracy*, *precision*, *recall*, dan *F1-score* masing-masing sebesar 98,31%, akan tetapi pada Skenario 2 (*class weighting*) lebih unggul pada durasi training yang lebih singkat yaitu masing-masing pada Skenario 4 (*baseline*) yaitu 32 menit dan pada Skenario 2 (*class weighting*) yaitu 23 menit. Hal ini mengindikasikan bahwa pada dataset Pistachio dengan tingkat ketidakseimbangan yang tergolong ringan (rasio 1,35:1) dan karakteristik citra yang sudah sangat bersih dan homogen, model *ResNet101* dengan bobot *pre-trained ImageNet* sudah memiliki kemampuan generalisasi yang cukup untuk menangani ketidakseimbangan kelas secara implisit tanpa memerlukan pembobotan eksplisit. Namun *class weighting* terbukti memberikan pengaruh positif yang lebih nyata ketika dikombinasikan dengan data augmentasi, terlihat dari perbandingan Skenario 3 (augmentasi tanpa *class weighting*) yang menghasilkan selisih *F1-score* antara *Kirmizi* (96,30%) dan *Siirt* (95,10%) sebesar 1,20 poin, sedangkan setelah penerapan *class weighting* pada Skenario 1 selisih tersebut mengecil menjadi 0,76 poin (*Kirmizi* 97,38% vs *Siirt* 96,62%), serta disertai peningkatan *accuracy* dari 95,78% menjadi 97,05%.

B. Saran

Berdasarkan keterbatasan dan temuan yang diperoleh selama penelitian, berikut saran yang dapat diberikan untuk pengembangan di masa mendatang.

1. Penelitian ini hanya menguji satu arsitektur yaitu *Resnet101* saja, pada penelitian selanjutnya disarankan untuk membandingkan *Resnet101* dengan arsitektur yang lebih modern seperti *EfficientNet*, *MobileNetV3*, atau *Vision Transformer (ViT)* menggunakan kondisi eksperimen yang identik agar perbandingan yang dihasilkan lebih adil dan komprehensif. Selain itu, mengingat *data augmentation* terbukti tidak efektif pada dataset ini, penelitian lanjutan dapat mengeksplorasi metode penambahan data yang lebih

sesuai seperti *synthetic data generation* menggunakan *Generative Adversarial Network (GAN)* untuk menghasilkan variasi data yang lebih realistis sehingga augmentasi dapat memberikan manfaat yang lebih nyata.

2. Dataset yang digunakan dalam penelitian ini hanya terdiri dari 2148 citra dengan latar belakang yang sangat terkontrol sehingga kemampuan generalisasi model pada kondisi pengambilan citra yang lebih bervariasi belum dapat dipastikan. Penelitian selanjutnya disarankan untuk memperluas dataset dengan menambahkan citra yang diambil dalam kondisi pencahayaan yang berbeda-beda, latar belakang yang bervariasi, serta berbagai sudut pengambilan gambar. Penambahan varietas *Pistachio* lain di luar *Kirmizi* dan *Siirt* juga dapat memperluas cakupan sistem klasifikasi sehingga lebih aplikatif untuk kebutuhan industri yang lebih luas.
3. Untuk penerapan nyata di lingkungan produksi, disarankan agar model diintegrasikan ke dalam sistem penyortiran otomatis di fasilitas pengolahan *Pistachio* dengan bantuan kamera yang terhubung ke sistem *REST API*, sehingga klasifikasi dapat dilakukan secara *real-time* selama proses panen berlangsung. Sebelum penerapan penuh, perlu dilakukan pengujian lapangan (*field testing*) menggunakan citra yang diambil langsung dari fasilitas produksi untuk memverifikasi performa model pada kondisi nyata, serta perlu disediakan mekanisme pembaruan model secara berkala seiring tersedianya data citra baru yang lebih beragam agar akurasi sistem dapat terus dipertahankan dalam jangka panjang.