

Perbandingan Performa CNN Inception-V3 dan ResNet50 Dalam Klasifikasi Kematangan Buah Tomat

I Putu Hanggara Diatha Putra^{a1}, I Wayan Supriana^{a2}, I Ketut Gede Suhartana^{a3}, I Gusti Ngurah Anom Cahyadi Putra^{a4}, Farhan Akmala Putra^{b5}

^aProgram Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Udayana
Kuta Selatan, Badung, Bali, Indonesia

^bMagister Agribisnis, Fakultas Peternakan dan Pertanian, Universitas Diponegoro, Indonesia

¹putuhanggaradiatha@gmail.com

²wayan.supriana@unud.ac.id

³ikg.suhartana@unud.ac.id

⁴anom.cp@unud.ac.id

⁵farhanakmalaputra@gmail.com

Abstrak

Buah tomat memiliki durasi mencapai kematangan yang singkat. Sehingga jika melewati durasi kematangannya, maka buah tomat akan seketika membusuk. Para petani buah tomat melakukan proses klasifikasi kematangan buah tomat secara manual. Proses klasifikasi secara manual dapat mengakibatkan hasil klasifikasi yang tidak konsisten, yang disebabkan karena proses tersebut sangat menguras tenaga manusia jika dilakukan dalam kuantitas yang banyak. Oleh karena itu, penulis merancang sistem klasifikasi tingkat kematangan buah tomat dengan algoritma Convolutional Neural Network (CNN). Metode yang digunakan dalam penelitian ini adalah model CNN dengan arsitektur Inception-V3 dan arsitektur ResNet50. Penulis juga melakukan perbandingan performa klasifikasi dari kedua arsitektur tersebut dan membandingkan arsitektur mana yang memiliki performa klasifikasi yang lebih baik. Berdasarkan hasil pengujian yang dilakukan, nilai akurasi terbaik diperoleh ketika menggunakan model CNN dengan arsitektur ResNet50 dengan tingkat akurasi sebesar 95%. Lalu, berdasarkan pengujian menggunakan data uji menunjukkan kedua model CNN tersebut dapat melakukan klasifikasi citra dengan optimal dan tanpa kesalahan.

Kata Kunci : Sistem Klasifikasi, *Convolutional Neural Network*, Inception-V3, ResNet50, Tomat

1. Pendahuluan


Buah tomat adalah salah satu tanaman yang potensial tumbuh di Indonesia. Hal ini dapat dibuktikan dengan produksi buah tomat yang mencapai 1.143.787,7 ton pada tahun 2023, menempati urutan keenam dari 10 besar produksi tanaman sayuran di Indonesia [1]. Buah tomat memiliki manfaat bagi tubuh karena mengandung vitamin, mineral, dan senyawa likopen sebagai antioksidan [2]. Tantangan utama yang dihadapi oleh petani saat meningkatnya produksi buah tomat adalah proses klasifikasi kematangan buah tomat yang masih dilakukan secara manual. Cara tersebut tidak hanya menguras tenaga, tetapi juga rawan menghasilkan klasifikasi yang tidak konsisten, sehingga dapat menyebabkan kerugian ekonomi jika buah tomat membusuk yang disebabkan karena panen yang tidak tepat waktu [3].

Seiring berkembangnya teknologi kecerdasan buatan, implementasi *deep learning* dapat mengatasi masalah tersebut. Salah satu algoritma *deep learning* yang banyak digunakan di berbagai bidang untuk klasifikasi citra adalah *convolutional neural network* (CNN) [4]. Dalam algoritma CNN, terdapat beberapa jenis arsitektur dan arsitektur yang sudah terbukti memiliki akurasi yang tinggi adalah Inception-V3 dan ResNet50. Algoritma CNN juga banyak digunakan dalam bidang pertanian. Penggunaan CNN dalam klasifikasi kematangan buah kopi kuning menggunakan arsitektur Inception-V3 menghasilkan performa klasifikasi yang mengesankan, dengan nilai akurasi sebesar 92% [5]. Kemudian, implementasi dari CNN ResNet50 dalam mengklasifikasi kematangan buah pisang menghasilkan figur nilai akurasi sebesar 91% [6].

Berdasarkan penelitian terdahulu, penelitian ini bertujuan untuk membandingkan performa antara arsitektur Inception-V3 dan ResNet50 dalam klasifikasi tingkat kematangan buah tomat. Hasil dari penelitian ini dapat mengetahui arsitektur mana yang memiliki performa klasifikasi yang akurat dan stabil, sehingga dapat membantu petani dalam mengklasifikasi tingkat kematangan buah tomat.

2. Metode Penelitian

Penelitian ini dilakukan dengan mengikuti alur penelitian agar proses penelitian berjalan dengan terarah. Alur penelitian merupakan tahapan-tahapan proses penelitian berdasarkan pada langkah-langkah seperti pada gambar di bawah ini :



Gambar 1. Alur Penelitian

2.1. Pengumpulan Data

Dalam pengumpulan data, dataset yang digunakan untuk proses melatih model CNN bersumber dari situs Mendeley Data dan Dataset Ninja [7][8]. Total data yang digunakan adalah 530 gambar, yang terdiri dari 260 gambar pada kelas belum matang dan 260 gambar pada kelas matang. Kemudian, data tersebut dibagi dengan rasio 76% untuk data *training*, 23% untuk data *validation*, dan 1% untuk data *testing*. Berikut rincian jumlah dan contoh dari dataset yang akan digunakan. Gambar isi kiri merupakan contoh gambar dari kelas belum matang dan gambar sisi kanan adalah contoh gambar dari kelas matang.

Tabel 1. Rincian Jumlah Dataset

Belum Matang			Matang		
<i>Training</i>	<i>Validation</i>	<i>Testing</i>	<i>Training</i>	<i>Validation</i>	<i>Testing</i>
200 citra	60 citra	5 citra	200 citra	60 citra	5 citra
Total Dataset		265 citra	Total Dataset		265 citra
Total Keseluruhan					530 citra



Gambar 2. Sampel Dataset Buah Tomat [7]

2.2. Pra-Pemrosesan Data


Pada tahap ini, dataset akan dilakukan pra-pemrosesan (*pre-processing*), sebuah tahap penyesuaian untuk menyeragamkan setiap data gambar buah tomat dalam satu dataset. Tahap pertama dari pra-pemrosesan adalah *rescaling*, untuk menyesuaikan nilai piksel dari [0,255] menjadi [0,1]. Kemudian, dilanjutkan ke tahap *resize* untuk menyesuaikan ukuran gambar dengan *input* standar dari masing-masing arsitektur, yaitu 299x299 piksel untuk arsitektur Inception-V3 [9]. Sedangkan ukuran standar dari arsitektur ResNet50 adalah 224x224 piksel [10]. Setelah dilakukan tahap *resize*, dilanjutkan ke tahap augmentasi data. Tahap ini dilakukan untuk menambah variasi data yang bertujuan untuk mengurangi risiko model CNN mengalami *overfitting*. Parameter yang digunakan dalam augmentasi data adalah *rotation range*, *shear range*, *zoom range*, *width shift range*, *height shift range*, *horizontal flip*, dan *fill mode*. Berikut Tabel 1 yang merupakan rincian dari parameter augmentasi data yang digunakan.

Tabel 1. Parameter Augmentasi Data

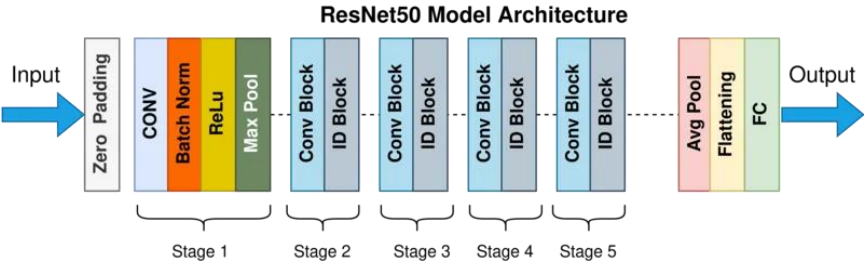
No	Parameter	Nilai
1	Rotation Range	40
2	Shear Range	0,2
3	Width Shift Range	0,2
4	Height Shift Range	0,2
5	Zoom Range	0,3
6	Horizontal Flip	True
7	Fill Mode	'nearest'

2.3. Perancangan Model CNN Inception-V3

Setelah melalui tahap pra-pemrosesan, dilakukan tahap perancangan yang bertujuan untuk merancang model CNN yang akan digunakan sebagai model klasifikasi kematangan buah tomat. Pada tahap ini, penulis merancang model CNN dengan arsitektur Inception-V3 dan kemudian dilanjutkan dengan arsitektur ResNet50. Arsitektur Inception-V3 memiliki kernel konvolusi metode pemisahan yang berfungsi untuk memecah konvolusi besar menjadi konvolusi kecil, sehingga proses pelatihan model lebih efisien dan meningkatkan kemampuan dalam mengekstrak fitur spasial [11]. Sedangkan, arsitektur ResNet50 menggunakan konsep *residual connection*, yang memungkinkan arsitektur ResNet50 dalam menggunakan fitur dari lapisan sebelumnya agar risiko kehilangan fitur penting saat proses konvolusi dapat diminimalisir [12]. Ilustrasi dari arsitektur Inception-V3 dan ResNet50 dapat dilihat pada gambar di bawah ini.



Gambar 3. Arsitektur Inception-V3 [13]



Gambar 4. Arsitektur ResNet50 [14]

2.4. Pelatihan Model

Setelah selesai merancang kedua model CNN tersebut, dilanjutkan proses pelatihan model. Dalam proses pelatihan, penulis menggunakan beberapa skenario penggunaan *hyperparameter* dalam pelatihan model. Rincian dari nilai *hyperparameter* yang digunakan dapat dilihat pada tabel di bawah ini.

Tabel 2. Skenario Hyperparameter


No	Parameter	Nilai
1	Epoch	10, 50, 100, 150
2	Learning rate	0,0001 dan 0,001

2.5. Pengujian Model

Setelah proses pelatihan selesai, dilanjutkan ke tahap pengujian model. Pengujian model menggunakan data *testing* yang telah disediakan di masing-masing kelas. Data *testing* terdiri dari 5 gambar dari masing-masing kelas.

2.6. Evaluasi Hasil

Tahap evaluasi hasil akan menggunakan metode confusion matrix, sebuah metode yang menghasilkan jumlah gambar beserta hasil prediksinya dari setiap kelas dengan nilai diagonal sebagai jumlah prediksi yang benar [10]. Selain itu, evaluasi hasil juga menggunakan evaluasi metrik yang terdiri dari *accuracy*, *precision*, *recall*, dan *f1-score*. Metrik *accuracy* akan mengukur persentase prediksi benar yang dihasilkan dari semua prediksi kelas, metrik *precision* akan mengukur tingkat keberhasilan suatu model dalam memprediksi kelas positif dari semua prediksi positif yang dihasilkan, metrik *recall* akan mengukur sejauh mana model mengklasifikasi kelas positif yang sebenarnya dengan akurat, lalu metrik *f1-score* akan mengukur kemampuan precision dan recall dari suatu model.



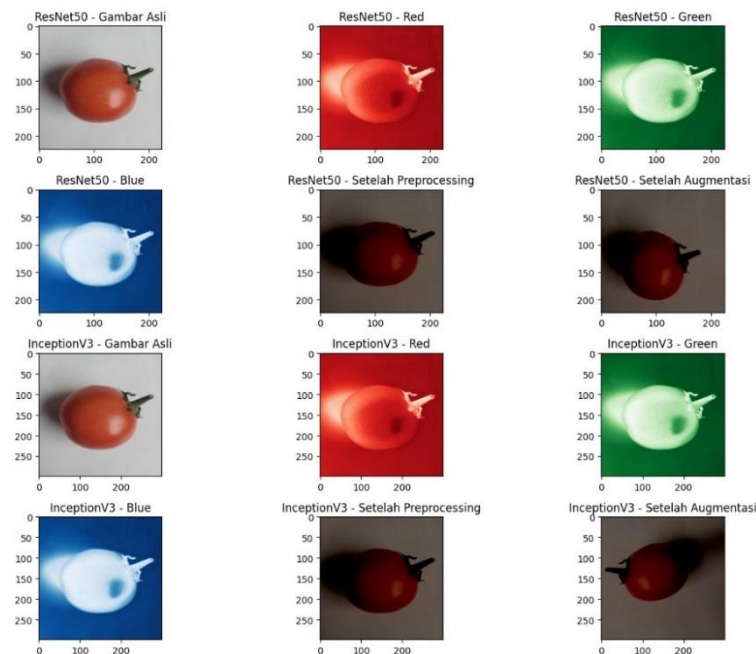
Gambar 5. Ilustrasi Confusion Matrix [15]

Tabel 3. Ilustrasi Hasil Metrik Evaluasi

No	Metrik	Nilai
1	<i>Accuracy</i>	0.8448
2	<i>Precision</i>	0.8479
3	<i>Recall</i>	0.8479
4	<i>F1-score</i>	0.8448

3. Hasil dan Pembahasan

Proses klasifikasi kematangan buah tomat menggunakan total data sebanyak 530 gambar, dengan persentase pembagian data 76% untuk data *training*, 23% untuk data *validation*, dan 1% untuk data *testing*. Sebelum melatih model CNN Inception-V3 dan ResNet50, dilakukan tahap pra-pemrosesan untuk menyeragamkan setiap data gambar buah tomat dalam satu dataset, agar proses pelatihan model lebih optimal. Berikut gambar dari hasil pra-pemrosesan yang terdiri dari *rescaling* dan *resize* yang dapat dilihat pada Gambar 6 di bawah ini



Gambar 6. Hasil Pra-Pemrosesan


Setelah melakukan pra-pemrosesan, dilakukan tahap augmentasi data untuk memberikan variasi data agar risiko *overfitting* saat pelatihan model dapat berkurang. Parameter yang digunakan dalam proses augmentasi data terdiri dari *rotation range*, *shear range*, *zoom range*, *width shift range*, *height shift range*, *horizontal flip*, dan *fill mode*. Hasil dari proses augmentasi data dapat dilihat pada Gambar 7 di bawah ini.



Gambar 7. Hasil Augmentasi Data

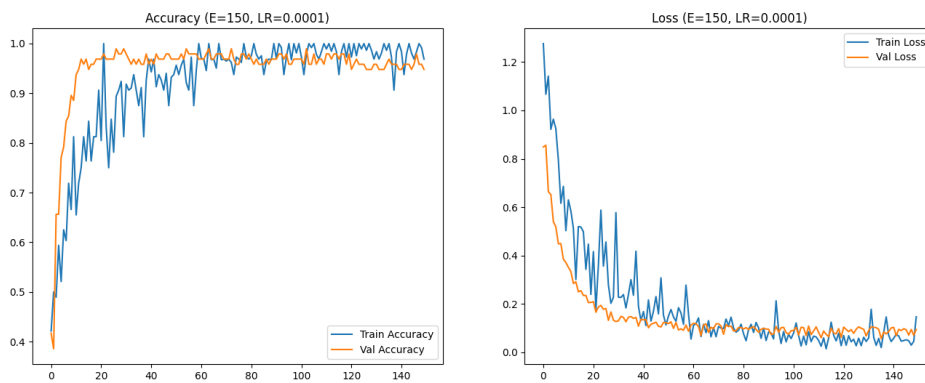
Kemudian dilanjutkan ke proses pelatihan model CNN Inception-V3 dan ResNet50. Berdasarkan proses pelatihan kedua model tersebut, diperoleh parameter yang menghasilkan tingkat akurasi paling

baik dari model CNN Inception-V3 dan ResNet50. Kedua model tersebut menghasilkan tingkat akurasi yang sama pada parameter *epoch* 150 dan nilai *learning rate* 0,0001. Model CNN Inception-V3 pada *epoch* 150 menghasilkan nilai *training accuracy* sebesar 93,75% dan nilai *validation accuracy* sebesar 94,79%. Sedangkan nilai *training loss* yang dihasilkan sebesar 27,63% dan *validation loss* sebesar 17,15%. Berikut grafik performa dari model CNN Inception-V3 yang dapat dilihat pada Gambar 8 di bawah ini.



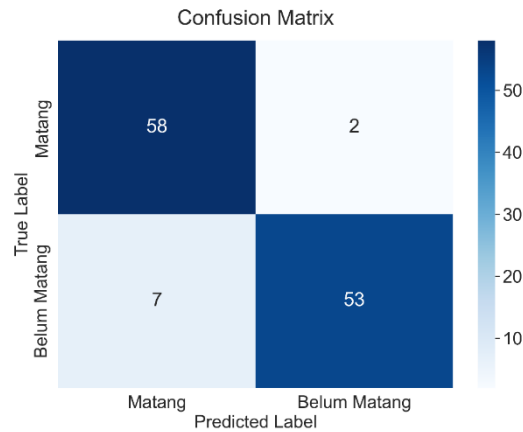
Gambar 8. Grafik Performa Model CNN Inception-V3

Di sisi lain, model CNN ResNet50 pada nilai *epoch* yang sama, yaitu *epoch* 150 menghasilkan nilai *training accuracy* sebesar 96,87% dan nilai *validation accuracy* sebesar 94,79%. Sedangkan nilai *training loss* yang dihasilkan sebesar 14,67% dan *validation loss* sebesar 9,46%. Berikut grafik performa dari model CNN ResNet50 yang dapat dilihat pada Gambar 9 di bawah ini.

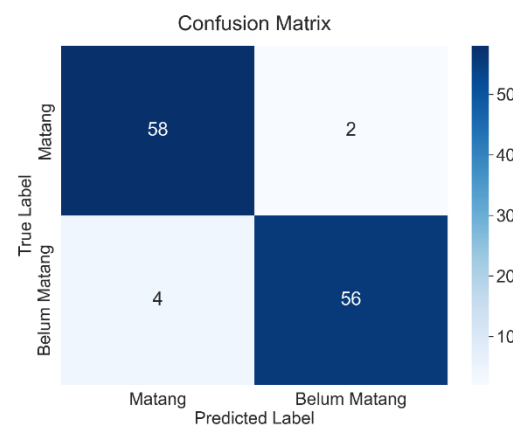


Gambar 9. Grafik Performa Model CNN ResNet50

Berdasarkan kedua grafik pada Gambar 8 dan 9, pada kurva grafik *training* terlihat bahwa arsitektur Inception-V3 mengalami fluktuasi nilai akurasi yang cukup tinggi. Dibandingkan dengan arsitektur ResNet50 yang walaupun juga mengalami fluktuasi nilai, tetapi pada pertengahan proses pelatihan model kurva bergerak lebih stabil setelah melewati *epoch* 60. Sedangkan di sisi kurva grafik *validation*, kedua arsitektur tersebut memiliki performa yang stabil. Namun, arsitektur ResNet50 memiliki performa *validation* yang lebih stabil daripada arsitektur Inception-V3. Kemudian, berdasarkan metode *confusion matrix* kedua model menunjukkan perbedaan performa yang tipis. Dari 60 gambar pada kelas belum matang dan 60 gambar pada kelas matang, terdapat 2 gambar yang salah diidentifikasi oleh model CNN Inception-V3, yaitu kelas matang yang salah diklasifikasi sebagai kelas belum matang, serta 7 gambar yang diklasifikasi sebagai kelas matang yang seharusnya adalah kelas belum matang. Sedangkan model CNN ResNet50 dengan jumlah gambar dan kelas yang sama, terdapat 2 gambar yang juga salah diklasifikasi seperti pada model CNN Inception-V3, yaitu kelas matang yang salah diklasifikasi sebagai kelas belum matang, serta 6 gambar yang diklasifikasi sebagai kelas matang yang seharusnya adalah kelas belum matang. Berikut adalah gambar dari *confusion matrix* dari kedua model tersebut yang dapat dilihat pada Gambar 10 dan 11.



Gambar 10. *Confusion Matrix* Model CNN Inception-V3



Gambar 11. *Confusion Matrix* Model CNN ResNet50

Kemudian, perbandingan antara arsitektur Inception-V3 dan ResNet50 dengan 4 metrik evaluasi (*accuracy*, *precision*, *recall*, dan *f1-score*) menunjukkan bahwa Inception-V3 menghasilkan nilai *accuracy* sebesar 94,16%, nilai *precision* sebesar 94,28%, nilai *recall* sebesar 94,17%, dan *f1-score* sebesar 94,16%. Sedangkan arsitektur ResNet50 menghasilkan nilai *accuracy* sebesar 95%, nilai *precision* sebesar 95,05%, lalu nilai *recall* serta *f1-score* yang sama-sama menghasilkan nilai 95%. Berdasarkan hasil tersebut, model CNN ResNet50 memiliki performa yang tidak berbeda jauh dengan model CNN Inception-V3. Berikut Tabel 4 dan 5 dari hasil metrik evaluasi dari kedua arsitektur tersebut.

Tabel 4. Hasil Metrik Evaluasi Model CNN Inception-V3

No	Metrik	Nilai
1	<i>Accuracy</i>	0.9417
2	<i>Precision</i>	0.9428
3	<i>Recall</i>	0.9417
4	<i>F1-score</i>	0.9416





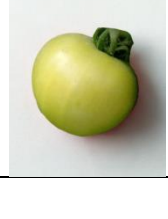
Tabel 5. Hasil Metrik Evaluasi Model CNN ResNet50

No	Metrik	Nilai
1	<i>Accuracy</i>	0.95
2	<i>Precision</i>	0.9505






3	<i>Recall</i>	0.95
4	<i>F1-score</i>	0.95

Setelah mengetahui performa dari kedua arsitektur tersebut, dilakukan pengujian menggunakan data *testing* yang telah disediakan untuk melihat implementasi kedua model tersebut dalam mengklasifikasi kematangan buah tomat. Hasil pengujian dengan data *testing* menunjukkan bahwa kedua model tersebut dapat mengklasifikasi gambar buah tomat dengan akurat. Baik arsitektur Inception-V3 maupun ResNet50 tidak mengalami kesalahan identifikasi dan sesuai dengan kelas target yang dipakai. Berikut tabel 6 dan 7 yang merupakan hasil pengujian data *testing* dari kelas belum matang dan matang.

Tabel 6. Hasil Klasifikasi Data *Testing* Kelas Belum Matang

No	Kelas Target	Gambar	Hasil Klasifikasi	
			Inception-V3	ResNet50
1	Belum Matang		Belum Matang	Belum Matang
2	Belum Matang		Belum Matang	Belum Matang
3	Belum Matang		Belum Matang	Belum Matang
4	Belum Matang		Belum Matang	Belum Matang
5	Belum Matang		Belum Matang	Belum Matang

Tabel 7. Hasil Klasifikasi Data *Testing* Kelas Matang

No	Kelas Target	Gambar	Hasil Klasifikasi	
			Inception-V3	ResNet50
1	Matang		Matang	Matang
2	Matang		Matang	Matang
3	Matang		Matang	Matang
4	Matang		Matang	Matang
5	Matang		Matang	Matang

4. Kesimpulan

Pada penelitian ini dapat diambil kesimpulan bahwa model CNN Inception-V3 dan ResNet50 menghasilkan performa klasifikasi yang mengesankan. Berdasarkan metrik evaluasi, arsitektur Inception-V3 menghasilkan performa *accuracy* sebesar 94,17%, *precision* 94,28%, *recall* 94,17%, dan *f1-score* 94,16%. Sedangkan arsitektur ResNet50 menghasilkan performa *accuracy* sebesar 95%, *precision* 95,05%, *recall* 95%, dan *f1-score* 95%. Walaupun di atas kertas performa arsitektur ResNet50 lebih unggul daripada arsitektur Inception-V3, hasil pengujian dengan data *testing* menunjukkan kedua model tersebut dapat mengklasifikasi gambar buah tomat dengan akurat.

Referensi

[1] Badan Pusat Statistik Indonesia, "Produksi Tanaman dan Sayuran Menurut Provinsi dan Jenis Tanaman", 8 Maret 2024, [Online], Available : <https://www.bps.go.id/id/statistics-table/3/ZUhFd1JtZzJWV/pqWTJsV05XTlhVmhRSzFoNFFUMDkjMw==/produksi-tanaman-sayuran-menurut-provinsi-dan-jenis-tanaman--2023.html?year=2023> [21 Agustus 2025].

- [2] A. S. Hadi, "KHASIAT BUAH TOMAT (*Solanum lycopersicum*) BERPOTENSI SEBAGAI OBAT BERBAGAI JENIS PENYAKIT", *Empiris : Journal of Progressive Science and Mathematics*, vol. 01, no. 01, p. 7-15, 2023.
- [3] H. Mubarak, S. Murni, and M. M. Santoni, "Penerapan Algoritma K-Nearest Neighbor untuk Klasifikasi Tingkat Kematangan Buah Tomat Berdasarkan Fitur Warna ", Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya (SENAMIKA), 2021.
- [4] W. Vidiadivani and I. K. G. Suhartana, "Klasifikasi Jenis Sampah Menggunakan Metode *Transfer Learning* Pada *Convolutional Neural Network* (CNN)", *JELIKU (Jurnal Elektronik Ilmu Komputer Udayana)*, vol. 12, no. 3, 2024.
- [5] U. Ungkawa and G. A. Hakim, "Klasifikasi Warna Pada Kematangan Buah Kopi Kuning Menggunakan Metode CNN Inception V3", *ELKOMIKA : Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, dan Teknik Elektronika*, vol. 11, no. 3, 2023.
- [6] P. D. Wardani and C. Dewi, "Klasifikasi Tipe Kematangan Buah Pisang Menggunakan Metode Ensemble Convolutional Neural Network (CNN)", *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 1, no. 1, 2024.
- [7] Mendeley Data, "Tomato Maturity Detection and Quality Grading Dataset", 4 September 2023, [Online], Available : <https://data.mendeley.com/datasets/s42kpg8h37/1> [27 Agustus 2025].
- [8] Dataset Ninja, "LaboroTomato Dataset", 14 Agustus 2020, [Online], Available : <https://datasetninja.com/laboro-tomato#download> [27 Agustus 2025].
- [9] V. R. Pratiwi and J. Pardede, "Image Captioning Menggunakan Metode Inception-V3 dan Transformer" in Prosiding Diseminasi FTI Genap 2021/2022, Bandung.
- [10] L. Trihardianingsih and H. Permatasari, "Model Transfer Learning untuk Klasifikasi Kesegaran Buah Jeruk Menggunakan Citra Digital" in Prosiding Seminar Nasional Teknologi dan Sains Tahun 2025, Kediri, 2025, vol. 4.
- [11] I. Mustikasari, I. I. Tritasmoro, and R. Purnamasari, "Identifikasi Kanker Kulit Melanoma Berbasis Inception V3 Menggunakan Pra-Pemrosesan dan Augmentasi Data pada Dataset Citra Kulit" in e-Proceeding of Engineering, Bandung, vol. 10, no. 5.
- [12] I. P. Putra, Rusbandi, and D. Alamsyah, "Klasifikasi Penyakit Daun Tomat Menggunakan Metode Convolutional Neural Network", *Jurnal Algoritme*, vol. 2, no. 2.
- [13] Digital Ocean, "Deep Learning Architecture Explained : ResNet, InceptionV3, SqueezeNet", 20 Maret 2025, [Online], Available : <https://www.digitalocean.com/community/tutorials/popular-deep-learning-architectures-resnet-inceptionv3-squeezenet> [27 Agustus 2025].
- [14] Medium, "Exploring ResNet50 : An In-Depth Look at the Model Architecture and Code Implementation", 23 Januari 2023, [Online], Available : <https://medium.com/@nitishkundu1993/exploring-resnet50-an-in-depth-look-at-the-model-architecture-and-code-implementation-d8d8fa67e46f> [27 Agustus 2025].
- [15] Medium, "Memahami Confusion Matrix : Accuracy, Precision, Recall, dan F1-Score untuk Evaluasi Model Klasifikasi", 11 Juni 2023, [Online], Available : <https://esairina.medium.com/memahami-confusion-matrix-accuracy-precision-recall-specificity-dan-f1-score-610d4f0db7cf> [27 Agustus 2025].