

KLASIFIKASI TINGKAT KEMATANGAN CITRA BUAH TOMAT MENGGUNAKAN DENSENET-121

Septinna Choirunisa^{1*}, Supatman²

^{1,2}Universitas Mercu Buana Yogyakarta; Jl. Jembatan Merah No.84 C Gejayan Yogyakarta 55283, Telp. (0274) 563589, Faks. (0274) 550703

Keywords:

tomato, ripeness, DenseNet121, classification, image

Correspondent Email:

211110043@student.mercubuana-yogya.ac.id

supatman.fti@mercubuana-yogya.ac.id



JITET is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License

Abstrak. Tomat merupakan komoditas penting dalam sektor pertanian, yang kualitasnya ditentukan oleh tingkat kematangan. Penilaian kematangan secara manual sering kali bersifat subjektif dan kurang konsisten dalam skala besar, sehingga diperlukan sistem klasifikasi otomatis berbasis citra. Penelitian ini mengusulkan penggunaan arsitektur DenseNet-121 untuk mengklasifikasikan tingkat kematangan buah tomat menjadi tiga kelas: matang, setengah matang, dan mentah. Dataset yang digunakan berjumlah 600 citra yang diambil dari data publik Kaggle dan data primer. Hasil pelatihan menunjukkan peningkatan akurasi signifikan dari 65,26% menjadi 100% dalam 10 epoch, dengan nilai loss akhir 0,0016. Evaluasi menunjukkan akurasi 99%, serta precision, recall, dan F1-score sebesar 0,99 untuk semua kelas. Hasil ini membuktikan bahwa DenseNet121 lebih unggul mengidentifikasi karakteristik visual objek dalam sistem klasifikasi citra berbasis machine learning.

Abstract. Tomato is an important commodity to the agricultural sector, of which quality is primarily defined by level of ripeness. Manual inspection to determine level of ripeness is often subjective and does not provide consistent accuracy on a larger scale, which leads to a need for an automated image-based classification system to classify the ripeness of tomato. This study contributes a first step to identifying the optimum architecture to classify tomato ripeness based on image, using the DenseNet-121 architecture to classify ripe, semi-ripe, and unripe images of tomato. The dataset is comprised of 600 images from public Kaggle data and original images from the authors. The results from the training phases showed a noticeable increase in accuracy from an initial baseline of 65.26% to perfect accuracy of 100% in just 10 epochs of training, with a final loss value of 0.0016 post training. Evaluation shows a mean accuracy of 99% for the evaluation dataset images, with 99% precision, recall, and F1-score for all classes combined, proving that the DenseNet121 architecture and heads comprised from convolutional neural networks (CNN's) is favourable for recognizing visual object characteristics in machine learning based image classification systems.

1. PENDAHULUAN

Tomat (*Solanum lycopersicum*) merupakan bahan pangan bernilai ekonomi tinggi yang banyak dikonsumsi Masyarakat [1]. Kualitas dan umur simpan tomat bergantung pada tingkat kematangannya yang diidentifikasi melalui perubahan warna menjadi merah saat matang. Oleh karena itu, pengklasifikasian

tingkat kematangan tomat secara tepat sangat dibutuhkan mutu produk dan mendukung efisiensi dalam penyimpanan serta distribusi.

Kemajuan ilmu pengetahuan dan teknologi pengolahan citra digital telah banyak dimanfaatkan dibidang pertanian, salah satunya untuk membantu proses klasifikasi kematangan tomat berdasarkan fitur visual seperti warna

dan tekstur [2], [3],[4]. Pendekatan efektif yang digunakan yaitu Convolutional Neural Network (CNN), yang mampu mengekstraksi pola pada citra dua dimensi untuk mengenali ciri-ciri visual tomat secara lebih efisien [5].

Penelitian klasifikasi tingkat kematangan buah tomat menggunakan pengolahan citra dan algoritma machine learning telah menunjukkan beragam hasil. Misalnya, penelitian oleh [6] menggunakan YOLOv5 dengan bounding box untuk mendeteksi kematangan tomat, mencapai akurasi 73% dan F1-score 0,97 pada nilai confidence 0,352. Penelitian lain [7] menerapkan DenseNet201 dan VGG-19, dengan akurasi 92% untuk DenseNet201 dengan weight ImageNet dan 82% untuk VGG-19, sementara tanpa weight ImageNet, akurasi masing-masing adalah 88% dan 90%.

Penelitian [8] menggunakan VGG16 untuk memprediksi tingkat kematangan tomat dengan dataset 481 citra, mencapai akurasi 97,1% pada data latih dan 95,56% pada data validasi. Meskipun arsitektur seperti YOLOv5, VGG-19, DenseNet201, dan VGG16 menunjukkan akurasi baik, metode ini memerlukan komputasi lebih tinggi dan dataset yang lebih besar untuk meningkatkan hasil.

Oleh karena itu, penelitian ini bertujuan untuk mengklasifikasikan tingkat kematangan buah tomat menggunakan DenseNet-121, yaitu salah satu arsitektur CNN modern dengan tujuan dapat mencapai akurasi lebih tinggi melalui dataset yang lebih besar. Selain itu, penelitian ini diharapkan dapat mendukung otomatisasi di sektor pertanian melalui penerapan teknologi klasifikasi berbasis CNN dalam sistem pemantauan kualitas hasil pertanian dan perencanaan panen, sekaligus memberikan kontribusi signifikan terhadap pengembangan literatur akademik di bidang pengolahan citra digital dan jaringan saraf tiruan.

2. TINJAUAN PUSTAKA

2.1 Tomat

Solanum lycopersium, yang dikenal sebagai tomat, merupakan bahan pangan utama dengan nilai ekonomi tinggi yang dikonsumsi secara luas oleh Masyarakat [1], [9]. Tanaman ini memiliki keunggulan adaptif karena dapat dibudidayakan di berbagai kondisi lingkungan, baik di dataran rendah maupun tinggi, serta

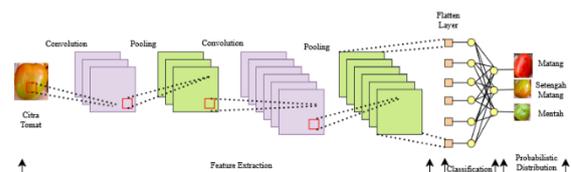
mampu tumbuh dengan baik di lahan bekas sawah ataupun lahan kering [7].

Dalam perspektif industri pertanian dan distribusi pangan, buah tomat menempati posisi strategis karena pemanfaatannya yang luas dalam penyediaan makanan sehari-hari. Fleksibilitas penggunaannya membuat tomat menjadi komoditas yang senantiasa dicari dan memiliki rantai distribusi yang kompleks dari petani hingga ke konsumen akhir [7].

Kualitas tomat menjadi faktor determinan yang mempengaruhi penerimaan konsumen, nilai ekonomi, serta efektivitas dalam proses distribusi dan pemasaran. Parameter kualitas tomat terutama tercermin dari warnanya, yang kemudian berhubungan langsung dengan karakteristik tekstur, cita rasa, dan kandungan nutrisi yang terkandung dalam buah [8]. Tingkat kualitas ini menjadi pertimbangan utama dalam seluruh rantai nilai komoditas tomat.(1).

2.2 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu jenis jaringan saraf tiruan yang dirancang khusus untuk mengolah data citra [10]. CNN unggul dalam mengenali pola dan objek kompleks melalui proses yang menyerupai cara kerja sistem visual pada makhluk hidup. Arsitektur CNN terdiri dari beberapa lapisan, seperti convolution layer, pooling layer, dan fully connected layer [11]. Lapisan konvolusi berfungsi mengekstraksi fitur dari citra dengan menerapkan operasi konvolusi menggunakan filter. Hasil dari proses ini berupa feature map, yang kemudian disederhanakan melalui pooling layer, dan akhirnya diproses dalam fully connected layer untuk menghasilkan output klasifikasi citra [10]. Gambar 1 menunjukkan visualisasi arsitektur CNN klasifikasi tingkat kematangan citra buah tomat.



Gambar 1. Arsitektur CNN Klasifikasi Tingkat Kematangan Citra Buah Tomat

2.3 Arsitektur DenseNet121

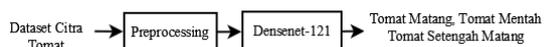
DenseNet121 adalah arsitektur Convolutional Neural Network (CNN) yang

menerapkan pola koneksi padat, di mana setiap lapisan meneruskan output-nya ke seluruh lapisan berikutnya, sehingga memungkinkan penggunaan ulang fitur yang telah dipelajari sebagai input pada lapisan-lapisan selanjutnya dalam jaringan [10]. DenseNet201, varian yang diperkenalkan pada 2017, terdiri dari 201 lapisan yang diorganisir dalam beberapa komponen utama yaitu dense block dan transition layer, dengan integrasi batch normalization dan fungsi aktivasi ReLU untuk meningkatkan kecepatan konvergensi serta performa.

Keunggulan utama arsitektur ini terletak pada kemampuannya memanfaatkan ulang fitur secara efisien, sehingga mengurangi jumlah parameter yang dibutuhkan sambil tetap mempertahankan kinerja tinggi dan stabilitas gradien selama proses pelatihan. Meskipun DenseNet201 menawarkan solusi efektif untuk meningkatkan efisiensi dan performa model deep learning, penerapannya tetap memerlukan perhatian khusus terhadap tantangan komputasi dan kebutuhan memori yang muncul.

3. METODE PENELITIAN

Penelitian ini terdiri dari lima tahap yang terstruktur, dimulai dari pengumpulan dataset citra tomat, dilanjutkan dengan preprocessing, pelatihan menggunakan arsitektur DenseNet-121, hingga proses klasifikasi tingkat kematangan tomat menjadi tiga kelas, yaitu matang, setengah matang, dan mentah. Gambar 2 menunjukkan tahapan alur penelitian.



Gambar 2. Metodologi Penelitian

3.1 Dataset Citra Tomat

Pengumpulan data citra buah tomat pada penelitian ini diperoleh melalui dua sumber, yaitu platform kaggle sebagai sumber sekunder, dan sumber primer berupa gambar yang dikumpulkan secara langsung. Dalam pengambilan image tomat, peneliti membagi menjadi tiga kelas yaitu tomat matang, tomat mentah, dan tomat setengah matang. Masing-masing kelas memiliki 200 citra, sehingga total gambar berjumlah 600. Distribusi jumlah gambar pada setiap kelas tingkat kematangan tomat pada dataset dapat dilihat pada Gambar 3.



Gambar 3. Grafik Jumlah Dataset Citra Pada Setiap Kelas Tingkat Kematangan Tomat

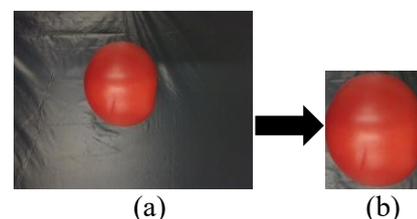
Kemudian contoh visual untuk kelas tingkatan kematangan tomat pada dataset dapat dilihat pada Tabel 1.

Tabel 1. Tingkatan Kematangan Tomat

<i>Gambar Tomat</i>	<i>Tingkat Kematangan</i>
	Matang
	Setengah Matang
	Mentah

3.2 Preprocessing

Tahap preprocessing dilaksanakan melalui proses pemotongan gambar hasil pemotretan buah tomat, dengan area cropping sangat dekat dengan batas tepi gambar kontur objek tomat yang menjadi fokus pengamatan [12]. Gambar 4 memperlihatkan contoh hasil preprocessing pada tomat matang.



Gambar 4. Hasil Preprocessing Tomat Matang: (a) Sebelum Cropping; (b) Sesudah Cropping

3.3 Split Dataset

Setelah tahap preprocessing, dilanjutkan dengan split data. Proses ini digunakan untuk memisahkan dataset ke dalam beberapa bagian

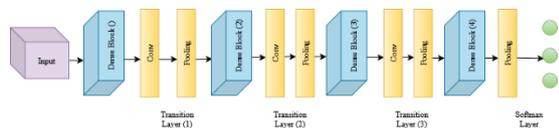
[3]. Dataset dibagi menjadi tiga kelompok: data training, validation, dan testing. Pembagian ini dilakukan untuk memastikan model dapat belajar mengenali pola dengan baik dan memberikan hasil prediksi yang akurat. Dataset didistribusikan dengan komposisi 80% untuk training, 16% untuk validation, dan 4% untuk testing. Rincian jumlah gambar untuk setiap kelompok dataset dapat dilihat pada Tabel 2.

Tabel 2. Hasil Pembagian Dataset Tomat

Kelas	Traini ng	Validati on	Testin g	Tot al
Matang	119	26	4	149
Setengah	133	25	8	166
Matang Mentah	132	25	8	165
Total Dataset	384	76	20	480

3.4 Arsitektur Model DenseNet121

Model yang digunakan pada penelitian ini menerapkan klasifikasi dengan deep learning menggunakan model DenseNet121. Arsitektur model denseNet121 dapat dilihat pada Gambar 5.



Gambar 5. Arsitektur DenseNet121

Setiap blok Dense memiliki konektivitas dengan blok Dense berikutnya dalam arsitektur, sehingga memungkinkan blok Dense di lapisan terakhir dapat memanfaatkan informasi yang dihasilkan oleh blok Dense pada lapisan pertama [10].

3.5 Evaluasi Model

Tahap pengujian dilakukan untuk menilai sejauh mana model CNN mampu mengklasifikasikan tingkat kematangan tomat ke dalam tiga kelas, yaitu matang, setengah matang, dan mentah. Pengujian dilakukan menggunakan data yang telah dipisahkan khusus untuk menguji performa model. Evaluasi dilakukan dengan menggunakan metrik umum seperti akurasi, precision, recall, dan F1-score guna memberikan gambaran yang menyeluruh terhadap kinerja model. Untuk memastikan apakah model CNN sudah bekerja

secara optimal, digunakan juga Confusion Matrix sebagai alat evaluasi visual, yang dapat memberikan informasi lebih rinci mengenai jumlah prediksi yang benar dan salah pada tiap kelas.

		Nilai Aktual	
		Positive	Negative
Nilai Prediksi	Positive	TP	FP
	Negative	FN	TN

Gambar 6. Tabel Confusion Matrix

Berdasarkan tabel Confusion Matrix yang ditampilkan pada Gambar 6, dapat diperoleh ilai True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN) yang selanjutnya digunakan untuk menghitung metrik evaluasi seperti akurasi, presisi, recall, dan F1-score dari arsitektur CNN yang digunakan. Representasi matematis dari akurasi, presisi, recall, dan F1-score ditunjukkan pada persamaan (1) hingga (4).

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (1)$$

$$Presisi = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

$$Recaall = \frac{TP}{TP+FN} \times 100\% \quad (3)$$

$$F1\ Score = \frac{2*(Persisi*Recall)}{Persisi+Reacall} \times 100\% \quad (4)$$

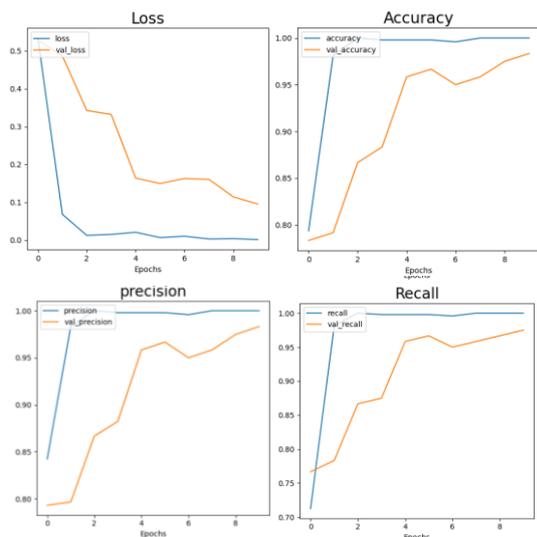
Keterangan :

- TP (True Positive) = Jumlah data positif yang diprediksi benar oleh model
- TN (True Negative) = Jumlah data negatif yang diprediksi benar oleh model
- FP (False Positive) = Jumlah data negatif yang diprediksi salah sebagai positif oleh model
- FN (False Negative) = Jumlah data positif yang diprediksi salah sebagai negatif oleh model

4. HASIL DAN PEMBAHASAN

Berdasarkan hasil pelatihan yang telah dilakukan terhadap model klasifikasi tingkat kematangan buah tomat menggunakan metode Convolutional Neural Network (CNN), diperoleh beberapa temuan yang menunjukkan performa model secara signifikan. Pada epoch

awal, akurasi masih rendah (65,26%) dengan nilai loss 0.7903, namun terus meningkat hingga mencapai akurasi 100% pada epoch ke-10 dengan loss sangat kecil (0.0016). Akurasi validasi juga tinggi, yaitu 98,33%, disertai precision 98,32% dan recall 97,50%. Gambar 7 menunjukkan hasil akurasi pada nilai loss, nilai akurasi, nilai precision, dan nilai recall.



Gambar 7. Performa Model Epoch

Evaluasi menunjukkan model bekerja sangat baik pada data pelatihan, dengan akurasi 99,58%, precision 99,79%, dan recall 99,58%. Tidak ditemukan overfitting karena performa pada data validasi tetap tinggi dan stabil. Hal ini menunjukkan model mampu mengenali pola dengan baik dan melakukan klasifikasi secara konsisten.

Tabel 3. Hasil Pengujian Menggunakan DenseNet121

<i>kelas</i>	<i>precision</i>	<i>recall</i>	<i>F1-score</i>
Matang	1.00	0.99	0.99
Setengah matang	0.99	0.99	0.99
Mentah	0.99	0.99	0.99
Macro avg accuracy	0.99	0.99	0.99

Hasil pengujian model CNN yang di tunjukkan pada Tabel 3 terhadap klasifikasi tingkat kematangan buah tomat menunjukkan performa yang sangat baik. Untuk kelas matang, model berhasil mencapai nilai

precision sempurna sebesar 1.00, yang berarti seluruh prediksi terhadap kelas matang benar. Recall-nya sedikit lebih rendah, yaitu 0.99, yang menunjukkan hanya sedikit gambar matang yang tidak terdeteksi. Kelas setengah matang juga menunjukkan performa konsisten, dengan precision dan recall masing-masing sebesar 0.99, menandakan bahwa sebagian besar gambar dalam kelas ini berhasil diidentifikasi dengan akurat dan minim kesalahan klasifikasi. Begitu pula untuk kelas mentah, di mana precision dan recall-nya juga mencapai 0.99, mencerminkan kemampuan model dalam membedakan citra tomat mentah secara konsisten.

Nilai macro average dari precision dan recall keduanya sebesar 0.99, menunjukkan bahwa model bekerja secara seimbang pada ketiga kelas. Rata-rata F1-score juga tercatat 0.99, memperkuat bukti bahwa model memiliki kinerja klasifikasi yang sangat baik secara keseluruhan. Akurasi total model adalah 0.99, yang berarti 99% dari seluruh data uji berhasil diklasifikasikan dengan benar. Berdasarkan Confusion Matrix, dapat disimpulkan bahwa model CNN mampu mengenali karakteristik visual dari tiap tingkat kematangan tomat dengan sangat baik, dan tidak menunjukkan adanya bias terhadap kelas tertentu.

Secara umum, CNN terbukti efektif dalam mengenali tingkat kematangan tomat dari citra. Teknik augmentasi berhasil meningkatkan keragaman data dan memperkuat kemampuan generalisasi model. Namun, untuk memastikan keandalannya di kondisi nyata, perlu dilakukan pengujian lanjutan pada data uji baru. Penggunaan teknik regularisasi juga disarankan untuk meningkatkan ketahanan model terhadap data yang lebih kompleks.

5. KESIMPULAN

Hasil pengujian menunjukkan bahwa model DenseNet-121 mampu mencapai akurasi 99% pada data uji dan 98,33% pada data validasi tanpa indikasi overfitting. Precision dan recall untuk seluruh kelas (matang, setengah matang, dan mentah) berada pada rentang 0.99 hingga 1,00, menunjukkan kinerja klasifikasi yang konsisten. Proses pelatihan mengalami peningkatan akurasi signifikan dari 65,26% menjadi 100% dalam 10 epoch, dengan nilai loss rendah. Temuan ini menunjukkan bahwa model DenseNet121 lebih unggul

mengidentifikasi karakteristik visual objek dalam sistem klasifikasi citra berbasis machine learning.

UCAPAN TERIMA KASIH

Penulis menyampaikan apresiasi kepada seluruh pihak yang telah memberikan dukungan dan kontribusi dalam pelaksanaan penelitian ini.

DAFTAR PUSTAKA

- [1] A. B. M. Widat, A. Baijuri, and F. Lazim, "Klasifikasi Kematangan Citra Buah Tomat Berdasarkan Ekstraksi Fitur Warna Menggunakan Metode K-NN," *G-Tech J. Teknol. Terap.*, vol. 8, no. 3, pp. 1779–1786, 2024, doi: 10.33379/gtech.v8i3.4539.
- [2] N. Arifin, C. N. Insani, and M. R. Rasyid, "Klasifikasi Tingkat Kematangan Buah Tomat menggunakan Computer Vision untuk Smart Agriculture," *J. SAINTIKOM (Jurnal Sains Manaj. Inform. dan Komputer)*, vol. 22, no. 2, p. 509, 2023, doi: 10.53513/jis.v22i2.8387.
- [3] E. Widyastuti, A. Hermawan, D. Avianto, T. Informasi, U. T. Yogyakarta, and G. Z. Tomato, "Klasifikasi tomat berdasarkan varietas dengan ekstraksi fitur rgb dan algoritma naïve bayes," vol. 8, pp. 127–137, 2025.
- [4] S. Gustina, "Aplikasi Machine Learning untuk Mendeteksi Kematangan Tomat menggunakan Metode Backpropagation," *J. Engine Energi, Manufaktur, dan Mater.*, vol. 8, pp. 81–88, 2024, [Online]. Available: https://ejournal.up45.ac.id/index.php/Jurnal_ENGINE/article/view/1815%0Ahttps://ejournal.up45.ac.id/index.php/Jurnal_ENGINE/article/download/1815/1001
- [5] I. Irma, M. Muchtar, R. Adawiyah, and S. Sarimuddin, "Klasifikasi Tingkat Kematangan Cabai Merah Keriting Menggunakan Svm Multiclass Berdasarkan Ekstraksi Fitur Warna," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, pp. 1747–1755, 2024, doi: 10.23960/jitet.v12i3.4430.
- [6] S. Aras, P. Tanra, and M. Bazhar, "Deteksi Tingkat Kematangan Buah Tomat Menggunakan YOLOv5," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 2, pp. 623–628, 2024, doi: 10.57152/malcom.v4i2.1270.
- [7] C. A. Sanjaya, M. Waluyo, and T. Industri, "ANALISIS PERBANDINGAN METODE TRANSFER LEARNING DENSENET201 DAN VGG-19 TERHADAP," vol. 13, no. 1, 2025.
- [8] F. Sains and U. T. Yogyakarta, "SISTEM PREDIKSI TINGKAT KEMATANGAN BUAH TOMAT MENGGUAKAN ARSITEKTUR VGG16," vol. 5, no. 3, pp. 401–414, 2024, doi: 10.46576/djtechno.
- [9] A. R. Atmaja, U. Islam, and N. Sumatera, "Penerapan Local Binary Pattern (Lbp) Dan K-Nearest Neighbors (Knn) Untuk Mendeteksi," vol. 4307, no. August, pp. 1028–1037, 2024.
- [10] W. Wijaya Kusuma, R. Rizal Isnanto, A. Fauzi, and P. Korespondensi, "DenseNet121 Menggunakan Kerangka Kerja TensorFlow untuk Deteksi Jenis Hewan," *J. Tek. Komput.*, vol. 1, no. 4, pp. 141–147, 2023, doi: 10.14710/jtk.v1i4.37009.
- [11] D. Lisa and R. Putri, "KLASIFIKASI CITRA JENIS HIJAB MENGGUNAKAN DENSENET-121," vol. 13, no. 1, 2025.
- [12] B. Maulana Alfaruq, D. Erwanto, and I. Yanuartanti, "Klasifikasi Kematangan Buah Tomat Dengan Metode Support Vector Machine," *Gener. J.*, vol. 7, no. 3, pp. 64–72, 2023, doi: 10.29407/gj.v7i3.21092.