



**PENERAPAN *CONVOLUTIONAL NEURAL NETWORK* (CNN) UNTUK KLASIFIKASI
TINGKAT KEMATANGAN CABAI RAWIT MERAH BERDASARKAN WARNA**

**APPLICATION OF A *CONVOLUTIONAL NEURAL NETWORK* (CNN) FOR
CLASSIFYING THE MATURITY LEVELS OF RED BIRD'S EYE CHILI PEPPERS
BASED ON COLOR**

Indriyani Dwi Wulandari*, Prodi Matematika FMIPA UNY

Fatma Agus Setyaningsih, Prodi Matematika FMIPA UNY

*e-mail: indriyanidwi.2020@student.uny.ac.id

Abstrak. Penentuan tingkat kematangan cabai rawit merah merupakan tahapan penting dalam menjaga kualitas hasil panen, namun proses sortasi yang masih dilakukan secara manual cenderung bersifat subjektif dan rentan terhadap kesalahan klasifikasi. Penelitian ini bertujuan mengembangkan model *Convolutional Neural Network* (CNN) untuk mengklasifikasikan tingkat kematangan cabai rawit merah berdasarkan warna citra digital ke dalam tiga kategori, yaitu matang, setengah matang, dan belum matang. Penelitian menggunakan 120 citra digital yang terdiri atas 60 citra cabai matang, 40 citra setengah matang, dan 20 citra belum matang, dengan pembagian data sebesar 80% untuk pelatihan dan 20% untuk validasi. Tahapan penelitian meliputi *preprocessing* berupa *resize* citra dan augmentasi data, kemudian perancangan model CNN dengan 3 *convolution layer*, 3 *max pooling layer*, 1 *flatten layer*, 3 *dense layer*, dan 2 *dropout layer*, menggunakan fungsi aktivasi ReLU dan *Softmax* serta *optimizer* Adam. Hasil penelitian menunjukkan bahwa model memperoleh akurasi validasi sebesar 96%, yang menunjukkan kinerja yang baik dalam mengklasifikasikan tingkat kematangan pada dataset validasi penelitian. Dengan demikian, metode CNN efektif diterapkan untuk klasifikasi tingkat kematangan cabai rawit merah dan berpotensi mendukung pengembangan sistem sortasi otomatis yang lebih efisien, konsisten, serta mendukung implementasi teknologi *smart farming*.

Kata kunci: *Convolutional Neural Network*, Cabai Rawit Merah, Tingkat Kematangan.

Abstract. Determining the maturity level of red bird's eye chili peppers is an important stage in maintaining postharvest quality; however, manual sorting remains subjective and is prone to classification errors. This study aimed to develop a *Convolutional Neural Network* (CNN) model for classifying the maturity levels of red bird's eye chili peppers based on the color characteristics of digital images into three categories: ripe, semi-ripe, and unripe. The study used 120 digital images consisting of 60 ripe, 40 semi-ripe, and 20 unripe chili pepper images, with 80% of the data allocated for training and 20% for validation. The research procedures included image preprocessing, consisting of image resizing and data augmentation, followed by the development of a CNN model comprising 3 convolutional layers, 3 max-pooling layers, 1 flatten layer, 3 dense layers, and 2 dropout layers, using ReLU and Softmax activation functions and the Adam optimizer. The results showed that the model achieved a validation accuracy of 96%, indicating good performance in classifying the maturity levels within the validation dataset. Therefore, the CNN method demonstrated good performance in classifying the maturity levels of red bird's eye chili peppers and shows potential for supporting automated sorting systems.

Keywords: *Convolutional Neural Network*, Red Bird's Eye Chili Pepper, Maturity Level.

PENDAHULUAN

Perkembangan teknologi digital dalam era Revolusi Industri 4.0 telah membawa dampak transformatif di berbagai sektor, termasuk pertanian. Dalam konteks Indonesia, transformasi digital menjadi suatu keniscayaan untuk meningkatkan efisiensi dan produktivitas sektor pertanian secara berkelanjutan. Salah satu komoditas hortikultura strategis yang memerlukan pendekatan inovatif adalah cabai rawit merah (*Capsicum frutescens* L.), yang tidak hanya memiliki nilai ekonomi tinggi, tetapi juga memberikan kontribusi signifikan terhadap PDB sektor pertanian nasional (Kementan, 2023).

Menurut data Badan Pusat Statistik (BPS, 2023), produksi cabai rawit merah di Indonesia mencapai 1,24 juta ton pada tahun 2022. Besarnya produksi tersebut menunjukkan pentingnya pengelolaan kualitas hasil panen, termasuk penentuan tingkat kematangan pada saat panen dan sortasi. Analisis Ditjen Hortikultura (2022) mengungkapkan bahwa kenaikan harga cabai rawit merah bisa mencapai sekitar 43%. Fluktuasi harga yang ekstrem dalam lima tahun terakhir menunjukkan adanya ketidaktepatan dalam rantai produksi, terutama dalam penentuan waktu panen. Hal ini diperburuk oleh fakta bahwa metode konvensional yang digunakan petani masih sangat bergantung pada pengamatan visual, yang bersifat subjektif dan sangat dipengaruhi oleh kondisi eksternal seperti pencahayaan dan latar belakang lingkungan (Khoirunnisa et al., 2023).

Penentuan tingkat kematangan cabai merupakan salah satu tahapan penting dalam proses panen dan penanganan pascapanen karena tingkat kematangan menjadi salah satu faktor yang perlu diperhatikan dalam menentukan kualitas hasil panen (Fitri et al., 2020). Dalam praktiknya, identifikasi tingkat kematangan cabai secara manual masih bergantung pada pengamatan visual dan perbedaan persepsi mengenai tingkat kematangan, sehingga dapat menghasilkan penilaian yang subjektif dan tidak konsisten, terutama ketika proses sortasi dilakukan dalam waktu yang lama (Luthfi et al., 2023; Ulum et al., 2024). Kondisi tersebut mendorong penerapan pengolahan citra berbasis kecerdasan buatan (*Artificial Intelligence/AI*) sebagai pendekatan untuk meningkatkan objektivitas dan konsistensi dalam identifikasi tingkat kematangan cabai dan kualitas hasil panen. Salah satu metode yang dapat diterapkan adalah *Convolutional Neural Network* (CNN), yang mampu memanfaatkan karakteristik visual citra untuk melakukan klasifikasi tingkat kematangan secara otomatis.

Pendekatan berbasis *Convolutional Neural Network* (CNN) telah banyak dimanfaatkan dalam klasifikasi citra karena memiliki kemampuan mengekstraksi karakteristik visual secara otomatis dan efektif, serta menghasilkan akurasi yang tinggi pada berbagai objek pertanian, termasuk klasifikasi tingkat kematangan buah seperti tomat, mangga, dan pisang, dengan akurasi lebih dari 90% (Koirala et al., 2019; Afonso et al., 2020; Thenmozhi & Reddy, 2019). Meskipun demikian, penerapan CNN untuk klasifikasi tingkat kematangan cabai rawit merah masih relatif terbatas dan penelitian ini berfokus pada klasifikasi tiga tingkat kematangan cabai rawit merah berdasarkan karakteristik warna, khususnya menggunakan dataset citra yang diperoleh secara langsung dengan kondisi akuisisi yang terstandarisasi. Oleh karena itu, diperlukan penelitian yang mengembangkan model CNN untuk mengidentifikasi tingkat kematangan cabai rawit merah berdasarkan karakteristik warna citra digital.

Berdasarkan permasalahan tersebut, penelitian ini difokuskan pada dua pertanyaan utama, yaitu: (1) bagaimana mengimplementasikan metode CNN untuk mengklasifikasikan tingkat kematangan cabai rawit merah berdasarkan warna citra digital, dan (2) bagaimana tingkat akurasi model CNN yang dihasilkan dalam mengklasifikasikan tiga tingkat kematangan cabai, yaitu matang, setengah matang, dan belum matang? Sejalan dengan rumusan masalah tersebut, penelitian ini bertujuan mengembangkan model CNN untuk

klasifikasi tingkat kematangan cabai rawit merah serta mengevaluasi kinerja model berdasarkan nilai akurasi hasil klasifikasi.


Penelitian ini memberikan kontribusi pada pengembangan penerapan *deep learning* di bidang pengolahan citra digital untuk sektor pertanian, khususnya dalam klasifikasi tingkat kematangan cabai rawit merah. Model yang dihasilkan diharapkan dapat menjadi dasar pengembangan sistem sortasi otomatis yang lebih efisien, konsisten, dan objektif, serta mendukung implementasi teknologi *smart farming* melalui pemanfaatan analisis citra digital dalam proses pengambilan keputusan pada kegiatan pascapanen.

METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk mengembangkan dan mengevaluasi model *Convolutional Neural Network* (CNN) dalam klasifikasi tingkat kematangan cabai rawit merah berdasarkan warna citra digital. Data penelitian berupa 120 citra cabai rawit merah yang diperoleh dari petani cabai dan tempat pelelangan cabai. Dataset terdiri atas 60 citra cabai matang, 40 citra setengah matang, dan 20 citra belum matang. Pengambilan citra dilakukan menggunakan kamera utama smartphone dengan objek diletakkan pada alas berwarna putih untuk memperoleh kualitas citra yang konsisten. Kamera digunakan dalam mode manual dengan parameter ISO, *shutter speed*, dan *aperture* yang dibuat sama untuk setiap pengambilan citra agar kondisi citra relatif seragam.

Tahapan penelitian diawali dengan studi literatur dan penyiapan data, kemudian dilanjutkan dengan *preprocessing*, perancangan model CNN, pelatihan dan pengujian model, serta evaluasi hasil klasifikasi. Pada tahap *preprocessing*, citra melalui proses *cropping* untuk memperoleh objek cabai secara lebih dominan, *resize* menjadi 150×150 piksel, normalisasi nilai piksel dengan membagi nilai piksel dengan 255 sehingga berada pada rentang 0–1, serta pelabelan berdasarkan tiga kategori kematangan. Data juga diberikan augmentasi berupa *horizontal flip*, rotasi hingga 30° , *shear*, *zoom*, serta pergeseran lebar dan tinggi citra. Dataset kemudian dibagi menjadi data pelatihan dan data validasi dengan proporsi 80% dan 20%. Pada tahap berikutnya, dirancang model CNN dengan tiga *convolution layer*, tiga *max pooling layer*, satu *flatten layer*, tiga *dense layer*, dan dua *dropout layer*. Model menggunakan fungsi aktivasi ReLU dan Softmax serta optimizer Adam. Model dilatih menggunakan 25 *epoch* dan *batch size* 10 dengan fungsi *loss categorical crossentropy*. Setelah pelatihan, model dievaluasi menggunakan data validasi untuk mengetahui kemampuan klasifikasi pada tiga kategori tingkat kematangan.

Analisis data dilakukan dengan mengevaluasi performa model berdasarkan hasil klasifikasi menggunakan *confusion matrix* akurasi, *precision*, *recall*, dan *f1-score*. Kinerja model diukur melalui nilai akurasi yang diperoleh dari proses validasi untuk mengetahui kemampuan model dalam mengklasifikasikan tingkat kematangan cabai rawit merah. Hasil evaluasi selanjutnya digunakan sebagai dasar untuk menilai efektivitas penerapan metode CNN dalam mendukung proses klasifikasi tingkat kematangan secara otomatis. Langkah-langkah pengklasifikasian tingkat kematangan cabai rawit merah dalam penelitian ini ditampilkan dalam bentuk *flowchart* pada gambar 1.



Gambar 1. Langkah-langkah Penelitian

HASIL PENELITIAN DAN PEMBAHASAN

1. Preprocessing dan Pembagian Dataset

Penelitian ini menggunakan 120 citra cabai rawit merah yang terdiri atas 60 citra matang, 40 citra setengah matang, dan 20 citra belum matang. Seluruh citra diproses melalui tahap *preprocessing* dengan mengubah ukuran citra menjadi 150×150 piksel agar memiliki dimensi input yang seragam. Dataset kemudian dibagi secara acak dengan proporsi 80% untuk pelatihan dan 20% untuk validasi. Dengan pembagian tersebut, diperoleh 96 citra untuk data pelatihan dan 24 citra untuk data validasi.

Tabel 1. Distribusi Dataset Penelitian

Tingkat kematangan	Jumlah citra	Data pelatihan	Data validasi
Matang	60	48	12
Setengah matang	40	32	8
Belum matang	20	16	4
Total	120	96	24

Untuk meningkatkan variasi data, diterapkan augmentasi berupa rotasi hingga 30° , *horizontal flip*, *shear*, pergeseran lebar dan tinggi, serta *zoom*. Nilai piksel juga dinormalisasi ke rentang 0–1 melalui proses *rescale*. Strategi ini memungkinkan model memperoleh variasi representasi citra yang lebih beragam selama pelatihan.

2. Perancangan dan Pelatihan Model CNN

Model CNN dirancang menggunakan arsitektur *Sequential* dengan 3 *convolution layer* dan 3 *max pooling layer* sebagai bagian ekstraksi fitur. Selanjutnya,

fitur diubah melalui *flatten layer* dan diteruskan ke 3 *dense layer* serta 2 *dropout layer*. Model menggunakan ukuran input 150×150 piksel dan filter berukuran 3×3 . Fungsi aktivasi ReLU digunakan pada proses ekstraksi dan klasifikasi akhir menggunakan *Softmax* untuk menghasilkan probabilitas tiga kelas, yaitu matang, setengah matang, dan belum matang.

```
[ ] model.summary()
```


Model: "sequential_2"

Layer (type)	Output Shape	Param #
conv2d_6 (Conv2D)	(None, 148, 148, 16)	448
max_pooling2d_6 (MaxPooling2D)	(None, 74, 74, 16)	0
conv2d_7 (Conv2D)	(None, 72, 72, 32)	4,640
max_pooling2d_7 (MaxPooling2D)	(None, 36, 36, 32)	0
conv2d_8 (Conv2D)	(None, 34, 34, 64)	18,496
max_pooling2d_8 (MaxPooling2D)	(None, 17, 17, 64)	0
flatten_2 (Flatten)	(None, 18496)	0
dense_6 (Dense)	(None, 200)	3,699,400
dropout_4 (Dropout)	(None, 200)	0
dense_7 (Dense)	(None, 500)	100,500
dropout_5 (Dropout)	(None, 500)	0
dense_8 (Dense)	(None, 3)	1,503

Total params: 3,824,987 (14.59 MB)
 Trainable params: 3,824,987 (14.59 MB)
 Non-trainable params: 0 (0.00 B)

Gambar 2. Arsitektur Model CNN

Model dilatih menggunakan *optimizer Adaptive Moment Estimation* (Adam) dengan fungsi *loss categorical crossentropy* selama 25 *epoch* dan *batch size* 10. Selama pelatihan, akurasi dan *loss* pada data training dan validasi menunjukkan kecenderungan membaik. Namun, terdapat fluktuasi pada performa validasi, termasuk kondisi ketika akurasi validasi mencapai 100% kemudian menurun dan *loss* validasi meningkat pada beberapa *epoch* ketika *loss* training terus menurun. Pola tersebut menunjukkan adanya indikasi *overfitting* ringan, sehingga performa model perlu dinilai lebih lanjut menggunakan data validasi yang belum digunakan dalam proses pembelajaran.



Gambar 3. Grafik Model

Fluktuasi tersebut menunjukkan bahwa akurasi tinggi yang diperoleh selama pelatihan perlu diinterpretasikan secara hati-hati. Model memang mampu mempelajari karakteristik data pelatihan dengan baik, tetapi perubahan performa pada data validasi

menunjukkan bahwa kemampuan generalisasi model masih dapat ditingkatkan. Temuan ini relevan karena dataset penelitian relatif terbatas.

3. Evaluasi Kinerja Model

Evaluasi akhir dilakukan menggunakan data validasi dengan *confusion matrix* dan *classification report*. Confusion matrix digunakan untuk mengetahui jumlah prediksi benar dan salah pada setiap kelas, sedangkan *classification report* memberikan informasi mengenai *precision*, *recall*, dan *f1-score*. Hasil evaluasi menunjukkan bahwa dari 24 citra validasi, sebanyak 23 citra berhasil diklasifikasikan dengan benar dan satu citra mengalami kesalahan klasifikasi.

Tabel 2. *Confusion Matrix* Hasil Klasifikasi

Kelas aktual	Belum matang	Matang	Setengah matang
Belum matang	4	0	0
Matang	0	12	0
Setengah matang	0	1	7

Tabel tersebut menunjukkan bahwa seluruh empat citra belum matang berhasil dikenali dengan benar. Demikian pula, seluruh 12 citra matang berhasil diklasifikasikan sebagai matang. Kesalahan hanya terjadi pada kelas setengah matang, yaitu satu citra yang diprediksi sebagai matang. Dengan demikian, tingkat keberhasilan klasifikasi mencapai 23 dari 24 citra validasi.

Confusion Matrix:				
[[4 0 0]				
[0 12 0]				
[0 1 7]]				
Classification Report:				
	precision	recall	f1-score	support
belum matang	1.00	1.00	1.00	4
matang	0.92	1.00	0.96	12
setengah matang	1.00	0.88	0.93	8
accuracy			0.96	24
macro avg	0.97	0.96	0.96	24
weighted avg	0.96	0.96	0.96	24

Gambar 4. *Confusion Matrix* dan *Classification Report*

Hasil tersebut menunjukkan akurasi keseluruhan sebesar 96%. Kelas belum matang dan setengah matang menunjukkan *precision*, *recall*, dan *F1-score* yang tinggi, sedangkan kelas matang memiliki *recall* sebesar 1,00 dan *precision* sebesar 0,92. Kesalahan pada satu citra setengah matang yang diprediksi sebagai matang menunjukkan bahwa batas karakteristik visual antara kedua tingkat kematangan tersebut masih memiliki kemiripan. Meskipun demikian, tidak ditemukan kesalahan klasifikasi pada kelas belum matang, dan seluruh citra matang berhasil dikenali oleh model.

4. Interpretasi Hasil

Akurasi sebesar 96% menunjukkan bahwa CNN mampu mempelajari karakteristik visual citra cabai rawit merah untuk membedakan tiga tingkat kematangan yang digunakan dalam penelitian. Hasil ini memperlihatkan bahwa informasi visual pada citra RGB, termasuk karakteristik warna yang berkaitan dengan tingkat kematangan, dapat dimanfaatkan oleh CNN untuk membedakan tiga kelas kematangan sebagai fitur dalam proses klasifikasi otomatis. Kemampuan model dalam mengenali seluruh citra belum matang dan matang dengan benar juga menunjukkan bahwa karakteristik visual pada kedua kelas tersebut relatif dapat dibedakan oleh model.

Namun, satu kesalahan klasifikasi pada kelas setengah matang menunjukkan bahwa kelas tersebut menjadi bagian yang paling sulit dibedakan dari kelas matang. Hal ini dapat dimaknai bahwa perubahan tingkat kematangan tidak selalu menghasilkan perbedaan visual yang tegas, terutama pada tahap peralihan. Dengan demikian, meskipun model menghasilkan akurasi yang tinggi, hasil penelitian belum dapat diartikan bahwa model sepenuhnya bebas dari kesalahan klasifikasi.

Temuan ini memberikan kontribusi pada penerapan *deep learning* dalam pengolahan citra digital untuk klasifikasi kematangan cabai rawit merah. Model yang dihasilkan menunjukkan potensi untuk mendukung proses klasifikasi yang lebih objektif dibandingkan pengamatan visual secara manual. Akan tetapi, interpretasi terhadap performa model perlu mempertimbangkan ukuran dataset validasi yang relatif kecil, yaitu 24 citra. Oleh karena itu, akurasi 96% menunjukkan kinerja yang baik pada data penelitian ini, tetapi belum cukup untuk menyatakan bahwa model memiliki kemampuan generalisasi yang sama pada kondisi citra yang lebih beragam.

SIMPULAN DAN SARAN

Penelitian ini berhasil menerapkan *Convolutional Neural Network* (CNN) untuk mengklasifikasikan tingkat kematangan cabai rawit merah berdasarkan citra digital ke dalam tiga kategori, yaitu matang, setengah matang, dan belum matang. Model menggunakan 3 *convolution layer*, 3 *max pooling layer*, 1 *flatten layer*, 3 *dense layer*, dan 2 *dropout layer*, dengan fungsi aktivasi ReLU dan *Softmax* serta *optimizer* Adam. Pelatihan dilakukan selama 25 *epoch* dengan *batch size* 10. Hasil evaluasi menunjukkan bahwa model memperoleh akurasi sebesar 96% pada 24 citra validasi, dengan 23 citra diklasifikasikan secara benar dan satu citra setengah matang diklasifikasikan sebagai matang. Hasil tersebut menunjukkan bahwa model CNN mampu memberikan kinerja klasifikasi yang baik pada dataset validasi penelitian.

Secara praktis, hasil penelitian menunjukkan potensi CNN sebagai dasar pengembangan sistem klasifikasi tingkat kematangan cabai secara otomatis. Namun, penelitian ini masih memiliki keterbatasan pada jumlah dan keragaman dataset serta kondisi pengambilan citra yang relatif terkontrol. Penelitian selanjutnya perlu mempertimbangkan penambahan jumlah dan variasi citra, penggunaan kondisi pencahayaan dan latar belakang yang lebih beragam, serta perbandingan dengan arsitektur *deep learning* lainnya untuk meningkatkan kemampuan generalisasi model.

UCAPAN TERIMA KASIH

Terima kasih kepada Koordinator Prodi Matematika dan seluruh Dosen Prodi Matematika yang telah memberikan ilmu hingga terselesainya artikel ini.

DAFTAR PUSTAKA

- Afonso, M., et al. (2020). " *Tomato Fruit Detection and Counting in Greenhouses Using Deep Learning*." *Computers and Electronics in Agriculture*, 173, 105407.
- BPS. (2023). "Produksi Tanaman Hortikultura 2023." Badan Pusat Statistik Indonesia.
- Fitri, Z. E., Nuhanatika, U., Madjid, A., & Imron, A. M. N. (2020). Penentuan tingkat kematangan cabe rawit (*Capsicum frutescens* L.) berdasarkan *Gray Level Co-Occurrence Matrix*. *Jurnal Teknologi Informasi dan Terapan*, 7(1), 1–5.
- Kementerian Pertanian Republik Indonesia. (2023). *Laporan Tahunan Sub-Sektor Hortikultura 2023*. Jakarta: Kementerian Pertanian RI.
- Khoirunnisa, A., et al. (2023). "Color-Based Classification of Chili Pepper Ripeness Using Image Processing." *Journal of Agricultural Engineering*, 15(2), 112-120.
- Koirala, A., Walsh, K. B., Wang, Z., & McCarthy, C. (2019). *Deep learning–Method overview and review of use for fruit detection and yield estimation*. *Computers and Electronics in Agriculture*, 162, 219–234.
- Luthfi, A., Sari, A. M., Dewi, G. R., Dwijayanti, Y., Satya, T. P., Sari, A. R., & Anoraga, S. B. (2023). Penentuan klasifikasi kematangan dan kualitas cabai merah besar (*Capsicum annum* L.) menggunakan aplikasi Color Grab. *Agrointek: Jurnal Teknologi Industri Pertanian*, 17(2), 280–287.
- Thenmozhi, K., & Srinivasulu Reddy, U. (2019). *Crop pest classification based on deep convolutional neural network and transfer learning*. *Computers and Electronics in Agriculture*, 164, 104906.
- Ulum, M. R. B., Rahmat, B., & Swari, M. H. P. (2024). Implementasi metode CNN dan *K-Nearest Neighbor* untuk klasifikasi tingkat kematangan tanaman cabai rawit. *Modem: Jurnal Informatika dan Sains Teknologi*, 2(3), 112–123.