



Klasifikasi Tingkat Kematangan Pisang Menggunakan Metode *DEEP Learning* dengan CNN

Angga Daru Arsianto^{1*}, Hustinawaty²

¹⁻² Magister Manajemen Sistem Informasi, Universitas Gunadarma, Indonesia

*Penulis Korespondensi: anggadaruarsianto@gmail.com

Abstract. *This study aims to develop a banana ripeness classification system using the Convolutional Neural Network (CNN) method. The dataset includes four ripeness categories: Unripe, Half-Ripe, Ripe, and Overripe. The model was trained with variations of 10, 20, 30, 40, and 50 epochs, using a learning rate of 0.001 and a batch size of 16 to determine the optimal configuration. The experimental results show that the best performance was achieved at 30 epochs, producing a validation accuracy of 0.99 and a validation loss of 0.02, indicating high model stability and minimal error. Performance evaluation was conducted using a confusion matrix and supported by Precision, Recall, and F1-Score metrics. Two classes achieved perfect scores of 1.00, while the other two classes recorded F1-Scores above 0.95, reflecting highly accurate predictions. Misclassifications were minimal and occurred only between visually similar categories, specifically Ripe and Overripe. Overall, the CNN model demonstrates strong generalization ability and is highly suitable for automated banana ripeness classification applications.*

Keywords: *Banana Ripeness; CNN; Confusion Matrix; Deep Learning; Image Classification.*

Abstrak. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi kematangan pisang menggunakan metode Convolutional Neural Network (CNN). Dataset mencakup empat kategori kematangan: Mentah, Setengah Matang, Matang, dan Terlalu Matang. Model dilatih dengan variasi 10, 20, 30, 40, dan 50 epoch, menggunakan learning rate 0,001 dan ukuran batch 16 untuk menentukan konfigurasi optimal. Hasil eksperimen menunjukkan bahwa performa terbaik dicapai pada 30 epoch, menghasilkan akurasi validasi 0,99 dan loss validasi 0,02, menunjukkan stabilitas model yang tinggi dan kesalahan minimal. Evaluasi performa dilakukan menggunakan matriks kebingungan dan didukung oleh metrik Presisi, Recall, dan F1-Score. Dua kelas mencapai skor sempurna 1,00, sedangkan dua kelas lainnya mencatat F1-Score di atas 0,95, mencerminkan prediksi yang sangat akurat. Kesalahan klasifikasi minimal dan hanya terjadi antara kategori yang secara visual serupa, khususnya Matang dan Terlalu Matang. Secara keseluruhan, model CNN menunjukkan kemampuan generalisasi yang kuat dan sangat cocok untuk aplikasi klasifikasi kematangan pisang secara otomatis.

Kata kunci: CNN; Confusion Matrix; Deep Learning; Kematangan Pisang; Klasifikasi Citra.

1. LATAR BELAKANG

Perkembangan teknologi smartphone dan kecerdasan buatan (Artificial Intelligence/AI) telah membawa transformasi signifikan dalam berbagai sektor, termasuk pertanian. Salah satu pendekatan yang dapat digunakan untuk memenuhi kebutuhan tersebut adalah dengan mengintegrasikan Artificial Intelligence (AI) ke dalam aplikasi berbasis mobile yang memungkinkan implementasi sistem cerdas yang lebih praktis, efisien, dan mudah diakses oleh pengguna (Dhia Yusrana, Yukandri, Nurdin, Handrianus Pranatawijaya, & Noor Kamala Sari, 2024). Melalui pendekatan machine learning, komputer mampu melakukan proses analisis data dan pengambilan keputusan tanpa harus diprogram secara eksplisit untuk setiap kemungkinan kondisi (Chyan, Arni, & Thayf, n.d.). Semakin kompleks algoritma yang digunakan, semakin optimal pula performa dan akurasi keputusan yang dihasilkan (Faiza, Gunawan, & Andriani, 2022).

Salah satu cabang machine learning yang berkembang pesat adalah deep learning, khususnya metode Convolutional Neural Network (CNN). Convolutional Neural Network (CNN) merupakan salah satu jenis jaringan saraf tiruan bertipe deep feedforward yang banyak digunakan dalam bidang visi komputer. Metode ini juga sering disebut sebagai ConvNet (Maulana, Khairunisa, & Mufidah, 2024), yang memiliki kemampuan unggul dalam pengolahan citra digital. CNN bekerja dengan mekanisme konvolusi menggunakan kernel untuk mengekstraksi fitur-fitur penting dari data berbentuk gambar, sehingga sangat efektif dalam tugas klasifikasi visual (Radikto, Mulyana, Rofik, & Zakaria, 2022). Kemajuan teknologi komputasi seperti pemanfaatan GPU serta ekosistem Big Data berbasis multi-node cluster turut mempercepat proses pelatihan dan inferensi model (Cholissodin & Soebroto, 2021).

Dalam sektor pertanian, salah satu tantangan yang masih banyak dilakukan secara manual adalah penentuan tingkat kematangan buah. Namun demikian, manusia terkadang mengalami kesulitan dalam menentukan apakah suatu buah sudah matang atau belum. Tingkat kematangan buah biasanya dinilai berdasarkan beberapa parameter, salah satunya adalah warna kulit buah (Putri Ananda, Viola Widyasari, Ihsan Muttaqin, & Stefanie, 2023). Pisang adalah salah satu komoditas hortikultura buah tropis yang banyak diminati serta memiliki nilai ekonomi yang tinggi, sehingga berpotensi untuk dikembangkan secara intensif dengan pendekatan agribisnis (Sirappa, 2021), khususnya varietas Pisang Cavendish yang banyak dibudidayakan secara komersial. Hampir 50% produksi pisang di seluruh dunia didominasi oleh kelompok pisang Cavendish (Gakkaishi, 2023). Tingkat kematangan pisang menjadi faktor krusial karena memengaruhi rasa, tekstur, aroma, serta daya simpan buah.

Secara umum, klasifikasi kematangan pisang dibagi menjadi empat kategori, yaitu mentah, setengah matang, matang, dan terlalu matang, berdasarkan warna kulit dan tekstur buah. Namun, proses penilaian ini masih dilakukan secara manual dan subjektif, sehingga berpotensi menimbulkan inkonsistensi serta kerugian ekonomi akibat kesalahan pemilahan (Hastungkoro, Putro Wicaksono, & Diah Rosita, 2024).

Sejumlah penelitian terdahulu telah membuktikan bahwa CNN memiliki kemampuan untuk mengklasifikasikan tingkat kematangan pisang dengan akurasi yang tinggi. (Hastungkoro et al., 2024) melaporkan mencapai akurasi 95% dengan dataset 1.000 citra. Meskipun demikian, sebagian besar penelitian tersebut masih berfokus pada pengembangan model dan belum banyak yang mengimplementasikan sistem klasifikasi tersebut ke dalam aplikasi berbasis mobile yang dapat digunakan secara real-time.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan model klasifikasi tingkat kematangan pisang berbasis Convolutional Neural Network (CNN). Model dirancang dan dilatih untuk mampu mengenali serta membedakan tingkat kematangan pisang secara otomatis berdasarkan citra digital. Dengan pendekatan deep learning ini, diharapkan diperoleh model yang memiliki akurasi tinggi, kemampuan generalisasi yang baik, serta dapat menjadi solusi yang efektif dan objektif dalam proses identifikasi tingkat kematangan pisang di sektor pertanian (Danang et al., 2026).

2. KAJIAN TEORITIS

Machine Learning

Machine Learning (ML) adalah salah satu bidang dalam Artificial Intelligence (AI) yang memungkinkan suatu sistem untuk belajar secara mandiri dari data, sehingga dapat mengambil keputusan tanpa perlu diprogram secara berulang oleh manusia (Retnoningsih & Pramudita, 2020). Melalui analisis pola dalam data, komputer dapat menghasilkan prediksi atau keputusan secara otomatis (Chyan et al., n.d.). Proses ini memanfaatkan data dalam jumlah besar sebagai input pada tahap pelatihan (training) untuk meningkatkan akurasi model (Retnoningsih & Pramudita, 2020). Menurut IBM, machine learning menggunakan data dan algoritma untuk meniru proses pembelajaran manusia, di mana peningkatan kompleksitas algoritma umumnya berbanding lurus dengan peningkatan performa sistem (Faiza et al., 2022).

Secara umum, machine learning terdiri dari supervised learning, unsupervised learning, dan reinforcement learning (Muzakir, Adi, & Kusumaningrum, 2024). Dalam klasifikasi citra, supervised learning paling banyak digunakan karena memanfaatkan dataset berlabel untuk memetakan input ke kategori yang tepat. Meskipun metode seperti SVM, Decision Tree, dan Naive Bayes dapat digunakan, pendekatan deep learning khususnya Convolutional Neural Network (CNN) menunjukkan kinerja yang lebih unggul dalam ekstraksi dan klasifikasi fitur citra secara otomatis.

Deep Learning

Deep learning adalah bagian dari machine learning yang menggunakan jaringan saraf tiruan, di mana komputer dapat mempelajari dan melakukan klasifikasi secara langsung berdasarkan data seperti gambar maupun suara (Setiyani, Indahsari, & Roestam, 2023). Jika kecerdasan buatan diibaratkan otak, maka pembelajaran mesin adalah proses di mana AI memperoleh kemampuan kognitif baru, dan deep learning adalah sistem pelatihan mandiri paling efektif yang tersedia saat ini (Mustafa, 2023). Keunggulannya terletak pada kemampuan


ekstraksi fitur otomatis, terutama pada data citra, sehingga mampu mengenali pola visual kompleks yang sulit ditangani metode konvensional. Perkembangannya meningkat pesat seiring kemajuan komputasi, dukungan Big Data seperti Hadoop dan Spark, serta pemrosesan paralel berbasis GPU yang mempercepat pelatihan model (Cholissodin & Soebroto, 2021). Secara arsitektural, deep learning terdiri dari beberapa lapisan dengan bobot yang saling terhubung, di mana setiap lapisan mengekstraksi fitur dari tingkat sederhana hingga kompleks. Dalam bidang pengolahan citra, kinerja deep learning sangat dipengaruhi oleh pemanfaatan Convolutional Neural Network (CNN) yang secara khusus dirancang untuk menangani data visual.

Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan arsitektur jaringan saraf tiruan yang dirancang khusus untuk mengolah data citra. CNN mampu mengenali pola spasial melalui operasi konvolusi menggunakan kernel untuk mengekstraksi fitur dari data input (Radikto et al., 2022). Model ini pertama kali diperkenalkan oleh Yann LeCun pada tahun 1998 melalui arsitektur LeNet untuk pengenalan tulisan tangan, dan sejak itu menjadi fondasi utama dalam pengembangan sistem pengenalan pola dan klasifikasi citra.

Dalam arsitektur CNN terdapat empat lapisan utama, yaitu lapisan konvolusi (Convolutional Layer), lapisan aktivasi (Activation Layer), lapisan pooling (Pooling Layer), dan lapisan fully connected (Fully Connected Layer) (Angginy Akhirunnisa Siregar, Citra Citra, Dechy Deswita Indriani.S, & Gifari Dhaffa Prawira Sianturi, 2023). Dibandingkan ANN dan RNN, CNN lebih efektif dalam pengolahan citra karena mampu mengurangi jumlah parameter melalui mekanisme konvolusi dan pooling, sehingga lebih efisien secara komputasi serta memiliki sifat translational invariance. Meskipun membutuhkan dataset berlabel dalam jumlah besar dan sumber daya komputasi yang tinggi saat pelatihan, perkembangan arsitektur modern seperti ResNet dan EfficientNet telah meningkatkan efisiensi dan performa model. Secara keseluruhan, CNN menjadi metode utama dalam berbagai aplikasi analisis citra, termasuk klasifikasi, deteksi objek, dan pengenalan wajah (Danang et al., 2025).

3. METODE PENELITIAN




Gambar 1. Tahapan perancangan model CNN.

Penelitian ini menggunakan pendekatan eksperimental dalam merancang dan mengevaluasi model Convolutional Neural Network (CNN) untuk klasifikasi tingkat kematangan pisang. Tahapan penelitian ditunjukkan pada Gambar 3.1 dan dijelaskan sebagai berikut.

Persiapan Dataset

Dataset yang digunakan pada aplikasi ini berjumlah 1865 gambar pisang cavendish yang terdiri dari 5 tingkat kematangan yaitu mentah, setengah matang, matang, terlalu matang. Pada pengumpulan dataset pisang cavendish data didapatkan dari website kaggle dengan spesifikasi gambar 250 x 250 piksel dalam format JPG. Visualisasi dataset seperti di gambar 3.14.



Gambar 2. Dataset Pisang Cavendish.

Pelabelan Data

Setiap citra diberi label sesuai kategori tingkat kematangan. Label terdiri dari mentah, setengah matang, matang, terlalu matang. Pelabelan dilakukan secara manual berdasarkan karakteristik visual.

Split Data

Setelah tahap pelabelan diselesaikan, dataset kemudian dibagi ke dalam tiga kelompok utama, yaitu data latih (training set), data validasi (validation set), dan data uji (testing set).

Pembagian ini dilakukan agar model Convolutional Neural Network (CNN) dapat dilatih secara maksimal sekaligus dievaluasi secara objektif menggunakan data yang sebelumnya belum pernah diproses oleh model. Dalam penelitian ini, dataset dibagi dengan proporsi 70% data latih, 15% data validasi, dan 15% data uji. Pembagian dilakukan secara acak (random splitting) dengan tetap menjaga distribusi jumlah data pada setiap kelas (stratified split), sehingga proporsi masing-masing kategori kematangan tetap seimbang di setiap subset data. .

Preprocessing Data

Tahap preprocessing dilakukan untuk menyiapkan data citra sebelum digunakan dalam proses pelatihan model Convolutional Neural Network (CNN). Proses ini bertujuan untuk meningkatkan kualitas data, menyeragamkan format input, serta membantu model dalam mengekstraksi fitur secara lebih optimal. Tahapan preprocessing yang dilakukan dalam penelitian ini meliputi:

a. Resize Citra

Seluruh citra diubah ukurannya menjadi resolusi yang seragam, yaitu 224×224 piksel, guna menyesuaikan dengan arsitektur model CNN yang digunakan. Penyeragaman ukuran diperlukan agar dimensi input konsisten selama proses pelatihan.

b. Normalisasi Nilai Piksel

Nilai piksel citra yang semula berada pada rentang 0–255 dinormalisasi ke rentang 0–1 dengan membagi setiap nilai piksel dengan 255. Proses ini bertujuan untuk mempercepat konvergensi model serta menjaga stabilitas proses pelatihan.

c. Data Augmentation

Untuk meningkatkan kemampuan generalisasi model sekaligus meminimalkan risiko overfitting, diterapkan teknik augmentasi data seperti rotasi, horizontal flipping, zooming, dan penyesuaian tingkat kecerahan. Proses augmentasi ini bertujuan agar model mampu mengenali berbagai variasi visual yang berpotensi muncul dalam kondisi nyata.

Training Model

Proses training dilakukan untuk melatih model Convolutional Neural Network (CNN) menggunakan data latih agar mampu mengenali pola tingkat kematangan pisang. Pembaruan bobot dilakukan melalui mekanisme forward propagation dan backpropagation. Model menggunakan fungsi aktivasi ReLU pada lapisan konvolusi dan Softmax pada lapisan keluaran untuk klasifikasi multi-kelas. Fungsi loss yang digunakan adalah categorical crossentropy, dengan optimasi menggunakan algoritma Adam. Pelatihan dilakukan selama 10, 20, 30, 40, 50 epoch dengan batch size 16 dan learning rate 0.001. Performa model dipantau menggunakan

data validasi untuk mencegah overfitting dan menentukan model terbaik sebelum tahap pengujian.

Pengujian Model

Tahapan pengujian dilaksanakan untuk menilai performa model Convolutional Neural Network (CNN) menggunakan data uji yang tidak dilibatkan dalam proses pelatihan. Pengujian ini bertujuan untuk mengukur kemampuan generalisasi model dalam mengklasifikasikan tingkat kematangan pisang pada data baru. Evaluasi performa dilakukan menggunakan metrik kuantitatif, yaitu accuracy, precision, recall, dan F1-score. Selain itu, confusion matrix digunakan untuk menganalisis distribusi kesalahan klasifikasi pada setiap kelas kematangan. Hasil pengujian tersebut digunakan sebagai acuan untuk mengevaluasi efektivitas arsitektur CNN yang telah dirancang serta mengukur tingkat keandalan model ketika diimplementasikan pada kondisi nyata.

4. HASIL DAN PEMBAHASAN


Penelitian ini melakukan pelatihan model Convolutional Neural Network (CNN) sebanyak lima skenario percobaan dengan variasi epoch 10, 20, 30, 40, dan 50 menggunakan batch size 16 dan learning rate 0.001. Hasil proses pelatihan menunjukkan kinerja yang sangat baik dalam mengklasifikasikan tingkat kematangan pisang.

Hasil Training Model

Tabel 1. Tabel hasil training model CNN.


Epoch	Batch	Learning Rate	Training Accuracy	Validation Accuracy	Training Loss	Validation Loss
10	16	0.001	0.99	0.97	0.01	0.065
20	16	0.001	0.99	0.985	0.018	0.09
30	16	0.001	0.99	0.99	0.01	0.02
40	16	0.001	1	0.99	0.001	0.1
50	16	0.001	1	0.99	0.001	0.108

Berdasarkan Tabel 4.1 peningkatan jumlah epoch berpengaruh terhadap peningkatan akurasi dan penurunan nilai loss.




Gambar 3. Grafik accuracy dan loss per epoch (10 epoch).

Pada epoch ke-10 diperoleh training accuracy sebesar 0.99 dan validation accuracy sebesar 0.97 seperti yang ter. Selisih keduanya kecil, sehingga menunjukkan kemampuan generalisasi yang baik. Nilai training loss sebesar 0.01 dan validation loss sebesar 0.065 juga tergolong rendah. Perbedaan loss yang masih wajar ini menandakan model telah belajar dengan baik tanpa indikasi overfitting. Secara keseluruhan, pada epoch ke-10 model sudah menunjukkan performa yang sangat baik dan stabil.




Gambar 4. Grafik accuracy dan loss per epoch (20 epoch).

Gambar 4.2 menunjukkan pada epoch ke-20, training accuracy tetap tinggi di 0.99 dan validation accuracy meningkat menjadi 0.985. Hal ini menunjukkan peningkatan kemampuan generalisasi dibanding epoch 10. Training loss sebesar 0.018 dan validation loss 0.09 masih tergolong rendah, meskipun validation loss sedikit lebih tinggi dari epoch 10. Secara umum, model masih belajar dengan baik tanpa indikasi overfitting yang signifikan.




Gambar 5. Grafik accuracy dan loss per epoch (30 epoch).

Pada epoch ke-30, validation accuracy mencapai 0.99, menyamai training accuracy 0.99. Ini menunjukkan performa optimal dan generalisasi yang sangat baik. Training loss turun menjadi 0.01 dan validation loss menurun signifikan menjadi 0.02. Grafik accuracy dan loss pada tahap ini menunjukkan keseimbangan terbaik antara performa dan stabilitas model.



Gambar 6. Grafik accuracy dan loss per epoch (40 epoch).

Pada epoch ke-40, training accuracy mencapai 1.00 sedangkan validation accuracy tetap 0.99. Namun, validation loss meningkat menjadi 0.10 meskipun training loss sangat kecil (0.001). Kenaikan validation loss ini mulai mengindikasikan gejala overfitting ringan, karena model semakin menyesuaikan diri dengan data latih.



Gambar 7. Grafik accuracy dan loss per epoch (50 epoch).

Pada epoch ke-50, pola serupa dengan epoch 40 masih terlihat. Training accuracy tetap 1.00 dan validation accuracy stagnan di 0.99. Training loss tetap sangat rendah (0.001), tetapi validation loss kembali meningkat menjadi 0.108. Hal ini memperkuat indikasi overfitting, karena tidak ada peningkatan akurasi validasi meskipun model semakin optimal pada data latih.

Secara keseluruhan, epoch ke-30 dapat dianggap sebagai titik optimal karena memberikan validation accuracy tinggi dengan validation loss paling rendah sebelum muncul tanda-tanda overfitting pada epoch 40 dan 50.


Secara umum, tren grafik menunjukkan:

- Accuracy meningkat secara konsisten seiring bertambahnya epoch.
- Training loss dan validation loss menurun secara paralel pada epoch awal.

- c. Kesenjangan antara training dan validation relatif kecil, menunjukkan generalisasi yang baik.

Epoch ke-30 memberikan keseimbangan terbaik antara akurasi tinggi dan loss yang rendah, sehingga dipilih sebagai model optimal.

Analisis Performa Model



Gambar 8. Confusion Matrix.

Dari confusin matrix pada gambar 4.6 dapat dapat dilakukan penghitungan Precision, Recall dan F1-Score untuk menganalisis performa model pada tiap kelas. Rumus yang digunakan adalah sebagai berikut :

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP})$$

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN})$$

$$\text{F1-Score} = 2 \times (\text{Precision} \times \text{Recall}) / (\text{Precision} + \text{Recall})$$

Keterangan:

- **TP (True Positive):** data kelas tersebut yang diprediksi benar
- **FP (False Positive):** data kelas lain yang salah diprediksi sebagai kelas tersebut
- **FN (False Negative):** data kelas tersebut yang salah diprediksi sebagai kelas lain

Berikut Adalah perhitungan untuk tiap kelas.

a. Kelas Matang

$$\text{TP} = 42$$

$$\text{FP} = 1 \text{ (dari Terlalu Matang} \rightarrow \text{Matang)}$$

$$\text{FN} = 3 \text{ (Matang} \rightarrow \text{Terlalu Matang)}$$

$$\text{Precision} = 42 / (1 + 42) = 0.977$$

$$\text{Recall} = 42 / (3 + 42) = 0.933$$

$$\text{F1} = 2 \times (0.977 \times 0.933) / (0.977 + 0.933) = 0.955$$

b. Kelas Mentah

$$TP = 74$$

$$FP = 0$$

$$FN = 0$$

$$\text{Precision} = 74 / (0 + 74) = 1.00$$

$$\text{Recall} = 74 / (0 + 74) = 1.00$$

$$F1=1.00$$

c. Kelas Setengah Matang

$$TP = 91$$

$$FP = 0$$

$$FN = 0$$

$$\text{Precision} = 91 / (0 + 91) = 1.00$$

$$\text{Recall} = 91 / (0 + 91) = 1.00$$

$$F1=1.00$$

d. Kelas Setengah Matang

$$TP = 71$$

$$FP = 3 \text{ (Matang} \rightarrow \text{Terlalu Matang)}$$

$$FN = 1 \text{ (Terlalu Matang} \rightarrow \text{Matang)}$$

$$\text{Precision} = 71 / (3 + 71) = 0.959$$

$$\text{Recall} = 71 / (1 + 71) = 0.986$$

$$F1=2 \times (0.959 \times 0.986) / (0.959 + 0.986) = 0.972$$

Dari Hasil perhitungan tersebut menghasilkan tabel matrix evaluasi seperti pada tabel 4.2 berikut.

Tabel 2. Tabel Matrix Evaluasi.

Kelas	Precision	Recall	F1-Score
Matang	0.977	0.933	0.955
Mentah	1	1	1
Setengah Matang	1	1	1
Terlalu Matang	0.959	0.986	0.972

Tabel tersebut menunjukkan model Convolutional Neural Network (CNN) menunjukkan kemampuan klasifikasi yang sangat baik terhadap empat tingkat kematangan pisang yaitu Mentah, Matang, Setengah Matang, dan Terlalu Matang. Mayoritas sampel pada setiap kelas

berhasil diklasifikasikan dengan benar, dengan tingkat kesalahan yang sangat rendah. Kesalahan klasifikasi hanya terjadi antara kelas Matang dan Terlalu Matang, di mana beberapa sampel Matang diprediksi sebagai Terlalu Matang dan sebaliknya. Hal ini wajar karena kedua kelas memiliki kemiripan visual, terutama dari segi warna kulit dan tekstur, sehingga batas antar kelas relatif tipis. Hasil evaluasi menggunakan metrik Precision, Recall, dan F1-Score memperkuat temuan tersebut. Kelas Mentah dan Setengah Matang memperoleh nilai sempurna (1.00) pada seluruh metrik, menunjukkan bahwa pola visual kedua kelas sangat jelas dan konsisten sehingga mudah dikenali oleh model. Sementara itu, kelas Matang (Precision 0.977; Recall 0.933; F1-Score 0.955) dan Terlalu Matang (Precision 0.959; Recall 0.986; F1-Score 0.972) menunjukkan performa yang tetap sangat tinggi meskipun terdapat kesalahan minor. Nilai F1-Score seluruh kelas berada di atas 0.95, menandakan keseimbangan yang sangat baik antara ketepatan prediksi (precision) dan kelengkapan deteksi (recall). Secara keseluruhan, model CNN memiliki akurasi dan kemampuan generalisasi yang sangat baik dalam klasifikasi multi-kelas. Kesalahan yang terjadi bersifat minor dan masih dalam batas wajar, serta berpotensi diminimalkan melalui peningkatan kualitas dataset atau proses fine-tuning. Dengan performa tersebut, model layak diimplementasikan sebagai sistem klasifikasi otomatis tingkat kematangan pisang.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian, model Convolutional Neural Network (CNN) yang dikembangkan mampu mengklasifikasikan tingkat kematangan pisang (Mentah, Setengah Matang, Matang, dan Terlalu Matang) dengan performa yang sangat baik. Performa optimal diperoleh pada epoch ke-30 dengan validation accuracy mencapai 0.99 dan validation loss sebesar 0.02. Hasil evaluasi menunjukkan sebagian besar data berhasil diklasifikasikan dengan benar, dengan kesalahan minor hanya terjadi antara kelas Matang dan Terlalu Matang yang memiliki kemiripan visual. Nilai Precision, Recall, dan F1-Score yang tinggi pada seluruh kelas menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan layak digunakan sebagai sistem klasifikasi otomatis.

Untuk pengembangan lebih lanjut, disarankan menambah variasi dan jumlah dataset, khususnya pada kelas yang memiliki kemiripan visual, serta melakukan fine-tuning arsitektur model untuk meningkatkan performa. Selain itu, model dapat dikembangkan ke dalam bentuk aplikasi berbasis web atau mobile dan diuji pada kondisi lapangan nyata guna memastikan keandalannya dalam penggunaan praktis.

DAFTAR REFERENSI

- Angginy Akhirunnisa Siregar, C., Citra, C., Dechy Deswita Indriani, S., & Gifari Dhaffa Prawira Sianturi, G. D. P. (2023). Klasifikasi batik parang menggunakan convolutional neural network (CNN). *Populer: Jurnal Penelitian Mahasiswa*, 3(1), 62–69. <https://doi.org/10.58192/populer.v3i1.1666>
- Cholissodin, I., & Soebroto, A. A. (2021). *AI, machine learning & deep learning (Teori & implementasi)*.
- Chyan, P., Arni, S., & Thayf, M. S. S. (n.d.). *Pengantar machine learning*. PT Mifandi Mandiri Digital.
- Danang, D., & Mustofa, Z. (2026). Digital forensics and automated incident response framework leveraging big data analytics and real-time network traffic profiling in heterogeneous cyber environments. *Cyber Security and Network Management*, 1(1), 44–45.
- Danang, D., Dianta, I. A., Santoso, A. B., & Kholifah, S. (2025). Hybrid CNN-GRU framework for early detection and adaptive mitigation of DDoS attacks in SDN using image-based traffic analysis. *International Journal of Information Engineering and Science*, 2(2), 66–78. <https://doi.org/10.62951/ijies.v2i2.292>
- Dhia Yusrana, R., Yukandri, Y., Nurdin, N., Handrianus Pranatawijaya, V., & Noor Kamala Sari, N. (2024). Implementasi kecerdasan buatan dalam pengembangan aplikasi mobile Binarytalkhub. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(4), 6075–6081. <https://doi.org/10.36040/jati.v8i4.10066>
- Faiza, I. M., Gunawan, G., & Andriani, W. (2022). Tinjauan pustaka sistematis: Penerapan metode machine learning untuk deteksi bencana banjir. *Jurnal Minfo Polgan*, 11(2), 59–63. <https://doi.org/10.33395/jmp.v11i2.11657>
- Gakkaishi, N. S. (2023). 開会の挨拶（中山理事長）風藤シラスウナギ生産部長. 11(3), 82–85.
- Hastungkoro, A. W., Putro Wicaksono, A. D., & Diah Rosita, Y. (2024). Klasifikasi kualitas dan kematangan pisang Cavendish menggunakan convolutional neural network. *Jurnal SAINTEKOM*, 14(2), 185–194. <https://doi.org/10.33020/saintekom.v14i2.686>
- Maulana, I., Khairunisa, N., & Mufidah, R. (2024). Deteksi bentuk wajah menggunakan convolutional neural network (CNN). *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(6), 3348–3355. <https://doi.org/10.36040/jati.v7i6.8171>
- Mustafa, M. (2023). Understanding of machine learning with deep learning. *Computers (MDPI)*, 12(91), 1–26. <https://doi.org/10.3390/computers12050091>
- Muzakir, A., Adi, K., & Kusumaningrum, R. (2024). *Penerapan konsep machine learning & deep learning*.
- Putri Ananda, T., Viola Widyasari, S., Ihsan Muttaqin, M., & Stefanie, A. (2023). Identifikasi tingkat kematangan buah pepaya menggunakan metode convolutional neural network (CNN). *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(3), 2094–2097. <https://doi.org/10.36040/jati.v7i3.7137>
- Radikto, Mulyana, D. I., Rofik, M. A., & Zakaria, M. O. Z. (2022). Klasifikasi kendaraan pada jalan raya menggunakan algoritma convolutional neural network (CNN). *Jurnal Pendidikan Tambusai*, 6(1), 1668–1679.
- Retnoningsih, E., & Pramudita, R. (2020). Mengenal machine learning dengan teknik supervised dan unsupervised learning menggunakan Python. *Bina Insani ICT Journal*, 7(2), 156–164. <https://doi.org/10.51211/biict.v7i2.1422>
- Setiyani, L., Indahsari, A. N., & Roestam, R. (2023). Analisis prediksi level obesitas menggunakan perbandingan algoritma machine learning dan deep learning. *JTERA*

(*Jurnal Teknologi Rekayasa*), 8(1), 139–146.
<https://doi.org/10.31544/jtera.v8.i1.2022.139-146>

Sirappa, M. P. (2021). Potensi pengembangan tanaman pisang: Tinjauan syarat tumbuh dan teknik budidaya pisang dengan metode BIT. *AgroSainT*, 12(2), 54–65.