



KLASIFIKASI TINGKAT KEMATANGAN PADA BUAH KELAPA SAWIT BERBASIS DEEP LEARNING

Aisah Rahmawati¹, Muhamad Akbar², Deni Nurdiansyah³

^{1,3}Program Studi Rekayasa Sistem Komputer, Universitas Bina Insan, Lubuklinggau

²Program Studi Informatika, Universitas Bina Insan, Lubuklinggau

e-mail: *¹aisahrahmawati011@gmail.com, ²muhamad.akbar@univbinainsan.ac.id,
³deninurdiansyah@univbinainsan.ac.id

Abstrak

Menentukan tingkat kematangan buah kelapa sawit merupakan hal krusial dalam proses panen guna memastikan kualitas dan produktivitas hasil. Penelitian ini bertujuan mengevaluasi kinerja algoritma *Convolutional Neural Network* (CNN) dalam mengklasifikasikan gambar buah kelapa sawit menjadi matang dan mentah. Dataset berisi gambar buah dengan berbagai kondisi pencahayaan dan sudut pengambilan. Model CNN memberikan akurasi keseluruhan sebesar *91.75%* pada data uji. Untuk kelas buah matang, model mencapai *precision 97%, **recall 94%, dan **F1-score 95%. Sementara itu, untuk kelas buah mentah, model mencapai **precision 78%, **recall 87%, dan **F1-score 83%*. Hasil ini menunjukkan bahwa pendekatan berbasis CNN dapat menjadi solusi efisien dalam meningkatkan akurasi dan efisiensi proses sortasi buah kelapa sawit.

Kata kunci—Klasifikasi; Deep Learning; CNN; Kelapa Sawit .

Abstract

*Determining the ripeness level of oil palm fruit is crucial in the harvesting process to ensure the quality and productivity of the yield. This study aims to evaluate the performance of the Convolutional Neural Network (CNN) algorithm in classifying oil palm fruit images into ripe and unripe categories. The dataset consists of images of fruits captured under various lighting conditions and angles. The CNN model achieved an overall accuracy of 91.75% on the test data. For the ripe fruit class, the model attained a precision of 97%, **recall of 94%, and F1-score of 95%.** Meanwhile, for the unripe fruit class, the model achieved a **precision of 78%, recall of 87%, and F1-score of 83%.** These results indicate that the CNN-based approach can be an efficient solution for improving the accuracy and efficiency of the oil palm fruit sorting process.*

Keywords— Classification; Deep Learning; CNN; Palm Oil.

I. PENDAHULUAN

Indonesia, dengan kondisi iklim tropisnya, menjadi salah satu negara yang sangat mendukung pertumbuhan tanaman perkebunan, termasuk kelapa sawit. Kelapa sawit (*Elaeis guineensis*) merupakan tanaman perkebunan yang memiliki nilai ekonomi tinggi, terutama sebagai sumber bahan baku untuk berbagai industri seperti makanan,

kosmetik, dan biofuel. Indonesia, bersama dengan Malaysia dan Thailand, merupakan negara penghasil minyak sawit terbesar di dunia[1][2]. Industri kelapa sawit juga memiliki peran strategis dalam meningkatkan kesejahteraan petani mandiri, menciptakan lapangan kerja, dan meningkatkan devisa negara [3][4].

Tanaman kelapa sawit mulai menghasilkan buah setelah berusia dua



hingga tiga tahun, dengan masa matang buah sekitar lima hingga enam bulan setelah penyerbukan. Proses pematangan buah kelapa sawit ditandai dengan perubahan warna kulit buah. Ketika buah matang, warna kulitnya berubah menjadi merah jingga kehitaman, yang menandakan kandungan minyak pada buah mencapai tingkat optimal. Sebaliknya, buah yang terlalu matang akan jatuh dari tandan, mengakibatkan penurunan kualitas dan kuantitas panen [5].

Dalam praktik tradisional, penentuan tingkat kematangan buah sawit biasanya dilakukan secara visual oleh pekerja berpengalaman. Penilaian ini didasarkan pada warna kulit buah atau jumlah buah yang jatuh dari tandan. Namun, metode ini memiliki beberapa kelemahan, seperti bersifat subjektif, bergantung pada pengalaman pengamat, serta memakan waktu. Kesalahan dalam penilaian, seperti terangkutnya buah mentah yang tidak layak diolah, dapat menyebabkan kerugian bagi industri kelapa sawit [4][5].

Penelitian ini bertujuan untuk menghadirkan solusi alternatif bagi pengelola dan petani kelapa sawit dalam proses klasifikasi tingkat kematangan buah. Dengan memanfaatkan teknologi deep learning berbasis Convolutional Neural Network (CNN), diharapkan tingkat kematangan buah dapat ditentukan secara cepat, hemat biaya, dan dengan tingkat akurasi yang tinggi. Teknologi ini lebih akurat dan objektif dibandingkan metode konvensional yang bergantung pada pengamatan visual, yang seringkali dipengaruhi oleh kondisi psikologis pengamat [6].

Seiring perkembangan teknologi, deep learning telah banyak diterapkan dalam berbagai bidang, termasuk pertanian. Dalam

beberapa penelitian sebelumnya, teknologi ini telah digunakan untuk klasifikasi tingkat kematangan buah kelapa sawit. Misalnya, penelitian oleh [7] yang menggunakan metode YOLO v4-Tiny berhasil mencapai akurasi 82,11%, meskipun masih memiliki kelemahan berupa akurasi yang perlu ditingkatkan. Penelitian lain oleh [8] menggunakan metode Multi-Layer Perceptron (MLP) dengan parameter warna untuk klasifikasi tandan buah segar (TBS), dengan akurasi sebesar 85,71%. Namun, kelemahan MLP adalah lambatnya proses konvergensi dan risiko terjebak dalam solusi lokal yang tidak optimal, yang dapat memengaruhi efektivitas model.

Berdasarkan latar belakang tersebut, penelitian ini dirancang untuk mengembangkan sistem klasifikasi tingkat kematangan buah kelapa sawit menggunakan metode deep learning berbasis CNN. CNN dipilih karena keunggulannya dalam mengenali pola dan menganalisis data citra secara efektif [3]. Sebagai bagian dari algoritma deep learning, CNN dirancang untuk menangani data dalam bentuk dua dimensi, seperti gambar, dan sangat cocok untuk tugas klasifikasi dengan data berlabel [9].

Penelitian ini berjudul **“Klasifikasi Tingkat Kematangan pada Buah Kelapa Sawit Berbasis Deep Learning”**, dengan harapan dapat memberikan kontribusi signifikan bagi industri kelapa sawit, terutama dalam meningkatkan efisiensi dan akurasi proses klasifikasi buah kelapa sawit.

II. METODOLOGI PENELITIAN

2.1 Metode Penelitian

Cross-Industry Standard Process for Data Mining (CRISP-DM), yang terdiri dari lima tahap: pemahaman bisnis, pemahaman data, pengolahan data, pemodelan, dan evaluasi

dan validasi. Tahapan penelitian ini dilakukan dengan menggunakan standar proses data mining ini[10].



Gambar 1. Model CRISP-DM[10].

- a. Fase Pemahaman Bisnis Dataset
Dataset penelitian ini berasal dari data publik yang diunduh dari *Zenodo* tentang kematangan buah kelapa sawit.
- b. Fase Pemahaman Data
Dataset tersebut terdiri atas dua kelas yaitu kelas mentah dan matang.
- c. Fase Pengolahan Data
Pada tahap ini dilakukan Pembersihan data, data yang tidak digunakan oleh peneliti akan dihapus, sehingga dataset hanya terdiri dari dua kelas : Sawit mentah dan sawit matang
- d. Fase Pemodelan
Peneliti menggunakan metode CNN untuk membangun model prediksi berbasis citra yang dapat mengklasifikasi gambar kelapa sawit kedalam dua kelas utama : sawit mentah dan sawit matang.
- e. Fase Evaluasi
Pada fase ini dilakukan pengukuran performa model dengan menggunakan teknik *Confussion Matrix*

2.2 Metode Pengumpulan Data

Penelitian ini menggunakan teknik pengumpulan data yang bertujuan untuk memperoleh informasi yang dibutuhkan dalam menyusun skripsi ini. Teknik ini dipilih untuk menganalisis kinerja sistem sehingga perangkat lunak yang dihasilkan lebih optimal dan akurat. Data yang digunakan dalam penelitian ini berupa gambar buah kelapa sawit yang dikategorikan dalam dua tingkat kematangan, yaitu mentah

dan matang. Berikut adalah langkah-langkah pengumpulan data yang dilakukan:

a. Sumber Data

Dataset yang digunakan dalam penelitian ini diperoleh dari beberapa sumber daring. Salah satu sumber utamanya adalah Zenodo melalui <https://zenodo.org/records/11114885>, yang dikembangkan oleh Zaid Omar, Anwar P.P. Abdul Majeed, Munirah Rosbi, Shuwaibatul Aslamiah Ghazalli, dan Hazlina Selamat, serta diterbitkan dalam *Data in Brief*. Dataset tambahan juga diperoleh dari platform Kaggle, yaitu <https://www.kaggle.com/datasets/hasantayouji/palm-oil/data>, yang dipublikasikan oleh Hasan Tayouji. Kombinasi dari ketiga sumber ini memberikan variasi data yang memadai untuk mendukung penelitian tentang tingkat kematangan buah kelapa yang sawit.

b. Persiapan Dataset

Dataset digunakan dalam penelitian ini telah melalui proses pembersihan data yang teliti untuk memastikan kualitas dan kesesuaian data dengan fokus penelitian.

c. Pembersihan Dataset

Dataset yang digunakan berasal dari berbagai sumber daring, yaitu Zenodo melalui <https://zenodo.org/records/11114885>, dan dataset tambahan dari <https://www.kaggle.com/datasets/hasantayouji/palm-oil/data>.

- 1) Dataset dari Zenodo terdiri dari lima kelas, yaitu: Gumpalan Kosong, Gumpalan Rusak, Mentah, Belum Matang, dan Berlebihan. Dalam proses pembersihan, kelas Gumpalan Kosong, Gumpalan Rusak, dan Berlebihan dihapus, sehingga hanya dua kelas yang



dipertahankan, yaitu Mentah dan Matang.

- 2) Dataset dari Kaggle memiliki enam kelas, yaitu: Janjangan Kosong, Mentah, Matang, Abnormal, Terlalu Matang, dan Kurang Matang. Kelas yang dipertahankan dalam proses pembersihan adalah Matang dan Mentah, sementara kelas lainnya dihapus.

Proses pembersihan ini dilakukan untuk menyelaraskan data dari berbagai sumber dan memastikan fokus penelitian pada dua kelas utama, yaitu Mentah dan Matang. Dengan demikian, penelitian ini dapat fokus pada analisis tingkat kematangan buah kelapa sawit secara lebih efektif.

3.3 Metode Pengujian Sistem

Confusion matrix multiclass adalah metode yang digunakan untuk mengukur kemampuan sistem dalam mengklasifikasikan data terstruktur dengan membandingkan nilai prediksi dengan nilai aktual, yang menghasilkan nilai akurasi [4].

Metode confusion matrix multiclass menggunakan empat istilah untuk menggambarkan hasil klasifikasi sebagai berikut:

- **TP (True Positive):** Data positif yang terklasifikasi benar oleh sistem.
- **TN (True Negative):** Data negatif yang terklasifikasi benar oleh sistem.
- **FP (False Positive):** Data negatif yang terklasifikasi sebagai positif oleh sistem.
- **FN (False Negative):** Data positif yang terklasifikasi sebagai negatif oleh sistem [4].

Gambar 2. *Confusion Matrix*[4].

Penjelasan mengenai Confusion Matrix:

- **True Positive (TP):** Gambar yang benar-benar matang dan diprediksi matang oleh model.
- **False Negative (FN):** Gambar yang benar-benar matang tetapi diprediksi mentah oleh model.
- **False Positive (FP):** Gambar yang sebenarnya mentah tetapi diprediksi matang oleh model.
- **True Negative (TN):** Gambar yang benar-benar mentah dan diprediksi mentah oleh model.

a. Accuracy

Accuracy mengukur seberapa akurat model dapat mengklasifikasi data dengan benar. Dengan kata lain, accuracy adalah rasio prediksi yang benar (positif dan negatif) dibandingkan dengan keseluruhan data. Nilai accuracy dapat dihitung dengan menggunakan persamaan berikut[4].

$$\text{accuracy} = \frac{\text{TP} + \text{TN}}{\text{FP} + \text{FN} + \text{TP} + \text{TN}}$$

b. Precision (Positive Predictive Value)

Precision (*Positive Predictive Value*) adalah ukuran keakuratan antara data yang diminta dan hasil prediksi model. Precision menunjukkan rasio prediksi benar positif dibandingkan dengan keseluruhan hasil yang diprediksi positif. Dengan kata lain, berapa banyak data yang benar-benar positif dari semua kelas yang diprediksi sebagai positif. Persamaan untuk menghitung precision adalah sebagai berikut[4].

Precision

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

c. Recall (True Positive Rate)

Recall menunjukkan seberapa baik model menemukan kembali informasi. Jadi, recall adalah rasio prediksi benar positif dibandingkan dengan keseluruhan data benar positif. Nilai recall dapat ditemukan dengan menggunakan persamaan berikut[4].

$$\text{recall} = \frac{TP}{TP+FN}$$


d. F-1 Skor

Skor F-1 menunjukkan perbandingan precision dan recall yang dibobotkan rata-rata. Jika dataset memiliki jumlah dataset data false negatif dan false positif yang sangat mirip, kita menggunakan akurasi tepat sebagai acuan untuk performansi algoritma. Akibatnya, skor F-1 adalah referensi yang tepat[4].

$$F1 - \text{score} = 2x = \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

$$= \frac{2TP}{2TP + FP + FN}$$

2.4 Rancangan Sistem



Gambar 3. Tahap rancangan sistem[10].

III. HASIL DAN PEMBAHASAN

3.1 Hasil Penelitian

3.1.1 Hasil Dataset Pelatihan

- a. Dataset yang digunakan dalam penelitian ini bertujuan untuk mengklasifikasikan tingkat kematangan

buah kelapa sawit dengan memanfaatkan gambar sebagai data utama. Gambar-gambar dalam dataset tersebut menunjukkan kondisi buah kelapa sawit pada dua kategori utama, yaitu *Unripe* (mentah) dan *Ripe* (matang). Pada dataset pelatihan, label *Train Unripe* digunakan untuk menandai buah kelapa sawit dalam kondisi mentah.

Pada tahap pelatihan, model CNN (*Convolutional Neural Network*) dilatih untuk mengenali pola-pola visual yang terdapat pada gambar, seperti warna dan tekstur. Pola visual ini merupakan karakteristik penting yang membedakan kondisi mentah (*Unripe*) dari kondisi matang (*Ripe*). Dengan proses ini, model CNN dapat mempelajari dan mengidentifikasi ciri-ciri visual yang terkait dengan tingkat kematangan buah kelapa sawit.




Gambar 4. Hasil label kelapa sawit *unripe*

- b. Dataset yang digunakan dalam penelitian ini bertujuan untuk mengklasifikasikan tingkat kematangan buah kelapa sawit berdasarkan gambar. Salah satu kategori utama adalah *Train Ripe* (matang), yang menunjukkan buah kelapa sawit dalam kondisi matang. Dataset pelatihan terdiri dari dua kelas utama, yaitu *Train Ripe* (matang) dan *Train Unripe* (mentah). Pada gambar dalam kategori ini, label yang digunakan adalah *Train Ripe*, yang menandakan bahwa buah kelapa sawit



dalam gambar memiliki karakteristik visual khas buah matang.

Visualisasi dataset dilakukan sebagai bagian dari eksplorasi awal untuk memastikan bahwa gambar telah sesuai dengan label yang diberikan. Validasi ini penting untuk memastikan keakuratan anotasi data, sehingga proses pelatihan model klasifikasi dapat berjalan dengan baik. Pada gambar-gambar dalam kategori matang, karakteristik visual utama yang diamati meliputi warna merah kehitaman dan tekstur buah yang terlihat padat. Ciri-ciri ini menjadi indikator penting yang membedakan kategori matang dari kategori lainnya.



Gambar 5. Hasil Label buah kelapa sawit Ripe

3.1.2 Evaluasi Model

a. Akurasi

Proses pelatihan model CNN dilakukan selama 20 *epoch* menggunakan perangkat CPU. Tabel hasil pelatihan menampilkan peningkatan akurasi pelatihan yang signifikan dan penurunan nilai *loss* secara bertahap. Pada *epoch* pertama, akurasi pelatihan dimulai dari 59.57% dengan nilai *loss* sebesar 3.7652. Akurasi model terus meningkat hingga mencapai 100% pada *epoch* ke-7, dan stabil di angka tersebut hingga *epoch* terakhir. Nilai *loss* juga menurun secara konsisten hingga mencapai 0.0001 pada *epoch* ke-20, menunjukkan model telah berhasil mempelajari data pelatihan dengan baik. Hasil akhir menunjukkan akurasi pengujian sebesar 91.75%, yang menggambarkan kemampuan

generalisasi model terhadap data baru. Detail hasil pelatihan ditampilkan pada Gambar 6 di bawah ini.

Epoch	Training Loss	Validation Loss	Training Accuracy	Validation Accuracy
1	3.7652	3.7652	0.5957	0.5957
2	3.7652	3.7652	0.5957	0.5957
3	3.7652	3.7652	0.5957	0.5957
4	3.7652	3.7652	0.5957	0.5957
5	3.7652	3.7652	0.5957	0.5957
6	3.7652	3.7652	0.5957	0.5957
7	3.7652	3.7652	0.5957	0.5957
8	3.7652	3.7652	0.5957	0.5957
9	3.7652	3.7652	0.5957	0.5957
10	3.7652	3.7652	0.5957	0.5957
11	3.7652	3.7652	0.5957	0.5957
12	3.7652	3.7652	0.5957	0.5957
13	3.7652	3.7652	0.5957	0.5957
14	3.7652	3.7652	0.5957	0.5957
15	3.7652	3.7652	0.5957	0.5957
16	3.7652	3.7652	0.5957	0.5957
17	3.7652	3.7652	0.5957	0.5957
18	3.7652	3.7652	0.5957	0.5957
19	3.7652	3.7652	0.5957	0.5957
20	3.7652	3.7652	0.5957	0.5957

Gambar 6. Tabel Hasil Pelatihan Model CNN dan Akurasi Pengujian

b. Confusion Matrix

Pada proses evaluasi model, digunakan *confusion matrix* untuk mengukur performa klasifikasi model pada dataset pengujian. *Confusion matrix* memberikan informasi mengenai jumlah prediksi benar dan salah yang dilakukan oleh model terhadap masing-masing kelas. Hasil evaluasi tersebut ditampilkan pada Gambar 7.

	precision	recall	f1-score	support
Matang	0.78	0.87	0.83	206
Mentah	0.97	0.94	0.95	734
accuracy			0.92	1000
macro-avg	0.87	0.91	0.89	1000
weighted avg	0.91	0.92	0.93	1000

	Actual: Matang	Actual: Mentah
Predict: Matang	180 (TP)	25 (FP)
Predict: Mentah	50 (FN)	100 (TN)

Gambar 7. Confusion Matrix Hasil Pengujian Model CNN

confusion matrix digunakan untuk mengevaluasi hasil prediksi model dalam mengklasifikasikan tingkat kematangan buah kelapa sawit, yaitu kategori Matang dan Mentah. Hasil *confusion matrix* menunjukkan distribusi sebagai berikut:

- 1) *True Positive* (TP): Sebanyak 180 gambar dengan label sebenarnya Matang diprediksi dengan benar sebagai Matang.



- 2) *False Negative* (FN): Sebanyak 26 gambar dengan label sebenarnya Matang diprediksi secara salah sebagai Mentah.
- 3) *False Positive* (FP): Sebanyak 50 gambar dengan label sebenarnya Mentah diprediksi secara salah sebagai Matang.
- 4) *True Negative* (TN): Sebanyak 744 gambar dengan label sebenarnya Mentah diprediksi dengan benar sebagai Mentah.

c. Evaluasi Model Berdasarkan Metrik *Precision*, *Recall*, *F1-Score*, dan *Accuracy*

Pengujian model *Convolutional Neural Network* (CNN) dilakukan dengan menggunakan metrik ketepatan, *recall*, skor *f1*, dan ketepatan. Metrik ini digunakan untuk mengevaluasi kemampuan model untuk mengklasifikasikan gambar buah kelapa sawit mentah dan matang secara akurat. Hasil evaluasi model dapat dijelaskan sebagai berikut:

a. **Precision**

- 1) Precision mengukur proporsi prediksi positif yang benar terhadap seluruh prediksi positif. Dengan kata lain, precision menunjukkan seberapa tepat model dalam membuat prediksi positif.
- 2) Nilai Precision pada Klasifikasi:
 - a) Matang: 0.78 (78% dari prediksi Matang adalah benar)
 - b) Mentah: 0.97 (97% dari prediksi Mentah adalah benar)

b. **Recall**

- 1) Recall mengukur kemampuan model untuk mendeteksi semua data positif yang benar. Dengan kata lain, recall adalah sensitivitas model dalam menangkap seluruh contoh positif.
- 2) Nilai Recall pada Klasifikasi:

- a) Matang: 0.87 (Model dapat mendeteksi 87% dari seluruh data sebenarnya Matang)
- b) Mentah: 0.94 (Model dapat mendeteksi 94% dari seluruh data sebenarnya Mentah)

c. **F1-Score**

- 1) *F1-Score* adalah rata-rata harmonik dari *precision* dan *recall*, yang memberikan keseimbangan antara keduanya. *F1-score* berguna jika terdapat ketidakseimbangan data.
- 2) Nilai *F1-Score* pada Klasifikasi:
 - a) Matang: 0.83
 - b) Mentah: 0.95

d. **Accuracy**

- 1) *Accuracy* adalah proporsi prediksi yang benar (baik positif maupun negatif) terhadap total keseluruhan data.
- 2) **Akurasi Model:** 0.92 (Model memiliki tingkat akurasi 92%).

e. **Macro Average**

- 1) Rata-rata *precision*, *recall*, dan *F1-score* dari kedua kelas tanpa mempertimbangkan jumlah data di setiap kelas.
- 2) *Macro average* menunjukkan performa rata-rata dari model untuk semua kelas secara merata.

f. **Weighted Average**

- 1) Rata-rata *precision*, *recall*, dan *F1-score* yang memperhitungkan jumlah data di setiap kelas.
- 2) *Weighted average* lebih relevan jika dataset memiliki distribusi yang tidak seimbang.

3.1.3 Perbandingan penelitian sebelumnya

Penelitian ini membandingkan beberapa metode dan pendekatan yang digunakan dalam klasifikasi tingkat



kematangan buah kelapa sawit, mulai dari metode berbasis CNN, YOLO V5, hingga ResNet 50. Berikut adalah hasil perbandingan metode yang diimplementasikan dalam penelitian-penelitian sebelumnya:

1. **Klasifikasi Tingkat Kematangan Buah Kelapa Sawit Berbasis Deep Learning Menggunakan CNN**

Penelitian ini menggunakan model CNN dengan dataset berjumlah 1.000 gambar yang diklasifikasikan ke dalam dua kelas, yaitu matang dan mentah. Model ini berhasil mencapai akurasi sebesar 91,75%, precision 97%, recall 94%, dan F1-Score 95%. Keunggulan metode ini terletak pada pemanfaatan fitur visual spesifik dari gambar, yang sederhana namun akurat. Namun, kekurangannya adalah waktu komputasi yang relatif lama, terutama saat menggunakan CPU.

2. **Klasifikasi Tingkat Kematangan Buah Kelapa Sawit Berbasis Deep Learning dengan YOLO V5**

Penelitian ini menggunakan metode YOLO V5 dengan dataset berjumlah 1.500 gambar yang dikategorikan ke dalam tiga kelas, yaitu matang, mentah, dan busuk. Model ini mencapai mAP (mean Average Precision) sebesar 92%, precision 97%, dan recall 96%. Metode ini memiliki keunggulan pada kompleksitas algoritma yang mampu mencapai akurasi tinggi. Namun, metode ini membutuhkan GPU dan sumber daya komputasi yang besar, sehingga memerlukan perangkat keras yang lebih canggih.

3. **Klasifikasi Kematangan Tandan Buah Segar Kelapa Sawit (*Elaeis Guineensis* Jacq)**

Penelitian ini menggunakan metode Multi-Layer Perceptron (MLP) dengan dataset berjumlah 120 gambar tandan buah segar (TBS) yang

diklasifikasikan ke dalam tiga kelas, yaitu matang, mentah, dan setengah matang. Model ini mencapai akurasi sebesar 85,71%. Keunggulannya adalah kesederhanaan dan kecepatan proses pelatihan. Namun, kelemahannya adalah akurasi yang relatif rendah dibandingkan metode lain.

4. **Classification of Palm Oil Maturity Using CNN (Convolutional Neural Network) Modelling ResNet 50**

Penelitian ini menggunakan model ResNet 50 dengan dataset yang berjumlah 4.938 gambar, yang diklasifikasikan ke dalam tiga kelas, yaitu matang, mentah, dan terlalu matang. Model ini menghasilkan akurasi sebesar 97%, precision 96%, dan recall 98%. Keunggulan utama metode ini adalah kemampuannya dalam menghasilkan akurasi yang sangat tinggi untuk klasifikasi berbasis visual. Namun, metode ini memiliki kelemahan dalam hal kompleksitas dan membutuhkan perangkat keras dengan spesifikasi tinggi.

IV. KESIMPULAN

Penelitian ini menggunakan pendekatan deep learning berbasis *Convolutional Neural Network* (CNN) untuk mengembangkan cara untuk mengklasifikasikan tingkat kematangan buah kelapa sawit. Dengan menggunakan dataset gambar yang terdiri dari dua kategori, yaitu buah mentah dan matang, penelitian ini menunjukkan bahwa CNN lebih baik dalam mengekstraksi pola visual seperti warna, tekstur, dan bentuk dari data gambar, sehingga membuat prediksi yang akurat tentang tingkat kematangan buah.



Proses pelatihan model dilakukan selama 20 *epoch*, dengan hasil akurasi pelatihan 100% dan akurasi pengujian 91,75%. Hasil ini menunjukkan bahwa model yang dirancang memiliki tingkat generalisasi yang tinggi, yang memungkinkannya mengenali data baru yang belum pernah ditemukan sebelumnya. Selain itu, evaluasi performa model juga dilakukan menggunakan metrik akurasi, *recall*, *skor f1*, dan *matrix confusion*, yang menunjukkan bahwa model secara konsisten memberikan hasil yang dapat diandalkan untuk kedua jenis.

Metode ini tidak hanya meningkatkan efisiensi dan akurasi dibandingkan dengan metode manual tradisional, tetapi juga menawarkan peluang untuk diterapkan lebih luas dalam industri pertanian. Teknologi ini dapat membantu petani dan pengelola perkebunan menemukan waktu panen yang ideal, mengurangi kesalahan manusia, dan meningkatkan kuantitas dan kualitas hasil produksi. Selain itu, teknologi berbasis CNN yang digunakan dalam penelitian ini membuka peluang untuk pengembangan sistem otomatisasi berbasis teknologi yang dapat membantu operasi industri dan diintegrasikan dengan perangkat keras modern seperti drone atau kamera penginderaan.

V. SARAN

Berikut ini adalah beberapa saran yang dapat dipertimbangkan dalam penelitian lanjutan untuk meningkatkan kualitas dan aplikasi hasil penelitian:

- a. Peningkatan dataset : Tujuan dari peningkatan dataset adalah untuk meningkatkan jumlah gambar, variasi kondisi pencahayaan, sudut pengambilan gambar, dan latar belakang. Ini dilakukan untuk meningkatkan kemampuan model untuk mengidentifikasi pola pada data baru dan mencegah *overfitting*.

- b. Augmentasi data : Disarankan untuk menggunakan metode augmentasi data seperti rotasi, *flip*, perubahan pencahayaan, dan *cropping* untuk secara *artifisial* meningkatkan variasi dataset tanpa mengambil gambar tambahan.
- c. Optimalisasi *hyperparameter* : Studi lebih lanjut disarankan untuk mengatur *hyperparameter* seperti *learning rate*, *epoch amount*, dan *batch size*. Konfigurasi ideal yang dapat meningkatkan akurasi model dapat dicapai dengan menggunakan metode seperti pencarian *grid* atau pencarian random.
- d. Penggunaan perangkat keras yang lebih canggih : Penggunaan Perangkat keras berbasis grafik grafis akan sangat membantu dalam mempercepat proses pelatihan model. Dengan bantuan GPU, penelitian dapat mengeksplorasi model atau dataset yang lebih besar.
- e. Integrasi ke aplikasi lapangan: Hasil penelitian ini dapat digunakan untuk mengembangkan aplikasi berbasis perangkat lunak atau ponsel yang dapat digunakan langsung oleh petani atau pekerja lapangan untuk mengetahui tingkat kematangan buah kelapa sawit.
- f. Penerapan model pada skala industri: Penelitian ini dapat diperluas untuk mengklasifikasikan lebih banyak kategori kematangan atau buah-buahan lainnya, sehingga dapat memberikan manfaat langsung kepada sektor pertanian dalam skala yang lebih luas.

VI. DAFTAR PUSTAKA

- [1] K. Pengantar, "YAYASAN LEMBAGA PENDIDIKAN ISLAM DAERAH RIAU UNIVERSITAS ISLAM RIAU PENERAPAN DATA MINING UNTUK



- MENENTUKAN KUALITAS PRODUK MENTAH KELAPA SAWIT MENGGUNAKAN METODE NAIVE BAYES,” 2021.
- [2] J. Zulkarnain, Kusri, and T. Hidayat, “Klasifikasi Tingkat Kematangan Tandan Buah Segar Kelapa Sawit Menggunakan Pendekatan Deep Learning,” *JST (Jurnal Sains dan Teknol.*, vol. 12, no. 3, pp. 748–758, 2024, doi: 10.23887/jstundiksha.v12i3.59140.
- [3] T. Sistematis, “G-Tech : Jurnal Teknologi Terapan,” vol. 8, no. 4, pp. 2324–2333, 2024.
- [4] R. Kurniawan, A. T. Martadinata, and S. D. Cahyo, “Klasifikasi Tingkat Kematangan Buah Sawit Berbasis Deep Learning dengan Menggunakan Arsitektur Yolov5,” vol. 5, no. 1, pp. 302–309, 2023, doi: 10.47065/josh.v5i1.4408.
- [5] C. A. P. Itu, “No Title,” vol. 22, pp. 457–466, 2023.
- [6] N. I. Firdausi, “No 主観的健康感を中心とした在宅高齢者における健康関連指標に関する共分散構造分析Title,” *Kaos GL Derg.*, vol. 8, no. 75, pp. 147–154, 2020, [Online]. Available: <https://doi.org/10.1016/j.jnc.2020.125798%0Ahttps://doi.org/10.1016/j.smr.2020.02.002%0Ahttp://www.ncbi.nlm.nih.gov/pubmed/810049%0Ahttp://doi.wiley.com/10.1002/anie.197505391%0Ahttp://www.sciencedirect.com/science/article/pii/B9780857090409500205%0Ahttp://>
- [7] Z. Omar, A. P.P. Abdul Majeed, M. Rosbi, S. A. Ghazalli, and H. Selamat, “Outdoor oil palm fruit ripeness dataset,” *Data Br.*, vol. 55, pp. 1–7, 2024, doi: 10.1016/j.dib.2024.110667.
- [8] P. Studi, T. Pertanian, F. Pertanian, and U. S. Kuala, “Program Studi Teknik Pertanian, Fakultas Pertanian, Universitas Syiah Kuala,” vol. 8, pp. 437–445, 2023.
- [9] B. Yanto *et al.*, “Klasifikasi Tekstur Kematangan Buah Jeruk Manis Berdasarkan Tingkat Kecenderungan Warna dengan Metode Deep Learning Convolutional Neural Network,” pp. 259–268, 2021.
- [10] T. Wuriyanto, H. B. Setiawan, and A. B. Tjandrarini, “Penerapan Model CRISP-DM pada Prediksi Nasabah Kredit yang Berisiko Menggunakan Algoritma Support Vector Machine,” *J. Ilm. Scroll (Jendela Teknol. Informasi)*, vol. 10, no. 1, pp. 1–6, 2022, [Online]. Available: <https://univ45sby.ac.id/ejournal/index.php/informatika/article/view/291>