

Penerapan *ResNet50* untuk Klasifikasi Citra Buah Kelapa Sawit Berdasarkan Tingkat Kematangan

¹Hadiguna Setiawan, ²Handrie Noprisson, ³Abraham Cornelius Dachi, ⁴Ilim Hilimudin

^{1,2,3,4}Fakultas Teknik dan Informatika, Universitas Dian Nusantara

¹hadiguna.setiawan@dosen.undira.ac.id, ²handrie.noprisson@dosen.undira.ac.id,

³411211089@mahasiswa.undira.ac.id, ⁴411212109@mahasiswa.undira.ac.id

Article Info

Article history:

Received, 2026-01-26

Revised, 2026-01-29

Accepted, 2026-01-30

Kata Kunci:

kelapa sawit,
tingkat kematangan,
klasifikasi citra,
convolutional neural network,
ResNet50

ABSTRAK

Penentuan tingkat kematangan secara manual masih memiliki keterbatasan karena bersifat subjektif dan bergantung pada pengalaman pengamat. Oleh karena itu, penelitian ini bertujuan untuk menerapkan metode *deep learning* berbasis arsitektur *ResNet50* dalam mengklasifikasikan tingkat kematangan buah kelapa sawit menjadi tiga kelas, yaitu mentah, matang, dan terlalu matang. Dataset yang digunakan terdiri dari 1.350 citra buah kelapa sawit berwarna (RGB) yang dibagi menjadi data latih, validasi, dan uji dengan rasio 70:10:20. Seluruh citra diproses melalui penyeragaman ukuran 224×224 piksel dan normalisasi nilai piksel, serta augmentasi data pada data latih untuk meningkatkan kemampuan generalisasi model. *ResNet50* pralatin ImageNet digunakan sebagai *feature extractor* dan dilatih menggunakan optimizer Adam dengan *learning rate* 1×10^{-4} selama 50 *epoch*. Hasil eksperimen menunjukkan bahwa model mencapai akurasi sebesar 89,7% pada data latih dan 84,1% pada data validasi. Evaluasi menggunakan data uji menghasilkan akurasi sebesar 84,07%, dengan nilai rata-rata *precision*, *recall*, dan *F1-score* masing-masing sebesar 84,71%, 84,07%, dan 84,32%. Hasil tersebut menunjukkan bahwa penerapan *ResNet50* mampu memberikan kinerja yang baik dan stabil dalam mengklasifikasikan tingkat kematangan buah kelapa sawit.

ABSTRACT

Keywords:

oil palm fruit,
ripeness classification,
image classification,
convolutional neural network,
ResNet50

Manual ripeness assessment still has limitations as it is subjective and highly dependent on human expertise. Therefore, this study aims to apply a deep learning approach based on the ResNet50 architecture to classify oil palm fruit ripeness into three categories, namely unripe, ripe, and overripe. The dataset used in this study consists of 1,350 RGB images of oil palm fruits, which are divided into training, validation, and testing sets with a ratio of 70:10:20. All images are preprocessed by resizing them to 224×224 pixels and normalizing pixel values, while data augmentation is applied to the training set to improve model generalization. A pre-trained ResNet50 model on the ImageNet dataset is employed as a feature extractor and trained using the Adam optimizer with a learning rate of 1×10^{-4} for 50 epochs. Experimental results show that the model achieves an accuracy of 89.7% on the training data and 84.1% on the validation data. Evaluation on the testing data yields an accuracy of 84.07%, with average precision, recall, and F1-score values of 84.71%, 84.07%, and 84.32%, respectively. These results indicate that the proposed ResNet50-based model demonstrates good and stable performance in classifying oil palm fruit ripeness levels.

This is an open access article under the CC BY-SA license.



Penulis Korespondensi:

Hadiguna Setiawan,
Fakultas Teknik dan Informatika
Universitas Dian Nusantara, Indonesia
Email: hadiguna.setiawan@dosen.undira.ac.id

1. PENDAHULUAN

Kelapa sawit (*Elaeis guineensis*) merupakan salah satu komoditas unggulan yang memiliki peran penting dalam perekonomian Indonesia [1], [2], [3]. Industri kelapa sawit memberikan kontribusi terhadap sektor ekspor dan pendapatan negara [3], [4]. Namun, keberhasilan industri ini sangat bergantung pada kualitas hasil produksi minyak sawit, yang dipengaruhi oleh tingkat kematangan buah kelapa sawit [5]. Buah yang dipanen pada tingkat kematangan yang tepat akan menghasilkan minyak dengan kualitas yang lebih baik, sedangkan buah yang terlalu matang dapat menurunkan kualitas dan kuantitas produksi minyak sawit [6].

Penentuan tingkat kematangan buah saat ini masih dilakukan secara manual, yang memerlukan pengamatan visual yang mendalam dan keahlian khusus [7], [8]. Proses ini sering kali memakan waktu lama dan rentan terhadap kesalahan manusia, terutama di lahan perkebunan yang luas [9], [10], [11]. Hal ini dapat menyebabkan kesalahan dalam penentuan buah yang siap panen dan berpotensi merugikan petani dan industri secara keseluruhan. Oleh karena itu, dibutuhkan solusi yang dapat mengklasifikasikan buah kelapa sawit berdasarkan tingkat kematangan [1], [12].

Beberapa penelitian sebelumnya telah menerapkan metode *deep learning* untuk mengklasifikasikan tingkat kematangan buah kelapa sawit. Penelitian oleh Triyogi et al. (2023) menggunakan arsitektur *Convolutional Neural Network* berbasis *ResNet50* untuk mendekripsi tingkat kematangan buah kelapa sawit dengan jumlah dataset sebanyak 612 citra, dan menunjukkan bahwa arsitektur *deep CNN* mampu mengekstraksi fitur citra [13]. Selanjutnya, Aryadi et al. (2024) mengimplementasikan arsitektur Xception dalam menentukan tingkat kematangan tandan buah segar kelapa sawit, dengan menekankan keunggulan model dalam akurasi klasifikasi penggunaan sumber daya komputasi [14]. Penelitian lain oleh Afandy et al (2024) juga memanfaatkan metode CNN dengan *transfer learning* berbasis Xception untuk klasifikasi kematangan sawit, yang menunjukkan performa baik dalam menangani kompleksitas citra dan variasi visual buah [15]. Berdasarkan penelitian-penelitian tersebut, dapat disimpulkan bahwa pendekatan CNN dengan *transfer learning* memiliki potensi dalam klasifikasi kematangan kelapa sawit, sehingga penelitian ini memilih *ResNet50* sebagai model utama untuk mengevaluasi performanya dalam skenario dataset dan konfigurasi pelatihan yang berbeda.

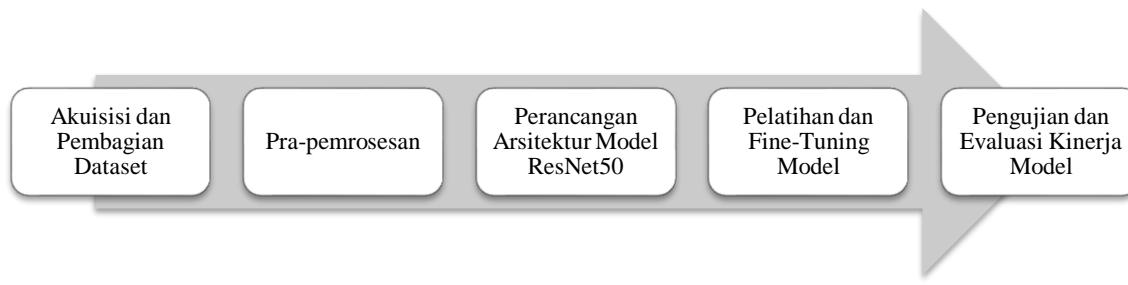
Salah satu solusi yang dapat diterapkan adalah dengan menggunakan teknologi *deep learning* dalam pengolahan citra. *Model deep learning ResNet50* merupakan salah satu arsitektur jaringan saraf yang telah diterapkan dalam berbagai tugas pengenalan citra. Melalui *transfer learning*, model ini dapat disesuaikan untuk mengklasifikasikan citra buah kelapa sawit ke dalam kategori tingkat kematangan. Dengan memanfaatkan model yang sudah dilatih sebelumnya pada dataset besar seperti *ImageNet*, diharapkan model dapat mencapai akurasi yang tinggi meskipun jumlah data yang tersedia terbatas.

Rumusan permasalahan dalam penelitian ini adalah bagaimana cara mengklasifikasikan citra buah kelapa sawit berdasarkan tingkat kematangan menggunakan model *ResNet50*, apa saja faktor yang mempengaruhi akurasi klasifikasi citra, serta sejauh mana model ini dapat mengklasifikasikan citra ke dalam tingkat kematangan yang telah ditentukan. Penelitian ini juga bertujuan untuk mengevaluasi kinerja model *ResNet50* dalam melakukan klasifikasi citra buah kelapa sawit, serta mengetahui apakah model ini dapat memberikan hasil yang konsisten dan akurat di berbagai kondisi citra yang berbeda.

Urgensi dari penelitian ini untuk meningkatkan akurasi dalam penentuan tingkat kematangan buah kelapa sawit. Sistem otomatis berbasis *deep learning* dapat menggantikan proses manual yang memakan waktu, meningkatkan konsistensi dalam pengambilan keputusan, serta mengurangi potensi kesalahan manusia. Selain itu, dengan menggunakan teknologi terkini seperti *deep learning*, penelitian ini dapat memberikan kontribusi besar terhadap inovasi dalam industri kelapa sawit, memaksimalkan hasil produksi minyak sawit, dan mendukung keberlanjutan industri dengan mengurangi pemborosan dan memaksimalkan pemanfaatan buah yang dipanen. Berbeda dengan penelitian sebelumnya, penelitian ini menggunakan dataset yang seimbang pada tiga kelas kematangan serta mengevaluasi kinerja *ResNet50* secara komprehensif menggunakan *confusion matrix* dan metrik evaluasi multikelas.

2. METODE PENELITIAN

Penelitian ini menggunakan 1.350 citra RGB buah kelapa sawit yang terbagi merata ke dalam tiga kelas tingkat kematangan, yaitu mentah, matang, dan terlalu matang, dengan pembagian data latih, validasi, dan uji masing-masing sebesar 70%, 10%, dan 20%. Seluruh citra dipra-pemrosesan dengan penyeragaman ukuran 224×224 piksel, normalisasi skala 1/255, serta augmentasi data pada data latih untuk meningkatkan keragaman dan mengurangi *overfitting*. Model klasifikasi dirancang menggunakan *ResNet50* pralatih *ImageNet* sebagai feature extractor dan dilatih melalui proses *fine-tuning* menggunakan *optimizer Adam* dengan *learning rate* 1×10^{-4} selama 50 epoch, kemudian dievaluasi menggunakan akurasi dan *confusion matrix*. Adapun alur penelitian dapat dilihat pada **Gambar 1**.



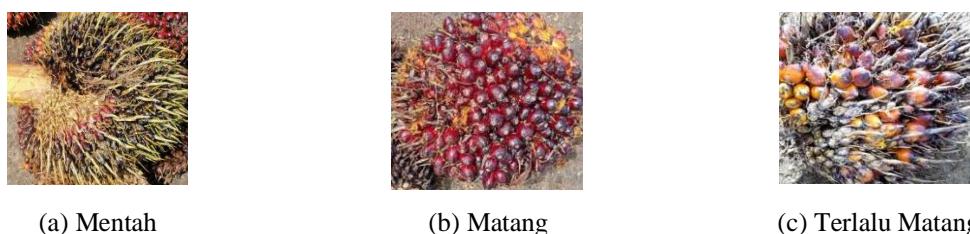
Gambar 1 Alur Penelitian

Tahap akuisisi dan pembagian dataset dialukan dengan pengumpulan citra digital buah kelapa sawit berwarna (RGB) yang merepresentasikan tiga tingkat kematangan, yaitu mentah, matang, dan terlalu matang. Dataset yang digunakan terdiri dari 1.350 citra dengan distribusi yang seimbang pada setiap kelas. Selanjutnya, dataset dibagi menjadi tiga subset, yaitu data latih (70%), data validasi (10%), dan data uji (20%). Pembagian ini bertujuan untuk proses pelatihan, validasi, dan pengujian model tidak bias terhadap data tertentu dengan komposisi seperti pada **Tabel 1**.

Tabel 1 Tabel Distribusi Dataset per Kelas dan *Subset*

Kelas	Train (70%)	Validation (10%)	Test (20%)	Total
Mentah	315	45	90	450
Matang	315	45	90	450
Terlalu matang	315	45	90	450
Total	945	135	270	1.350

Pada tahap pra-pemrosesan dan *augmentasi* citra, seluruh citra diseragamkan ke ukuran 224×224 piksel agar sesuai dengan spesifikasi input arsitektur *ResNet50*. Selain itu, dilakukan normalisasi nilai piksel dengan skala 1/255 untuk menyesuaikan rentang nilai input jaringan saraf. Contoh dataset yang dapat dilihat pada **Gambar 2**.



Gambar 2 Contoh Dataset Penelitian

Tahap perancangan model klasifikasi berbasis arsitektur *ResNet50* yang telah dilatih sebelumnya menggunakan dataset *ImageNet*. *ResNet50* digunakan sebagai *feature extractor* untuk mengekstraksi ciri penting dari citra buah kelapa sawit. Arsitektur ini memanfaatkan mekanisme skip connection pada *residual block* yang memungkinkan aliran gradien tetap stabil selama proses pelatihan, sehingga jaringan dengan kedalaman yang lebih besar dapat dilatih. Pada tahap pelatihan, fitur yang dihasilkan oleh *ResNet50* diproses lebih lanjut menggunakan *Global Average Pooling* (*GAP*) dan lapisan *fully connected* untuk melakukan klasifikasi tingkat kematangan buah. Model dilatih menggunakan optimizer Adam dengan learning rate sebesar 1×10^{-4} , batch size 16, dan jumlah *epoch* sebanyak 50. Proses *fine-tuning* dilakukan dengan menyesuaikan bobot model agar lebih sesuai dengan karakteristik citra buah kelapa sawit dengan parameter seperti pada **Tabel 2**.

Tabel 2 Parameter Eksperimen ResNet50

Parameter	Nilai
Model	ResNet50
Optimizer	Adam
Learning rate	1×10^{-4}
Epoch	50
Batch size	16
Dropout	0,5

Tahap akhir penelitian adalah pengujian model menggunakan data uji yang tidak terlibat dalam proses pelatihan. Kinerja model dievaluasi berdasarkan hasil prediksi terhadap kelas tingkat kematangan buah kelapa

sawit. Evaluasi dilakukan untuk menilai kemampuan model dalam melakukan klasifikasi dengan menggunakan rumus akurasi dan *confusion matrix*.

3. HASIL DAN ANALISIS

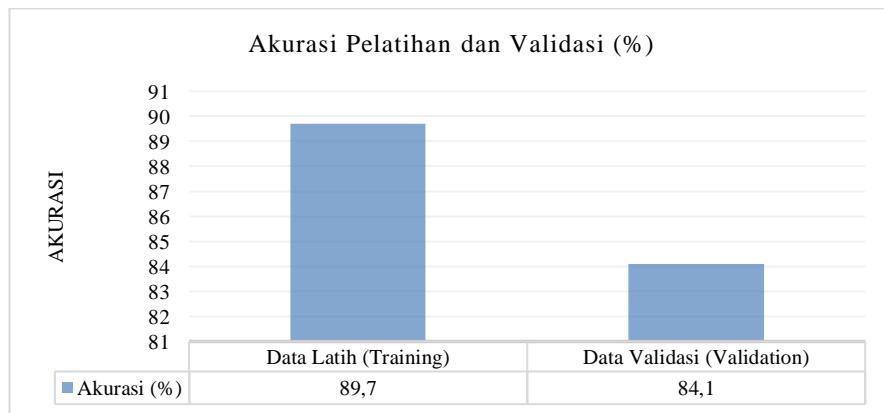
Data masukan pada penelitian ini berupa citra digital buah kelapa sawit berwarna (RGB) yang merepresentasikan tingkat kematangan buah, yaitu mentah, matang, dan terlalu matang. Seluruh citra diseragamkan ke ukuran $224 \times 224 \times 3$ piksel agar sesuai dengan spesifikasi masukan arsitektur *ResNet50*. Penyesuaian ukuran ini dilakukan untuk memastikan kompatibilitas dengan model pralatin sekaligus menjaga konsistensi dimensi data selama proses pelatihan dan pengujian.

Tahap pra-pemrosesan citra bertujuan untuk meningkatkan kualitas data dan mendukung kemampuan generalisasi model. Proses pra-pemrosesan meliputi perubahan ukuran citra menjadi 224×224 piksel serta normalisasi nilai piksel dengan skala 1/255. Selain itu, augmentasi data diterapkan secara opsional pada data latih berupa rotasi, pembalikan horizontal (*horizontal flip*), serta penyesuaian tingkat kecerahan dan kontras. Strategi *augmentasi* ini digunakan untuk meningkatkan keragaman data latih dan mengurangi risiko terjadinya *overfitting*.

Model klasifikasi pada penelitian ini memanfaatkan arsitektur *ResNet50* yang telah dilatih sebelumnya menggunakan dataset *ImageNet* sebagai *feature extractor*. *ResNet50* terdiri dari lapisan konvolusi awal berukuran 7×7 yang diikuti oleh operasi *max pooling* serta serangkaian *residual block* yang mencakup *convolution block* dan *identity block*. Mekanisme *skip connection* pada arsitektur *ResNet50* memungkinkan aliran gradien yang lebih stabil selama proses pelatihan, sehingga dapat mengatasi permasalahan *vanishing gradient* dan memungkinkan pelatihan jaringan yang lebih dalam. Output dari bagian ekstraksi fitur ini berupa *feature map* berukuran $7 \times 7 \times 2048$.

Feature map yang dihasilkan kemudian diproses menggunakan metode *Global Average Pooling* (GAP) untuk mengonversinya menjadi vektor satu dimensi berukuran 2048. Penggunaan GAP dipilih karena mampu mengurangi jumlah parameter model dibandingkan metode *flatten*, sehingga dapat menekan kompleksitas komputasi dan meminimalkan potensi *overfitting*. Vektor fitur hasil GAP selanjutnya diteruskan ke lapisan *fully connected* yang terdiri dari *Dense 256 neuron* dengan fungsi aktivasi *ReLU*, diikuti oleh *Dropout* sebesar 0,5, serta *Dense 128 neuron* dengan fungsi aktivasi *ReLU*.

Lapisan keluaran menggunakan *Dense layer* dengan tiga neuron dan fungsi aktivasi *Softmax* untuk menghasilkan probabilitas kelas tingkat kematangan buah kelapa sawit, yaitu mentah, matang, dan terlalu matang. Proses pelatihan model menggunakan fungsi *optimizer Adam* atau *AdamW*. Nilai *learning rate* ditetapkan sebesar 1×10^{-4} pada tahap *full fine-tuning*. Model dilatih selama 50 epoch dengan batch size 16 dengan hasil seperti pada **Gambar 3**.



Gambar 3 Hasil Akurasi Pelatihan dan Validasi

Gambar 3 menunjukkan grafik akurasi pelatihan dan validasi terhadap jumlah *epoch*, di mana sumbu horizontal merepresentasikan *epoch* dan sumbu vertikal menunjukkan nilai akurasi. Terlihat bahwa akurasi pelatihan dan validasi mengalami peningkatan yang stabil pada awal proses pelatihan dan mulai *konvergen* pada *epoch*-*epoch* akhir. Pola kurva yang relatif sejajar serta tidak menunjukkan perbedaan yang signifikan antara akurasi pelatihan dan validasi mengindikasikan bahwa model mampu melakukan generalisasi dengan baik dan tidak mengalami *overfitting* yang signifikan.

Hasil eksperimen menunjukkan bahwa model *ResNet50* mampu mencapai akurasi sebesar 89,7% pada data latih dan 84,1% pada data validasi. Perbedaan nilai akurasi antara data latih dan data validasi masih berada dalam batas yang wajar, yang mengindikasikan bahwa model dapat mempelajari pola data dengan baik tanpa mengalami *overfitting*. Nilai akurasi validasi yang relatif tinggi juga menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dalam mengklasifikasikan tingkat kematangan buah kelapa sawit pada data baru.

Confusion matrix digunakan untuk mengevaluasi kinerja model klasifikasi dengan membandingkan label aktual dan hasil prediksi model. Pada penelitian ini, *confusion matrix* disusun berdasarkan tiga kelas tingkat kematangan buah kelapa sawit, yaitu mentah, matang, dan terlalu matang, di mana baris merepresentasikan kelas aktual dan kolom merepresentasikan kelas prediksi.

Setiap elemen pada *confusion matrix* menunjukkan jumlah citra pada suatu kelas aktual yang diprediksi sebagai kelas tertentu. Sebagai contoh, nilai pada baris *mentah* dan kolom *mentah* menunjukkan jumlah citra buah mentah yang berhasil diklasifikasikan dengan benar oleh model (*true positive*). Sebaliknya, nilai pada baris *mentah* dan kolom *matang* atau *terlalu matang* menunjukkan jumlah citra buah mentah yang salah diklasifikasikan sebagai kelas lain (*false negative*). Proses yang sama berlaku untuk kelas *matang* dan *terlalu matang* dengan hasil seperti pada **Gambar 4**.

Aktual \ Prediksi	Mentah	Matang	Terlalu Matang
Mentah	70	12	8
Matang	8	79	3
Terlalu matang	6	4	78

Gambar 4 *Confusion matrix* untuk data pengujian

Berdasarkan *confusion matrix* pada Gambar 4, kesalahan klasifikasi paling banyak terjadi antara kelas mentah dan matang. Hal ini diduga disebabkan oleh kemiripan karakteristik visual, terutama warna dan tekstur permukaan buah yang masih berada pada *fase* transisi kematangan, sehingga menyulitkan model dalam membedakan batas antar kelas secara tegas. Selain itu, variasi pencahayaan dan sudut pengambilan citra juga berpengaruh terhadap perbedaan intensitas warna pada citra, yang dapat menyebabkan model salah menginterpretasikan tingkat kematangan buah kelapa sawit.

Dari total 90 data uji pada kelas mentah, sebanyak 70 citra berhasil diklasifikasikan dengan benar, sedangkan 12 citra salah diprediksi sebagai matang dan 8 citra sebagai terlalu matang. Pada kelas matang, model mampu mengklasifikasikan 79 citra secara benar, dengan kesalahan prediksi masing-masing sebanyak 8 citra sebagai mentah dan 3 citra sebagai terlalu matang. Sementara itu, pada kelas terlalu matang, sebanyak 78 citra berhasil diklasifikasikan dengan benar, dengan kesalahan prediksi sebanyak 6 citra sebagai mentah dan 4 citra sebagai matang, yang menunjukkan bahwa model masih mengalami kesulitan membedakan beberapa ciri visual yang saling berdekatan antar tingkat kematangan.

Berdasarkan *confusion matrix* tersebut, metrik evaluasi seperti akurasi, *precision*, *recall*, dan *F1-score* dapat dihitung. Akurasi diperoleh dari perbandingan jumlah prediksi benar (nilai diagonal) terhadap total data uji, sedangkan *precision*, *recall*, dan *F1-score* dihitung untuk masing-masing kelas dengan memanfaatkan nilai *true positive*, *false positive*, dan *false negative* yang diperoleh dari *confusion matrix* dengan hasil seperti pada **Tabel 3**.

Tabel 3 *Precision, Recall*, dan *F1-Score*

Kelas	Precision (%)	Recall (%)	F1-Score (%)
Mentah	83,33	77,78	80,39
Matang	83,16	87,78	85,41
Terlalu matang	87,64	86,67	87,15
Rata-rata	84,71	84,07	84,32

Kelas *terlalu matang* memperoleh performa terbaik dengan nilai *precision* sebesar 87,64%, *recall* 86,67%, dan *F1-score* 87,15%, yang menunjukkan kemampuan model dalam mengidentifikasi kelas tersebut secara akurat dan konsisten. Kelas *matang* juga menunjukkan kinerja yang baik dengan nilai *recall* tertinggi sebesar 87,78%, menandakan bahwa sebagian besar citra pada kelas ini berhasil dikenali dengan benar. Sementara itu, kelas *mentah* memiliki nilai *recall* terendah sebesar 77,78%, yang mengindikasikan masih adanya kesalahan

klasifikasi ke kelas lain, namun nilai precision yang relatif tinggi menunjukkan bahwa prediksi model untuk kelas ini tetap cukup andal. Nilai rata-rata *precision*, *recall*, dan *F1-score* yang berada di atas 84% menegaskan bahwa model memiliki kemampuan klasifikasi yang baik dan stabil pada seluruh kelas dengan perhitungan akurasi menggunakan Persamaan (1).

$$\text{Akurasi} = \frac{70 + 79 + 78}{270} \times 100\% = 84,07\% \quad (1)$$

Nilai akurasi pengujian sebesar 84,07% diperoleh dari perbandingan jumlah prediksi yang benar terhadap total data uji yang digunakan. Berdasarkan *confusion matrix*, jumlah citra yang berhasil diklasifikasikan dengan benar adalah 227 citra, yang merupakan penjumlahan dari prediksi benar pada masing-masing kelas, yaitu 70 citra pada kelas mentah, 79 citra pada kelas matang, dan 78 citra pada kelas terlalu matang, dari total 270 citra uji. Hasil ini menunjukkan bahwa model *ResNet50* mampu mengklasifikasikan sebagian besar citra buah kelapa sawit dengan tingkat ketepatan yang cukup tinggi, meskipun masih terdapat sejumlah kesalahan klasifikasi akibat kemiripan karakteristik visual antar tingkat kematangan.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan metode *deep learning* berbasis arsitektur *ResNet50* mampu mengklasifikasikan tingkat kematangan buah kelapa sawit ke dalam tiga kelas, yaitu mentah, matang, dan terlalu matang, dengan kinerja yang baik. Model yang dikembangkan menunjukkan akurasi sebesar 89,7% pada data latih, 84,1% pada data validasi, dan 84,07% pada data uji, yang mengindikasikan kemampuan generalisasi model yang cukup stabil. Nilai rata-rata *precision*, *recall*, dan *F1-score* yang masing-masing berada di atas 84% menunjukkan bahwa *ResNet50* efektif dalam mengekstraksi fitur visual penting dari citra buah kelapa sawit.

UCAPAN TERIMA KASIH

Terima kasih kepada Lembaga Riset dan Pengabdian kepada Masyarakat (LRPM) Universitas Dian Nusantara (UNDIR) yang telah mendanai penelitian ini melalui skema penelitian internal.

REFERENSI

- [1] W. F. Simanjuntak, R. M. Kusuma, S. Wiyatiningsih, and D. Zulperi, “Pest and Disease Challenges in Oil Palm (*Elaeis guineensis* Jacq) Seedling in Sukamara, Central Borneo,” *Agriverse*, vol. 1, no. 1, pp. 12–22, 2025.
- [2] K. Manorama, S. K. Behera, and K. Suresh, “Oil palm (*Elaeis guineensis* jacq),” in *Soil Health Management for Plantation Crops: Recent Advances and New Paradigms*, Springer, 2024, pp. 111–176.
- [3] A. M. Alhaji, E. S. Almeida, C. R. Carneiro, C. A. S. da Silva, S. Monteiro, and J. S. dos R. Coimbra, “Palm Oil (*Elaeis guineensis*): A Journey through Sustainability, Processing, and Utilization,” *Foods*, vol. 13, no. 17, p. 2814, 2024.
- [4] F. Hariyanti and A. Syahza, “Economic transformation based on leading commodities through sustainable development of the oil palm industry,” *Helijon*, vol. 10, no. 4, 2024.
- [5] M. C. S. Rao, B. N. Rao, D. V Swami, P. Ashok, G. R. Ramani, and B. B. Rao, “Management and processing of palm oil (*Elaeis guineensis* Jacq): The crop for future,” in *Palm Oil-Current Status and Updates*, IntechOpen, 2023.
- [6] D. H. Goenadi *et al.*, “Land suitability assessment and soil organic carbon stocks as two keys for achieving sustainability of oil palm (*Elaeis guineensis* Jacq.),” *Sarhad J. Agric.*, vol. 37, no. 1, pp. 184–196, 2021.
- [7] J. Y. Goh, Y. Md Yunos, and M. S. Mohamed Ali, “Fresh fruit bunch ripeness classification methods: A review,” *Food Bioprocess Technol.*, vol. 18, no. 1, pp. 183–206, 2025.
- [8] V. Ayumi, “Smart Village and Its Development in Research,” *Int. J. Adv. Stud. Comput. Sci. Eng.*, vol. 9, no. 10, pp. 1–5, 2020.
- [9] Y. H. Haw *et al.*, “Detection of Ganoderma Boninense Diseases of Palm Oil Trees Using Machine Learning,” in *2023 IEEE 13th Symposium on Computer Applications & Industrial Electronics (ISCAIE)*, IEEE, 2023, pp. 228–232.
- [10] J. W. Lai, H. R. Ramlie, L. I. Ismail, and W. Z. Wan Hasan, “Oil palm fresh fruit bunch ripeness detection methods: a systematic review,” *Agriculture*, vol. 13, no. 1, p. 156, 2023.
- [11] J. A. Bakar, M. A. M. Kehail, M. S. M. Kassim, R. Saravanan, Z. W. Cheng, and A. G. D. Al-Marsoomi, “Color-Based Ripeness Classification of Oil Palm Fresh Fruit Bunches Using Convolution Neural Networks and Data Augmentation,” in *2024 IEEE 7th International Conference on Electronics and Communication Engineering (ICECE)*, IEEE, 2024, pp. 136–140.
- [12] K. Yarak, A. Witayangkurn, K. Kritiyutanont, C. Arunplod, and R. Shibasaki, “Oil palm tree detection

- and health classification on high-resolution imagery using deep learning,” *Agriculture*, vol. 11, no. 2, p. 183, 2021.
- [13] R. Triyogi, R. Magdalena, and B. Hidayat, “Mendeteksi Kematangan Buah Kelapa Sawit Menggunakan Convolutional Neural Network Deep Learning,” *J. Nas. SAINS Dan Tek.*, vol. 1, no. 1, pp. 22–27, 2023.
- [14] I. Aryadi and A. Suhendar, “Implementasi Arsitektur Xception Dalam Menentukan Kematangan Tandan Buah Segar Kelapa Sawit,” *Jutisi J. Ilm. Tek. Inform. dan Sist. Inf.*, vol. 13, no. 3, 2024.
- [15] I. Afandy, B. N. Ahmad, and M. R. Amarharizqi, “Klasifikasi Kematangan Sawit Menggunakan Metode Convolutional Neural Network (CNN) Dengan Transfer Learning Xception,” *J. Ilm. Teknol. Inf. dan Robot.*, vol. 6, no. 2, pp. 88–98, 2024.