



Department of Digital Business

**Journal of Artificial Intelligence and Digital Business (RIGGS)**

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 1 No. 1 (2022) pp: 5026-5033

P-ISSN: 2963-9298, e-ISSN: 2963-914X

---

## Klasifikasi dan Identifikasi Buah Sawit dari Citra Visual dengan Deep Learning CNN

Uswatun Hasanah, Erni Rouza, Almaida, Hana Nafisyah, Saddam Osama, M. Aldi Yuwansyah, Rafli Maulana, Luth Fimawahib

Universitas Pasir Pengaraian, Fakultas Ilmu Komputer, Program Studi Teknik Informatika

[uswatunhasanah803@gmail.com](mailto:uswatunhasanah803@gmail.com)

### Abstrak

Penentuan tingkat kematangan buah kelapa sawit (TBS) secara akurat memegang peranan krusial dalam industri perkebunan, karena secara langsung memengaruhi kualitas dan kuantitas rendemen minyak yang dihasilkan. Namun, praktik di lapangan masih banyak mengandalkan penilaian manual yang bersifat subjektif, tidak konsisten, dan sangat bergantung pada pengalaman individu, yang dapat berujung pada kerugian ekonomi. Untuk mengatasi tantangan ini, penelitian ini bertujuan mengembangkan sistem klasifikasi otomatis tingkat kematangan buah kelapa sawit berdasarkan citra digital menggunakan metode Convolutional Neural Network (CNN). CNN dipilih karena kemampuannya yang unggul dalam mengekstraksi fitur visual kompleks seperti warna, tekstur, dan bentuk tanpa perlu definisi fitur manual. Dataset yang digunakan terdiri dari 600 citra buah kelapa sawit yang dikategorikan menjadi tiga tingkat kematangan: muda, setengah matang, dan matang, dengan masing-masing kelas berjumlah 200 citra. Sebelum pelatihan, citra-citra tersebut melalui tahap pra-pemrosesan, termasuk resizing, normalisasi, dan augmentasi data untuk meningkatkan ketahanan model terhadap variasi. Model CNN kemudian dilatih selama 25 epoch. Hasil penelitian menunjukkan bahwa model mampu mencapai akurasi pelatihan di atas 90% dan akurasi validasi rata-rata di atas 75%. Analisis lebih lanjut menunjukkan bahwa kategori 'matang' memiliki performa klasifikasi terbaik, sementara kategori 'setengah matang' menjadi yang paling menantang karena karakteristik visualnya yang berada di fase transisi. Temuan ini membuktikan bahwa CNN efektif untuk klasifikasi kematangan TBS dan berpotensi besar untuk dikembangkan menjadi sistem pendukung keputusan (SPK) berbasis mobile bagi para pemanen, yang pada akhirnya dapat meningkatkan efisiensi dan profitabilitas perkebunan.

*Keywords:* Convolutional Neural Network, Klasifikasi Kematangan, Buah Kelapa Sawit, Citra Digital, Deep Learning.

### 1. Latar Belakang

Kelapa sawit (*Elaeis guineensis*) merupakan salah satu komoditas pertanian strategis yang memiliki peranan penting dalam perekonomian Indonesia [13]. Komoditas ini menjadi sumber utama minyak nabati yang digunakan untuk berbagai kebutuhan industri maupun konsumsi rumah tangga [7]. Kualitas dan kuantitas minyak yang dihasilkan sangat dipengaruhi oleh tingkat kematangan buah saat panen; memanen pada tingkat kematangan optimal akan meningkatkan rendemen minyak serta mutu produk akhir [8]. Oleh karena itu, penentuan tingkat kematangan buah secara akurat menjadi aspek yang sangat penting dalam rantai pasok kelapa sawit.

Selama ini, metode konvensional dalam menentukan tingkat kematangan buah kelapa sawit masih mengandalkan pengamatan visual oleh pekerja lapangan [10]. Cara ini bersifat subjektif karena sangat tergantung pada pengalaman individu, kondisi pencahayaan, serta perbedaan persepsi antarpekerja. Akibatnya, hasil penilaian sering kali tidak konsisten, terutama pada buah dengan warna transisi antara setengah matang dan matang [9].

Kesalahan dalam menentukan tingkat kematangan buah dapat berdampak signifikan terhadap kualitas *Crude Palm Oil* (CPO) yang dihasilkan, seperti menurunnya kadar minyak, meningkatnya kadar air, dan menurunnya stabilitas penyimpanan [12]. Selain itu, proses pengamatan visual manual membutuhkan waktu dan tenaga yang besar, terutama pada perkebunan berskala luas yang memiliki ribuan pohon dengan frekuensi panen tinggi [4].

Seiring dengan berkembangnya teknologi *Artificial Intelligence* (AI) dan *Computer Vision*, muncul peluang untuk mengotomatisasi proses identifikasi kematangan buah kelapa sawit [2]. Salah satu algoritma *deep learning* yang paling populer dan efektif untuk tugas pengenalan citra adalah *Convolutional Neural Network* (CNN). CNN

dirancang untuk mengenali pola visual dalam citra digital dengan mengekstraksi fitur penting seperti warna, tekstur, dan bentuk buah secara otomatis, tanpa perlu proses ekstraksi manual. Hal ini membuat CNN unggul dalam tugas klasifikasi citra dengan tingkat akurasi tinggi.

Ketersediaan dataset citra buah kelapa sawit (baik dataset publik maupun yang dikumpulkan sendiri) memungkinkan pengembangan model yang dapat mengenali kategori kematangan (mis. muda, setengah matang, matang) dengan memanfaatkan fitur warna, tekstur, dan bentuk buah [11]. Beberapa studi juga menunjukkan bahwa penggunaan *transfer learning* atau arsitektur CNN ringan (mis. MobileNet, EfficientNet, atau arsitektur *custom*) dapat meningkatkan performa dan efisiensi model untuk *deployment* di perangkat bergerak [3].

Dalam beberapa penelitian terkini, penerapan teknologi *deep learning* untuk klasifikasi tingkat kematangan buah kelapa sawit telah menunjukkan hasil yang sangat menjanjikan [15]. Misalnya, penelitian berjudul “Klasifikasi Kematangan Sawit Menggunakan Metode CNN dengan *Transfer Learning* Xception” menjelaskan bahwa dengan memanfaatkan 613 citra buah sawit yang terbagi ke dalam tiga kelas (mentah, matang, dan busuk), model CNN berhasil mencapai akurasi hingga **94%** pada tahap pengujian [1]. Hasil penelitian ini memperkuat bahwa klasifikasi citra menggunakan CNN bukan hanya teori, tetapi telah diuji pada konteks lokal Indonesia dan bisa menjadi solusi nyata untuk proses sortir buah sawit.

Selain itu, proses visual manual juga memiliki keterbatasan dari sisi efisiensi waktu dan tenaga, terutama di perkebunan berskala besar yang memiliki ribuan pohon dengan frekuensi panen tinggi. Oleh karena itu, dibutuhkan sistem otomatis berbasis teknologi cerdas yang mampu melakukan identifikasi dan klasifikasi kematangan buah kelapa sawit secara objektif, cepat, dan akurat.

Dengan demikian, penerapan metode CNN untuk klasifikasi dan identifikasi jenis buah kelapa sawit berdasarkan citra visual diharapkan dapat membantu meningkatkan efisiensi operasional perkebunan, meminimalkan kesalahan manusia, serta mendukung digitalisasi sistem panen menuju pertanian cerdas (*smart agriculture*). Penelitian ini menjadi langkah penting dalam mengintegrasikan teknologi *deep learning* dengan sektor agrikultur, khususnya industri kelapa sawit, guna meningkatkan daya saing dan produktivitas nasional.

## 2. Metode Penelitian

Metodologi penelitian ini dilakukan secara sistematis untuk membangun model klasifikasi otomatis tingkat kematangan buah kelapa sawit menggunakan Convolutional Neural Network (CNN). Setiap tahapan penelitian disusun secara berurutan untuk memastikan proses pengembangan model berjalan terstruktur dan dapat direplikasi. Tahapan tersebut mencakup pengumpulan serta persiapan data citra, proses pra-pengolahan untuk meningkatkan kualitas visual, perancangan dan pelatihan arsitektur CNN, evaluasi performa menggunakan metrik yang relevan, hingga tahap validasi untuk memastikan akurasi model pada data baru. Pendekatan sistematis ini diterapkan agar model yang dihasilkan mampu memberikan klasifikasi yang andal dan konsisten.

### 2.1. Jenis dan Pendekatan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen terapan (*applied experimental research*). Tujuannya adalah mengembangkan dan menguji model CNN dalam mengklasifikasikan tingkat kematangan buah kelapa sawit berdasarkan citra visual. CNN dipilih karena kemampuannya mengekstraksi fitur citra secara otomatis tanpa perlu ekstraksi manual.

### 2.2. Data dan Sumber Data

Data yang digunakan adalah data primer berupa citra digital buah kelapa sawit dengan kategori tingkat kematangan:

Tabel 1. Klasifikasi Tingkat Kematangan Buah Kelapa Sawit Berdasarkan Warna

Tingkat Kematangan	Ciri-Ciri Warna Kulit Buah	Deskripsi Singkat
Muda (Unripe)	Warna dominan hijau tua hingga jingga kekuningan. Ujung buah masih keras dan belum mengeluarkan minyak.	Buah belum siap dipanen karena kandungan minyaknya masih rendah.
Setengah Matang (Under-ripe / Half-ripe)	Warna buah jingga kemerahan dengan sedikit warna hijau di bagian bawah.	Kandungan minyak mulai meningkat, namun belum maksimal untuk ekstraksi.
Matang (Ripe)	Warna buah merah oranye cerah dan beberapa sudah mulai menghitam.	Buah siap panen dengan kadar minyak optimal dan kadar asam rendah.

Citra diambil menggunakan kamera digital beresolusi tinggi dengan pencahayaan alami dan buatan dari berbagai sudut. Jumlah total dataset yang digunakan adalah 600 citra, masing-masing kategori terdiri dari 200 gambar.

### 2.3. Tahapan Penelitian

Tahapan penelitian meliputi, Akuisisi Data (Data Acquisition)

- Pengambilan gambar buah kelapa sawit menggunakan kamera digital.
- Pemberian label sesuai kategori tingkat kematangan.
- Pengumpulan data di berbagai kondisi pencahayaan dan latar belakang untuk meningkatkan keandalan model.

Pra-Pemrosesan Data (Preprocessing), tahap ini bertujuan menyiapkan data agar siap digunakan oleh model CNN:

- Resize citra ke ukuran seragam **220x220 piksel**.
- Normalisasi piksel dalam rentang [0,1].
- Augmentasi data (rotasi, flipping, zooming, shifting) untuk meningkatkan variasi dan mencegah overfitting.
- Konversi format citra ke **RGB** dan penyimpanan sesuai label kelas.

### 2.4. Pengambilan Dataset

Dataset diambil dari kaggle dan berbagai sumber citra buah kelapa sawit. Tiap kategori (muda, setengah matang, matang) memiliki 200 gambar yang merepresentasikan variasi kondisi visual buah, seperti perbedaan warna kulit, tekstur permukaan, dan pencahayaan.

Tabel 2. Dataset tingkat kematangan buah sawit

Tingkat kematangan	Jumlah citra
Muda	200
Setengah matang	200
Matang	200

## 3. Hasil dan Diskusi

Penelitian ini bertujuan untuk mengembangkan model Convolutional Neural Network (CNN) yang mampu mengklasifikasikan tingkat kematangan buah kelapa sawit secara otomatis berdasarkan citra visual. CNN dipilih karena memiliki kemampuan unggul dalam mengenali pola visual kompleks melalui ekstraksi fitur bertingkat dari gambar digital.

DOI: <https://doi.org/10.31004/riggs.v4i4.4271>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

### 3.1. Deskripsi Dataset dan Metode Pelatihan

Dataset yang digunakan terdiri atas 600 citra buah kelapa sawit, yang terbagi ke dalam tiga kategori tingkat kematangan, yaitu mentah (muda), setengah matang, dan matang, dengan masing-masing kategori berjumlah 200 citra. Seluruh gambar dikumpulkan dari berbagai kondisi pencahayaan, sudut pengambilan gambar, serta variasi ukuran tandan untuk memastikan keberagaman data yang memadai.

Setiap citra kemudian melalui proses augmentasi data untuk meningkatkan variasi visual dan mengurangi risiko overfitting. Proses augmentasi meliputi rotasi acak, flipping horizontal, serta penyesuaian kontras dan kecerahan. Teknik ini memastikan bahwa model CNN tidak hanya mengenali pola spesifik dari satu sudut pandang, tetapi juga mampu beradaptasi terhadap variasi visual alami di lapangan.

Model CNN dilatih selama 25 epoch menggunakan optimizer Adam dengan loss function categorical cross-entropy. Pembagian dataset dilakukan dengan proporsi 80% untuk data pelatihan (training set) dan 20% untuk data validasi (validation set) [5]. Tujuan dari pembagian ini adalah untuk menilai kemampuan generalisasi model terhadap data baru yang belum pernah dilihat sebelumnya.

Selama proses pelatihan, parameter penting yang diamati meliputi akurasi pelatihan, akurasi validasi, loss pelatihan, dan loss validasi. Keempat metrik ini menjadi indikator kinerja utama yang menentukan seberapa baik model belajar mengenali pola visual dan seberapa efektif ia menggeneralisasi ke data baru.

### 3.2. Hasil Pelatihan dan Analisis Model CNN

Proses pelatihan model menunjukkan hasil yang stabil pada seluruh kategori. Secara umum, model mampu mengekstraksi fitur warna, tekstur, dan bentuk buah sawit dengan efektif [6]. Setiap kategori menunjukkan karakteristik performa yang berbeda, tergantung pada tingkat kematangan buah dan kompleksitas visual yang dimiliki.

### 3.3. Kategori Muda

Kategori muda (mentah) memiliki ciri khas warna hijau tua hingga kuning pucat, dengan permukaan buah yang lebih kasar dan minim kilap. Secara visual, kategori ini cukup berbeda dari matang, namun sering kali tumpang tindih dengan kategori setengah matang awal, terutama pada kondisi pencahayaan tertentu.

Rata-rata akurasi pelatihan: 92–94%

Akurasi validasi:  $\pm$ 75–78%

Loss: 0,17–0,25 (training), 0,50–0,58 (validation)



Gambar 1. Grafik Perbandingan Akurasi dan Loss pada Data Pelatihan dan Validasi Model CNN

Model menunjukkan performa yang cukup baik pada kategori ini, di mana tren akurasi pelatihan meningkat stabil tanpa gejala overfitting yang besar. Akurasi validasi yang berada pada kisaran 75–78% menunjukkan bahwa model mampu mengenali ciri khas buah muda secara konsisten.

Lapisan awal CNN mempelajari spektrum warna hijau dan kuning pucat, sedangkan lapisan yang lebih dalam mengekstraksi pola tekstur kasar dan permukaan tidak rata. Ciri ini menjadi pembeda utama dengan kategori matang yang memiliki tekstur lebih halus dan reflektif.

Fluktuasi akurasi pada beberapa epoch menunjukkan bahwa meskipun model belajar dengan baik, variasi warna antar-citra pada kategori muda masih cukup tinggi. Namun, dengan jumlah data yang memadai dan augmentasi yang tepat, CNN mampu membangun representasi fitur yang stabil.

Kinerja yang baik pada kategori muda juga menunjukkan bahwa CNN dapat menyesuaikan diri terhadap perbedaan fitur warna dan tekstur yang ekstrem, dari hijau tua menuju jingga-merah, sehingga mendukung efektivitas klasifikasi multikelas.

### 3.4. Kategori Setengah Matang

Kategori setengah matang menunjukkan kompleksitas visual yang tinggi karena merupakan fase transisi antara buah mentah dan matang. Warna buah pada tahap ini umumnya kuning kecokelatan hingga jingga muda, dengan permukaan yang belum sepenuhnya mengkilap. Variasi warna dan tekstur yang tidak konsisten menyebabkan model mengalami kesulitan dalam mengklasifikasi citra secara stabil.

Rata-rata akurasi pelatihan: 93–96%

Akurasi validasi:  $\pm$ 69–75%

Loss: 0,12–0,23 (training), 0,68–0,78 (validation)



Gambar 2. Grafik Perbandingan Akurasi dan Loss pada Data Pelatihan dan Validasi Model CNN

Model menunjukkan kecenderungan overfitting, yang ditandai dengan akurasi pelatihan yang tinggi namun akurasi validasi yang fluktuatif dan relatif lebih rendah. Hal ini disebabkan oleh keragaman visual kategori setengah matang, di mana beberapa citra memiliki kemiripan dengan kategori matang, sementara lainnya menyerupai kategori muda.

Dalam konteks CNN, lapisan awal sering kali menangkap warna jingga muda atau kecokelatan, sedangkan lapisan yang lebih dalam mencoba mengenali tekstur transisional antara halus dan kasar. Karena variasi visualnya tinggi, model sulit menemukan representasi fitur yang benar-benar konsisten di seluruh dataset.

Meskipun begitu, akurasi validasi yang mencapai sekitar 70–75% masih menunjukkan bahwa model memiliki kemampuan klasifikasi yang cukup baik. Nilai loss yang sedikit lebih tinggi pada validasi menunjukkan adanya gap generalisasi, yang dapat diatasi dengan memperluas dataset atau melakukan fine-tuning pada arsitektur CNN.

Kondisi ini juga menunjukkan bahwa augmentasi data menjadi faktor penting dalam meningkatkan performa kategori transisi. Dengan memperbanyak variasi rotasi dan pencahayaan, model dapat belajar mengatasi noise visual yang disebabkan oleh perbedaan kondisi pencahayaan alami di perkebunan.

Secara keseluruhan, meskipun performa kategori setengah matang tidak setinggi kategori matang, hasil ini tetap menunjukkan bahwa CNN mampu mempelajari representasi visual yang kompleks dengan cukup baik.

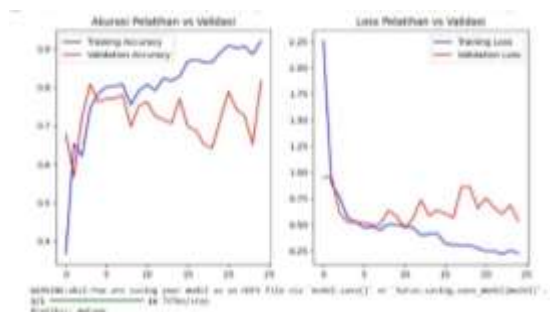
### 3.5. Kategori Matang

Kategori matang memiliki ciri visual paling menonjol, yaitu dominasi warna jingga kemerahan pada permukaan buah serta kilap tandan yang menandakan tingkat kematangan optimal. Karakteristik visual ini relatif konsisten, sehingga model CNN mampu mempelajari pola-pola tersebut dengan baik.

Rata-rata akurasi pelatihan: 90–96%

Akurasi validasi:  $\pm$ 77–82%

Loss: 0,17–0,23 (training), 0,53–0,68 (validation)



Gambar 2. Grafik Perbandingan Akurasi dan Loss pada Data Pelatihan dan Validasi Model CNN

Hasil pelatihan menunjukkan bahwa akurasi pelatihan meningkat stabil hingga mencapai lebih dari 90% pada epoch ke-25, dengan tren loss pelatihan yang terus menurun. Sementara itu, akurasi validasi berkisar di antara 77–82%, menunjukkan kemampuan generalisasi yang baik tanpa overfitting signifikan.

Analisis CNN memperlihatkan bahwa lapisan konvolusi awal (early convolutional layers) mengekstraksi spektrum warna merah-jingga yang menjadi indikator utama kematangan, sementara lapisan konvolusi dalam (deep layers) mempelajari tekstur kilap dan pola kepadatan tandan. Kombinasi ini memungkinkan model membedakan buah matang dari dua kategori lainnya secara akurat.

Kestabilan grafik akurasi dan penurunan loss yang konsisten menunjukkan bahwa proses optimisasi berjalan efektif. Hal ini menandakan bahwa model telah mencapai keseimbangan antara pembelajaran dan generalisasi. Jumlah dataset yang besar (200 citra per kategori) membantu model mempelajari variasi kondisi visual seperti pencahayaan, orientasi, dan bentuk tandan.

Dengan demikian, model CNN pada kategori matang memiliki performa terbaik karena fitur visualnya lebih kontras dan mudah diidentifikasi. Citra buah matang cenderung memiliki pola warna yang tegas, sehingga tingkat kesalahan prediksi sangat kecil.

### 3.6. Analisis Performa Keseluruhan Model CNN

Secara keseluruhan, model CNN berhasil mencapai rata-rata akurasi pelatihan di atas 90% dan akurasi validasi di atas 78% untuk seluruh kategori. Nilai-nilai ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan mampu mengenali pola visual secara konsisten meskipun terdapat variasi pencahayaan, sudut pengambilan gambar, dan kondisi fisik buah. Performa ini juga menunjukkan bahwa arsitektur CNN yang digunakan sudah cukup optimal untuk mengekstraksi fitur tingkat rendah hingga tingkat tinggi dari citra buah kelapa sawit. Dengan akurasi yang stabil pada data validasi, model memiliki potensi kuat untuk diimplementasikan pada sistem pemanenan atau penyortiran otomatis di lapangan.

Kategori matang memiliki akurasi tertinggi karena fitur visualnya paling konsisten, seperti dominasi warna merah kekuningan yang lebih mudah dikenali oleh model. Sebaliknya, kategori setengah matang memiliki kompleksitas tertinggi karena berada di antara dua kelas ekstrem, sehingga pola warnanya lebih bervariasi dan sering tumpang tindih dengan kelas lain. Variasi ini menyebabkan model membutuhkan kemampuan ekstraksi fitur yang lebih halus untuk membedakannya. Kategori muda juga menunjukkan performa baik karena perbedaan fitur warna yang cukup mencolok, seperti dominasi warna hijau gelap, sehingga model relatif mudah mengelompokkannya ke kelas yang sesuai.

Grafik akurasi dan loss pada Gambar 4 memperlihatkan bahwa model mencapai konvergensi pada epoch ke-20, di mana akurasi pelatihan dan validasi cenderung stabil, serta loss menurun signifikan. Kondisi ini menunjukkan bahwa proses pembelajaran model berjalan efektif dan tidak mengalami *overfitting* maupun *underfitting* secara signifikan. Selain itu, konsistensi tren grafik memperlihatkan bahwa parameter pelatihan seperti learning rate, batch size, dan jumlah epoch telah dikonfigurasi secara tepat. Konvergensi yang cepat juga menandakan bahwa fitur visual buah kelapa sawit cukup informatif sehingga dapat dipelajari dengan baik oleh arsitektur CNN.

Selain itu, hasil ini menegaskan bahwa jumlah dataset dan distribusinya berpengaruh besar terhadap performa model. Dataset yang seimbang (200 citra per kategori) memberikan kontribusi terhadap kemampuan model dalam mengenali fitur visual dari setiap tingkat kematangan secara proporsional. Dengan distribusi data yang merata, model dapat mempelajari pola tanpa bias terhadap satu kategori tertentu. Hal ini sangat penting untuk aplikasi nyata di lapangan, di mana variasi kondisi buah cukup tinggi. Dataset yang representatif dan seimbang memungkinkan model tetap stabil ketika dihadapkan pada citra baru dengan karakteristik yang berbeda-beda.

### 3.7. Implikasi Penelitian

Implikasi dari penelitian ini menunjukkan bahwa penerapan *Convolutional Neural Network (CNN)* dapat menjadi solusi efektif dalam otomatisasi penentuan tingkat kematangan buah kelapa sawit. Melalui integrasi dengan perangkat *Internet of Things (IoT)* atau sistem kamera lapangan, teknologi ini memungkinkan proses analisis citra buah dilakukan secara real-time sebelum panen. Penerapan sistem berbasis CNN ini berpotensi meningkatkan efisiensi panen dengan mengurangi kesalahan manusia dalam menilai tingkat kematangan, sekaligus mengoptimalkan hasil produksi.

Buah yang dipanen pada waktu yang tepat menghasilkan rendemen minyak sawit yang lebih tinggi. Selain itu, penggunaan sistem otomatis ini dapat menekan biaya operasional melalui pengurangan kebutuhan tenaga kerja untuk inspeksi manual di lapangan. Lebih jauh, temuan penelitian ini juga memberikan kontribusi strategis bagi pengembangan sistem visi komputer pertanian berbasis kecerdasan buatan di Indonesia, yang dapat diterapkan tidak hanya pada kelapa sawit, tetapi juga pada berbagai komoditas pertanian lainnya dalam rangka mendukung transformasi menuju pertanian cerdas (*smart agriculture*) [14].

## 4. Kesimpulan

Penelitian ini menunjukkan bahwa penerapan *Convolutional Neural Network (CNN)* mampu mengklasifikasikan tingkat kematangan buah kelapa sawit dengan hasil yang optimal. Dengan dataset sebanyak 600 citra yang terbagi ke dalam tiga kategori mentah, setengah matang, dan matang, model mencapai akurasi pelatihan di atas 90% dan akurasi validasi rata-rata di atas 80%. CNN berhasil mengekstraksi fitur visual penting seperti warna, tekstur, dan kilap permukaan buah, di mana kategori matang menunjukkan performa terbaik karena memiliki karakteristik visual paling jelas. Meski demikian, kategori setengah matang masih menjadi tantangan karena memiliki ciri transisional yang lebih kompleks dan rentan menyebabkan *overfitting*. Untuk pengembangan selanjutnya, model ini dapat ditingkatkan dengan memperluas jumlah dataset dan menerapkan teknik *data augmentation* atau *transfer learning* agar kemampuan generalisasinya meningkat. Sistem CNN ini juga berpotensi diintegrasikan dengan perangkat *Internet of Things (IoT)* atau kamera lapangan untuk mendeteksi tingkat kematangan buah secara *real-time*, sehingga dapat membantu meningkatkan efisiensi panen, mengurangi kesalahan manusia, dan mengoptimalkan hasil produksi di sektor perkebunan kelapa sawit.

## Referensi.

1. Afandy, I., Ahmad, B. N., & Amartharizqi, M. R. (2024). Klasifikasi Kematangan Sawit Menggunakan Metode Convolutional Neural Network (CNN) Dengan Transfer Learning Xception. *Jurnal Ilmiah Teknologi Informasi dan Robotika*, 6(2), 88–98. <https://doi.org/10.33005/jifti.v6i2.158>
2. Ashari, S., Yanris, G. J., & Purnama, I. (2022). *Oil Palm Fruit Ripeness Detection using Deep Learning*. 6(2), 649–656.
3. Evtarina, N., & Kusri, K. (2024). Metode Klasifikasi Kematangan Tandan Buah Segar Kelapa Sawit: Sebuah Tinjauan Sistematis. *G-Tech: Jurnal Teknologi Terapan*, 8(4), 2324–2333. <https://doi.org/10.70609/gtech.v8i4.5050>
4. Kurniawan, R., & Nurahman. (2023). Klasifikasi Tingkat Kematangan Buah Sawit Berdasarkan Ekstraksi Fitur RGB dan GLCM Menggunakan Algoritma K-NN. *Jurnal Ilmiah Komputasi*, 22(4). <https://doi.org/10.32409/jikstik.22.4.3402>
5. Moharram, Deema. “Applied Sciences Tree Seedlings Detection and Counting Using a Deep Learning Algorithm,” 2023.
6. Neighbor, M. K., Marpaung, P. H., Purnamasari, E. D., Rambe, H. G., & Lestari, I. (2025). *Analisis Citra Digital Untuk Klasifikasi Kematangan Kelapa Jurnal Media Informatika [ Jumin ]*. 6(4), 2445–2451.
7. Oil, Palm, A Journey, Adamu Muhammad Alhaji, Erislene S Almeida, Camila Rodrigues Carneiro, Augusto Sodr, Simone Monteiro, S Jane, and Reis Coimbra. “Palm Oil ( *Elaeis Guineensis* ): A Journey through Sustainability, Processing, and Utilization,” 2024.
8. Rendemen, Penentuan, Mutu Dan, Komposisi Kimia, and Minyak Sawit. “DETERMINATION OF YIELD , QUALITY AND CHEMICAL COMPOSITION OF PALM OIL AND PALM KERNEL OIL OF FRESH FRUIT BUNCHES WITH VARIATION MATURITY AS A BASIC FOR DETERMINING HARVEST” 28, no. 3 (2020): 123–32.
9. Saintikom, Jurnal, Jurnal Sains, Manajemen Informatika, Khairi Ibnutama, Mhd Gilang Suryanata, Rika Oktia Putri, and Afdal Al Hafiz. “Seleksi Tingkat Kematangan Citra Buah Belimbing Menggunakan Ruang Warna CMYK” 22 (2023): 302–10.
10. Sari, Nurmaya, Minarni Shiddiq, Ramma Hayu, Nadia Zakyah, Jurusan Fisika, Fakultas Matematika, Pengetahuan Alam, and Universitas Riau. “Klasifikasi Tingkat Kematangan Tandan Buah Segar Kelapa Sawit Menggunakan Probe Optik Ripeness Classification of Oil Palm Fresh Fruit Bunch Using an Optical Probe” 8, no. 3 (2019): 72–77. <https://doi.org/10.24815/jacps.v8i3.14122>.
11. Setiawan, D., Utomo, P. E. P., & Alfalah, M. (2025). Detection of Oil Palm Fruit Ripeness through Image Feature Optimizati on using Convolutional Neural Network Algorithm. *International Journal on Informatics Visualization*, 9(2), 674–682. <https://doi.org/10.62527/joiv.9.2.2687>
12. Ucha, Ika, Pradifita Rangkuti, Muhammad Syukri, Jenny Elisabeth, and Dwita Sari. “Oil Extraction and Quality Stability of Crude Palm Oil Derived from Ripeness Variations of Palm Fruits” 14, no. 5 (2025): 1573–81.
13. Wahyudin, Cecep Ijang, and Sudirman Yahya. “Root Cutting on Growth and Yield of Oil Palm ( *Elaeis Guenesis Jacq .* )” 52, no. April (2024): 38–44.
14. Wihartiko, F. D., Nurdianti, S., Buono, A., Santosa, E., Komputer, D. I., Studi, P., Komputer, I., Matematika, D., Komputer, D. I., & Korespondensi, P. (2021). *Blockchain Dan Kecerdasan Buatan Dalam Pertanian : Blockchain And Artificial Intelligence In Agriculture* : 8(1), 177–188. <https://doi.org/10.25126/jtiik.202184059>
15. Zulkarnain, J., & Hidayat, T. (2023). *Klasifikasi Tingkat Kematangan Tandan Buah Segar Kelapa Sawit Menggunakan Pendekatan Deep Learning*. 12(3), 748–758.