

DETEKSI KEMATANAGAN BUAH SAWIT DENGAN MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK

Muhammad Rizky Pratama Siregar✉, Al-Khowarizmi

Universitas Muhammadiyah Sumatera Utara, Medan, Indonesia

Email: mrizkypratamasiregar16@gmail.com

ABSTRACT

This research aims to develop an automatic palm fruit ripeness detection system using the Convolutional Neural Network (CNN) algorithm. The dataset used consists of thousands of images of ripe and unripe palm fruits with varying lighting conditions and shooting angles. The CNN model used is MobileNetV2 which has been adapted for binary classification tasks. The training process is performed using data augmentation techniques to improve the generalization of the model. The evaluation results show that the developed CNN model is able to classify the ripeness of palm fruits with an accuracy of 84%. Comparison with conventional methods that rely on visual assessment shows that the CNN model provides more consistent and objective results. The implementation of this model has the potential to increase the efficiency of the harvesting and processing of palm fruits and reduce production costs.

Keyword: Convolutional Artificial Neural Network, Palm, Architecture Model.

ABSTRAK

Penelitian ini bertujuan untuk mengembangkan sistem pendeteksi kematangan buah kelapa sawit secara otomatis dengan menggunakan algoritma Convolutional Neural Network (CNN). Dataset yang digunakan terdiri dari ribuan gambar buah kelapa sawit yang matang dan belum matang dengan kondisi pencahayaan dan sudut pengambilan gambar yang berbeda-beda. Model CNN yang digunakan adalah MobileNetV2 yang telah diadaptasi untuk tugas klasifikasi biner. Proses pelatihan dilakukan dengan menggunakan teknik augmentasi data untuk meningkatkan generalisasi model. Hasil evaluasi menunjukkan bahwa model CNN yang dikembangkan mampu mengklasifikasikan tingkat kematangan buah kelapa sawit dengan tingkat akurasi sebesar 84%. Perbandingan dengan metode konvensional yang mengandalkan penilaian visual menunjukkan bahwa model CNN memberikan hasil yang lebih konsisten dan objektif. Implementasi model ini berpotensi meningkatkan efisiensi proses pemanenan dan pengolahan buah kelapa sawit serta mengurangi biaya produksi.

Kata Kunci: Jaringan Syaraf Tiruan Convolutional, Kelapa Sawit, Model Arsitektur.

PENDAHULUAN

Pemilihan kualitas kelapa sawit masih menggunakan cara tradisional pengambilan per buah, sehingga ada beberapa sawit yang tidak matang lolos kualifikasi untuk diolah. Buah sawit yang tidak matang akan memberikan hasil yang tidak maksimal saat pengolahan di pabrik sawit. Cara tradisional tersebut sangat tidak objektif karena pemilihan hanya menggunakan kasat mata yang datanya tidak dapat dipertanggungjawabkan. Untuk itu, dibutuhkan teknologi yang dapat membantu permasalahan tersebut dan menghasilkan data yang dapat diolah untuk kebutuhan pengelolaan sawit (Bowo et al., 2020).

Oleh karena itu, pengembangan metode deteksi otomatis yang lebih cepat dan akurat menjadi sangat penting dalam industri kelapa sawit. Sistem deteksi kematangan buah sawit berbasis Convolutional Neural Network (CNN) diharapkan dapat meningkatkan efisiensi dan akurasi dalam mendeteksi kematangan

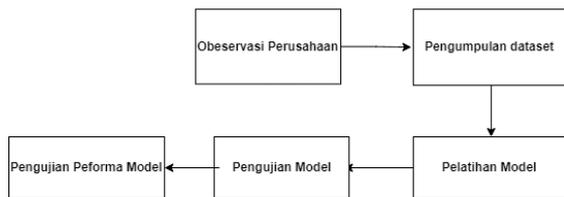
buah sawit, sehingga membantu meningkatkan kualitas dan jumlah produksi minyak kelapa sawit (Charli et al., 2020).

Salah satu inovasi yang dapat mendukung peningkatan kualitas adalah penggunaan teknologi Machine Learning, khususnya CNN, dalam menganalisis kualitas kelapa sawit. Menurut Mahesh, produk dari pembelajaran mesin adalah pengklasifikasi yang dapat digunakan pada perangkat keras yang tersedia, dan pembuatan pengklasifikasi harus sangat termekanisasi untuk meminimalkan bias manusia (Mahesh, 2020). Algoritme ini harus didasarkan pada data yang konkret dan dapat diamati. Farsi et al. menyatakan bahwa metode pembelajaran mendalam CNN sangat efektif untuk merepresentasikan pola spasial, memungkinkan ekstraksi berbagai properti vegetasi dari citra penginderaan jauh (Farsi et al., 2021). Ulasan ini menjelaskan prinsip-prinsip CNN dan mengapa metode ini cocok untuk penginderaan

jauh vegetasi, serta mencakup tren dan perkembangan saat ini, termasuk resolusi spektral, butir spasial, jenis sensor, dan pendekatan arsitektur CNN (Gulzar, 2023). Penerapan ini memerlukan dataset sawit untuk membentuk model prediksi tingkat kematangan sawit dan nilai kematangan yang mempertimbangkan kesiapan panen. Dengan demikian, penelitian ini tidak hanya memberikan kontribusi teoritis pada pengembangan teknologi, tetapi juga menawarkan solusi praktis yang dapat langsung diterapkan dalam industri kelapa sawit di Indonesia (Hajar et al., 2020).

METODE PENELITIAN

Pada bagian metode penelitian ini, peneliti memberikan penjelasan mengenai alur dari metodologi penelitian yang digunakan. Penelitian ini mencakup beberapa tahapan penting, yaitu observasi awal terhadap perusahaan, pengumpulan dataset yang relevan, proses pelatihan model menggunakan arsitektur CNN MobileNetV2, serta evaluasi performa model (Hasibuan, 2020). Penjelasan ini mencakup alur penelitian, detail mengenai dataset yang digunakan, proses pra-pemrosesan data, arsitektur model yang diterapkan, serta langkah-langkah pelatihan dan pengujian model untuk mendapatkan hasil yang optimal dalam mendeteksi kematangan buah sawit.



Gambar 1. Alur Penelitian

Metode Penelitian dapat dilihat pada gambar 1, yang menjelaskan proses penelitian dari observasi hingga evaluasi model:

- Observasi Perusahaan: Tahap awal dilakukan observasi di perusahaan untuk memahami proses pengelolaan kelapa sawit.
- Pengumpulan Dataset: Mengumpulkan dataset berupa citra buah sawit dengan berbagai tingkat kematangan.
- Pelatihan Model dengan MobileNetV2: Menggunakan dataset untuk melatih model Convolutional Neural Network (CNN) dengan arsitektur MobileNetV2 (Husna et al., 2022).
- Pengujian Model: Melakukan pengujian model dengan dataset uji untuk menilai kemampuannya dalam mendeteksi kematangan buah sawit.
- Pengujian Performa Model: Mengevaluasi performa model dengan metrik seperti akurasi, presisi, recall, dan F1-score.

Penelitian ini melakukan pengamatan di PT. Anugera Makmur Jaya dan menemukan masalah terkait proses penyortiran kematangan buah sawit. Masalah yang dihadapi adalah kesalahan yang sering terjadi saat pemisahan antara buah sawit yang sudah matang dan yang belum matang, sehingga kedua jenis buah sawit tersebut sering tercampur (Islamiah et al., 2021).

Dalam konteks PT. Anugera Makmur Jaya, terdapat masalah serius terkait proses penyortiran kematangan buah sawit. Kesalahan sering terjadi saat penyortir memisahkan buah sawit yang sudah matang dan yang belum matang, sehingga buah-buah tersebut sering tercampur (Krisdiarto et al., 2017). Hal ini mengakibatkan penurunan kualitas hasil produksi, karena buah sawit yang belum matang cenderung menghasilkan minyak yang kurang berkualitas (Krisdiarto et al., 2017).



Gambar 2. Observasi Pertama

Pada Gambar 2, ditampilkan kegiatan observasi pertama yang dilakukan di lokasi pengolahan kelapa sawit, di mana tim peneliti mengamati secara langsung proses penanganan dan pengelolaan buah sawit, termasuk tahap penerimaan di pabrik. Gambar ini memberikan konteks tentang alur kerja perusahaan yang terkait dengan pemrosesan buah sawit, yang berpotensi mempengaruhi efektivitas penyortiran.

Pengumpulan dataset merupakan bagian integral dari penelitian ini. Dataset yang digunakan untuk melatih dan mengevaluasi model terdiri dari sawit matang dan tidak matang yang diperoleh dari pengumpulan saat observasi di lapangan (Suharjo et al., 2023). Data yang digunakan dalam penelitian ini terklasifikasi ke dalam dua kategori, yaitu kelas sawit matang dan sawit tidak matang.



Gambar 3. Observasi kedua



Gambar 4. Sawit Matang



Gambar 5. Sawit Mentah

Pada Gambar 4, ditampilkan contoh citra dari buah sawit matang, yang menunjukkan karakteristik visual yang menandakan kematangan buah. Gambar ini memberikan pemahaman yang jelas mengenai ciri-ciri sawit matang yang perlu dikenali oleh model. Sementara itu, Gambar 5 menggambarkan citra buah sawit yang tidak matang, memperlihatkan perbedaan signifikan dalam penampilan dan kondisi buah dibandingkan dengan sawit matang.

Penelitian ini bertujuan untuk mengetahui performa model Deep Learning MobileNetV2 dalam deteksi dan klasifikasi jenis sawit. Dalam

penerapannya, MobileNetV2, seperti halnya model Deep Learning lainnya, memerlukan dataset yang berupa citra beserta labelnya untuk digunakan dalam proses pelatihan/training (Irawan & Susilawati, 2022). Pada kasus MobileNetV2, ini merupakan proses transfer learning. Dataset sebanyak 500 citra yang diperlukan untuk pelatihan model MobileNetV2 dalam penelitian ini merupakan kumpulan gambar sawit matang dan tidak matang dengan label yang sesuai untuk masing-masing citra, mengikuti format label yang ditetapkan oleh MobileNetV2.

Setelah proses pra-pemrosesan dataset selesai dilakukan, maka proses pelatihan model MobileNetV2 dapat dilakukan. Dikarenakan model MobileNetV2 merupakan model pra-terlatih (pretrained), proses pelatihan ini merupakan proses transfer learning yang hanya melatih lapisan akhir untuk menyesuaikan model dalam mendeteksi kelas-kelas dalam dataset yang diberikan. Sebelum proses pelatihan ini dilakukan, perlu dilakukan sedikit konfigurasi terhadap model MobileNetV2 yang akan digunakan, seperti pengaturan direktori dataset, ukuran citra input, dan kedalaman citra (Salambue & Shiddiq, 2019). Selain itu, konfigurasi pelatihan juga mencakup penetapan jumlah epoch, batch size, dan callback untuk target angka akurasi. Pada tahap ini, model akan dilatih selama 50 epoch, yang memungkinkan penyesuaian yang cukup baik terhadap dataset.

Setelah model berhasil dilatih dan menghasilkan akurasi pelatihan yang memuaskan, maka selanjutnya dapat dilakukan evaluasi performa model terhadap gambar sawit matang dan tidak matang. Dalam proses evaluasi dilakukan prediksi terhadap kelompok gambar yang memiliki label untuk mengetahui hasil aslinya dan kelompok gambar ini harus tidak pernah digunakan dalam proses pelatihan untuk memastikan integritas hasil evaluasi. Proses evaluasi dilakukan dengan melakukan prediksi pada direktori yang mengandung kelompok dataset evaluasi, dan menghasilkan angka angka evaluasi yang akan dilakukan analisa pada proses selanjutnya (Sitorus et al., 2020).

Langkah selanjutnya adalah mengintegrasikan model ke dalam aplikasi yang akan digunakan untuk klasifikasi kematangan buah sawit secara praktis. ini melibatkan pengembangan antarmuka pengguna yang ramah pengguna, yang memungkinkan pengguna untuk mengambil gambar foto kematangan buah sawit dan mendapatkan klasifikasi tingkat kematangan dari model MobileNetV2 dan tahapan terakhir adalah pengujian performa model yang diimplementasikan pada aplikasi yang dikembangkan. Ini melibatkan uji coba aplikasi dengan pengguna yang sesungguhnya atau dengan data yang relevan untuk mengevaluasi

seberapa baik model MobileNetV2 berkinerja dalam mengklasifikasikan kematangan buah sawit yoga dalam penyortiran.

HASIL DAN PEMBAHASAN

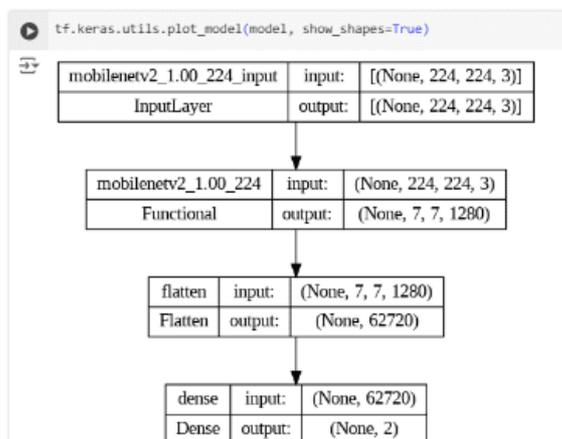
Pada bagian ini membahas hasil dan pembahasan dari penelitian, yang mencakup proses klasifikasi, hasil klasifikasi, serta evaluasi kinerja model. Pengujian dan analisis dilakukan dengan menggunakan layanan berbasis cloud, yaitu Google Colaboratory (Colab). Dalam penelitian ini, dataset yang digunakan diperoleh secara langsung dari PT. Anugrah Makmur Jaya, Roboflow, dan platform Kaggle. Dataset tersebut terdiri dari 1.557 data *training* dan 707 data *validation*, yang diklasifikasikan ke dalam dua kategori, yaitu sawit matang (*ripe*) dan sawit tidak matang (*unripe*). Total keseluruhan dataset adalah 2.264 data. Seluruh dataset diunggah ke Google Drive untuk mempermudah pemanggilan direktori selama proses pelatihan model. Setelah dataset berhasil diunggah, langkah berikutnya adalah memanggil direktori penyimpanan file dataset di Google Drive dengan bantuan bahasa pemrograman Python dan Google Colab.

Penelitian ini menggunakan MobileNetV2 sebagai model klasifikasi utama karena efisiensinya dalam mendeteksi objek dengan akurasi yang tinggi serta ukuran model yang relatif kecil. MobileNetV2 dipilih berdasarkan kemampuannya untuk mengklasifikasikan gambar dengan baik, terutama pada perangkat dengan keterbatasan daya komputasi. Pada penelitian ini, model MobileNetV2 diimplementasikan dengan beberapa tahapan, termasuk preprocessing data, pelatihan model, serta evaluasi kinerja model menggunakan metrik seperti akurasi, presisi, dan recall. Hasil penelitian menunjukkan bahwa MobileNetV2 mampu memberikan hasil yang memuaskan dalam tugas klasifikasi, dengan waktu inferensi yang lebih cepat dibandingkan model konvolusi lainnya.

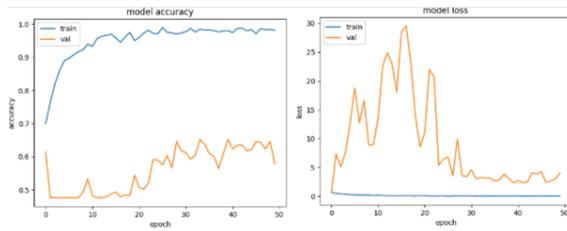
Pada gambar 6 digunakan empat lapisan dalam arsitektur model. Lapisan pertama adalah input layer, yang menunjukkan bahwa input berupa gambar dengan ukuran 224x224 piksel dan memiliki 3 saluran warna (RGB). Lapisan kedua adalah MobileNetV2 layer, di mana arsitektur MobileNetV2 yang telah dilatih sebelumnya digunakan sebagai backbone. MobileNetV2 ini mengubah input gambar menjadi fitur-fitur berukuran 7x7 dengan 1280 saluran fitur. Selanjutnya, lapisan ketiga adalah flatten layer, yang mengubah fitur-fitur berdimensi 7x7x1280 tersebut menjadi vektor satu dimensi dengan panjang 62.720. Vektor ini kemudian diteruskan ke lapisan terakhir, yaitu dense layer atau lapisan fully connected, yang menghubungkan semua neuron dari lapisan sebelumnya ke dua neuron pada lapisan output. Dua neuron pada lapisan output ini menunjukkan bahwa model digunakan untuk klasifikasi ke dalam dua kelas yang berbeda. Gambar 7 memperlihatkan keseluruhan arsitektur ini, di mana efisiensi MobileNetV2 dimanfaatkan untuk pengenalan gambar dan dikombinasikan dengan lapisan fully connected untuk menghasilkan prediksi klasifikasi akhir.

Pada tahap pengujian model, penelitian ini bertujuan untuk mengevaluasi performa model dalam melakukan klasifikasi. Hasil yang diperoleh menunjukkan perbedaan signifikan antara dataset tanpa augmentasi dan dataset yang telah di-augmentasi (Samuel et al., 2022). Pada dataset tanpa augmentasi, validation accuracy tercatat sebesar 47%, sementara setelah augmentasi, nilai tersebut meningkat menjadi 83%. Proses pelatihan dihentikan pada epoch ke-14 untuk dataset tanpa augmentasi dan pada epoch ke-50 untuk dataset yang telah di-augmentasi, menggunakan teknik early stopping dan callback untuk menghentikan pelatihan secara otomatis apabila tidak ada peningkatan akurasi yang signifikan. Berdasarkan hasil akurasi yang lebih tinggi, penelitian ini memilih untuk menggunakan dataset yang telah di-augmentasi dalam seluruh proses evaluasi.

Grafik model accuracy dan model loss menampilkan dua garis, yaitu garis biru untuk data pelatihan (train) dan garis kuning untuk data validasi (val). Garis untuk data pelatihan menggambarkan tingkat akurasi model pada data yang digunakan selama pelatihan, sedangkan garis untuk data validasi menggambarkan performa model pada data yang tidak digunakan dalam pelatihan, tetapi digunakan untuk evaluasi model (Satia et al., 2022).

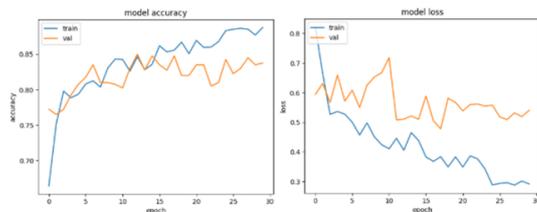


Gambar 6. Model CNN dan MobileNetV2



Gambar 7. Akurasi dan Loss dataset sebelum Augmentasi

Pada Gambar 7, grafik akurasi menunjukkan bahwa akurasi data pelatihan meningkat secara bertahap dari 0,65 pada epoch pertama hingga mencapai 0,96 pada epoch ke-14. Namun, akurasi validasi mengalami penurunan, dari 0,65 pada epoch pertama menjadi 0,47 pada epoch ke-14. Tren ini menunjukkan bahwa model mengalami overfitting, di mana model sangat baik dalam mempelajari data pelatihan tetapi kurang mampu mempertahankan performa yang sama pada data validasi. Pada grafik loss, terlihat bahwa loss data pelatihan menurun secara signifikan dari 10 pada epoch pertama menjadi 0 pada epoch ke-14. Sementara itu, loss data validasi juga mengalami penurunan, meskipun nilainya lebih tinggi dibandingkan data pelatihan, yaitu mencapai 0,5 pada epoch ke-14. Hal ini mengonfirmasi bahwa tanpa augmentasi, model cenderung melakukan overfitting, dengan performa validasi yang lebih rendah dibandingkan pelatihan.



Gambar 8. Akurasi dan Loss dataset Setelah Augmentasi

Pada gambar 9 menampilkan hasil performa model setelah augmentasi data diterapkan. Pada grafik akurasi, terlihat bahwa akurasi data pelatihan dimulai dari 0,66 pada epoch pertama dan stabil di sekitar 0,88 mulai dari epoch ke-20 hingga epoch ke-50. Akurasi validasi juga mengalami peningkatan yang signifikan, mencapai 0,83 pada epoch ke-50, menunjukkan bahwa augmentasi data membantu meningkatkan generalisasi model dan menjaga performa akurasi pada data validasi. Pada grafik loss, loss data pelatihan lebih rendah dibandingkan sebelum augmentasi, dengan nilai stabil di sekitar 0,2 pada epoch-epoch akhir. Loss data validasi juga menurun secara signifikan, mencapai 1 pada epoch ke-20, yang menunjukkan bahwa augmentasi data membantu menekan overfitting,

sehingga model menjadi lebih robust dalam melakukan prediksi pada data yang tidak terlihat selama pelatihan.

Berdasarkan perbandingan kedua grafik di atas, dapat disimpulkan bahwa augmentasi data secara signifikan meningkatkan akurasi model, baik untuk data pelatihan maupun validasi, serta menurunkan nilai loss. Dengan demikian, augmentasi data terbukti sebagai teknik yang efektif untuk meningkatkan performa model deep learning dalam penelitian ini (Intyanto, 2021).

Tabel 1. Perhitungan hasil Akurasi dataset Sebelum Augmentasi

| | <i>Precision</i> | <i>recall</i> | <i>f1-score</i> | <i>support</i> |
|-------------------------------------|------------------|---------------|-----------------|----------------|
| <i>ripe</i> | 0.60 | 0.30 | 0.40 | 186 |
| <i>unripe</i> | 0.50 | 0.77 | 0.61 | 168 |
| <i>accuracy</i> | | | 0.53 | 354 |
| <i>Macro avg</i> | 0.55 | 0.54 | 0.50 | 354 |
| <i>Weighted avg</i> | 0.55 | 0.53 | 0.50 | 354 |
| Accuracy of the model: 52.5% | | | | |

Pada tahapan ini, penelitian ini bertujuan untuk menilai hasil dari proses pelatihan model sebelumnya, dengan fokus pada penyesuaian performa model agar sesuai dengan tujuan yang telah ditetapkan. Pada tahap ini, model Convolutional Neural Network (CNN) akan dievaluasi menggunakan Confusion Matrix sebagai alat ukur akurasi. Selain itu, metrik-metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score* juga dihitung untuk memberikan gambaran menyeluruh mengenai tingkat akurasi dan efektivitas model. Evaluasi ini diharapkan mampu memberikan pandangan yang komprehensif terkait performa model yang diterapkan dalam penelitian ini.

Tabel 2. Perhitungan hasil Akurasi dataset Setelah Augmentasi

| | <i>Precision</i> | <i>recall</i> | <i>f1-score</i> | <i>support</i> |
|-------------------------------------|------------------|---------------|-----------------|----------------|
| <i>ripe</i> | 0.60 | 0.30 | 0.40 | 186 |
| <i>unripe</i> | 0.50 | 0.77 | 0.61 | 168 |
| <i>accuracy</i> | | | 0.53 | 354 |
| <i>Macro avg</i> | 0.55 | 0.54 | 0.50 | 354 |
| <i>Weighted avg</i> | 0.55 | 0.53 | 0.50 | 354 |
| Accuracy of the model: 52.5% | | | | |

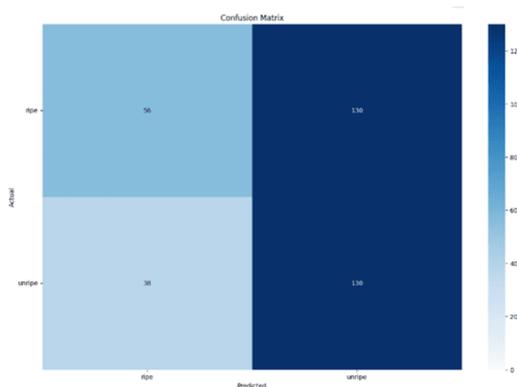
Pada tabel 1 menampilkan hasil perhitungan akurasi pada dataset sebelum dilakukan augmentasi.

Berdasarkan gambar tersebut, akurasi model tercatat sebesar 52,5%. Metrik evaluasi lainnya seperti precision, recall, dan f1-score untuk kelas *ripe* (matang) dan *unripe* (belum matang) juga ditampilkan. Untuk kelas *ripe*, precision sebesar 0,60, recall 0,30, dan f1-score 0,40, dengan jumlah sampel 186. Sedangkan untuk kelas *unripe*, precision adalah 0,50, recall 0,77, dan f1-score 0,61, dengan jumlah sampel 168. Nilai rata-rata macro untuk precision, recall, dan f1-score masing-masing adalah 0,55, 0,54, dan 0,50. Hasil ini menunjukkan performa model yang masih kurang optimal, terutama pada kelas *ripe*, sehingga diperlukan peningkatan performa, misalnya dengan menerapkan augmentasi data.

Tabel 2 menampilkan hasil perhitungan akurasi dataset setelah dilakukan augmentasi. Dari gambar ini, akurasi model meningkat menjadi 84,8%. Metrik evaluasi seperti precision, recall, dan f1-score untuk kedua kelas, yaitu *ripe* (matang) dan *unripe* (belum matang), juga diperlihatkan. Untuk kelas *ripe*, precision sebesar 0,83, recall 0,88, dan f1-score 0,85, dengan total sampel sebanyak 202. Sementara itu, kelas *unripe* memiliki precision sebesar 0,87, recall 0,81, dan f1-score 0,84, dengan jumlah sampel 198. Nilai rata-rata macro untuk precision, recall, dan f1-score masing-masing adalah 0,85. Hasil evaluasi ini menunjukkan bahwa augmentasi data berhasil meningkatkan performa model secara signifikan dibandingkan dengan sebelum dilakukan augmentasi.

Berdasarkan hasil evaluasi performa model klasifikasi sebelum dan sesudah augmentasi data, terlihat peningkatan yang signifikan dalam akurasi dan kinerja keseluruhan model setelah augmentasi diterapkan. Sebelum augmentasi, akurasi model hanya mencapai 52,5%, dengan f1-score yang rendah pada kelas *ripe* (0,40) dan lebih baik pada kelas *unripe* (0,61). Hal ini mengindikasikan bahwa model awal kesulitan dalam secara konsisten mendeteksi buah sawit yang matang, sementara performanya lebih baik dalam mengenali buah sawit yang belum matang. Setelah augmentasi, terjadi peningkatan yang signifikan dengan akurasi model melonjak hingga 84,8%. Pada kelas *ripe*, precision dan recall masing-masing meningkat menjadi 0,83 dan 0,88, yang menunjukkan peningkatan signifikan dalam kemampuan model untuk mendeteksi sawit matang. F1-score pada kelas ini juga naik menjadi 0,85. Demikian pula, kelas *unripe* menunjukkan peningkatan performa yang konsisten, dengan f1-score mencapai 0,84, yang menunjukkan bahwa model dapat mendeteksi buah sawit yang belum matang dengan lebih baik. Secara keseluruhan, nilai rata-rata makro untuk precision, recall, dan f1-score meningkat dari

0,55 menjadi 0,85, yang menegaskan bahwa model kini bekerja dengan lebih baik dan konsisten pada kedua kelas.

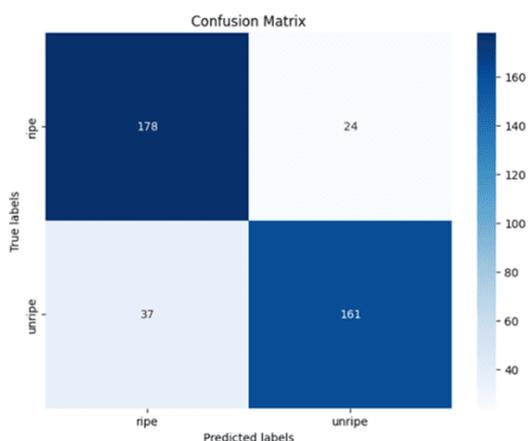


Gambar 9. Confusion Matrix sebelum Augmentasi

Kesimpulannya, augmentasi data terbukti sangat efektif dalam meningkatkan akurasi dan performa model secara keseluruhan. Akurasi model meningkat dari 52,5% menjadi 84,8%, memperlihatkan kemampuan yang jauh lebih baik dalam mendeteksi dan mengklasifikasikan kondisi kematangan sawit. Peningkatan f1-score di kedua kelas menunjukkan keseimbangan yang lebih baik antara precision dan recall, yang berarti model lebih konsisten dalam melakukan klasifikasi. Oleh karena itu, model yang dilatih dengan augmentasi data tidak hanya lebih akurat, tetapi juga lebih andal dan siap digunakan dalam skenario nyata yang memerlukan klasifikasi otomatis tingkat kematangan sawit dengan akurasi tinggi.

Pada gambar 9 menunjukkan *confusion matrix* untuk model sebelum dilakukan augmentasi data. Matriks ini berfungsi untuk memberikan gambaran tentang kinerja model klasifikasi dalam memprediksi dua kelas, yaitu *ripe* (matang) dan *unripe* (belum matang). Pada sumbu vertikal ditampilkan kelas asli (actual), sedangkan sumbu horizontal menunjukkan kelas hasil prediksi oleh model. Pada bagian kiri atas, terdapat 56 prediksi benar untuk kelas *ripe* (matang), yang berarti model berhasil mengklasifikasikan 56 sampel matang dengan tepat. Namun, pada bagian kanan atas, terdapat 130 prediksi keliru, di mana sampel matang salah diprediksi sebagai belum matang. Ini menunjukkan adanya jumlah kesalahan yang cukup besar dalam membedakan buah matang sebagai belum matang. Sementara itu, pada bagian kiri bawah, terdapat 38 prediksi salah untuk kelas *unripe* (belum matang), di mana model memprediksi buah yang sebenarnya belum matang sebagai matang. Pada bagian kanan bawah, terdapat 130 prediksi benar untuk kelas *unripe*, yang menandakan bahwa 130 sampel belum

matang diprediksi dengan benar. Secara keseluruhan, meskipun model berhasil mengidentifikasi sejumlah besar sampel yang belum matang dengan tepat, akurasi dalam mendeteksi sampel matang masih rendah. Hal ini terlihat dari jumlah kesalahan yang lebih tinggi pada prediksi kelas matang, yang mengindikasikan bahwa model mengalami bias dalam klasifikasi dan lebih sering menganggap sampel sebagai belum matang. Oleh karena itu, augmentasi data dapat menjadi langkah yang dibutuhkan untuk meningkatkan kemampuan model dalam menangani ketidakseimbangan dan meningkatkan akurasi keseluruhan.



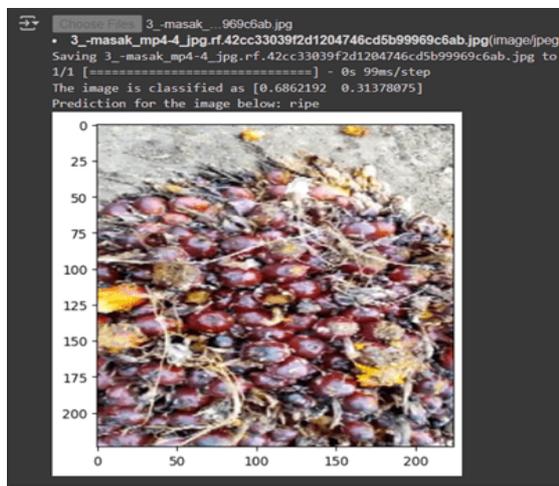
Gambar 10. Confusion Matrix sebelum Augmentasi

Pada gambar 10 menunjukkan matriks kebingungan (*confusion matrix*) untuk model setelah dilakukan augmentasi data. Pada matriks ini, terlihat peningkatan yang signifikan dalam kinerja model dibandingkan dengan matriks sebelumnya. Sumbu vertikal menampilkan kelas asli (*true labels*), sedangkan sumbu horizontal menunjukkan hasil prediksi model (*predicted labels*). Dari data yang ditampilkan, terdapat 178 sampel matang (*ripe*) yang berhasil diprediksi dengan benar, sementara hanya 24 sampel matang yang keliru diklasifikasikan sebagai belum matang (*unripe*). Ini menunjukkan bahwa model setelah augmentasi mampu meningkatkan akurasi dalam mengenali buah yang matang, dengan jumlah kesalahan yang jauh lebih rendah dibandingkan dengan sebelum augmentasi. Di sisi lain, untuk kelas belum matang (*unripe*), model juga menunjukkan peningkatan. Sebanyak 161 sampel belum matang diprediksi dengan benar, sedangkan hanya 37 sampel yang keliru diklasifikasikan sebagai matang. Meskipun masih terdapat beberapa kesalahan, proporsi prediksi yang benar meningkat secara signifikan dibandingkan dengan sebelum augmentasi. Secara keseluruhan, augmentasi data berhasil meningkatkan kinerja model dengan memperbaiki distribusi dan keragaman data

pelatihan, sehingga model lebih mampu membedakan kedua kelas dengan lebih akurat. Hasil ini menunjukkan bahwa augmentasi data memberikan dampak positif dalam mengurangi bias dan meningkatkan kemampuan generalisasi model.

Dari gambar 9 dan Gambar 10 menunjukkan bahwa augmentasi data berhasil meningkatkan kinerja model klasifikasi secara signifikan. Pada Gambar 9 (sebelum augmentasi), model mengalami kesulitan dalam mengenali kelas ripe (matang), dengan hanya 56 prediksi benar dan 130 kesalahan, di mana sampel matang salah diklasifikasikan sebagai belum matang. Walaupun untuk kelas unripe (belum matang) kinerja sedikit lebih baik, masih terdapat 38 kesalahan prediksi. Setelah augmentasi data, seperti yang terlihat pada Gambar 10, akurasi model meningkat secara drastis. Jumlah prediksi benar untuk kelas matang meningkat menjadi 178, dengan hanya 24 kesalahan. Untuk kelas belum matang, model berhasil memprediksi 161 sampel dengan benar, dan kesalahan berkurang menjadi 37. Secara keseluruhan, augmentasi data membantu model dalam memahami pola dari kedua kelas dengan lebih baik, mengurangi bias, dan meningkatkan akurasi prediksi. Augmentasi terbukti efektif dalam memperbaiki kemampuan generalisasi model, membuatnya lebih akurat dan andal dalam mengklasifikasikan buah matang dan belum matang.

Pada tahap prediksi model, penelitian ini memungkinkan pengguna untuk menginput file gambar penyakit dalam format JPG. Setelah file gambar diunggah, program akan membaca dan memproses gambar tersebut, kemudian secara otomatis menampilkan hasil prediksi. MobileNetV2, yang digunakan dalam penelitian ini, memanfaatkan arsitekturnya yang efisien untuk memberikan hasil prediksi secara cepat dan akurat, bahkan pada perangkat dengan sumber daya terbatas.



Gambar 11. Prediksi Sawit Ripe

Pada Gambar 11 ini, model memberikan probabilitas sebesar 0,6862192 (68,62%) bahwa gambar tersebut termasuk dalam kelas "ripe" (matang) dan 0,31378075 (31,38%) bahwa gambar tersebut termasuk dalam kelas "unripe" (tidak matang). Berdasarkan probabilitas yang lebih tinggi, model mengklasifikasikan gambar ini sebagai "ripe" (matang).



Gambar 11. Prediksi Sawit Unripe

Pada Gambar 12, model CNN memberikan probabilitas sebesar 0,3124623 (31,24%) bahwa gambar tersebut termasuk dalam kelas "ripe" (matang) dan 0,9687537 (96,87%) bahwa gambar tersebut termasuk dalam kelas "unripe" (tidak matang). Berdasarkan probabilitas yang lebih tinggi, model mengklasifikasikan gambar ini sebagai "unripe" (tidak matang).

KESIMPULAN

Penelitian ini berhasil mengimplementasikan model deteksi menggunakan algoritma *Convolutional Neural Network* (CNN) untuk mengklasifikasikan kematangan buah sawit. Model ini mampu mengenali pola-pola visual yang terkait dengan tingkat kematangan buah sawit, seperti warna dan tekstur, yang menjadi indikator utama dalam klasifikasi.

Model deteksi yang diimplementasikan menghasilkan akurasi 84,75% yang cukup tinggi dalam klasifikasi kematangan buah sawit dengan penggunaan dataset 2264 data. Hal ini menunjukkan bahwa algoritma CNN efektif dalam memproses citra buah sawit dan menghasilkan prediksi yang akurat mengenai tingkat kematangannya. Akurasi yang diperoleh membuktikan bahwa model CNN memiliki potensi besar untuk diterapkan dalam industri perkebunan kelapa sawit

Saran untuk penelitian selanjutnya yang akan menggunakan topik yang sama yaitu melakukan perbandingan dengan metode algoritma CNN lainnya

untuk mendapatkan hasil yang lebih baik. Namun harus ada pertimbangan pada *transfer learning* yang ingin digunakan, setiap waktunya ada *update* pada *library* untuk penggunaan model. Dataset yang bagus akan membentuk model arsitektur yang bagus pula karena model belajar dari dataset yang dilabel. Penambahan kelas pada label dataset untuk lebih spesifik pada jenis sawit. Pengenalan pada objek harus.

DISEMINASI

Artikel ini telah diseminasi pada Seminar Nasional Teknologi Informasi dan Komunikasi (SEMNASTIK) APTIKOM Tahun 2024 yang diselenggarakan oleh Universitas Methodist Indonesia pada tanggal 24-26 Oktober 2024.

DAFTAR PUSTAKA

- Bowo, T. A., Syaputra, H., & Akbar, M. (2020). Penerapan Algoritma Convolutional Neural Network Untuk Klasifikasi Motif Citra Batik Solo. *Journal of Software Engineering Ampera*, 1(2), 82–96. <https://doi.org/10.51519/journalsea.v1i2.47>
- Charli, F., Syaputra, H., Akbar, M., Sauda, S., & Panjaitan, F. (2020). Implementasi Metode Faster Region Convolutional Neural Network (Faster R-CNN) Untuk Pengenalan Jenis Burung Lovebird. *Journal of Information Technology Ampera*, 1(3), 185–197. <https://doi.org/10.51519/journalita.volume1.issuue3.year2020.page185-197>
- Farsi, B., Amayri, M., Bouguila, N., & Eicker, U. (2021). On Short-Term Load Forecasting Using Machine Learning Techniques and a Novel Parallel Deep LSTM-CNN Approach. *IEEE Access*, 9, 31191–31212. <https://doi.org/10.1109/ACCESS.2021.3060290>
- Gulzar, Y. (2023). Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique. *Sustainability*, 15(3), 1906. <https://doi.org/10.3390/su15031906>
- Hajar, S., Novany, A. A., Windarto, A. P., Wanto, A., & Irawan, E. (2020). Penerapan K-means clustering pada ekspor minyak kelapa sawit menurut negara tujuan. *Seminar Nasional Teknologi Komputer & Sains (SAINTEKS)*, 314–318.
- Hasibuan, H. A. (2020). Penentuan Rendemen, Mutu dan Komposisi Kimia Minyak Sawit dan Minyak Inti Sawit Tandan Buah Segar Bervariasi Kematangan sebagai Dasar untuk Penetapan Standar Kematangan Panen. *Jurnal Penelitian Kelapa Sawit*, 28(3), 123–132. <https://doi.org/10.22302/iopri.jur.jpks.v28i3.106>
- Husna, I. N., Ulum, M., Saputro, A. K., & Laksono, D. T. (2022). Rancang Bangun Sistem Deteksi Dan Perhitungan Jumlah Orang Menggunakan Metode Convolutional Neural Network (CNN). *SinarFe7*, 5(1), 1–6.

- Intyanto, G. W. (2021). Klasifikasi citra bunga dengan menggunakan deep learning: CNN (convolutional neural network). *Jurnal Arus Elektro Indonesia (JAEI)*, 7(3), 80.
- Irawan, Y. P., & Susilawati, I. (2022). Klasifikasi jenis aglaonema berdasarkan citra daun menggunakan convolutional neural network (CNN). *Journal Of Information System And Artificial Intelligence*, 2(2), 64–70.
- Islamiah, S., Rezeki, S., & Ivontianti, W. D. (2021). Studi Pengaruh Tingkat Kematangan Buah Kelapa Sawit Terhadap Kandungan Asam Lemak Melalui Metode Maserasi. *Rafflesia Journal of Natural and Applied Sciences*, 1(1), 40–49. <https://doi.org/10.33369/rjna.v1i1.15602>
- Krisdiarto, A. W., Sutiarto, L., & Widodo, K. H. (2017). Optimasi Kualitas Tandan Buah Segar Kelapa Sawit dalam Proses Panen-Angkut Menggunakan Model Dinamis. *Agritech*, 37(1), 102. <https://doi.org/10.22146/agritech.17015>
- Mahesh, B. (2020). Machine Learning Algorithms - A Review. *International Journal of Science and Research (IJSR)*, 9(1), 381–386. <https://doi.org/10.21275/ART20203995>
- Salambue, R., & Shiddiq, M. (2019). Klasifikasi kematangan buah sawit menggunakan model warna RGB. *SEMNASITIK 2019*, 434–440.
- Samuel, S., Prilianti, K. R., Setiawan, H., & Mimboro, P. (2022). Metode Deteksi Pokok Pohon Secara Otomatis pada Citra Perkebunan Sawit Menggunakan Model Convolutional Neural Network (CNN) pada Perangkat Lunak Sistem Informasi Geografis. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 9(7), 1689–1698. <https://doi.org/10.25126/jtiik.2022976772>
- Satia, G. A. W., Firmansyah, E., & Umami, A. (2022). Perancangan sistem identifikasi penyakit pada daun kelapa sawit (*Elaeis guineensis* Jacq.) dengan algoritma deep learning convolutional neural networks. *Jurnal Ilmiah Pertanian*, 19(1), 1–10. <https://doi.org/10.31849/jip.v19i1.9556>
- Sitorus, M. L. F., Akoeb, E. N., Sembiring, R., & Siregar, M. A. (2020). Peningkatan Produksi Crude Palm Oil Melalui Kriteria Matang Panen Tandan Buah Segar untuk Optimalisasi Pendapatan Perusahaan. *AGRISAINS: Jurnal Ilmiah Magister Agribisnis*, 2(1), 26–32. <https://doi.org/10.31289/agrisains.v2i1.251>
- Suharjito, Asrol, M., Utama, D. N., Junior, F. A., & Marimin. (2023). Real-Time Oil Palm Fruit Grading System Using Smartphone and Modified YOLOv4. *IEEE Access*, 11, 59758–59773. <https://doi.org/10.1109/ACCESS.2023.3285537>