

Klasifikasi Kematangan Buah Kelapa Sawit Menggunakan Metode *Convolutional Neural Network* (CNN)

^{1st} Yoga Syahputra
Fakultas Teknik Elektro
Telkom University Purwokerto
Purwokerto, Indonesia
yogabude@student.telkomuniversity.
ac.id

^{2nd} Mas Aly Afandi, S.ST., M.T
Fakultas Teknik Elektro
Telkom University Purwokerto
Purwokerto, Indonesia
alyafandi@telkomuniversity.ac.id

^{3rd} Sevia Indah Purnama, S.ST., M.T
Fakultas Teknik Elektro
Telkom University Purwokerto
Purwokerto, Indonesia
seviaindah@telkomuniversity.ac.id

Abstrak — Industri kelapa sawit berperan penting dalam perekonomian global, namun klasifikasi tingkat kematangan buah sawit secara efisien masih menjadi tantangan. Klasifikasi manual memakan waktu dan sumber daya yang besar dengan akurasi yang kurang memadai. Oleh karena itu, pendekatan seperti *Convolutional Neural Network* (CNN) menjadi solusi yang menjanjikan. CNN memanfaatkan kemampuan jaringan saraf tiruan untuk memahami fitur kompleks dalam gambar, memungkinkan klasifikasi otomatis yang lebih akurat. Penelitian ini menggunakan CNN untuk klasifikasi kematangan buah sawit. Dataset gambar buah sawit dengan berbagai tingkat kematangan dikumpulkan dan dibagi menjadi tiga bagian: training (70%, 152 data), validasi (15%, 32 data), dan pengujian (15%, 32 data), dengan total 216 data. Pembagian ini memastikan evaluasi kinerja model yang seimbang dan akurat. Model yang dihasilkan diharapkan mampu mengenali dan mengklasifikasikan buah sawit berdasarkan tingkat kematangan dengan lebih efektif. Hasil pengujian menunjukkan bahwa selama epoch 1-20, akurasi training mencapai 100% dan loss menurun hingga 2,24%, sementara akurasi validasi stabil di sekitar 95%. Epoch terbaik tercatat pada epoch ke-20 dengan akurasi 100% dan loss 2,24% untuk training, serta loss validasi 12,04%. Confusion matrix menunjukkan 13 prediksi benar untuk buah matang dan 16 untuk buah mentah, dengan 3 false negatives dan tanpa false positives. Model memiliki akurasi 90,63%, presisi 100%, dan recall 81,25%

Kata kunci— AI, CNN, Buah Sawit, Klasifikasi

I. PENDAHULUAN

Meningkatnya permintaan global terhadap minyak sawit, didorong oleh peran ekonomi dan kontribusinya yang signifikan terhadap industri minyak nabati, menjadikan klasifikasi kematangan buah kelapa sawit yang efisien menjadi penting. Minyak kelapa sawit menyumbang lebih dari 30% pasokan minyak nabati dunia, dengan Indonesia dan Malaysia memimpin sebagai produsen terbesar, mencakup sekitar 85% produksi global [1]. Industri ini sangat penting untuk neraca perdagangan, pengendalian inflasi, pengeluaran pemerintah, dan pertumbuhan investasi. Selain itu, praktik pertanian berkelanjutan kini mengutamakan efisiensi dalam pemanfaatan sumber daya untuk memaksimalkan potensi produksi sekaligus meminimalkan kerugian [2].

Memastikan pasokan minyak sawit yang stabil memerlukan sistem klasifikasi kematangan buah yang akurat, karena faktor ini berdampak langsung pada kualitas minyak sawit mentah (CPO) [3]. Tiga faktor penentu kualitas CPO adalah tandan buah segar tingkat kematangan (TBS), rendahnya kandungan asam lemak bebas, dan efisiensi yang tinggi dari ekstraksi. Metode klasifikasi tradisional, yang bergantung pada penilaian manusia, seringkali bersifat subjektif, memakan waktu, dan tidak konsisten [4]. Keterbatasan ini menjadikan otomatisasi sebagai langkah penting dalam meningkatkan akurasi dan keandalan klasifikasi dalam industri.

Kemajuan dalam kecerdasan buatan (AI) telah membuka jalan bagi sistem klasifikasi otomatis yang meningkatkan efisiensi dalam pengolahan minyak sawit [5]. Teknik deteksi berbasis gambar menggunakan AI terbukti sangat akurat dalam mengidentifikasi tingkat kematangan buah. Pembelajaran mendalam, khususnya *Convolutional Neural Networks* (CNN), adalah salah satu metode paling efektif untuk tugas klasifikasi visual, karena meniru penglihatan manusia dalam memproses pola gambar yang kompleks. Penerapan CNN memungkinkan klasifikasi kematangan buah kelapa sawit yang lebih tepat, konsisten, dan terukur, mengurangi ketergantungan pada penilaian manusia dan meningkatkan produktivitas [6].

Penelitian ini bertujuan untuk mengembangkan sistem otomatis berbasis CNN untuk mengklasifikasikan kematangan buah kelapa sawit, sehingga menawarkan alternatif yang lebih efisien dibandingkan metode tradisional. Dengan memanfaatkan teknik pembelajaran mendalam, petani dan pelaku industri dapat mengoptimalkan proses pemanenan, memastikan hanya buah matang yang dipilih untuk diproduksi. Penelitian ini mengevaluasi kinerja CNN dalam membedakan buah sawit matang dan mentah, serta berkontribusi terhadap kemajuan teknologi dalam pertanian cerdas. Pada akhirnya, pendekatan ini berupaya meningkatkan akurasi klasifikasi, meningkatkan produktivitas, dan mendukung produksi minyak sawit berkelanjutan.

II. KAJIAN TEORI

A. Penelitian Terkait

Penelitian yang dilakukan oleh Abdulrazak Yahya Saleh dan Ermawati Liansitim berjudul *Palm Oil Classification Using Deep Learning* menganalisis efektivitas CNN dalam mengklasifikasikan tingkat kematangan buah kelapa sawit. menggunakan 628 foto yang dibagi ke dalam dua kelas, matang dan mentah, model CNN berhasil mencapai akurasi 98% setelah lima epoch pelatihan, menunjukkan kemampuannya yang unggul dalam mengenali fitur visual seperti tekstur dan warna [7].

Herman dan rekan-rekannya, dalam penelitian berjudul *Oil Palm Fruit Image Ripeness Classification with Computer Vision Using Deep Learning and Visual Attention*, mengembangkan model berbasis DenseNet dengan mekanisme residual visual attention. Menggunakan 400 gambar yang mencakup tujuh tingkat kematangan serta teknik praproses untuk meningkatkan variabilitas data, model ini mencapai akurasi 69%, menyoroti potensi mekanisme visual attention dalam meningkatkan akurasi klasifikasi [8].

Penelitian oleh Indra Alfredo dan Suhajito, *Optimization of AlexNet Model for Detecting Oil Palm Ripeness Using Image Enhancement and Hyperparameter Tuning*, menggunakan dataset berisi 6.000 gambar yang dikategorikan ke dalam enam tingkat kematangan. Dengan tuning hyperparameter dan teknik peningkatan citra, model AlexNet yang dioptimalkan mencapai akurasi tinggi sebesar 95,53%, menunjukkan pentingnya strategi ini dalam proses otomatisasi pengolahan kelapa sawit [6].

Elok Faiqotul Himmah dan rekan-rekannya, dalam penelitian berjudul *Identification of Oil Palm Fruit Ripeness Based on RGB and HSV Color Features Using K-Means Clustering*, menerapkan MATLAB dan metode K-Means clustering untuk klasifikasi berbasis warna. Dengan menggunakan fitur RGB dan HSV, model ini mengkategorikan buah kelapa sawit ke dalam kategori mentah, setengah matang, dan matang, dengan akurasi sebesar 64,58% [10].

Penelitian serupa oleh Prateek Dutta, *Palm Oil Classification Using Deep Learning*, melatih model CNN dengan dataset berisi 628 gambar, mencapai akurasi 95,6% setelah lima epoch, yang semakin menegaskan efektivitas CNN dalam klasifikasi tingkat kematangan [11].

B. Buah Kelapa Sawit

Kelapa sawit merupakan salah satu komoditas perkebunan yang paling penting dan berkontribusi besar pada perekonomian nasional. Selain meningkatkan neraca perdagangan, kelapa sawit juga membantu menekan inflasi, mengurangi belanja pemerintah, dan meningkatkan hasil investasi. Dengan statusnya sebagai produsen dan eksportir terbesar di dunia, Indonesia memiliki peluang besar dalam pasar minyak kelapa sawit dan minyak inti sawit. Produk-produk ini banyak digunakan di berbagai sektor, seperti fraksinasi, lemak khusus, margarin, oleokimia, dan pembuatan sabun. Permintaan terbesar untuk *Crude Palm Oil* (CPO) bermula dari industri minyak goreng dengan kebutuhan rata-rata nilainya mencapai 4,21 juta ton per tahun, sementara total kebutuhan domestik untuk industri pengolahan mencapai 5,43 juta ton per tahun. Selain itu, dalam beberapa tahun terakhir, CPO semakin diminati

sebagai bahan baku produksi biodiesel, baik untuk kebutuhan domestik maupun internasional.

Buah kelapa sawit (*Elaeis guineensis*) adalah bagian utama dari tanaman kelapa sawit yang digunakan untuk menghasilkan minyak sawit. Buah ini tumbuh dalam tandan besar dengan berat antara 20-50 kilogram per tandan, tergantung pada usia dan varietas pohon. Struktur buah sawit mencakup tiga lapisan yaitu: kulit luar (eksokarp), lapisan daging buah berserat (mesokarp), dan biji keras di tengah (endokarp) yang melindungi inti biji. Minyak sawit mentah (*Crude Palm Oil* atau CPO) dikeluarkan dari mesokarp, sedangkan minyak inti sawit (Palm Kernel Oil atau PKO) didapat dari bijinya.

Secara kimiawi, buah sawit kaya akan trigliserida dan asam lemak, menjadikannya bahan baku utama untuk berbagai produk seperti minyak goreng, margarin, biodiesel, dan bahan baku kosmetik. Tanaman kelapa sawit mulai berbuah pada usia tiga hingga empat tahun dan dapat terus berproduksi secara optimal hingga usia 20-25 tahun. Tingkat kematangan buah sawit sangat memengaruhi kualitas minyak yang dihasilkan; buah yang belum matang menghasilkan minyak yang mengandung banyak asam lemak bebas, sementara buah yang terlalu matang menghasilkan minyak dengan kualitas lebih rendah. Oleh karena itu, panen dilakukan berdasarkan tingkat kematangan optimal untuk memaksimalkan hasil produksi dan kualitas minyak. Contoh gambar Buah kelapa sawit tampak pada Gambar 1 [12].



(a) (b)
GAMBAR 1
Buah sawit (a) Matang, (b) Mentah


C. Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan arsitektur yang dapat dilatih yang terdiri dari beberapa tahapan, meliputi tahapan pemasukan, pemrosesan, dan pengeluaran [16]. Tahap input menerima data mentah, seperti gambar atau video, yang kemudian diproses melalui beberapa lapisan, termasuk lapisan konvolusional, lapisan penggabungan, dan lapisan yang terhubung sepenuhnya. Setiap lapisan memiliki fungsi tertentu, seperti ekstraksi fitur, reduksi dimensi data, dan pembuatan prediksi. Kombinasi berlapis ini memungkinkan CNN memproses data secara hierarki, dari fitur sederhana hingga kompleks.

CNN adalah arsitektur pembelajaran mendalam yang sangat efektif dalam mengidentifikasi pola spasial. Dengan kemampuannya, CNN dapat mendeteksi dan mengenali objek dalam suatu gambar [17]. Ini dapat mengidentifikasi fitur seperti tekstur, tepi, atau bentuk tertentu, sehingga cocok untuk pekerjaan seperti klasifikasi gambar, deteksi objek, dan segmentasi gambar.

Karena kemampuannya yang unggul dalam memahami struktur spasial, CNN telah menjadi teknologi dominan dalam berbagai aplikasi, termasuk pengenalan wajah, analisis citra medis, dan sistem kendaraan otonom. Kemampuan

pemrosesan hierarkinya memungkinkannya mencapai akurasi tinggi dalam tugas pengenalan visual yang kompleks.




GAMBAR 2
Arsitektur CNN

Pada Gambar 2, CNN melibatkan serangkaian proses yang mencakup operasi konvolusi dan penggabungan lapisan untuk memproses data. Ada empat tahapan dalam CNN: masukan, tahap ekstraksi fitur, tahap klasifikasi, dan keluaran. Melalui tahapan tersebut, CNN dapat membentuk suatu sistem yang mampu mengenali objek atau gambar bahkan melakukan aktivitas serupa dengan manusia.

CNN menginstruksikan dan menguji setiap gambar yang dimasukkan melalui berbagai prosedur, dimulai dengan lapisan konvolusional diikuti dengan pengumpulan untuk mengekstrak karakteristik gambar masukan secara berurutan. Setelah proses pengumpulan, gambar diubah menjadi bentuk rata dan kemudian dimasukkan ke dalam lapisan yang terhubung sepenuhnya untuk tugas klasifikasi. Arsitektur CNN menggambarkan struktur dan urutan proses dalam metode CNN [16].

III. METODE PENELITIAN

Penelitian ini dilakukan dalam beberapa tahap yang dapat dilihat pada Gambar 3.



GAMBAR 3
Alur Penelitian


Berdasarkan Gambar 3, penelitian diawali dengan tinjauan pustaka mengumpulkan data dan informasi yang diperlukan. Prosesnya melibatkan sumber informasi dari jurnal, buku, dan artikel dari situs web yang berkaitan dengan topik klasifikasi gambar. Referensi mencakup publikasi

nasional dan internasional. Materi yang dipelajari untuk mendukung penelitian ini antara lain klasifikasi kematangan buah kelapa sawit, citra digital, deep learning, algoritma Convolutional Neural Network (CNN), metode Sequential, pengembangan dataset pelatihan, validasi dan pengujian, serta tingkat kesalahan dan pengukuran akurasi. Rumusan masalah meliputi tujuan penelitian, objek, dan metode yang akan digunakan. Penelitian ini fokus pada klasifikasi kematangan buah kelapa sawit dan menentukan tingkat akurasi yang dicapai pada citra buah kelapa sawit menggunakan metode Convolutional Neural Network.

Proses pengumpulan data meliputi pengumpulan data buah kelapa sawit yang terdiri dari dua kategori: matang dan mentah. Data dikumpulkan secara langsung untuk menghindari plagiarisme dan menambah keunikan penelitian. Karena penelitian ini berfokus pada gambar buah kelapa sawit, pengambilan gambar secara langsung akan menjamin kualitas data yang lebih baik. Data gambar diperoleh dengan mengambil foto menggunakan smartphone Android Vivo Y12, dengan jarak foto 25 cm. Untuk menghasilkan gambar yang lebih jelas, kamera diatur ke mode malam. Pengambilan gambar dilakukan pada masing-masing buah kelapa sawit yang sudah matang dan belum matang, dengan proses pendataan yang memakan waktu lebih dari satu jam.

A. Pembuatan Model CNN

Penelitian ini fokus pada klasifikasi kematangan buah kelapa sawit dengan menggunakan metode Convolutional Neural Network (CNN) yang dapat mendeteksi fitur secara otomatis dari data yang disediakan. Metode ini mencakup dua tahap utama. Bagian pertama adalah pembelajaran fitur, yang melibatkan dua lapisan utama: lapisan konvolusional dan lapisan pengumpulan. Setelah melewati lapisan-lapisan tersebut, fungsi aktivasi ReLU digunakan sebagai fungsi aktivasi pada tahap ini. Tahap kedua adalah klasifikasi, yang mencakup lapisan yang terhubung sepenuhnya dimana fungsi aktivasi softmax diterapkan untuk melakukan klasifikasi. Rencana desain model dapat dilihat pada Gambar 4.



GAMBAR 4
Desain Model CNN

B. Parameter Model CNN

Selanjutnya pada proses klasifikasi terdapat operasi perataan yang digunakan untuk mengubah array multidimensi menjadi array satu dimensi. Ini diikuti oleh lapisan terhubung penuh yang menerapkan metode padat untuk menghubungkan setiap neuron dengan neuron di lapisan sebelumnya dan selanjutnya. Proses kemudian dilanjutkan ke klasifikasi menggunakan fungsi aktivasi sigmoid karena jumlah kelasnya dua.

TABEL 1
PARAMETER MODEL CNN

Parameter	Configuration
Filter	16,32,64
Kernel Size	3x3
Pooling	Maximum Pooling
Dense	128
Activation	ReLU + Softmax
Neuron Output Layer	2
Optimisation	Adam

Tabel 1 menunjukkan parameter yang digunakan untuk klasifikasi, memanfaatkan penggabungan maksimum sebagai jenis pengumpulan. Ukuran kernel atau pemilihan data di lapisan konvolusi diatur ke 3x3. Parameter lain yang digunakan adalah sebagai berikut.

Jumlah filter mewakili nilai filter yang diterapkan pada input, yaitu 16, 32, dan 64. Operasi konvolusi dilakukan sebanyak jumlah filter yang disediakan [27]. Pemilihan filter 16, 32, dan 64 pada CNN bertujuan untuk menangkap fitur secara progresif, dari yang sederhana hingga yang kompleks. Filter yang lebih kecil di awal mengurangi kebutuhan komputasi, sementara filter yang lebih besar di lapisan selanjutnya memungkinkan jaringan mempelajari pola yang lebih kompleks. Pendekatan ini menyeimbangkan performa

model dan risiko overfitting dan biasanya digunakan dalam arsitektur CNN yang populer.

Ukuran kernel mewakili dimensi kernel yang digunakan untuk proses konvolusi. Lapisan pooling mengurangi ukuran spasial dengan memilih piksel yang lebih penting, dengan pooling maksimum memilih nilai piksel terbesar dari piksel sebelumnya. Lapisan padat menambahkan lapisan terhubung penuh yang terdiri dari 128 neuron. Fungsi aktivasi ReLU mengubah nilai filter negatif menjadi nol. Neuron lapisan keluaran mewakili jumlah kelas yang digunakan untuk klasifikasi, yaitu 2. Adam adalah metode yang digunakan untuk menghitung kecepatan pembelajaran untuk parameter yang berbeda. Penelitian ini juga menganalisis akurasi, presisi dan recall menggunakan epoch 100 untuk mengetahui kinerjanya

C. Pembagian Data Set

Distribusi data pada Tabel 2 dibagi menjadi persentase sebesar 70% untuk data Training, 15% untuk data Validasi, dan 15% untuk data Testing.

TABEL 2
DISTRIBUSI DATA SET

Data	Distributionnn	Dataset	Total Dataset
Training	70%	152	216
Validation	15%	32	
Testing	15%	32	


IV. HASIL DAN PEMBAHASAN

A. Hasil Training dan Validation


Dari total 216 gambar dalam dataset buah sawit matang dan mentah, sebanyak 152 gambar digunakan untuk proses pelatihan. Data pelatihan didistribusikan secara merata, dengan 50% gambar mewakili buah matang dan 50% mewakili buah mentah. Proses pelatihan bertujuan untuk melatih model agar dapat mengenali pola spesifik pada setiap kategori, seperti perbedaan warna, tekstur, dan karakteristik lainnya yang membedakan buah matang dari buah mentah. Dengan distribusi yang seimbang, model diharapkan mampu mencapai generalisasi yang baik ketika diterapkan pada data baru.

Selain itu, 32 gambar digunakan untuk proses validasi. Data validasi juga didistribusikan secara merata, dengan 50% gambar untuk buah matang dan 50% untuk buah mentah. Proses validasi dilakukan untuk mengevaluasi kinerja model pada data pelatihan yang tidak digunakan, memastikan bahwa model tidak overfitting dan dapat mempertahankan akurasi pada data baru. Validasi juga menjadi langkah penting untuk mendeteksi kelemahan model sebelum diterapkan pada data uji.

Setelah dataset dipersiapkan, model dikompilasi menggunakan Adam optimizer dan perhitungan loss dengan binary cross-entropy, dengan akurasi sebagai metrik evaluasi. Proses pemodelan dilakukan selama 0 hingga 100 epoch. Hasil akurasi model dapat dilihat pada Gambar 5, sedangkan hasil loss ditampilkan pada Gambar 6.



GAMBAR 5
Hasil Akurasi Training dan Validation berdasarkan Epoch



GAMBAR 6
Hasil Loss Training dan Validation berdasarkan Epoch

Gambar 5 menunjukkan grafik keakurasian model CNN untuk Training dan validasi berdasarkan variasi epoch. Sumbu X merepresentasikan nilai epoch dari 1 hingga 100, sedangkan sumbu Y menunjukkan akurasi model. Gambar 6 menggambarkan grafik loss untuk Training dan validasi CNN berdasarkan variasi epoch, dengan sumbu X menunjukkan nilai epoch dari 1 hingga 100, dan sumbu Y menunjukkan nilai loss model. Berdasarkan Gambar 5 dan 6, model menunjukkan peningkatan performa yang signifikan pada epoch awal sebelum stabil dengan fluktuasi kecil di epoch-epoch berikutnya. Pada epoch pertama, akurasi Training dimulai dari 57,86% dengan nilai loss 76,89%, sedangkan akurasi validasi mencapai 50% dengan nilai loss 69,05%. Hal ini menunjukkan bahwa model awalnya kesulitan mempelajari pola data secara efektif, namun proses Training menunjukkan kemajuan pada epoch-epoch berikutnya. Akurasi terbaik tercapai pada epoch ke-20, di mana akurasi Training dan validasi sama-sama mencapai 100%, dengan nilai loss masing-masing sebesar 2,24% untuk Training dan 12,04% untuk validasi, menunjukkan kemampuan optimal model dalam mengenali pola pada dataset.

Namun, performa model tidak sepenuhnya konsisten setelah mencapai akurasi puncaknya. Meskipun akurasi Training tetap stabil di angka 1,0 pada epoch-epoch berikutnya, akurasi validasi mulai menurun secara perlahan seiring waktu. Hal ini mengindikasikan ada kemungkinan overfitting, ketika model terlalu berkonsentrasi pada data pelatihan sehingga kemampuan generalisasi terhadap data validasi menurun. Loss validasi terbaik tercatat pada epoch ke-32 dengan nilai 2,94%, yang menunjukkan tingkat kesalahan yang sangat rendah pada prediksi validasi.


Sebaliknya, loss validasi terburuk terjadi pada epoch ke-40 dengan nilai loss 58,65%. Penurunan ini disertai dengan turunnya akurasi validasi menjadi 84,38%, mengindikasikan bahwa model mulai kehilangan kemampuan mempertahankan performa pada data validasi.

Anomali pada epoch ke-40, di mana loss validasi meningkat signifikan dibandingkan epoch sebelumnya, menunjukkan adanya masalah dalam proses generalisasi model. Beberapa faktor yang mungkin menyebabkannya termasuk model yang mulai terlalu menghafal data Training (overfitting), distribusi data validasi yang tidak mencerminkan data Training, atau adanya outlier dalam data validasi yang menyulitkan prediksi. Selain itu, fluktuasi seperti ini juga dapat disebabkan oleh tingkat pembelajaran yang terlalu tinggi, sehingga model membuat pembaruan parameter yang terlalu agresif, menyebabkan performa validasi menjadi tidak stabil.

Berdasarkan temuan ini, epoch terbaik tercatat pada epoch ke-20, di mana akurasi Training dan validasi mencapai 100%, dengan nilai loss masing-masing 2,24% untuk Training dan 12,04% untuk validasi. Loss validasi terbaik tercatat pada epoch ke-32 dengan nilai 2,94%, sedangkan loss validasi terburuk terjadi pada epoch ke-40 dengan nilai 58,65%, disertai penurunan akurasi validasi menjadi 84,38%.

B. Hasil Pengujian

Setelah proses pelatihan dan validasi selesai, model berhasil disimpan untuk memastikan performa optimal pada tahap pengujian. Langkah pengujian dilakukan untuk mengevaluasi kemampuan model dalam mengenali pola pada data baru belum pernah digunakan sebelumnya. Hasil evaluasi ditampilkan dalam bentuk matriks konfusi, yang memberikan informasi tentang jumlah prediksi yang salah dan benar untuk setiap kategori, seperti buah sawit matang dan mentah. Matriks konfusi ini, yang dapat dilihat pada Gambar 7, memberikan gambaran detail mengenai akurasi model dan potensi kesalahan, menjadi dasar untuk analisis kinerja dan pengembangan lebih lanjut.



GAMBAR 7
Hasil Confusion Matrix

Berdasarkan matriks konfusi pada Gambar 7, model ini membandingkan label sebenarnya dengan label prediksi, sehingga menunjukkan seberapa baik model mengklasifikasikan data. Analisis menunjukkan bahwa model tersebut memprediksi dengan tepat 13 contoh buah kelapa sawit matang dan 16 contoh buah mentah, yang menunjukkan kinerja klasifikasi yang baik. Namun, ada

beberapa kesalahan, dengan tidak ada positif palsu (buah matang salah diklasifikasikan sebagai mentah) namun tiga negatif palsu (buah mentah salah diklasifikasikan sebagai matang). Hal ini menunjukkan bahwa meskipun model tersebut dapat mengidentifikasi buah yang matang dengan baik, model tersebut mengalami kesulitan dalam mengidentifikasi buah yang belum matang.

Dengan menggunakan data matriks konfusi, metrik evaluasi utama seperti akurasi, presisi, dan perolehan dapat ditentukan untuk menilai performa model. Akurasi mewakili proporsi prediksi yang benar, presisi mengukur seberapa baik model menghindari kesalahan positif, dan recall mengevaluasi kemampuan model untuk mendeteksi dengan benar semua kejadian dalam kategori tertentu, khususnya buah kelapa sawit yang belum matang. Metrik ini membantu menganalisis kekuatan dan kelemahan model.

Dari evaluasi, model mencapai akurasi 90,63%, yang menunjukkan efektivitas keseluruhan dalam klasifikasi. Skor presisinya adalah 100%, yang menunjukkan bahwa semua perkiraan kejadian buah matang telah diklasifikasikan dengan benar. Namun, skor perolehannya adalah 81,25%, yang menunjukkan bahwa model tersebut melewati beberapa contoh buah mentah. Hasil ini menyoroti bahwa meskipun model ini sangat presisi dalam mengidentifikasi buah matang, model ini memerlukan perbaikan dalam mendeteksi buah mentah untuk meningkatkan kemampuan generalisasinya. Pengoptimalan lebih lanjut dapat dilakukan dengan menyesuaikan parameter pelatihan atau menyempurnakan kumpulan data untuk meningkatkan perolehan tanpa mengurangi akurasi.

V. KESIMPULAN

Akurasi dan loss model menunjukkan bahwa selama epoch 1-20, akurasi Training meningkat secara signifikan hingga mencapai 100%, sementara loss Training menurun tajam hingga 2,24%. Namun, akurasi validasi tetap stabil di sekitar 95,00%, yang mengindikasikan adanya potensi overfitting sejak awal proses pelatihan. Epoch terbaik tercatat pada epoch ke-20, di mana akurasi Training dan validasi sama-sama mencapai 100%, dengan nilai loss 2,24% untuk Training dan 12,04% untuk validasi. Namun, loss validasi terbaik terjadi pada epoch ke-32 dengan nilai 2,94%, yang menunjukkan optimasi yang lebih baik dibandingkan epoch lainnya. Berdasarkan matriks konfusi, model berhasil mengklasifikasikan 13 gambar buah sawit matang dan 16 gambar buah sawit mentah dengan benar, dengan tiga kesalahan false negative dan tanpa false positive. Perhitungan menunjukkan akurasi model sebesar 90,63%, presisi 100%, dan recall 81,25%, yang mengindikasikan bahwa model memiliki kinerja yang baik dalam mengidentifikasi buah sawit matang maupun mentah.

REFERENSI

- [1] S. Tarmadja, M. Vernando, and T. N. B. Santosa, "Kehilangan Hasil Dalam Proses Panen Kelapa Sawit," *Pros. Semin. Nas. Instiper*, vol. 1, no. 1, pp. 79–84, 2022, doi: 10.55180/pro.v1i1.245.
- [2] S. A. Ghazali, H. Selamat, Z. Omar, and R. Yusof, "Image Analysis Techniques for Ripeness Detection of Palm Oil Fresh Fruit Bunches," *Elektr. J. Electr. Eng.*, vol. 18, no. 3, pp. 57–62, 2019, doi:10.1113/elektrika.v18n3.192.
- [3] W. I. W. Ishak and R. M. Hudzari, "Image based modeling for oil palm fruitmaturity prediction," *J. Food, Agric. Environ.*, vol. 8, no. 2, pp. 469–476, 2010.
- [4] W. E. Sari, M. Muslimin, A. Franz, and P. Sugiartawan, "Deteksi Tingkat Kematangan Tandan Buah Segar Kelapa Sawit dengan Algoritme K-Means," *SINTECH (Science Inf. Technol. J.)*, vol. 5, no. 2, pp. 154–164, 2022, doi: 10.31598/sintechjournal.v5i2.1146.
- [5] Athallah Tsany Rakha Dzaky, "Deteksi Penyakit Virus Gemini Pada Tanaman Cabai Menggunakan Convolutional Neural Network," *e- Proceeding En*, vol. 8, no. 2, pp. 3039–3055, 2022, [Online]. Available: <https://repository.mercubuana.ac.id/69270/>
- [6] I. W. Suartika E. P., "Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) Pada Caltech," *J. Tek. ITS*, vol. 5, no. 1, p. 76, 2019, [Online].
- [7] A. Y. Saleh and E. Liansitim, "Palm oil classification using deep learning," *Sci. Inf. Technol. Lett.*, vol. 1, no. 1, pp. 1–8, 2020, doi: 10.31763/sitech.v1i1.1.
- [8] Herman, A. Susanto, T. Wawan Cenggoro, Suharjito, and B. Pardamean, "Oil Palm Fruit Image Ripeness Classification with Computer Vision using Deep Learning and Visual Attention," *J. Telecommun. Electron. Comput. Eng.*, vol. 12, no. 2, pp. 21–27, 2020, [Online]. Available: https://farm3.static.flickr.com/2337/2387965665_1d4278c6
- [9] Alfredo and Suharjito, "Perbaikan Model Alexnet Untuk Mendeteksi Kematangan Tbs Kelapa Sawit Dengan Menggunakan Image Enhancement Dan Hyperparameter Tuning," *J. Ilm. Teknol. dan Rekayasa*, vol. 27, no. 1, pp. 56–68, 2022, doi: 10.35760/tr.2022.v27i1.5973.
- [10] E. F. Himmah, M. Widyarningsih, and M. Maysaroh, "Identifikasi Kematangan Buah Kelapa Sawit Berdasarkan Warna RGB Dan HSV Menggunakan Metode K-Means Clustering," *J. Sains dan Inform.*, vol. 6, no. 2, pp. 193–202, 2020, doi: 10.34128/jsi.v6i2.242.
- [11] Prateek Dutta, "Palm oil classification using deep learning," *Int. Jjournal Adv. Res. Ideas Innov. Technol.*, vol. 1, no. 1, pp. 1–8, 2020, doi: 10.31763/sitech.v1i1.1.
- [12] F. Akmal, F. Ramdani, and A. Pinandito, "Sistem Informasi Pengelolaan Perkebunan Kelapa Sawit Berbasis Web GIS," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 5, pp. 1894–1901, 2018.
- [13] R. A. Citra Saragih, Ratya Anindita, "Analisis Komoditas Kelapa Sawit (Elaeis Guineensis Jacq) Di Indonesia," *J. Ekon. Pertan. dan Agribisnis*, vol. 6, no. 2, pp. 478–486, 2022.
- [14] Siti Rahmah Danur Amiril, "Implementasi Algoritma Convolutional Neural Network Pada Klasifikasi Penyakit Padi Melalui Citra Daun," Universitas Islam Indonesia, 2020.
- [15] S. Ilahiyah and A. Nilogiri, "Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network," vol. 3, no. 2, pp. 49–56, 2018, doi: doi.org/10.32528/justindo.v3i2.2254.
- [16] S. Faisal, T. F. Butarbutar, and P. Sirait, "Implementasi CNN dan SVM untuk Identifikasi Penyakit Tomat via Daun," *J. SIFO Mikrosil*, vol. 20, no. 2, pp. 117–134, 2019, doi: doi.org/10.55601/jsm.v20i2.670.
- [17] U. K. Enie Yuliani, Afifah Nur Aini, "Perbandingan Jumlah Epoch Dan Steps Per Epoch Pada Convolutional Neural Network Untuk Meningkatkan Akurasi Dalam Klasifikasi Gambar," *J. Inf. Politek. Indonusa Surakarta*, vol. 5, no. 3, pp. 2–6, 2019.
- [18] Savira Anggita Sabrina & Wiky Fawwaz Al Maki, "Klasifikasi Penyakit pada Tanaman Kopi Robusta Berdasarkan Citra Daun Menggunakan Convolutional Neural Network," *e-Proceeding Eng.*, vol. 9, no. 3, pp. 1919–1927, 2022.
- [19] A. Asrafil, A. Paliwang, R. D. Septian, M. Cahyanti, and R. Swedia, "Klasifikasi Penyakit Tanaman Apel Dari Citra Daun Dengan Convolutional Neural Network," *Sebatik*, vol. 24, no. 2, pp. 207–212, 2020.
- [20] W. Rawat and Z. Wang, "Deep Convolutional Neural Networks for Image Classification : A Comprehensive Review Deep Convolutional Neural Networks for Image Classification : A Comprehensive Review," *Neural Comput.*, vol. 12, no. 7, pp. 2354–2449, 2017, doi: 10.1162/NECO_a_00990.
- [21] F. A. Ridho Aji Pangestu, Basuki Rahmat, "Implementasi algoritma cnn untuk klasifikasi citra lahan dan perhitungan luas," *J. Inform. dan Sist. Inf.*, vol. 1, no. 1, pp. 166–174, 2020.
- [22] Torangto Yos P. Situngkir, "Klasifikasi Penyakit Pada Daun Kentang Menggunakan Pengolahan Citra Dengan Metode Convolutional Neural Network," Universitas Pembangunan Nasional Veteran Yogyakarta, 2022.
- [23] Cahya Bagus Sanjaya and Muhammad Imron Rosadi, "Klasifikasi buah mangga berdasarkan tingkat kematangan menggunakan least-

- squares support vector machine,” *Explor. IT*, vol. 10, no. 2, pp. 1–13, 2018.
- [24] M. S. Wibawa, “Pengaruh Fungsi Aktivasi, Optimisasi dan Jumlah Epoch Terhadap Performa Jaringan Saraf Tiruan,” *J. Sist. dan Inform.*, vol. 11, no. 1, pp. 167–174, 2018, doi: 10.13140/RG.2.2.21139.94241.
- [25] M. Raihan, R. Allaam, and A. T. Wibowo, “Klasifikasi Genus Tanaman Anggrek Menggunakan Metode Convolutional Neural Network (CNN),” *e-Proceeding Eng.*, vol. 8, no. 2, pp. 1–1153, 2021.
- [26] F. E. Ramadhan, “Penerapan Image Classification Dengan Pre-Trained Model Mobilenet Dalam Client-Side Machine Learning,” 2020.
- [27] C. T. Emanuella, M. Musfita, dan A. Lawi, “Klasifikasi Suara Kucing dan Anjing Menggunakan Convolutional Neural Network,” *Konferensi Nasional Ilmu Komputer (KONIK)*, vol. 1, no. 1, pp. 321–327, 2021.

