

Klasifikasi Penyakit Daun Kelapa Sawit Menggunakan Metode *Convolutional Neural Network* (CNN)

1st Arya Abimanyu
Fakultas Teknik Elektro
Telkom University Purwokerto
Purwokerto, Indonesia
19101111@ittelkom-pwt.ac.id

2nd Mas Aly Afandi
Fakultas Teknik Elektro
Telkom University Purwokerto
Purwokerto, Indonesia
alyafandi@telkomuniversity.ac.id

3rd Sevia Indah Purnama
Fakultas Teknik Elektro
Telkom University Purwokerto
Purwokerto, Indonesia
seviaindah@telkomuniversity.ac.id

Abstrak — Kelapa sawit merupakan salah satu komoditas perkebunan yang memiliki peran strategis dalam pembangunan ekonomi Indonesia. Sebagai tulang punggung ekonomi bagi jutaan penduduk, perkembangan sektor ini menekankan pemenuhan persyaratan guna menjamin hasil produksi yang berkualitas. Tantangan utama yang dihadapi petani adalah penyakit pada tanaman kelapa sawit yang disebabkan oleh hama dan kekurangan unsur hara, yang dapat menghambat pertumbuhan dan mengurangi hasil panen. Kurangnya pengetahuan petani mengenai jenis penyakit daun kelapa sawit sering kali mengakibatkan kesalahan dalam penanganannya. Penelitian ini berfokus pada klasifikasi penyakit daun kelapa sawit menggunakan pengolahan citra berbasis kecerdasan buatan (*Artificial Intelligence*), dengan tujuan membantu petani dalam mengidentifikasi daun sehat dan berpenyakit secara akurat. Metode *Convolutional Neural Network* (CNN) digunakan untuk mengenali pola dan fitur kompleks pada citra daun kelapa sawit. Hasil menunjukkan bahwa akurasi pelatihan meningkat cepat hingga hampir 1 pada epoch 1–20, dengan loss turun signifikan. Namun, akurasi validasi stabil di sekitar 0,95, menandakan adanya *overfitting*. Epoch terbaik tercatat pada epoch 20 dengan akurasi pelatihan 1 dan loss 0,001, sementara akurasi validasi tertinggi terjadi pada epoch 80 sebesar 0,975. Berdasarkan *confusion matrix*, model berhasil mengklasifikasikan daun berpenyakit sebanyak 66 kali dan daun sehat sebanyak 80 kali, dengan 14 kesalahan *false positive* dan tanpa *false negative*. Akurasi model mencapai 91,25%, dengan presisi 82,5% dan *recall* 100%, menunjukkan performa yang baik dalam mengidentifikasi daun sehat dan berpenyakit. Harapannya, penelitian ini dapat menjadi solusi praktis bagi petani dalam mendeteksi penyakit daun kelapa sawit secara cepat dan akurat, meminimalkan kesalahan, dan meningkatkan hasil pertanian secara keseluruhan.

Kata kunci— AI, CNN, Daun Sawit, Klasifikasi

I. PENDAHULUAN

Tanaman kelapa sawit (*Elaeis guineensis* Jacq) merupakan salah satu komoditas perkebunan dengan prospek industri yang menjanjikan, baik di pasar domestik maupun internasional [1]. Kelapa sawit menjadi tanaman penting secara global karena menghasilkan minyak yang digunakan sebagai bahan baku minyak nabati dan biodiesel [2]. Sejak awal pengembangan perkebunan, kelapa sawit menjadi sektor prioritas di Indonesia, terutama bagi perusahaan milik negara seperti PT. Perkebunan Nusantara. Tanaman ini memiliki

peran besar dalam peningkatan devisa negara, sehingga memerlukan perawatan optimal untuk mendapatkan hasil panen yang berkualitas [3]. Menurut [4], Pusat Penelitian Kelapa Sawit (PPKS) mengelola sekitar 80% dari 364 juta tanaman kelapa sawit di Indonesia. PPKS berfokus pada peningkatan kualitas dan kuantitas produksi kelapa sawit. Oleh karena itu, perawatan yang baik sangat diperlukan untuk menghasilkan benih unggul dan mencegah serangan berbagai penyakit yang dapat merusak tanaman [5].

Saat ini, berbagai jenis penyakit yang menyerang kelapa sawit serta cara penanggulangannya masih belum banyak diketahui oleh petani maupun masyarakat umum. Serangan penyakit yang sering terjadi menyebabkan petani kesulitan dalam mendeteksi serta menangani penyakit kelapa sawit akibat keterbatasan pengetahuan [6]. Hampir seluruh bagian tanaman kelapa sawit rentan terhadap serangan penyakit, terutama bagian daun. Kondisi ini dapat menyebabkan gagal panen serta menurunkan kualitas buah kelapa sawit. Deteksi dini penyakit sangat penting untuk mengurangi risiko kerusakan dan kerugian di perkebunan [7]. Oleh karena itu, identifikasi dan klasifikasi penyakit tanaman kelapa sawit perlu dilakukan dengan tepat agar dapat diterapkan langkah pengendalian yang efektif.

Berdasarkan permasalahan yang telah diuraikan, penelitian ini berfokus pada klasifikasi kesehatan tanaman kelapa sawit dengan menganalisis warna daunnya. Dengan menerapkan pengolahan citra berbasis kecerdasan buatan, penelitian ini bertujuan untuk membantu petani dalam mengurangi kesalahan dalam mendeteksi penyakit daun kelapa sawit. Sistem klasifikasi yang dirancang diharapkan dapat mempermudah petani dalam membedakan daun yang sehat dan yang terinfeksi penyakit [8].

Metode yang banyak digunakan dalam pengolahan citra adalah *Convolutional Neural Network* (CNN). CNN merupakan salah satu algoritma dalam *deep learning* yang dirancang untuk mengolah data dua dimensi dalam bentuk gambar. Secara teknis, CNN merupakan arsitektur yang dapat dilatih dengan beberapa tahapan utama, yaitu *convolution layer*, *activation function layer*, dan *pooling layer* [9]. CNN sering digunakan dalam pemrosesan citra karena memiliki tingkat akurasi tinggi serta lebih efektif dalam mengenali objek visual [10].

Oleh karena itu, penelitian ini bertujuan untuk menerapkan metode *Convolutional Neural Network* (CNN) dalam sistem klasifikasi penyakit daun kelapa sawit. Selain itu, penelitian ini juga menganalisis tingkat akurasi serta mengevaluasi hasil implementasi sistem yang dikembangkan. Harapannya, sistem

ini dapat membantu petani dalam mengidentifikasi daun kelapa sawit yang sehat maupun yang terinfeksi secara lebih akurat dan efisien. Selain itu, penelitian ini juga mengevaluasi efektivitas metode CNN dalam klasifikasi penyakit daun kelapa sawit guna memberikan solusi yang lebih optimal dalam mendukung produktivitas perkebunan kelapa sawit.

II. KAJIAN TEORI

A. Penelitian Terkait

Penelitian Beberapa penelitian terkait penyakit daun kelapa sawit telah dilakukan oleh [11] dalam studinya berjudul *Klasifikasi Penyakit Daun Sawit Menggunakan Metode Jaringan Saraf Tiruan Dengan Fitur Local Binary Pattern*. Studi ini menawarkan diagnosis penyakit kelapa sawit menggunakan metode klasifikasi Jaringan Saraf Tiruan (JST) dan metode ekstraksi fitur Local Binary Pattern (LBP). Data diperoleh dari dataset *date-palm-data* di Kaggle yang berisi 2.631 citra penyakit daun sawit, dengan 320 citra yang digunakan dalam penelitian ini. Gambar-gambar tersebut dibagi menjadi tiga kategori: *health*, *brown spot*, dan *white scale*. Sebelum klasifikasi dilakukan, gambar dikonversi ke grayscale dan diekstraksi menggunakan LBP. Model JST diuji dengan 17 fungsi pelatihan, menghasilkan akurasi tertinggi sebesar 97% dengan 10 neuron. Fungsi pelatihan terbaik yang digunakan adalah *trainbr*, yang mencapai akurasi 100% dengan 5 neuron dan presisi serta recall 100% dengan 10 neuron [11].

Penelitian lain dilakukan oleh [12] dengan judul *Klasifikasi Citra Kualitas Bibit dalam Meningkatkan Produksi Kelapa Sawit Menggunakan Metode Convolutional Neural Network (CNN)*. Studi ini menggunakan 612 foto bibit kelapa sawit yang diambil langsung di lapangan dengan kamera DSLR. Bibit diklasifikasikan ke dalam empat kategori, yaitu bibit bagus, bibit dengan penyakit jamur *Curvularia*, serta bibit yang terkena hama belalang dan kumbang malam. Dataset diolah menggunakan metode *transfer learning* dengan model ResNet50. Model yang dikembangkan dalam bahasa pemrograman Python ini berhasil mengklasifikasikan data dengan akurasi 95%. Hasil ini menunjukkan bahwa metode CNN dengan pendekatan *transfer learning* dapat menjadi strategi yang efektif untuk mengklasifikasikan kualitas bibit kelapa sawit secara lebih akurat [12].

Penelitian berikutnya dilakukan oleh [13] dengan judul *Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode Convolutional Neural Network (CNN)*. Penelitian ini bertujuan untuk mengklasifikasikan kesehatan tanaman tomat berdasarkan warna daunnya menggunakan arsitektur model VGG-16. Dataset terdiri dari 10 kelas penyakit tanaman tomat dan diperoleh melalui situs Kaggle. Hasil klasifikasi menunjukkan bahwa model CNN dengan VGG-16 mencapai akurasi pelatihan sebesar 98% dan akurasi validasi sebesar 82%. Selain itu, model yang dikembangkan telah diimplementasikan ke dalam sistem berbasis web. Diharapkan sistem ini dapat digunakan oleh petani atau peneliti untuk mengidentifikasi penyakit tanaman tomat dengan lebih efisien [13].


Penelitian selanjutnya oleh [14] berjudul *Machine Learning for Detection of Palm Oil Leaf Disease Visually using Convolutional Neural Network Algorithm*. Studi ini bertujuan untuk mengembangkan perangkat lunak berbasis *machine learning* dan *computer vision* guna mendeteksi

penyakit daun kelapa sawit secara otomatis. Model CNN diterapkan pada dataset berisi 60 gambar daun, dengan 50 gambar menunjukkan lima jenis penyakit, yaitu *Curvularia sp*, *Cochliobolus carbonus*, *Capnodium sp*, *Drechslera*, dan defisiensi unsur hara, serta 10 gambar daun sehat. Hasil pengujian menunjukkan bahwa model CNN dapat mendeteksi penyakit dengan akurasi hingga 99%, meskipun akurasi keseluruhan pengujian berada di angka 69% [14].

Dalam penelitian ini, dilakukan tinjauan terhadap berbagai studi terdahulu yang berkaitan dengan penyakit daun kelapa sawit dan metode Convolutional Neural Network. Studi-studi yang dianalisis menunjukkan relevansi langsung maupun tidak langsung dengan topik yang diteliti. Literatur yang digunakan tidak hanya sebagai dasar teori, tetapi juga memberikan bukti empiris yang mendukung penelitian ini. Dengan landasan yang kuat dari penelitian sebelumnya, studi ini memiliki kerangka kerja yang kokoh dan lebih terarah.

B. Penyakit Daun Kelapa Sawit

Kesehatan tanaman berperan penting dalam meningkatkan produktivitas serta keberlanjutan produksi. Sebuah tanaman dikatakan sehat jika menunjukkan pertumbuhan yang optimal, seperti memiliki daun dan batang yang segar. Tanaman yang sehat mampu menjalankan fungsi biologisnya secara efisien, termasuk dalam proses fotosintesis, metabolisme, penyerapan, serta distribusi zat hara dan air. Namun, gangguan yang disebabkan oleh hama atau penyakit dapat menghambat proses fisiologis tersebut, yang berdampak negatif terhadap pertumbuhan dan hasil produksi tanaman [17].



GAMBAR 1

Jenis – jenis penyakit daun kelapa sawit (a) Bercak daun, (b) Karat daun, (c) Serangan ulat, (d) Kekurangan unsur hara [17].

Gambar 1 menunjukkan berbagai gejala kerusakan pada daun tanaman, seperti bercak daun, karat daun, serangan ulat, dan kekurangan unsur hara. Setiap gejala memiliki penyebab dan dampak yang berbeda terhadap pertumbuhan tanaman. Pemahaman yang baik mengenai gejala-gejala ini penting untuk menentukan langkah pengendalian yang tepat agar produktivitas tanaman tetap optimal.

Bercak daun, yang umum terjadi akibat infeksi jamur atau bakteri, ditandai dengan noda coklat gelap atau hitam yang menyebar di permukaan daun. Penyakit ini dapat menghambat fotosintesis dan menurunkan pertumbuhan tanaman. Pengendalian dapat dilakukan dengan memperbaiki drainase, mengurangi kelembapan, serta menggunakan fungisida yang sesuai. Sementara itu, karat daun muncul sebagai bercak coklat menyerupai karat akibat infeksi jamur yang menyebar melalui spora. Penyakit ini dapat menyebabkan penurunan hasil panen jika tidak ditangani. Pencegahannya melibatkan pemangkasan daun terinfeksi, penggunaan fungisida, dan rotasi tanaman.

Serangan ulat ditandai dengan daun berlubang atau terkoyak akibat serangga pemakan daun. Jika tidak


dikendalikan, serangan ini dapat mengurangi produktivitas tanaman secara signifikan. Pengendalian dilakukan dengan memanfaatkan predator alami, menggunakan insektisida, serta melakukan monitoring intensif. Kekurangan unsur hara terlihat dari perubahan warna daun, seperti menguning atau munculnya bercak coklat, akibat kurangnya nutrisi penting. Penanganan dilakukan dengan analisis tanah dan pemberian pupuk yang sesuai untuk memenuhi kebutuhan tanaman [17].

C. Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan arsitektur yang dapat dilatih yang terdiri dari beberapa tahapan, meliputi tahapan input, pemrosesan, dan output [21]. 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 [22]. Ini dapat mengidentifikasi fitur seperti tekstur, tepi, atau bentuk tertentu, sehingga cocok untuk tugas-tugas 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 melatih dan menguji setiap gambar masukan melalui serangkaian proses, dimulai dengan lapisan konvolusional diikuti dengan pengumpulan untuk mengekstrak fitur dari gambar masukan secara berurutan. Setelah operasi 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 [23].

III. METODE PENELITIAN

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



GAMBAR 3
Alur Penelitian

Berdasarkan Gambar 3, penelitian ini diawali dengan studi literatur untuk memperoleh informasi dan data yang relevan. Proses ini melibatkan berbagai sumber, seperti jurnal, buku, dan artikel dari situs web yang berhubungan dengan klasifikasi gambar. Referensi yang digunakan mencakup publikasi dari tingkat nasional maupun internasional. Beberapa materi yang dikaji mencakup klasifikasi kematangan buah kelapa sawit, citra digital, deep learning, algoritma Convolutional Neural Network (CNN), metode Sequential, serta proses pengembangan dataset untuk pelatihan, validasi, dan pengujian. Selain itu, penelitian ini juga membahas pengukuran akurasi dan tingkat kesalahan dalam klasifikasi.


Perumusan masalah dalam penelitian ini mencakup tujuan, objek penelitian, serta metode yang diterapkan. Fokus utama penelitian ini adalah klasifikasi tingkat kematangan buah kelapa sawit serta penentuan akurasi model dalam mengklasifikasikan gambar buah kelapa sawit menggunakan metode *Convolutional Neural Network*. Pengumpulan data dilakukan dengan mengumpulkan gambar buah sawit dalam dua kategori, yaitu matang dan mentah. Data diambil secara langsung untuk memastikan keaslian dan menghindari plagiarisme, sekaligus meningkatkan kualitas serta keunikan penelitian. Mengingat penelitian ini berbasis citra buah sawit, pengambilan gambar secara langsung dapat memastikan kualitas data yang lebih baik untuk proses klasifikasi.

A. Pembuatan Model CNN

Model klasifikasi yang dikembangkan dalam penelitian ini bertujuan untuk mengelompokkan daun kelapa sawit menjadi dua kelas, yaitu sehat dan sakit, menggunakan algoritma Deep Learning, khususnya Convolutional Neural Network (CNN). Metode CNN terdiri dari dua tahap utama, yaitu *feature learning* dan *classification*. *Feature learning* mencakup *convolution layer* dan *pooling layer*, diikuti oleh

fungsi aktivasi ReLU. Setelah itu, tahap *classification* dilakukan menggunakan *fully connected layer* dan fungsi aktivasi *softmax*.

Gambar 4 menunjukkan rancangan arsitektur CNN yang digunakan dalam penelitian ini. Model dibangun dengan menginput dataset dan menggunakan tiga *convolutional layer*, tiga lapisan aktivasi ReLU, serta tiga *pooling layer*. Proses klasifikasi dilakukan pada lapisan *fully connected* dan lapisan output yang disesuaikan dengan jumlah kelas data (binary).



GAMBAR 4
Desain Model CNN

B. Parameter Model CNN

Pada tahap klasifikasi, terdapat proses *flattening* yang berfungsi untuk mengonversi array multidimensi menjadi array satu dimensi. Setelah itu, model menggunakan *fully connected layer* yang menerapkan metode *dense* untuk menghubungkan setiap neuron dengan neuron di lapisan sebelumnya dan berikutnya. Proses klasifikasi kemudian dilakukan dengan menerapkan fungsi aktivasi sigmoid, mengingat model ini memiliki dua kelas.

TABEL 1

PARAMETER MODEL CNN	
Parameter	Configuration
Filter	32,64,128
Kernel Size	3x3
Pooling	Maximum Pooling
Dense	128
Activation	ReLU + Softmax
Neuron Output Layer	2
Optimization	Adam

Tabel 1 menunjukkan parameter yang digunakan untuk klasifikasi. Proses ekstraksi fitur dilakukan dengan

menggunakan tiga lapisan *convolutional* yang masing-masing memiliki jumlah filter sebesar 32, 64, dan 128. Ukuran kernel yang digunakan adalah 3x3 untuk setiap lapisan konvolusi, yang berfungsi untuk menangkap pola serta fitur penting dari gambar input.

Setelah proses konvolusi, model menerapkan *maximum pooling* untuk mengurangi dimensi fitur tanpa kehilangan informasi yang signifikan. Pada tahap klasifikasi, digunakan lapisan *dense* dengan 128 neuron untuk menghubungkan fitur yang telah diekstraksi ke dalam proses klasifikasi. Fungsi aktivasi yang diterapkan dalam model ini adalah ReLU untuk lapisan tersembunyi dan *softmax* untuk lapisan output, yang memungkinkan model membedakan dua kategori utama, yaitu daun sehat dan daun sakit.

Lapisan output model terdiri dari dua neuron yang mewakili kategori klasifikasi biner. Proses optimasi dilakukan menggunakan algoritma Adam, yang dikenal dapat meningkatkan efisiensi pembelajaran model dengan menyesuaikan tingkat pembaruan bobot secara adaptif. Dengan kombinasi parameter ini, model diharapkan dapat mengklasifikasikan daun kelapa sawit dengan tingkat akurasi yang optimal.

C. Pembagian Data Set

Distribusi data pada Tabel 2 terlihat bahwa presentase data latih (training) sebesar 70% dari total data sehingga jumlahnya 560 data. Untuk data validasi (validation) memiliki ukuran 10% dari total data sehingga jumlahnya hanya 80 data. Sedangkan data uji (testing) sebesar 20% sehingga jumlahnya 160 data


TABEL 2
DISTRIBUSI DATA SET

Data	Distributionn	Dataset	Total Dataset
Training	70%	560	800
Validation	10%	80	
Testing	20%	160	

IV. HASIL DAN PEMBAHASAN

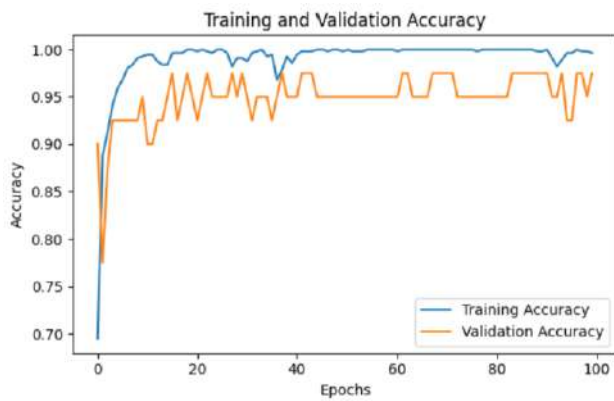
A. Hasil Training dan Validation

Setelah data set dipersiapkan, model di kompilasi dengan *optimizer adam* dan perhitungan *loss* dengan *binary cross entropy* dengan *metric* untuk mengetahui *accuracy*. Pemodelan dilakukan menggunakan *epoch* 100. 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 akurasi 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, pada awal pelatihan (epoch 1-20), akurasi data *training* meningkat pesat, mencapai hampir 1 pada epoch ke-20, dengan *loss* yang menurun signifikan. Namun, akurasi validasi tetap stabil di sekitar 0,95, dengan *loss* validasi berkisar antara 0,2 hingga 0,6, yang menunjukkan tanda-tanda *overfitting*. Pada epoch 21-40, akurasi pelatihan hampir 1, tetapi akurasi validasi tetap berada di kisaran 0,95 hingga 0,96, dengan *loss* validasi sekitar 0,4 hingga 0,8. Selanjutnya pada epoch 41-60, akurasi pelatihan tetap di nilai 1, namun akurasi validasi tidak meningkat secara signifikan, tetap di sekitar 0,95 hingga 0,975. Pada epoch 61-80, akurasi pelatihan tetap tinggi dengan nilai 1, dan akurasi validasi berada di 0,95 – 0,975. Pada epoch 81-100, tidak ada peningkatan signifikan pada akurasi validasi, dengan nilai tetap di kisaran 0,95 - 0,975. Berdasarkan data tersebut, Epoch terbaik dapat dilihat pada epoch ke-20, di mana akurasi pelatihan mencapai nilai 1, meskipun akurasi validasi tertinggi tetap tercatat pada epoch ke-80, dengan nilai 0,975. *Loss* terbaik tercatat pada epoch 20, yaitu sekitar 0,001 pada pelatihan dan 0,2 pada validasi.

Berdasarkan data, hubungan antara akurasi dan *loss* tidak bersifat linear, karena *loss* mencerminkan rata-rata kesalahan numerik dalam prediksi model, sedangkan akurasi hanya mengukur persentase prediksi yang benar. Dalam penelitian ini, *loss* dihitung menggunakan *binary cross-entropy*, yang mengukur perbedaan antara probabilitas prediksi model dan label sebenarnya untuk klasifikasi biner. Sebagai contoh, meskipun akurasi validasi stabil atau meningkat, *loss* validasi dapat tetap tinggi atau fluktuatif. Fenomena ini mengindikasikan bahwa model dapat mencapai akurasi tinggi tanpa penurunan *loss* yang signifikan, terutama jika mulai *overfitting* terhadap data pelatihan.

B. Hasil Pengujian

Setelah tahap pelatihan dan validasi selesai, model disimpan guna memastikan kinerjanya tetap optimal saat diuji. Proses pengujian dilakukan untuk menilai sejauh mana

model mampu mengenali pola dalam data baru yang belum pernah digunakan sebelumnya. Hasil pengujian dianalisis menggunakan matriks konfusi, yang menampilkan jumlah prediksi yang benar dan salah dalam setiap kategori. Matriks ini, seperti yang ditunjukkan pada Gambar 7, memberikan gambaran rinci mengenai tingkat akurasi model serta potensi kesalahan, yang dapat menjadi dasar evaluasi dan pengembangan lebih lanjut.



GAMBAR 7
Hasil Confusion Matrix

Berdasarkan Confusion Matrix pada Gambar 4.7, model membandingkan label asli (*true labels*) dengan label yang diprediksi (*predicted labels*). Hasil analisis menunjukkan bahwa model berhasil memprediksi dengan benar sebanyak 66 kali untuk daun sawit berpenyakit dan 80 kali untuk daun sawit sehat. Namun, terdapat 14 kesalahan *false positive*, di mana daun sawit berpenyakit diklasifikasikan sebagai daun sawit sehat, sedangkan tidak ditemukan kesalahan *false negative*, yang berarti semua daun sawit sehat berhasil diklasifikasikan dengan benar.

Dari hasil tersebut, dapat diperoleh nilai evaluasi model seperti akurasi, presisi, dan *recall*. Akurasi menunjukkan proporsi prediksi yang benar terhadap seluruh data yang diuji, sedangkan presisi mengukur seberapa baik model dalam menghindari kesalahan *false positive*. *Recall* menunjukkan sejauh mana model mampu mendeteksi semua sampel positif dengan benar. Hasil evaluasi ini memberikan gambaran mengenai kinerja model dalam mengklasifikasikan daun sawit sehat dan berpenyakit serta menjadi dasar untuk perbaikan dan pengembangan lebih lanjut.

V. KESIMPULAN

Akurasi Berdasarkan pembahasan, dapat disimpulkan bahwa model klasifikasi penyakit daun kelapa sawit berhasil dikembangkan dengan menunjukkan keberhasilan dalam proses klasifikasi. Akurasi dan *loss* model menunjukkan peningkatan akurasi pelatihan yang signifikan pada epoch 1-20 hingga mendekati 1, sementara *loss* mengalami penurunan drastis. Namun, akurasi validasi tetap stabil di sekitar 0,95, yang mengindikasikan adanya *overfitting*. Epoch terbaik tercatat pada epoch 20 dengan akurasi pelatihan mencapai 1 dan *loss* sebesar 0,001, sedangkan akurasi validasi tertinggi terjadi pada epoch 80 dengan nilai 0,975. Berdasarkan analisis *confusion matrix*, model berhasil mengklasifikasikan daun sawit berpenyakit dengan benar sebanyak 66 kali dan daun sawit sehat sebanyak 80 kali. Namun, terdapat 14

kesalahan *false positive* tanpa adanya kesalahan *false negative*. Hasil perhitungan evaluasi model menunjukkan akurasi sebesar 91,25%, presisi 82,5%, dan *recall* 100%. Nilai ini mengindikasikan bahwa model memiliki performa yang baik dalam mengidentifikasi daun sawit sehat dan berpenyakit, meskipun masih terdapat potensi perbaikan untuk mengurangi kesalahan klasifikasi.

REFERENSI

- [1] N. N. Duakajui, F. Juita, And E. Anshori, "Analisis Ekonomi Pendapatan Usaha Perkebunan Kelapa Sawit (Elais Gueneensis J) Desa Sukomulyo Kecamatan Sepaku Kabupaten Penajam Paser Utara (Revenue Analysis Of Palm Oil (Elais Gueneensis J) In Sukomulyo Village Of Sepaku Distict Of Penajam Paser Utara R."
- [2] R. Candra, P. Meganningrum, M. Prayudha, And R. Susanti, "Inovasi Baru Buah Nanas Sebagai Alternatif Pengganti Feromon Kimiawi Untuk Perangkap Hama Penggerek Batang (Oryctes Rhinoceros L.) Pada Tanaman Kelapa Sawit Di Areal Tanah Gambut New Innovation Of Pineapple As An Alternative Of Chemical Feromone Replaceme," *Online) Oktober*, Vol. 22, No. 2, 2019, Doi: 10.30596/Agrium.V21i3.2456.
- [3] N. Haryanti And A. Marsono, "76 Strategi Implementasi Pengembangan Perkebunan Kelapa Sawit Di Era Industri 4.0," *J. Din. Ekon. Syariah*, Vol. 08, No. 01, 2021, [Online]. Available: [Http://ejurnal.laipd-nganjuk.ac.id/index.php/es/index](http://ejurnal.laipd-nganjuk.ac.id/index.php/es/index)
- [4] D. Marcelina, E. Yulianti, And Z. R. Mair, "Penerapan Metode Forward Chaining Pada Sistem Pakar Identifikasi Penyakit Tanaman Kelapa Sawit," *J. Ilm. Inform. Glob.*, Vol. 13, No. 2, Aug. 2022, Doi: 10.36982/Jiig.V13i2.2299.
- [5] J. A. Widians And F. N. Rizkyani, "Identifikasi Hama Kelapa Sawit Menggunakan Metode Certainty Factor," *Ilk. J. Ilm.*, Vol. 12, No. 1, Pp. 58–63, Apr. 2020, Doi: 10.33096/Ilkom.V12i1.526.58-63.
- [6] S. Surianti And N. A. Banyal, "Sistem Pakar Diagnosa Penyakit Tanaman Kelapa Sawit Berbasis Android," *J. Ilm. Matrik*, Vol. 23, No. 1, Pp. 28–33, 2021, Doi: 10.33557/Jurnalmatrik.V23i1.1276.
- [7] Y. Cahaya Khairani And G. W. Nurcahyo, "Sistem Pakar Dalam Mengidentifikasi Tingkat Keparahannya Penyakit Pada Tanaman Kelapa Sawit Menggunakan Framework Codeigniter," *J. Inf. Dan Teknol.*, Sep. 2020, Doi: 10.37034/Jidt.V3i1.113.
- [8] F. Afriliya And B. Al Fajar, "Keanekaragaman Jenis-Jenis Penyakit Dan Cara Pengendaliannya Di Pembibitan Kelapa Sawit (Elais Guinensis Jacq) Pt. Perkebunan Nusantara I Langsa," *J. Biol. Samudra*, Vol. 1, No. 1, Pp. 34–40, 2019.
- [9] R. Pujiati And N. Rochmawati, "Identifikasi Citra Daun Tanaman Herbal Menggunakan Metode Convolutional Neural Network (Cnn)," *J. Informatics Comput. Sci.*, Vol. 03, 2022.
- [10] S. Yuliany, Aradea, And Andi Nur Rachman, "Implementasi Deep Learning Pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (Cnn)," *J. Buana Inform.*, Vol. 13, No. 1, Pp. 54–65, 2022, Doi: 10.24002/Jbi.V13i1.5022.
- [11] A. J. O. Simanjuntak And D. Udjulawa, "Klasifikasi Penyakit Daun Sawit Menggunakan Metode Jaringan Saraf Tiruan Dengan Fitur Local Binary Pattern," *J. Algoritma*, Vol. 3, No. 1, Pp. 1–9, 2022, Doi: 10.35957/Algoritma.V3i1.3158.
- [12] E. Oktafanda, "Klasifikasi Citra Kualitas Bibit Dalam Meningkatkan Produksi Kelapa Sawit Menggunakan Metode Convolutional Neural Network (Cnn)," *J. Inform. Ekon. Bisnis*, Vol. 4, No. 3, Pp. 72–77, 2022, Doi: 10.37034/InfEb.V4i3.143.
- [13] R. Soekarta, N. Nurdjan, And A. Syah, "Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode Convolutional Neural Network (Cnn)," *Insect (Informatics Secur. J. Tek. Inform.*, Vol. 8, No. 2, Pp. 143–151, 2023, Doi: 10.33506/Insect.V8i2.2356.
- [14] A. Asrianda, H. A. K. Aidilof, And Y. Pangestu, "Machine Learning For Detection Of Palm Oil Leaf Disease Visually Using Convolutional Neural Network Algorithm," *J. Informatics Telecommun. Eng.*, Vol. 4, No. 2, Pp. 286–293, 2021, Doi: 10.31289/Jite.V4i2.4185.
- [15] Y. Defitri, "Intensitas Dan Persentase Serangan Beberapa Penyakit Utama Pada Tanaman Sawit (Elais Guineensis Jacq.) Di Desa Tebing Tinggi Kecamatan Mara Sebo Ulu Kabupaten Batanghari," *J. Ilm. Univ. Batanghari Jambi*, Vol. 21, No. 3, P. 1399, 2021, Doi: 10.33087/Jiubj.V21i3.1761.
- [16] T. P. Sihaloho, W. Tarigan, S. Siallagan, And F. Haris Simbolon, "Model Case Based Reasoning Dalam Mendiagnosa Penyakit Kelapa Sawit," *J. Mnemon.*, Vol. 5, No. 2, Pp. 178–183, 2022, Doi: 10.36040/Mnemonic.V5i2.5248.
- [17] R. B. Yurianda, D. Setyawan, And W. Warsito, "Metode Klasifikasi Normalized Difference Vegetation Index Berbasis Citra Landsat 8 Untuk Identifikasi Sebaran Kondisi Kesehatan Tanaman Kelapa Sawit Di Pt. Andira Agro, Sumatera Selatan," *Pedontropika J. Ilmu Tanah Dan Sumber Daya Lahan*, Vol. 8, No. 2, P. 15, 2022, Doi: 10.26418/Pedontropika.V8i2.56431.
- [18] H. F. Putro, R. T. Vlandari, And W. L. Y. Saptomo, "Penerapan Metode Naive Bayes Untuk Klasifikasi Pelanggan," *J. Teknol. Inf. Dan Komun.*, Vol. 8, No. 2, 2020, Doi: 10.30646/Tikomsin.V8i2.500.
- [19] H. S. Disemadi, "Urgensi Regulasi Khusus Dan Pemanfaatan Artificial Intelligence Dalam Mewujudkan Perlindungan Data Pribadi Di Indonesia," *J. Wawasan Yuridika*, Vol. 5, No. 2, P. 177, 2021, Doi: 10.25072/Jwy.V5i2.460.
- [20] B. Yanto, L. Fimawahib, A. Supriyanto, B. H. Hayadi, And R. R. Pratama, "Classification Of Sweet Orange Fruit Maturity Texture Based On Color Brightness Level With Deep Learning Convolutional Neural Network Method," *Inovtek Polbeng - Seri Inform.*, Vol. 6, No. 2, P. 259, 2021.
- [21] A. Arkadia, S. Ayu Damayanti, And D. Sandya Prasvita, "Klasifikasi Buah Mangga Badami Untuk Menentukan Tingkat Kematangan Dengan Metode Cnn," *Semin. Nas. Mhs. Ilmu Komput. Dan Apl. Jakarta-Indonesia*, Vol. 2, No. 2, Pp. 158–165, 2021, [Online]. Available: <https://conference.upnvj.ac.id/Index.Php/Senamika/Article/View/1813>
- [22] A. Zalvadila, "Klasifikasi Penyakit Tanaman Bawang Merah Menggunakan Metode Svm Dan Cnn," *J. Inform. J. Pengemb. It*, Vol. 8, No. 3, Pp. 255–260, 2023, Doi: 10.30591/Jpit.V8i3.5341.
- [23] H. Herdianto And D. Nasution, "Implementasi Metode Cnn Untuk Klasifikasi Objek," *Methomika J. Manaj. Inform. Dan Komputerisasi Akunt.*, Vol. 7, No. 1, Pp. 54–60, 2023, Doi: 10.46880/Jmika.Vol7no1.Pp54
- [24] R. H. Alfikri, M. S. Utomo, H. Februariyanti, And E. Nurwahyudi, "Pembangunan Aplikasi Penerjemah Bahasa Isyarat Dengan Metode Cnn Berbasis Android," *J. Teknoinfo*, Vol. 16, No. 2, P. 183, 2022, Doi: 10.33365/Jti.V16i2.1752.
- [25] K. Azmi, S. Defit, And S. Sumijan, "Implementasi Convolutional Neural Network (Cnn) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat," *J. Unitek*, Vol. 16, No. 1, Pp. 28–40, 2023, Doi: 10.52072/Unitek.V16i1.504.
- [26] R. Magdalena, S. Saidah, N. K. C. Pratiwi, And A. T. Putra, "Klasifikasi Tutupan Lahan Melalui Citra Satelit Spot-6 Dengan Metode Convolutional Neural Network (Cnn)," *J. Edukasi Dan Penelit. Inform.*, Vol. 7, No. 3, P. 335, 2021, Doi: 10.26418/Jp.V7i3.48195.
- [27] Y. Achmad, R. C. Wihandika, And C. Dewi, "Klasifikasi Emosi Berdasarkan Ciri Wajah Menggunakan Convolutional Neural Network," *J. Pengemb. Teknol. Inf. Dan Ilmu Komput.*, Vol. 3, No. 11, Pp. 10595–10604, 2019.
- [28] Ilahiyah S And Nilogiri A, "Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network _ Ilahiyah _ Justindo (Jurnal Sistem Dan Teknologi Informasi Indonesia)," *Justindo (Jurnal Sist. Teknol. Inf. Indones.*, Vol. 3, No. 2, Pp. 49–56, 2018.
- [29] M. Padhilah *Et Al.*, "Implementasi Neural Network Multilayer Perceptron Dan Stemming Nazief & Adriani Pada Chatbot Faq Prakerja," *J. Sains Komput. Inform. (J-Sakti)*, Vol. 6, No. 2, Pp. 671–685, 2022.
- [30] F. Paraijun, R. N. Aziza, And D. Kuswardani, "Implementasi Algoritma Convolutional Neural Network Dalam Mengklasifikasi Kesegaran Buah Berdasarkan Citra Buah," *Kilat*, Vol. 11, No. 1, Pp. 1–9, 2022, Doi: 10.33322/Kilat.V10i2.1458.
- [31] F. Masykur, M. B. Setyawan, And K. Winangun, "Epoch Optimization On Rice Leaf Image Classification Using Convolutional Neural Network (Cnn) Mobilenet," *Cess (Journal Comput. Eng. Syst. Sci.*, Vol. 7, No. 2, P. 581, 2022, Doi: 10.24114/Cess.V7i2.37336.
- [32] S. Asy Syifa And I. Amelia Dewi, "Mind (Multimedia Artificial Intelligent Networking Database Arsitektur Resnet-152 Dengan Perbandingan Optimizer Adam Dan Rmsprop Untuk Mendeteksi Penyakit Paru-Paru," *J. Mind J. / Issn*, Vol. 7, No. 2, Pp. 139–150, 2022, [Online]. Available: <https://doi.org/10.26760/Mindjournal.V7i2.139-150>
- [33] Jaka Naufal Semendawai, Indah Febiola, Bima Pamungkas, And Muhammad Deka Ruliansyah, "Perancangan Aplikasi Otomatisasi Menggunakan Bahasa Pemrograman Python Pada Aktivitas Monitoring Pemakaian Data Harian Kartu Internet Of Things," *J. Rekayasa Elektro Sriwij.*, Vol. 3, No. 1, Pp. 193–198, 2021, Doi:

10.36706/Jres.V3i1.42.

- [34] G. I. E. Soen, M. Marlina, And R. Renny, "Implementasi Cloud Computing Dengan Google Colaboratory Pada Aplikasi Pengolah Data Zoom Participants," *Jitu J. Inform. Technol. Commun.*, Vol. 6, No. 1, Pp. 24–30, 2022, Doi: 10.36596/Jitu.V6i1.781.

