

Penerapan Convolutional Neural Network untuk Mengidentifikasi Penyakit Tanaman Kelapa Sawit

Itin Riati[✉], Yuhandri, Gunadi W Nurcahyo

Fakultas Ilmu Komputer, Universitas Putra Indonesia YPTK, Padang, 25221, Indonesia

itinriyantibts@gmail.com

Abstract

The use of technology can be developed in all fields such as in the field of oil palm plantations. Oil palm plants are a plantation commodity in Indonesia that has grown rapidly, factors that affect the growth and productivity of oil palm must be considered such as the presence of pests and diseases of oil palm plants. Artificial intelligence is a current technology whose concept is to transfer human intelligence into machines. There are several types of artificial intelligence used in education, namely Machine Learning and Deep Learning, one of the Deep Learning algorithms which is a development of Multilayer Perceptron (MPL) which is designed to process data in two-dimensional form, such as images or sound, namely Convolutional Neural Network (CNN). The method that can be used in this identification is the Convolutional Neural Network (CNN) which can display objects in image patterns. This study aims to improve the accuracy of detecting diseases and pests in oil palm seedlings, using a dataset consisting of images of infected and healthy seedlings. The data taken is 800 oil palm seedling image data which are divided into 3 classes, namely good, kulvularia sp and anthracnose. The parameters tested in this study are hidden layers and optimizers that affect system performance in the form of accuracy, precision, recall, fl-score, and loss values. In this study, the best results were obtained by using four Hidden Layers and Adam Optimizer, the accuracy results were 91.66%, Precision, recall, fl score were 90% and loss was 0.0047 and the accuracy and loss performance graphs were good fit. The results showed that CNN can effectively detect various types of pests and diseases in oil palm plants with an accuracy of more than 90%. This study shows great potential in modern agriculture and can facilitate more sustainable and efficient agricultural practices.

Keywords: Convolutional Neural Network, Identification, Pests, Diseases, Oil Palm Plants.

Abstrak

Pemanfaatan teknologi dapat dikembangkan di segala bidang seperti dalam bidang perkebunan kelapa sawit. Tanaman kelapa sawit merupakan komoditas perkebunan di Indonesia yang telah berkembang dengan pesat, faktor-faktor yang mempengaruhi pertumbuhan dan produktivitas kelapa sawit harus diperhatikan seperti adanya hama dan penyakit tanaman kelapa sawit. Kecerdasan buatan merupakan teknologi masa kini yang konsepnya memindahkan kecerdasan manusia ke dalam mesin. Terdapat beberapa jenis kecerdasan buatan yang digunakan dalam pendidikan yakni Machine learning dan Deep Learning. Penelitian ini bertujuan untuk meningkatkan akurasi dalam deteksi penyakit serta hama pada bibit kelapa sawit, menggunakan dataset yang terdiri dari gambar bibit yang terinfeksi dan sehat. Metode penelitian ini menggunakan metode Convolutional Neural Network (CNN). Data yang di ambil yaitu 800 data gambar bibit kelapa sawit yang di bagi menjadi 3 kelas yaitu bagus, kulvularia sp dan antraknosa. Parameter yang diujikan pada penelitian ini yaitu hidden layer dan optimizer berpengaruh terhadap performa sistem yang berupa nilai akurasi, precision, recall, fl-score, dan loss. Hasil penelitian menyajikan hasil terbaik dengan penggunaan empat hidden layer dan optimizer Adam didapatkan hasil akurasi sebesar 91,66%, precision, recall, fl score sebesar 90% dan loss sebesar 0,0047 serta grafik performa akurasi dan loss secara good fit. Hasil penelitian menunjukkan bahwa CNN dapat secara efektif mendeteksi berbagai jenis hama dan penyakit pada tanaman kelapa sawit dengan akurasi lebih dari 90%. Penelitian ini menunjukkan potensi besar dalam pertanian modern dan dapat memfasilitasi praktik pertanian yang lebih berkelanjutan dan efisien.

Kata kunci: Convolutional Neural Network, Identifikasi, Hama, Penyakit, Tanaman Kelapa Sawit.

KomtekInfo is licensed under a Creative Commons Attribution-Share Alike 4.0 International License.



1. Pendahuluan

Perkembangan teknologi saat ini, pemanfaatan teknologi dapat dikembangkan di segala bidang, seperti dalam bidang perkebunan kelapa sawit. Banyak investor memulai usaha untuk menghasilkan buah kelapa sawit yang berkualitas tinggi yang terhindar dari berbagai serangan penyakit. Seperti tanaman lain tanaman kelapa sawit juga memiliki hama penyakit

yang sering sekali menyerang tanaman pohon kelapa sawit di perkebunan banyak penyakit kelapa sawit yang dapat menimbulkan tanaman ini menghasilkan buah kelapa sawit yang kurang bagus bahkan terancam mati menyusahkan para petani [1].

Tanaman kelapa sawit merupakan komoditas perkebunan di Indonesia yang telah berkembang dengan pesat dengan luasan 16,2 juta dan menyumbangkan devisa negara cukup besar pada sektor non migas. Di

Indonesia, kepemilikan perkebunan kelapa sawit terbagi atas 3 jenis, yaitu perkebunan milik negara, perkebunan swasta, dan perkebunan yang dikelola oleh pekebun rakyat [2].

Manfaat dari pertumbuhan dan produktivitas kelapa sawit yang meningkat terus menerus sangat besar baik bagi negara, swasta, maupun masyarakat, maka dari itu faktor – faktor yang mempengaruhi pertumbuhan dan produktivitas kelapa sawit harus diperhatikan seperti adanya hama dan penyakit tanaman kelapa sawit. Penyakit tanaman dapat dilihat dari gejala – gejala fisik seperti daun, batang, akar, maupun dari buah sawit yang dihasilkan [3].

Hama dan penyakit akan menyebabkan tanaman tidak dapat tumbuh secara optimal atau bahkan mati. Hal ini tentu akan berdampak pada hasil panen. Identifikasi hama dan penyakit dapat dilakukan dengan melakukan observasi gejala dan karakteristik yang muncul pada tanaman kelapa sawit. Proses tersebut harus dilakukan dengan cepat dan akurat karena hama dan penyakit akan menyebar pada lahan pertanian dengan cepat pula. Identifikasi biasanya tidak dapat dilakukan dengan mudah sebab tanaman kelapa sawit yang terkena serangan hama atau penyakit dapat menunjukkan gejala yang mirip dan sulit dibedakan satu sama lain. dari ahli pertanian [4].

Hama yang menyerang kelapa sawit dikelompokkan berdasarkan bagian yang diserang yakni hama pemakan pucuk dan daun, pemakan tandan, batang dan akar . Ulat pemakan daun kelapa sawit merupakan hama penting karena menyerang dan menghilangkan banyak daun daunan kelapa sawit sehingga menurunkan produksi [5]. Penyakit pada daun tanaman menyebabkan penurunan produksi besar dan kerugian ekonomi negara. Di sisi lain, pekebun kelapa sawit seringkali memiliki pengetahuan terbatas mengenai jenis penyakit dan metode pengendalian yang tepat. Oleh karena itu, perlu adanya suatu sistem pendamping bagi pekebun sehingga dapat melaksanakan identifikasi dan pengendalian penyakit kelapa sawit yang tepat dengan dampak lingkungan yang minimal [6].

Salah satu langkah penting dalam pengendalian penyakit pada perkebunan kelapa sawit adalah identifikasi jenis penyakit pada daun tanaman kelapa sawit. Identifikasi yang tepat adalah setengah jalan untuk pengendalian yang tepat. Selanjutnya hasil identifikasi jenis penyakit tersebut dapat dijadikan dasar penentuan kebijakan penanggulangan hama dan penyakit pada tanaman kelapa sawit yang paling sesuai untuk pengendaliannya. Penggunaan kecerdasan buatan (Artificial Intelligence) berpotensi digunakan dalam identifikasi penyakit pada sistem pertanian presisi [7].

Hasil dari Riset Marcelina dkk Sistem dapat memberikan informasi mengenai penyakit tanaman kelapa sawit beserta penyebab dan cara pengendaliannya. Proses pelacakan akan diuji dari gejala pertama sampai terakhir untuk mendapatkan

kesimpulan berupa nama penyakit beserta penyebab dan cara pengendaliannya. Pengujian kepakaran dilakukan dengan cara membandingkan hasil diagnosis penyakit oleh sistem dengan hasil diagnosis penyakit oleh seorang ahli pakar. Berdasarkan hasil pengujian kepakaran diperoleh hasil yang baik yaitu sistem dapat mengidentifikasi penyakit tanaman kelapa sawit sesuai dengan yang diharapkan, pengujian dilakukan dengan memberikan kuisioner 35 orang responden (pakar). Hasil kuisioner menunjukkan 89,2% [8] .

Penelitian terdahulu lainnya yang dilakukan oleh Santosa dkk Jurnal ini membahas Deteksi Penyakit pada Tanaman Padi Menggunakan Pengolahan Citra Digital dengan Metode Convolutional Neural Network (CNN). Penelitian ini menggunakan CNN untuk mengidentifikasi penyakit pada tanaman padi dengan mengolah 16.000 gambar dari empat kelas (tiga jenis penyakit dan padi sehat) [9]. Hasil terbaik diperoleh dengan empat Hidden Layer dan Optimizer Adam, mencapai akurasi dan nilai Precision, Recall, Serta F1-Scor. Metode ini menunjukkan performa yang sangat baik dalam deteksi penyakit dengan kehilangan data yang minim dan klasifikasi yang efektif [10].

Memberikan dukungan teknologi bagi petani sangat penting karena teknologi memiliki peran yang sangat penting dalam meningkatkan produktivitas, efisiensi, dan keberlanjutan di sektor pertanian. Karena itulah, memberikan bantuan teknologi kepada petani merupakan investasi yang sangat berarti untuk meningkatkan kesejahteraan mereka, meningkatkan hasil pertanian, serta mendorong sektor pertanian menuju keberlanjutan dan kemajuan yang berkelanjutan [11].

Convolutional Neural Network (CNN) merupakan salah satu model pembelajaran deep learning yang mampu melatih sistem dengan data yang cukup banyak serta menggabungkan proses ekstraksi ciri dan klasifikasi. Convolutional Neural Network (CNN) memiliki beberapa arsitektur, salah satu arsitekturnya adalah AlexNet. Convolutional Neural Network (CNN) digunakan untuk mengolah data dengan struktur grid yaitu salah satunya berupa citra dua dimensi dan juga mampu memproses data dengan dimensi tinggi seperti video [12].

Penelitian terdahulu yang dilakukan oleh Car dkk Menjelaskan Klasifikasi Hama Tanaman Padi Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network. Jurnal ini membahas penggunaan metode Convolutional Neural Network (CNN) untuk mengklasifikasikan hama pada tanaman padi menggunakan TensorFlow dan Platform Android. Penelitian menunjukkan peningkatan akurasi dari 61% menjadi 99% melalui berbagai uji variasi, dengan rata-rata akurasi sekitar 90%. Metodologi yang diterapkan melibatkan pengumpulan gambar hama, pelabelan, pelatihan model CNN, dan implementasi pada aplikasi Android. Hasilnya menunjukkan bahwa metode ini

efektif dalam membantu masyarakat dan petani mengidentifikasi hama secara akurat [13].

Penelitian terdahulu lainnya yang dilakukan oleh Lesmana dkk Penyakit Pada Citra Daun Kentang Menggunakan Convolutional Neural Network (CNN) Jurnal ini membahas penerapan Convolutional Neural Network (CNN) untuk identifikasi penyakit pada daun kentang, yaitu Early Blight dan Late Blight. Penelitian menggunakan 5400 citra yang dibagi menjadi tiga kelas: sehat, Early Blight, Dan Late Blight. Dengan akurasi tertinggi mencapai 99% pada Data Validation, hasil menunjukkan metode CNN sangat efektif dalam identifikasi penyakit tersebut [14].

Penerapan Convolutional Neural Network (CNN) melibatkan beberapa langkah, termasuk pengumpulan dataset gambar yang mencakup berbagai jenis hama dan penyakit yang umumnya menyerang kelapa sawit, pelatihan model Convolutional Neural Network (CNN) menggunakan dataset tersebut, dan evaluasi kinerja model untuk mengukur tingkat akurasi dan kehandalan dalam mengidentifikasi hama dan penyakit [15].

Penelitian terdahulu yang dilakukan oleh Oktafanda juga menjelaskan Klasifikasi citra kualitas bibit kelapa sawit dengan Metode Convolutional Neural Network (CNN) adalah pendekatan teknologi yang menggunakan jaringan saraf untuk secara otomatis mengenali dan membedakan bibit yang baik dan buruk berdasarkan citra visualnya. Hal ini membantu dalam meningkatkan produksi kelapa sawit dengan memastikan penanaman bibit berkualitas tinggi, yang pada gilirannya dapat meningkatkan efisiensi pengelolaan kebun dan hasil panen secara keseluruhan. Metode Convolutional Neural Network (CNN) sangat bagus diterapkan di citra namun jika membuat model baru, harus memiliki dataset yang besar, agar mendapatkan model yang bagus. Metode ini dapat mengimplementasikan Transfer Learning Model ResNet50 sehingga tingkatkan akurasi penentuan kualitas terjamin dalam meningkatkan produksi [16].

Sistem yang ada pada saat ini diharapkan mampu untuk mengidentifikasi hama dan penyakit pada tanaman kelapa sawit secara otomatis dan cepat, dan diharapkan para petani dapat lebih responsif dalam mengambil tindakan pencegahan atau penanggulangan yang tepat waktu. Hal ini dapat membantu meningkatkan produktivitas dan keberlanjutan sektor pertanian kelapa sawit secara keseluruhan. Berdasarkan paparan di atas, maka penulis membuat penelitian tentang penerapan Convolutional Neural Network (CNN) untuk mengidentifikasi hama dan penyakit pada tanaman kelapa sawit. Hasil penelitian ini diharapkan mampu membantu petani dalam mengidentifikasi jenis penyakit berdasarkan ciri tanaman yang telah terserang penyakit.

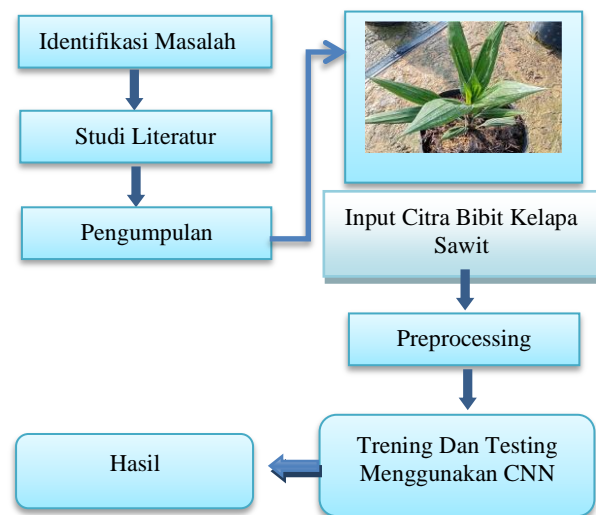
2. Metodologi Penelitian

Metodologi penelitian adalah proses sistematis yang digunakan untuk mengumpulkan, menganalisis, dan

menginterpretasikan data dalam rangka menjawab pertanyaan penelitian atau memecahkan masalah. Metodologi penelitian untuk menyediakan kerangka dan prosedur sistematis yang digunakan peneliti untuk mengumpulkan, menganalisis, dan menyajikan data dengan cara yang valid. Prinsip dasar dari metodologi penelitian umumnya melibatkan proses yang sistematis dan terstruktur untuk memastikan bahwa hasil penelitian dapat dipercaya dan bermanfaat.

2.1 Kerangka Penelitian

Tanaman kelapa sawit memiliki peranan penting dalam industri pertanian dan perkebunan di banyak negara tropis. Namun serangan hama dan penyakit sering mengganggu produksi, menyebabkan penurunan hasil dan kualitas buah. Deteksi dini dan identifikasi tepat terhadap hama dan penyakit menjadi krusial dalam mengurangi kerugian dalam produksi kelapa sawit. Penelitian ini bertujuan untuk menerapkan Convolutional Neural Network (CNN) untuk mengidentifikasi hama dan penyakit pada tanaman kelapa sawit secara otomatis. Harapannya penelitian ini akan menyumbangkan pemahaman baru dalam pengembangan sistem deteksi dini dan pengendalian hama dan penyakit pada tanaman kelapa sawit, yang dapat meningkatkan produktivitas dan kualitas hasil panen.



Gambar 1. Kerangka Kerja Penelitian

Menguraikan tahapan dalam penulisan berdasarkan kerangka kerja penelitian, berikut adalah struktur umum yang dapat digunakan. Setiap tahapan dalam kerangka kerja penelitian biasanya mencakup beberapa bagian penting. Berdasarkan kerangka kerja penelitian di atas, maka dapat diuraikan pembahasan masing-masing tahapan dalam penulisan sebagai berikut.

1. Identifikasi Masalah

Merupakan tahapan dimana semua analisis dan hasil penelitian yang ada dikemukakan dan dibahas secara

detail untuk mengetahui dan menguraikan masalah dan mencari gambaran dari sistem yang sedang berjalan serta mengatasi kelemahan-kelemahan yang ada dengan memberikan solusi atau hasil penelitian.

2. Studi Literatur

Studi Literatur adalah cara untuk menyelesaikan persoalan dengan menelusuri sumber-sumber tulisan yang pernah dibuat sebelumnya. Dengan kata lain, istilah Studi Literatur ini juga sangat familier dengan sebutan studi pustak. Tujuan utamanya adalah untuk Mengidentifikasi apa yang telah diteliti dan ditemukan sebelumnya.

3. Pengumpulan Dataset Citra Gambar Bibit Kelapa Sawit

Pengumpulan dataset ini adalah tahapan proses riset dimana peneliti mengumpulkan data citra gambar dengan cara penilitian di lapangan dan memotret langsung tanaman kelapa sawit yang terkena hama dan penyakit. Data citra gamabr di bagi menjadi tiga bagian yaitu : Bagus (Normal), Culvularia sp (Jamur), Antraknosa

4. Preprocessing Citra

Citra yang sudah diakuisisi kemudian dipilih tingkat kelayakannya sebagai citra sampel. Citra yang dianggap layak sebagai sampel adalah citra yang menampakkan gambar daun yang terpapar hama dan penyakit dengan jelas. Setelah melakukan akuisisi dan pemilahan data, maka selanjutnya adalah melakukan preprocessing data menggunakan aplikasi pengolah gambar.

- a. Cropping : Melakukan pemotongan gambar untuk menghilangkan bagian yang tidak dibutuhkan. Hal ini dimaksudkan untuk memperkecil dimensi citra dan memotong waktu komputasi.
- b. Translation : melakukan perputaran, pencerminan terhadap citra. Proses rotasi dilakukan untuk menyediakan data ciri yang beragam, sehingga bisa mengenali orientasi yang bervariasi.

Algoritma Deep Learning yang digunakan untuk memproses inputan data gambar, menentukan kepentingan (bobot dan bias yang dapat dipelajari) ke berbagai aspek dalam gambar dan berfungsi untuk membedakan objek satu dengan objek lainnya. CNN adalah salah satu jenis arsitektur Neural Network yang biasa digunakan pada data image. Sebenarnya CNN ini tidak jauh berbeda dengan Neural Network pada umumnya

5. Hasil

Pengujian Hasil ini dilakukan untuk mengevaluasi model yang dihasilkan oleh CNN. Pengujian dilakukan dalam dua tahap, yaitu tahap pelatihan dan tahap

pengujian. Tahap pelatihan merupakan tahap dimana model CNN diuji dengan data test yang telah disediakan. Tahap ini merupakan tahap pengujian model yang telah dilakukan pada tahap test.

2.2 Arsitektur CNN

1. Konvolusi (convolution)

konvolusi adalah jumlah total dari hasil kali antara setiap elemen yang bersesuaian (memiliki posisi koordinat yang sama) dalam dua matriks atau dua vektor[17]. Dalam arsitektur jaringan saraf konvolusional (CNN), konvolusi memainkan peran kunci dalam ekstraksi fitur dari data input. Konvolusi adalah operasi yang melibatkan dua fungsi atau matriks fungsi input dan filter (atau kernel).

2. Pooling

Pooling adalah proses mereduksi ukuran sebuah data citra. Dalam pengolahan citra, pooling juga bertujuan untuk meningkatkan invariansi posisi dari fitur serta mempercepat komputasi dan mengontrol terjadinya overfitting. Terdapat dua teknik Pooling, yaitu Max Pooling dan Average Pooling. Max Pooling bertujuan dalam menemukan nilai maksimum dalam suatu area, sedangkan Average Pooling untuk menemukan rata-rata dari fitur dari suatu area.

3. ReLu Aktivasi

Rectified linear unit, yang dikenal sebagai ReLU, adalah cara paling umum dan dasar untuk memperkenalkan non-linearitas ke dalam jaringan saraf. Fungsi ini hanya $\max(0, x)$. ReLu adalah fungsi aktivasi yang sangat efektif dan banyak digunakan dalam berbagai arsitektur jaringan saraf karena kesederhanaannya dan kemampuannya untuk mendukung pelatihan jaringan yang lebih dalam dengan lebih baik. ReLu mudah dihitung karena hanya memerlukan perbandingan sederhana, menjadikannya sangat efisien untuk komputasi.

4. Confusion Matrix

Confusion matrix adalah salah satu metode yang digunakan untuk mengevaluasi metode metode klasifikasi. Confusion Matrix memberikan informasi rinci tentang bagaimana model mengklasifikasikan data dan membantu dalam memahami di mana model mungkin melakukan kesalahan. Biasanya, Confusion Matrix untuk masalah klasifikasi biner (dua kelas) memiliki bentuk 2x2, tetapi dapat diperluas untuk masalah klasifikasi dengan lebih dari dua kelas.

Tabel 1. Istilah Confusion Matrix

		Kelas Prediksi (Observation)	
		Positif	Negatif
Kelas (Expectation)	Aktual	TP	FN
		FP	TN

Nilai True Negative (TN) adalah data yang di klasifikasi dengan tepat sebagai keluaran negatif atau salah. True Positive (TP) adalah data yang diklasifikasi dengan tepat sebagai keluaran positif atau benar. False Positive (FP) adalah data yang diklasifikasi dengan kurang tepat apabila keluaran berupa positif atau benar. False Negative (FN) adalah data yang diklasifikasi dengan kurang tepat [18]. Perhitungan nilai precision dapat dilakukan dengan Persamaan 1.

$$\text{Precision} = \frac{\sum TP_i}{\sum TP_i + FP_i} \quad (1)$$

Persamaan 1 merupakan perhitungan rata-rata nilai precision yaitu dari data hasil klasifikasi seberapa banyak data yang benar. antara nilai sebenarnya dengan prediksi yang diberikan oleh sistem. Precision mengukur seberapa baik model klasifikasi dalam mengidentifikasi kelas positif yang benar dari semua prediksi positif yang dibuat. Untuk memahami persamaan tersebut secara lebih rinci, mari kita lihat bagaimana precision dihitung dan dirata-ratakan. Perhitungan nilai recall dapat dilakukan dengan Persamaan 2.

$$\text{Recall} = \frac{\sum TP_i}{\sum TP_i + FN_i} \quad (2)$$

Persamaan 2 merupakan perhitungan rata-rata nilai recall yaitu dari seluruh data benar seberapa banyak data yang keluar dalam hasil klasifikasi. Recall (juga dikenal sebagai Sensitivity atau True Positive Rate) mengukur seberapa baik model dalam mendeteksi semua contoh positif dari kelas yang sebenarnya. Dalam klasifikasi multi-kelas, recall dihitung untuk setiap kelas dan kemudian dirata-ratakan. Mari kita bahas lebih lanjut tentang recall dan cara perhitungannya. Perhitungan nilai akurasi dapat dilakukan dengan Persamaan 3.

$$\text{Akurasi} = \frac{\sum TP_i + TN_i}{\sum TP_i + FP_i + TN_i + FN_i} \quad (3)$$

Persamaan 3 merupakan perhitungan rata-rata nilai akurasi untuk menunjukkan tingkat efektifitas per kelas dari sebuah klasifikasi [19]. Recall (juga dikenal sebagai Sensitivity atau True Positive Rate) mengukur seberapa baik model dalam mendeteksi semua contoh positif dari kelas yang sebenarnya. Dalam klasifikasi multi-kelas, recall dihitung untuk setiap kelas dan kemudian dirata-ratakan. Mari kita bahas lebih lanjut tentang recall dan cara perhitungannya. Perhitungan nilai FScore dapat dilakukan dengan Persamaan 4.

$$\text{Fscore} = \frac{2 \times \text{recall} \times \text{presisi}}{\text{recall} + \text{presisi}} \quad (4)$$

Persamaan 4 merupakan perhitungan rata-rata nilai Fscore yang merupakan nilai kombinasi dari perhitungan recall dan presisi [20]. pada F-Score atau F1-Score, yang merupakan metrik evaluasi yang menggabungkan precision (presisi) dan recall dalam satu nilai. F1-Score memberikan ukuran tunggal yang mencerminkan keseimbangan antara precision dan recall, dan sangat berguna.



3. Hasil dan Pembahasan

Bagian ini umumnya mencakup data kuantitatif dan kualitatif yang diperoleh, dan bisa mencakup tabel, grafik, dan statistik yang relevan. Tujuannya adalah untuk memberikan gambaran yang jelas dan terperinci tentang apa yang ditemukan tanpa terlalu banyak interpretasi atau analisis. Dengan menyusun bagian Hasil dan Pembahasan dengan cara ini, Anda memberikan pembaca gambaran yang jelas dan terperinci tentang temuan penelitian Anda serta bagaimana temuan tersebut berkontribusi pada pengetahuan di bidang tersebut.

1. Data Masukan

Data yang diambil dari penelitian ini yaitu data citra gambar bibit sawit yang diambil dari PT. Selago Makmur Plantation Unit Kelapa Sawit. Pengumpulan data ini dilakukan dengan memotret secara langsung di lapangan menggunakan Camera dan gambar yang diambil merupakan bibit sawit yang sepertinya terkena hama dan penyakit dan juga bibit sawit yang terlihat sehat dan bagus. Sistem yang diterapkan pada data ini diimplementasikan untuk mengidentifikasi hama dan penyakit pada tanaman kelapa sawit. Terdapat 3 jenis data tanaman yang ditemukan dalam kondisi 1 tanaman bibit sawit yang terkena hama, 1 tanaman bibit sawit yang terkena terkena penyakit dan 1 bibit yang baik dan bagus. Setiap data memiliki ciri khas tersendiri yang dapat dijadikan acuan identifikasi pada CNN. Adapun citra gambar yang akan diolah dalam penelitian ini berjumlah 500 gambar yang terdiri dari 3 kelas seperti pada Tabel 2.

Tabel 2. Jenis Data

No	Keterangan	Gambar
1.	Bagus (Normal)	
2.	Culvularia sp	

3. Antraknosa



1. Bagus (normal)

Bibit sawit yang normal akan terlihat hijau bersih dan dengan pola yang bagus, dan juga tidak memiliki bercak bercak pada daunnya. Bibit sawit yang normal dapat diidentifikasi melalui warna daun hijau bersih, pola pertumbuhan yang bagus, dan ketiadaan bercak pada daun. Memperhatikan indikator kesehatan ini dapat membantu Anda dalam memilih bibit yang memiliki potensi pertumbuhan yang baik dan meminimalkan risiko masalah di kemudian hari.

2. Culvularia sp

Penyakit bercak daun yang disebabkan oleh Culvularia berupa bercak kuning yang menginfeksi tajuk dan helai daun yang lama kelamaan akan menjadi bercak kering berwarna coklat abu-abu, sehingga mengkerut dan mati. Culvularia sp menyebabkan bercak daun dengan gejala awal bercak kuning yang berkembang menjadi bercak kering berwarna coklat abu-abu. Infeksi dapat mengakibatkan penurunan kesehatan tanaman dan produktivitas.

3. Antraknosa

Antraknosa yang disebabkan oleh Botryodiplodia sp dapat dijumpai pada bagian tengah atau ujung daun gejala ini umumnya dimulai dengan bintik terang atau transparan yang kemudian berkembang menjadi bercak berwarna gelap. Penyakit ini dapat mempengaruhi berbagai jenis tanaman, termasuk tanaman hortikultura dan tanaman perkebunan seperti sawit. Pengendalian penyakit ini melibatkan praktik budidaya yang baik, pengelolaan kelembaban, penggunaan fungisida, pemangkasan daun terinfeksi, dan pemantauan rutin.

3.2 Meningkatkan Jumlah Data

Sebelum menuju ke tahap selanjutnya data citra akan diperbanyak terlebih dahulu. Untuk menghindari Overfitting & Underfitting dataset yang awalnya 100 akan ditingkatkan hingga menjadi total keseluruhan 500 data kemudian dibagi menjadi 2 sub dengan perbandingan 70 % data Train 30 % data Validation. Semakin banyak data yang digunakan maka akan lebih banyak program berlatih sehingga memiliki tingkat akurasi yang lebih baik.

3.3 Pelabelan Data

Data yang sudah ditingkatkan akan dibagi menjadi dua sub data yaitu data Train berfungsi untuk mengerjakan model Matching Learning dan data Validation yang merupakan kumpulan data actual saat membuat kumpulan data pengujian, hasil yang diprediksi oleh model yang Train dibandingkan dengan hasil yang

sebenarnya. Pelabelan dapat dilakukan dengan penamaan folder pada tiap kelas, nama folder tersebut akan dipakai sebagai nama kelas seperti pada Tabel 2.


Tabel 3. Pembagian Data Training Dan Data Validation

No	Nama Label	Train	Validation	Test
1.	Bagus (Normal)	200	50	8
2.	Culvularia sp	100	50	6
3.	Antraknosa	50	50	4

Tabel menunjukkan bahwa jumlah data pelatihan lebih banyak dibandingkan dengan data validasi dan pengujian untuk setiap label. Untuk "Bagus (Normal)" dan "Culvularia sp", jumlah data pelatihan lebih banyak daripada untuk "Antraknosa". Hal ini bisa disebabkan oleh jumlah data yang tersedia atau kebutuhan spesifik dari aplikasi atau studi tersebut.


3.4 Pemodelan CNN

Tahap ini adalah tahap membangun model penelitian ini memanfaatkan sebuah metode Transfer Learning untuk membantu pada tahap Feature Extraction agar mendapatkan model yang lebih baik, layer Feature extraction yang digunakan adalah Residual Network (ResNet50). Convolutional Neural Network (CNN) umumnya ada dua tahapan yaitu Feature Extraction dan Fully Connected Terlihat pada Gambar 2 Arsitektur umum CNN.



Gambar 2. Arsitektur Umum CNN

Arsitektur ResNet50 adalah salah satu varian dari Residual Networks (ResNets) yang terkenal dalam dunia pembelajaran mendalam, khususnya dalam pengenalan citra dan pemrosesan gambar. Arsitektur ini dirancang untuk mengatasi masalah pelatihan jaringan saraf yang sangat dalam dengan memperkenalkan konsep residual learning. Pemodelan yang akan digunakan adalah arsitektur Resnet50 yang terdiri dari 50 layer dengan 5 stage proses konvolusi. Dengan citra masukan 224 x 224, 3 chanel proses feature extraction seperti pada Gambar 3.



Gambar 3. Output Size Resnet50

Gambar 3 terlihat semakin dalam layer pada Resnet50 size citra atau bisa di sebut Feature semakin mengecil. Gambar 3 memperlihatkan bagaimana ukuran citra atau feature map mengalami perubahan seiring dengan bertambahnya kedalaman layer dalam arsitektur ResNet50. Dalam arsitektur ResNet50, ukuran feature

map mengecil seiring dengan bertambahnya kedalaman layer.

1. Input Image

Input Image dalam konteks pemodelan dengan ResNet50 merujuk pada citra yang dimasukkan ke dalam model untuk diproses. Input Image setelah dilakukan augmentasi akan menuju ke layer berikutnya. Sebagai contoh penelitian ini akan mengambil satu sampel citra.

2. Stage 0

Stage 0 adalah tahap awal dalam arsitektur ResNet50 di mana citra input pertama kali diproses setelah augmentasi. Proses ini melibatkan langkah-langkah konvolusi awal yang penting untuk memulai ekstraksi fitur dari citra. Penjelasan berikut merinci bagaimana citra dengan dimensi 224 x 224 diproses dalam Stage 0. Proses stage 0 dengan input citra 224 x 224 yang diteruskan dari layer input dapat dilihat dari tabel 4. pada convolusi 1 hanya terdapat 1 kali convolusi 1 ReLu disajikan pada Tabel 4.

Tabel 4. Parameter Dan Output Pada Strage 0

Input size	Filter	Filter size	Padding	Stride	Output Size	Output Chanel
224x 224	64	7 x 7	3 x 3	2x2	112	7

Tabel 4 Output Size citra dapat dihitung dengan menggunakan persamaan pada rumus Size sedangkan untuk output chanel akan sama dengan jumlah filter. Di mana in adalah size citra yang akan di proses dan p adalah size dari Padding, k adalah size dari karnel kemudian s adalah size dari stride selanjutnya akan di tambahkan 1 maka size output citra pada layer convolusi 1 sebagai berikut :

$$\text{Size} = (224+3-7)/2 + 1 = 112$$

3. Rectified linear unit (ReLU)

Fungsi linier yang akan mengeluarkan input secara langsung jika positif , jika tidak positif akan menghasilkan nol. ReLu berfungsi untuk mempertahankan informasi penting dalam citra . ReLu dapat ditulis dengan persamaan $\max(0, x)$ dimana x adalah nilai matrix citra. Ini telah menjadi fungsi aktivasi untuk banyak jenis jaringan saraf karenamodel yang menggunakannya lebih mudah untuk dilatih dan seringkali mencapai kinerja yang lebih baik. Fungsi aktivasi ReLu digunakan di beberapa stage pada Resnet50.

4. Pooling Layer

Pooling Layer adalah komponen penting dalam arsitektur jaringan saraf konvolusi seperti ResNet50, yang berfungsi untuk mengurangi dimensi spasial dari feature map dan menggabungkan informasi penting dari area yang lebih besar. Dalam arsitektur ResNet50, max

pooling digunakan secara spesifik untuk mencapai tujuan ini. Poling layer menggunakan max pooling seperti yang sudah bahas pada bab II max pooling akan mencari matrix terbesar pada pixel 112 x 112 dengan ukuran pembeding 2 x 2 parameter dapat dilihat pada Tabel 5.

Tabel 5. Parameter Pooling Layer\

Input Size	Pooling layer	Padding	stride	Output Layer
112 x 112,3	3 x 3	1 x 1	2 x 2	56 x 56

Untuk mendapatkan ukuran output dari max pooling layer, digunakan, dengan parameter yang mencakup ukuran feature map sebelumnya, ukuran kernel pooling, dan stride. Dalam kasus ini, ukuran output feature map setelah max pooling adalah 56 x 56 piksel. Maka untuk mendapatkan hasil dari max pooling dapat dihitung dengan persamaan pada rumus berikut. Dimana m adalah size dari matrix citra hasil dari conv 1 sedangkan p adalah max pooling size yaitu (H , W) 2 x 2 pixel matrix. $\text{MaxPool} = (112+1-3)/2 + 1 = 56$.

5. Stage 1

Stage 1 arsitektur ResNet50, feature map berukuran 56 x 56 piksel dari layer max pooling diproses menggunakan tiga blok residual. Setiap blok residual terdiri dari tiga lapisan konvolusi yang diikuti oleh tiga fungsi aktivasi ReLU. Proses stage 1 dengan input citra 56 x 56 yang diteruskan dari layar max pooling dapat dilihat dari Tabel 6. Tahap convolusi dilakukan sebanyak tiga blok dan masing-masing blok terdiri dari tiga convolusi dan 3 kali ReLu disajikan pada Tabel 6

Tabel 6.Parameter Pooling Layer

Inpu t Size	Filte r	Filte r Size	Paddin g	Strid e	Outpu t Size	Ouput Channe l
56 x 56,3	64	1 x 1	0	1 x 1	56	64
56 x 56,3	64	3 x 3	1 x 1	1 x 1	56	64
56 x 56,3	256	1 x 1	0	1 x 1	56	256

Tabel 6 menunjukkan bagaimana ukuran output dari feature map setelah konvolusi dihitung dengan mempertimbangkan ukuran filter, padding, dan stride. Ukuran output tetap 56 x 56 piksel untuk setiap konvolusi yang diterapkan, sementara jumlah channel output sesuai dengan jumlah filter yang digunakan dalam setiap lapisan konvolusi. Tebel 6 output size dari citra dapat dihitung dengan menggunakan persamaan 4 sedangkan untuk output channel akan sama jumlah filter.

Out size = $(56-1)/1 + 1 = 56$
 Out size = $(56+1-3)/1 + 1 = 56$
 Out size = $(56+1-1)/1 + 1 = 56$

Convolution pada stege ini dilakukan sebanyak tiga kali dengan parameter yang sama dengan output size yang sama. Dari perhitungan di atas, kita dapat melihat bahwa ukuran output feature map tetap 56 x 56 piksel setelah konvolusi, terlepas dari ukuran filter yang digunakan, selama parameter padding dan stride tetap konsisten.

6. Stage 2

Stage 2 adalah tahap penting dalam arsitektur ResNet50 di mana feature map yang dihasilkan dari Stage 1 (dengan dimensi 56 x 56 piksel) diproses lebih lanjut. Pada proses stage 2 dengan input citra 56 x 56 yang diteruskan dari stage 2 dapat dilihat dari tabel 7 tahap konvolusi dilakukan sebanyak empat kali dan masing-masing blok terdiri dari tiga convolusi dan 4 kali ReLu. Pada Stage 2, feature map yang diterima dari Stage 1 memiliki dimensi 56 x 56 piksel disajikan pada Tabel 7.

Tabel 7. Parameter Dan Output Pada Stage 2

Input Size	Filter	Filter Size	Padding	Stride	Output Size	Output Channel
28x28	128	1 x 1	0	1 x 1	56	128
28x28	256	3 x 3	1 x 1	2 x 2	28	256
14x14	512	1 x 1	0	1 x 1	28	512

Out size = $(56-1)/1 + 1 = 56$
 Out size = $(56+1-3)/2 + 1 = 28$
 Out size = $(28-1)/1 + 1 = 28$

Pada Stage 2 dalam arsitektur ResNet50, ukuran output feature map dihitung dengan menggunakan parameter konvolusi tertentu yang mungkin melibatkan perubahan stride. Kemudian pada blok selanjutnya terdapat perbedaan pada parameter konvolusi yaitu nilai stride yang pada blok pertam 2 x 2 menjadi 1 x 1 selanjutnya output yang dilakukan tidak mengubah output dari blok pertama yaitu 28 x 28. Struktur ini memastikan bahwa ukuran output dapat dikelola dengan konsisten sepanjang tahap konvolusi.

7. Stage 3

Stage 3 adalah tahap dalam arsitektur ResNet50 di mana feature map yang dihasilkan dari Stage 2 (dengan dimensi 28 x 28 piksel) diproses lebih lanjut. Proses stage 3 dengan input citra 28 x 28 yang diturunkan dari stage 2 dapat dilihat dari Tabel 8 tahap konvolusi dilakukan sebanyak 6 blok dan masing-masing blok

terdiri dari tiga convolusi dan 6 kali ReLu. Setiap blok residual terdiri dari tiga lapisan konvolusi dan enam aplikasi fungsi aktivasi ReLu.

Tabel 8. Parameter Dan Output Pada Stage 3

Input Size	Filter	Filter Size	Padding	Stride	Output Size	Output Channel
28x28, 128	256	1 x 1	0	1 x 1	28	256
28x28, 256	256	3 x 3	1 x 1	2 x 2	14	256
14x14, 1024	1024	1 x 1	0	1 x 1	14	1024

Out size = $(28-1)/1 + 1 = 28$
 Out size = $(28+1-3)/2 + 1 = 14$
 Out size = $(14-1)/1 + 1 = 14$

Pada Stage 3 dalam arsitektur ResNet50, perhitungan ukuran output feature map melibatkan berbagai parameter konvolusi, termasuk ukuran filter dan stride. Blok selanjutnya terdapat perbedaan pada parameter konvolusi yaitu nilai stride yang pada blok pertama 2 x 2 menjadi 1 x 1 sehingga output yang dilakukan tidak merubah output dari blok pertama yaitu 14 x 14. Blok pertama menggunakan stride 2 pada konvolusi kedua, yang mengurangi ukuran feature map dari 28 x 28 menjadi 14 x 14. Blok-blok berikutnya menggunakan stride 1 x 1, sehingga ukuran feature map tetap konsisten pada 14 x 14 piksel.

8. Stage 4

Stage 4 adalah tahap berikutnya dalam arsitektur ResNet50 di mana feature map yang dihasilkan dari Stage 3 (dengan dimensi 14 x 14 piksel) diproses lebih lanjut. Proses stage 4 dengan input citra 14 x 14 yang diteruskan dari stage 3 dapat dilihat dari Tabel 10. Tahap konvolusi dilakukan sebanyak 6 blok dan masing – masing blok terdiri dari tiga convolusi dan 3 kali ReLu.

Tabel 10. Parameter Dan Output Pada Stage 4

Input Size	Filter	Filter Size	Padding	Stride	Output Size	Output Channel
14x 14, 256	512	1 x 1	0	1 x 1	14	512
14x 14, 256	512	3 x 3	1 x 1	2 x 2	7	512

Out size = $(14 - 1)/1 + 1 = 14$
 Out size = $(14 + 1 - 3)/2 + 1 = 7$
 Out size = $(7 - 1)/1 + 1 = 7$

Pada Stage 4 dalam arsitektur ResNet50, feature map berukuran 14 x 14 piksel dari Stage 3 diproses melalui beberapa konvolusi. Konvolusi pertama mempertahankan ukuran feature map pada 14 x 14 piksel, sedangkan konvolusi kedua mengurangi ukuran feature map menjadi 7 x 7 piksel akibat penggunaan stride 2 x 2. Konvolusi ketiga mempertahankan ukuran output pada 7 x 7 piksel dengan stride 1 x 1. Perubahan parameter konvolusi, khususnya stride, mempengaruhi ukuran output feature map dan konsistensi dimensi pada blok residual berikutnya.

9. Proses Training

Proses training merupakan proses pembelajaran dari Data Training dan perbandingan dengan Data Validation. Tujuan dari Training untuk mendapatkan model yang dapat mempelajari jenis hama dan penyakit pada penelitian ini. Terdapat training akan mengukur loss MSE dan accuracy pada data training data validasi. Sebelumnya melakukan tahapan Training menggunakan beberapa pengaturan, pengaturan yang dibutuhkan dijabarkan pada Tabel 11

Pengaturan	Filter
Batch size	32
Epoch	20
Optimizer	Adm
Learning rate	0.01

1. Batch size

Batch size adalah banyaknya citra yang akan diTraining dalam satu kali proses yaitu 40 Image. Memilih batch size yang tepat penting untuk keseimbangan antara memori yang digunakan dan kecepatan pelatihan. Batch size yang terlalu kecil mungkin menyebabkan pelatihan yang lebih tidak stabil, sedangkan batch size yang terlalu besar bisa memerlukan lebih banyak memori dan mungkin tidak berfungsi secara optimal untuk semua model.

2. Epoch


Epoch adalah satu putaran lengkap melalui seluruh dataset pelatihan. Selama satu epoch, model akan melakukan proses forward pass dan backward pass untuk setiap batch dalam dataset. Selanjutnya sampel yang diproses sebelum model di Update yaitu 10 Epoch. Jumlah epoch yang cukup diperlukan untuk memastikan model mempelajari fitur yang relevan dari data pelatihan. Namun, terlalu banyak epoch bisa menyebabkan overfitting, di mana model belajar terlalu banyak dari data pelatihan, mengurangi kemampuan generalisasi ke data yang belum terlihat.

3. Optimizer

Optimizer adalah algoritma yang digunakan untuk memperbarui bobot model berdasarkan gradien dari fungsi loss. Tujuannya adalah untuk meminimalkan nilai loss dan meningkatkan performa model. Optimizer diperlukan untuk mengurangi loss pada penelitian ini optimize yaitu digunakan adalah filter Adm. Adam adalah optimizer yang populer karena efisiensinya dan kemampuannya untuk menangani masalah dengan berbagai tingkat kerapatan gradien.

4. Learning Rate

Learning rate adalah parameter yang mengontrol seberapa besar perubahan yang dilakukan pada bobot model setiap kali update dilakukan selama pelatihan. Merupakan salah satu parameter Training untuk menghitung nilai koreksi bobot pada waktu proses Training. Nilai Learning Rate untuk Training yaitu 0,001. Agar proses pembelajaran lebih tergambar maka pada flowchar pada Gambar 2 Memperlihatkan alur dari proses pembelajaran mulai dari input citra sampai menghasilkan sebuah model disajikan pada Gambar 4.



Gambar 4. Hasil Pelatihan ANN

Akhir proses pelatihan model ANN yang tergambar pada beberapa metrik penting telah diukur untuk mengevaluasi kinerja model. Hasil tersebut mencakup Best Accuracy Train dan Best Accuracy Validation, serta visualisasi grafik hasil training. Hasil Training didapat Best Accuracy Train 0,94 dan Best Accuracy Validation 0,76 pada Epoch ke 16, grafik hasil training dapat dilihat pada Gambar 4. Ini adalah akurasi terbaik yang dicapai oleh model pada data validasi (validation data). Akurasi 0,76 berarti model berhasil mengklasifikasikan dengan benar 76% dari citra dalam data validasi.

4. Kesimpulan

Dari hasil pembahasan di atas dapat disimpulkan bahwa Penelitian ini berfokus pada penerapan Convolutional Neural Network (CNN) untuk identifikasi hama dan penyakit pada tanaman kelapa sawit. Dengan memanfaatkan model CNN, penelitian ini bertujuan untuk meningkatkan akurasi dalam deteksi penyakit serta hama pada bibit kelapa sawit, menggunakan dataset yang terdiri dari gambar bibit yang terinfeksi dan sehat. Implementasi model CNN diharapkan dapat

membantu petani dalam mengidentifikasi dan menangani penyakit tanaman secara lebih cepat dan efektif, sehingga berkontribusi pada peningkatan produktivitas dan keberlanjutan sektor perkebunan kelapa sawit.

Daftar Rujukan

- [1] A. D. Sabilla, P. Studi, S. Informasi, U. I. Nadhlatul, and U. Jepara, "Sistem pakar diagnosa penyakit dan hama tanaman kelapa sawit dengan metode forward chaining," vol. 4, no. 1, 2022.
- [2] Z. P. Nasution, R. Farrasati, and E. S. Sutarta, "Analisis Usahatani Tumpang Sari Hortikultura pada Fase Tanaman Kelapa Sawit Belum Menghasilkan (TBM) serta Dampaknya terhadap Kesuburan Tanah di Kecamatan Tandun, Rokan Hulu, Riau," *J. Ekon. Pertan. dan Agribisnis*, vol. 6, no. 2, p. 642, 2022, doi: 10.21776/ub.jepa.2022.006.02.28. doi: 10.21776/ub.jepa.2022.006.02.28.
- [3] R. Firnando,) ; Asnawati, and J. Fredicka, "Disease Diagnosis Expert System In Palm Oil Plants Using Forward Chaining Method Android Based Sistem Pakar Diagnosis Penyakit Pada Tanaman Kelapa Sawit Menggunakan Metode Forward Chaining Berbasis Android," *J. Kom.*, vol. 2, no. 2, pp. 643–652, 2022, [Online]. Available: <https://doi.org/10.53697/jkomitek.v2i2> DOI: 10.53697/jkomitek.v2i2.
- [4] R. Philips, "Sistem Pakar Diagnosa Penyakit Kelapa Sawit Menggunakan Metode Certainty Factor Berbasis Web," vol. 4, no. 3, 2022.
- [5] M. Mariana, A. Puspitaningrum, and W. Manullang, "KEEFEKTIFAN PENGENDALIAN HAMA ULAT API MENGGUNAKAN FOGGING PADA TANAMAN KELAPA SAWIT DI PT. SOCFINDO KEBUN MATAPAO," 2023.
- [6] A. Rohim, Y. A. Sari, and Tibyani, "Convolution Neural Network (CNN) Untuk Pengklasifikasian Citra Makanan Tradisional," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 7, pp. 7038–7042, 2019.
- [7] J. Kuswanto and J. Dapiokta, "Penerapan Metode Forward Chaining untuk Diagnosa Penyakit Pneumonia," *J. Unitek*, vol. 15, no. 1, pp. 20–26, 2022, doi: 10.52072/unitek.v15i1.311.
- [8] A. Car *et al.*, "No 主観的健康感を中心とした在宅高齢者における健康関連指標に関する共分散構造分析Title," *Int. J. Technol.*, vol. 47, no. 1, p. 100950, 2023, [Online]. Available: <https://doi.org/10.1016/j.tranpol.2019.01.002> Ahttps://doi.org/10.1016/j.cstp.2023.100950%0Ahttps://doi.org/10.1016/j.g eforum.2021.04.007%0Ahttps://doi.org/10.1016/j.trd.2021.1 02816%0Ahttps://doi.org/10.1016/j.tra.2020.03.015%0Ahttps ://doi.org/10.1016/j DOI: 10.1016/j.tranpol.2019.01.002
- [9] F. Rizal, F. Hasyim, K. Malik, and Y. Yudistira, "Implementasi Algoritma Convolutional Neural Networks (CNN) Untuk Klasifikasi Batik," *COREAI J. Kecerdasan Buatan, Komputasi dan Teknol. Inf.*, vol. 2, no. 2, pp. 40–47, 2022, doi: 10.33650/coreai.v2i2.3365. doi: 10.33650/coreai.v2i2.3365.
- [10] A. M. Lesmana, R. P. Fadhillah, and C. Rozikin, "Identifikasi Penyakit pada Citra Daun Kentang Menggunakan Convolutional Neural Network (CNN)," *J. Sains dan Inform.*, vol. 8, no. 1, pp. 21–30, 2022, doi: 10.34128/jsi.v8i1.377. doi: 10.34128/jsi.v8i1.377.
- [11] M. Afdhal and Rita, "Sistem Pakar Diagnosa Penyakit Hiperlipidemia Menggunakan Metode Certainty Factor Berbasis Web," *J. KomtekInfo*, vol. 11, no. 1, pp. 133–139, 2022, doi: 10.35134/komtekinfo.v9i4.321. doi: 10.35134/komtekinfo.v9i4.321.
- [12] V. Zuraida, D. Kusbianto, and M. R. Pahlevi, "Sistem Pakar Diagnosis Penyakit dan Hama pada Tanaman Padi dengan Metode Forward Chaining," *J. Minfo Polgan*, vol. 12, no. 1, pp. 378–384, 2023, doi: 10.33395/jmp.v12i1.12437. doi: 10.33395/jmp.v12i1.12437.
- [13] A. A. Santosa, R. Y. N. Fu'adah, and S. Rizal, "Deteksi Penyakit pada Tanaman Padi Menggunakan Pengolahan Citra Digital dengan Metode Convolutional Neural Network," *J. Electr. Syst. Control Eng.*, vol. 6, no. 2, pp. 98–108, 2023, doi: 10.31289/jesce.v6i2.7930. doi: 10.31289/jesce.v6i2.7930.
- [14] I. D. Zianka, S. D. Alim, M. K. Adiputro, and A. Setiawan, "Perancangan Aplikasi Android untuk Perhitungan Nutrisi Makanan Pencegah Stunting dengan Metode CNN di Jakarta," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 1, pp. 99–107, 2023, doi: 10.57152/malcom.v4i1.1027. doi: 10.57152/malcom.v4i1.1027.
- [15] 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/infv.v4i3.143. doi: 10.37034/infv.v4i3.143.
- [16] S. A. Maulana *et al.*, "Penerapan Metode CNN (Convolutional Neural Network) Dalam Mengklasifikasi Jenis Ubur-Ubur," *J. Penelit. Rumpun Ilmu Tek.*, vol. 2, no. 4, pp. 122–130, 2023, [Online]. Available: <https://doi.org/10.55606/juprit.v2i4.3084> DOI: 10.55606/juprit.v2i4.3084
- [17] 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. doi: 10.33322/kilat.v10i2.1458.
- [18] A. ANHAR and R. A. PUTRA, "Perancangan dan Implementasi Self-Checkout System pada Toko Ritel menggunakan Convolutional Neural Network (CNN)," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 11, no. 2, p. 466, 2023, doi: 10.26760/elkomika.v11i2.466. doi: 10.26760/elkomika.v11i2.466.