

Sistem Klasifikasi Akurat Penyakit Daun Padi Menggunakan Convolutional Neural Network (CNN) Model Xception

Rico Satria Ananda Putra¹
Rifqi Ardiyansyah¹

AFILIASI :

Jurusan Fisika, Fakultas Matematika
dan Ilmu Pengetahuan, Universitas
Jember

ALAMAT:

Universitas Jember, Jalan Kalimantan
Tegal Boto, Nomor 37, Jember, Jawa
Timur 68121

KORESPONDENSI:

Rico Satria Ananda Putra
Tel : +62 857-2974-7681
Email : ricosatria363@gmail.com

KATA KUNCI:

Convolutional Neural Network
Deteksi penyakit daun padi
Analisis citra daun
Klasifikasi berbasis citra

JEI

<https://journal.unej.ac.id/JEI>
jei@unej.ac.id
FMIPA UNIVERSITAS JEMBER
ISSN:3032 3398

ABSTRAK

Penelitian ini mengatasi tantangan dalam mengidentifikasi penyakit tanaman daun padi secara akurat dalam pengolahan tanaman agar berjalan secara efektif dan mengurangi kerugian ekonomi yang disebabkan oleh penurunan produktivitas hasil panen. Padi merupakan komoditas utama dalam sektor pertanian, sehingga aya identifikasi dini terhadap penyakit tanaman daun padi dapat memberikan dampak signifikan terhadap stabilitas pangan. Dengan memanfaatkan metode Convolution Neural Network (CNN) untuk menganalisis gambar daun yang terinfeksi, penelitian ini juga bertujuan untuk meningkatkan akurasi klasifikasi penyakit, sehingga dapat mendukung intervensi yang cepat dan tanggap dalam pengoahan padi yang lebih tepat. Metode yang digunakan dalam penelitian ini menggunakan CNN dengan fokus pada analisis tekstur citra daun padi yang diambil menggunakan kamera Vivo Y17. Data set yang digunakan mencakup berbagai jenis penyakit yang telah diberi label dengan kategori penyakit, meliputi bacterial blight, blast, brown spot, sehat dan tungro. Data set ini diperoleh dari berbagai kondisi pencahayaan dan variasi daun yang terinfeksi kemudian digunakan untuk memastikan kekayaan data yang dapat meningkatkan akurasi model. Hasil penelitian menunjukkan bahwa model CNN dengan arsitektur Xception yang dibangun memiliki kinerja yang sangat baik dengan akurasi sebesar 98,99%, nilai presisi sebesar 94%, nilai recall 96%, dan F1-Score 96% yang mengindikasikan bahwa model ini dapat membedakan berbagai kategori penyakit dengan akurasi yang tinggi berperan besar dalam membantu diagnosis otomatis penyakit daun padi dengan menganalisis gambar daun secara cepat dan akurat.

PENDAHULUAN

Masyarakat Indonesia sendiri bergantung pada sektor pertanian untuk memenuhi bahan pokok kebutuhannya dengan ekspor, pertanian dapat memberikan lapangan kerja dan devisa kepada negara [1]. Informasi yang sedikit tentang pengetahuan mengenai berbagai jenis penyakit tanaman padi hal ini akan mengakibatkan petani mengalami kesulitan dalam mengidentifikasi berbagai jenis penyakit pada tanaman padi, sehingga dalam pengendaliannya untuk mengurangi permasalahan penyakit tanaman padi yang dilakukan kurang sesuai [2]. Hal tersebut dapat menyebabkan petani mengalami kegagalan panen yang diakibatkan oleh serangan hama, kerugian tersebut dapat ditaksir mencapai 200.000 – 300.000 ton per-tahun [3]. Pentingnya penelitian ini terletak pada upaya untuk meningkatkan efisiensi dan akurasi dalam penanganan penyakit tanaman padi, yang merupakan salah satu komoditas utama dalam sektor pertanian di Indonesia. Melalui penerapan model machine learning serta pengembangan arsitektur klasifikasi berdasarkan citra daun, dapat membantu petani dalam identifikasi awal yang merupakan solusi instan untuk monitoring tanaman padi secara realtime dan efisiensi.

Penurunan hasil produksi, kualitas, dan kuantitas padi dapat disebabkan oleh penyakit tanaman. Sebagian besar, penyakit ini disebabkan oleh cendawan dan dapat berkembang dengan cepat, terutama pada fase pertumbuhan tertentu tanaman padi [4]. Penyakit tanaman padi merupakan tantangan besar dalam budidaya padi, yang dapat menyebabkan penurunan produksi dan kerugian ekonomi yang signifikan bagi petani. Menurut penelitian, bacterial blight, blast, brown spot, dan tungro adalah beberapa jenis penyakit padi yang umum [5]. Banyak petani padi di Indonesia masih mengalami kesulitan menemukan penyakit yang menyerang tanaman dengan cepat. Pengetahuan tentang berbagai jenis penyakit yang menyerang tanaman sering kali membuat sulit untuk mengidentifikasi gejala awal yang muncul pada daun. Petani sering

mengabaikan penanganan yang tepat karena sebagian besar informasi yang mereka miliki berasal dari pengalaman atau penyuluhan yang terbatas. Akibatnya, kesalahan diagnosis dan penanganan dapat menyebabkan gagal panen, yang dapat menyebabkan kerugian besar. Dalam keadaan seperti ini, penemuan metode yang tepat dapat membantu petani menemukan penyakit tanaman padi dengan cepat dan akurat yang merupakan poin penting untuk mengurangi risiko kerugian yang lebih besar.

Penelitian terdahulu telah banyak melakukan penelitian tentang mendeteksi penyakit tanaman padi dengan menggunakan metode CNN dan citra digital, penelitian yang dilakukan oleh Abwabul Jinan et al [6]. Mendeteksi bahwa penyebab terbesar kegagalan panen yaitu umumnya disebabkan oleh penyakit pada tanaman yang sangat mempengaruhi hasil panen dan berdampak besar pada produksi pangan nasional dan menyebabkan penurunan pada sektor ekonomi pertanian Indonesia. Penelitian ini memfokuskan penyakit yang paling sering menyerang tanaman padi yaitu bacterial leaf blight, brown spot, dan leaf spot. Tujuan penelitian ini adalah untuk mengklasifikasikan penyakit padi berdasarkan gambar daun yang terinfeksi menggunakan teknik deep learning CNN. Penelitian ini juga menggunakan skenario perbandingan parameter datasheet sebesar 90%, dengan menggunakan ukuran gambar 100x100 piksel, kernel 3x3, optimizer adam sebanyak 150 epoch dan ukuran batch 30.

Susi Yuliany et al [7]. Menangani pengendalian hama yang berfokus pada klasifikasi kerusakan tanaman, bukan pada klasifikasi hama itu sendiri. Oleh karena itu, melakukan klasifikasi jenis hama pada tanaman padi dapat membantu petani dalam menangani hama sesuai dengan jenisnya secara lebih cepat. Penelitian ini mengadopsi metode CNN yang meskipun metode ini kerap mengalami masalah overfitting dalam beberapa studi sebelumnya. Mengatasi permasalahan tersebut, penelitian ini mengusulkan penerapan tiga jenis

pembagian data untuk pelatihan training dan pengujian (testing). Hasil evaluasi menunjukkan bahwa pembagian data dengan rasio 90% banding 10% adalah yang paling sesuai untuk datasheet yang digunakan. Arsitektur CNN yang digunakan menunjukkan akurasi pelatihan sebesar 83,02% dengan akurasi pengujian mencapai 77,33%.

Erlyna dan Harintaka [8]. Menggunakan citra resolusi tinggi yang dihasilkan teknologi UAV (Unmanned Aerial Vehicle) memberikan hasil optimal untuk mengekstraksi, sehingga berguna dalam pemantauan dan pembaruan data visual khususnya dalam konteks tanaman pertanian. Penelitian ini berfokus pada pendekatan klasifikasi semantik otomatis yang membedakan jenis tanaman sebagai alternatif metode pengenalan objek dengan memanfaatkan deep learning khususnya melalui metode CNN. Hasil dalam proses pembelajaran jaringan menunjukkan akurasi 100% terhadap data pelatihan sementara akurasi terhadap data validasi mencapai 93% dan akurasi untuk data uji adalah 82%.

Rio Juan H. B. dan Noveri L. M [9]. Dalam alternatif pengobatan dan penyegaran berbagai penyakit, tanaman obat merupakan jenis tanaman yang efektif dalam menangani permasalahan ini. Fokus pada penelitian ini mengidentifikasi objek pada tanaman obat memanfaatkan metode transfer learning yang memungkinkan penggunaan model yang telah dilatih sebelumnya sebagai dasar untuk menyelesaikan tugas baru sehingga mengurangi kebutuhan akan data yang banyak. Model yang digunakan dalam penelitian ini adalah MobileNet V2, yang memiliki arsitektur ruangan dan akurasi tinggi. Teknik fine-tuning diterapkan untuk meningkatkan performa model dengan melakukan beberapa percobaan menggunakan berbagai parameter seperti jumlah epoch dan lapisan yang di fine-tune, untuk mencapai hasil yang optimal.

Penelitian yang dilakukan oleh Ummi S. R. dan Noveri L. M [10]. Mengidentifikasi jenis jamur dan mengembangkan model yang dapat mengklasifikasi jenis jamur berdasarkan genus

yang dapat dikonsumsi dan tidak dapat dikonsumsi (beracun). Metode yang digunakan adalah CNN yang dibangun terdiri dari tiga lapisan konvolusi, 3 lapisan max pooling, dan 2 lapisan dropout. Penggunaan lapisan dropout bertujuan untuk mengurangi masalah overfitting pada model. Data gambar yang digunakan berjumlah 1200 dengan perbandingan data training dan data validasi sebesar 70 banding 30. Terdapat 800 data untuk pelatihan dan 360 data untuk pengujian. Hasil akurasi terbaik yang diperoleh dari model ini adalah 89% untuk data pelatihan dan 82% untuk data pengujian.

Berdasarkan penelitian yang dilakukan oleh Arya Prayoga et al [11]. yang meneliti model klasifikasi citra batik dengan jumlah data 600 citra gambar yang dibagi atas 3 motif yang berbeda ceplok, kawung, dan parang dalam pengenalan motif batik Yogyakarta. Dalam penelitian menggunakan metode CNN yang diberi lapisan sub sampling yang berfungsi dalam mengurangi ukuran dimensi tanpa kehilangan bobot yang penting. Hasil akhir metode ini menggunakan fully connected agar menghasilkan klasifikasi secara linier. Hasil akurasi tertinggi dalam penelitian ini sebesar 87,66%. Sedangkan penelitian yang dilakukan oleh Uung U. dan Galih A. H. [12]. Yang mengklasifikasikan kematangan buah kopi menggunakan metode CNN Inception V3 yang menggunakan 1380 dataset citra dengan 984 data citra untuk training 246 citra sebagai validasi dan 150 citra untuk testing, menghasilkan akurasi sebesar 92.00%.

Selanjutnya ada banyak penelitian yang menggunakan implementasi penggunaan deep learning dengan metode CNN seperti penelitian yang dilakukan oleh Mutaqin Akbar et al [13]. Dalam mengklasifikasikan sel normal dari sel kanker dengan data set sebesar 582 data. Di dalamnya terdapat 3 lapisan konvolusi (ukuran filter 3x3, dan fungsi aktivasi ReLU) yang menghasilkan akurasi 98% pada epoch ke-20. Model CNN yang diberi hyper parameter tuning yang dilakukan oleh Siti A. dan Toni A. [14]. Dalam mengklasifikasi jenis batik, hyper parameter tuning menghasilkan penambahan akurasi yang lebih tinggi dibandingkan model CNN yang biasa untuk

mengurangi overfitting. Pengembangan model deep learning juga dapat ditransfer dalam berbasis website seperti klasifikasi uang kertas rupiah yang menggunakan CNN dengan akurasi 93,57% untuk membedakan uang yang terindikasi tidak layak edar dengan uang layak edar, menunjukkan akurasi 99,22% untuk training dan 96,19% untuk validasi [15]. Penelitian yang dilakukan oleh Yestikan Dian Wulandari et al [16] yang menggunakan objek daun cabe dengan metode Xception yang ditambahkan model training ImageNet untuk klasifikasi antara sehat dan terkena penyakit, menghasilkan akurasi sebesar 91% dan sukses memprediksi 10 dari 10 gambar data baru yang diberikan pada model.

Berdasarkan beberapa penelitian diatas yang menggunakan klasifikasi metode CNN menghasilkan hasil yang baik dalam pengolahan citra. Meskipun metode CNN telah digunakan secara luas dalam mendeteksi penyakit tanaman padi, penelitian sebelumnya hanya sebagian besar menggunakan arsitektur CNN konvensional yang memiliki keterbatasan dalam hal efisiensi dan akurasi. Beberapa penelitian telah menunjukkan hasil akurasi yang baik, tetapi seringkali terbatas pada beberapa jenis penyakit seperti bacterial leaf blight atau brown spot. Arsitektur yang digunakan juga seringkali rentan terhadap masalah overfitting dan membutuhkan data pelatihan yang sangat besar untuk mencapai akurasi yang optimal. Menjawab permasalahan ini, penelitian ini mengusulkan penggunaan model Xception, yang merupakan salah satu bagian dari CNN dengan performa yang lebih baik dalam klasifikasi gambar. Xception memiliki arsitektur yang lebih efisien dalam ekstraksi fitur gambar, sehingga dapat meningkatkan akurasi dalam klasifikasi penyakit yang lebih kompleks seperti bacterial blight, blast, brown spot, dan tungro. Penggunaan model Xception, penelitian ini diharapkan memberikan solusi instan yang lebih efisien dan akurat untuk mendeteksi berbagai penyakit padi melalui citra daun.

Penelitian ini dilakukan dengan tujuan untuk mengatasi masalah kritis dalam pertanian di Indonesia dengan merancang model

arsitektur Xception dalam klasifikasi tanaman padi berdasarkan citra daun sehingga penelitian ini menghasilkan suatu solusi agar tidak diperlukan untuk menginput secara manual dalam gejala-gejala permasalahan tanaman padi. Penelitian ini juga bertujuan untuk mempersingkat waktu dalam proses klasifikasi berbagai penyakit secara akurat untuk menentukan efektivitas dalam penanganan penyakit tanaman padi

METODE

Desain Penelitian

Penelitian ini menggunakan desain penelitian eksperimental dengan pendekatan kuantitatif, yang dirancang untuk mengevaluasi efektivitas model klasifikasi penyakit tanaman padi berdasarkan citra daun. Dalam penelitian ini, pengambilan sampel daun padi dilakukan secara langsung dari lahan pertanian di Kecamatan Summersari, Kabupaten Jember, di mana daun yang terinfeksi dan sehat dikumpulkan untuk dianalisis menggunakan model klasifikasi yang dikembangkan. Meskipun tidak secara eksplisit menyebutkan adanya kelompok kontrol, pengambilan gambar daun sehat dan terinfeksi dapat dipandang sebagai pengelompokan data yang akan diuji oleh model. Metode sampling yang digunakan adalah teknik pengambilan sampel acak untuk memastikan representasi yang baik dari setiap jenis daun dalam dataset.

Manfaat dari penelitian ini adalah untuk membuat model klasifikasi yang akurat dan efisien untuk menemukan penyakit pada tanaman padi. Diharapkan bahwa ini akan meningkatkan produktivitas pertanian di Indonesia. Penelitian ini bertujuan untuk mengatasi masalah kritis dalam pertanian di Indonesia dengan merancang model arsitektur Xception dalam klasifikasi tanaman padi berdasarkan citra daun sehingga penelitian ini menghasilkan suatu solusi agar tidak diperlukan untuk menginput secara manual dalam gejala-gejala permasalahan tanaman padi. Penelitian ini juga bertujuan untuk mempersingkat waktu dalam proses klasifikasi berbagai penyakit secara akurat

untuk menentukan efektivitas dalam penanganan penyakit tanaman padi.

Objek yang menjadi fokus penelitian ini adalah daun tanaman padi, yang digunakan untuk indikasi pertama adanya suatu jenis penyakit pada tanaman padi menggunakan citra daun sebagai input utama. Sampel daun diambil dari lahan pertanian di Kecamatan sumbersari, Kabupaten Jember. Dalam konteks lingkungan, padi rentan terhadap serangan hama dan penyakit, yang seringkali sulit dideteksi secara cepat dan akurat oleh petani. Oleh karena itu, pengukuran dan klasifikasi penyakit pada daun padi sangat penting untuk menjaga produktivitas pertanian dan memastikan ketersediaan pangan yang stabil di tengah tantangan agraris seperti perubahan iklim dan minimnya akses petani terhadap teknologi di Kabupaten Jember. Pengambilan sampel dari lingkungan yang bervariasi dan teknik augmentasi data pada sumber referensi juga akan memberikan dataset yang lebih komprehensif dan meningkatkan akurasi model klasifikasi.

Jenis data dan pengambilan data

Berbagai kelas penyakit yang digambarkan pada daun tanaman padi digunakan sebagai dataset penelitian. Total sampel yang digunakan dalam penelitian ini adalah 6.932 gambar daun dengan rincian 1.000 gambar daun sehat dan 5.932 gambar daun yang terinfeksi berbagai penyakit yang terbagi atas kedalam, beberapa kelas penyakit diantaranya yaitu brown spot, tungro, blast, bacterial blight yang diambil dari situs Mendeleey untuk memberikan ukuran sampel yang cukup untuk melatih dan menguji model klasifikasi. Dataset untuk daun tanaman padi yang sehat diperoleh dengan melakukan pengambilan data pada Kecamatan Sumbersari dengan lokasi yang sudah ditentukan, sebanyak 1.000 data. Detail jumlah data dan gambar foto daun pada setiap kelas pada penyakit daun tanaman padi dapat ditampilkan dalam gambar 1 dan tabel 1.

Diagram alir pada gambar 2 menjelaskan bagaimana alur pengambilan data yang dilakukan dalam penelitian ini. Tahap awal penelitian dilakukan dengan mengumpulkan

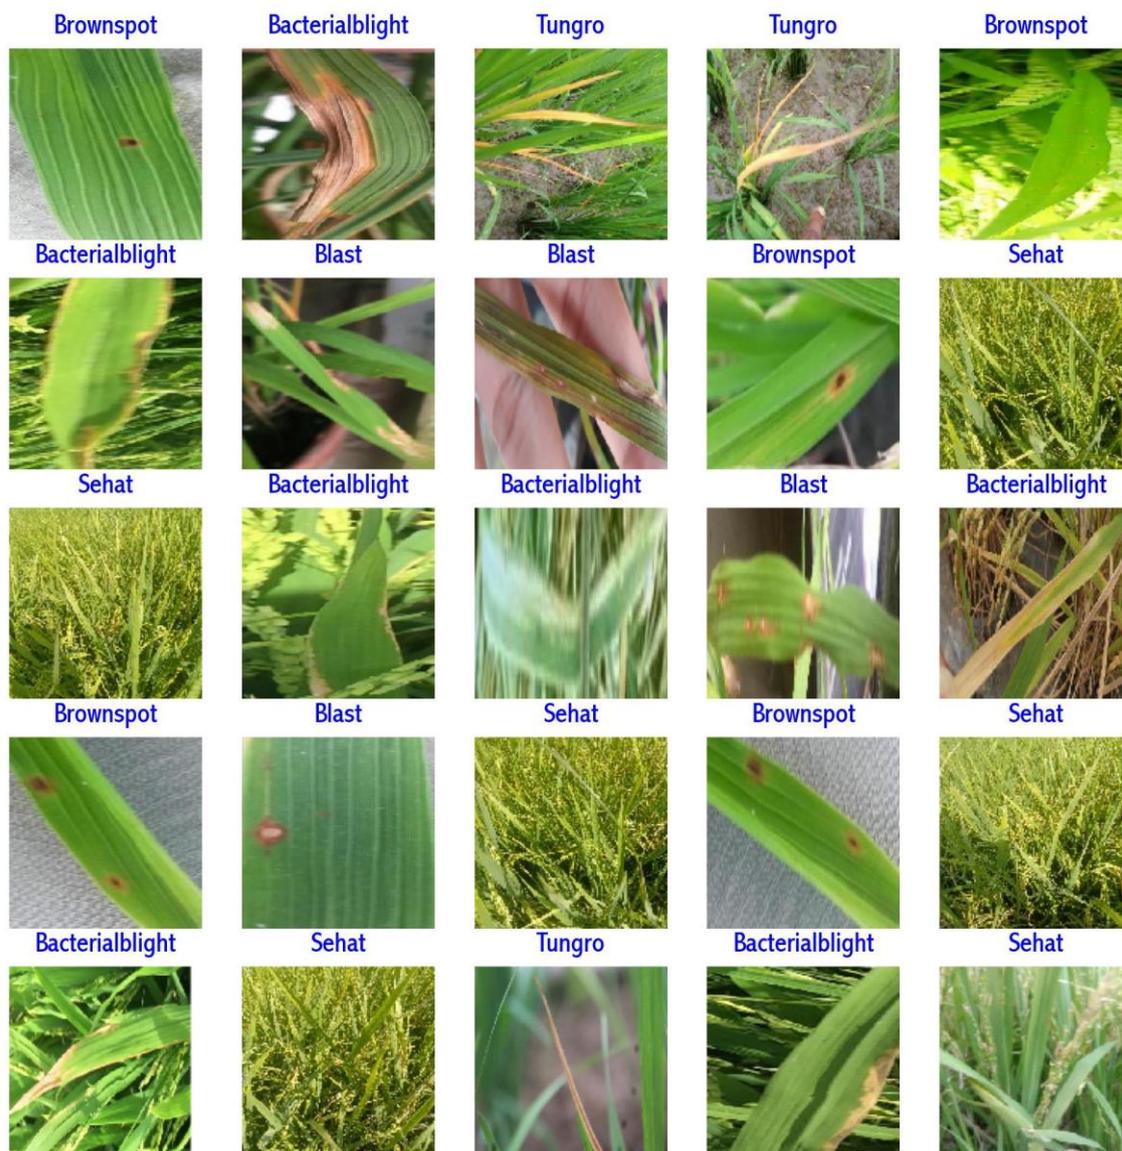
data penelitian sebanyak data yang telah ditentukan. Data tersebut kemudian dibedakan kedalam 5 kelas berbeda yakni bacterialblight, brownspot, tungro, sehat, dan blast seperti pada gambar 1 yang memperlihatkan dari kelas penyakit tersebut. Selanjutnya data dilakukan pemisahan data yang terdiri atas data pelatihan, data validasi, dan data pengujian, kemudian dari data tersebut dilakukan klasifikasi CNN. Hasil klasifikasi kemudian ditampilkan dalam bentuk grafik model dan confusion matrix.

Prosedur Penelitian

Prosedur penelitian dimulai dengan persiapan, yang mencakup pemilihan lokasi pengambilan sampel di lahan pertanian Kecamatan Sumbersari, Kabupaten Jember. Setelah lokasi ditentukan, langkah selanjutnya adalah menyiapkan alat pengambilan gambar, yaitu kamera smartphone Vivo Y17. Pengambilan gambar dilakukan secara langsung di lapangan dengan memotret daun padi yang sehat dan terinfeksi penyakit. Setiap gambar diambil pada resolusi 13MP dengan mempertimbangkan variasi pencahayaan dan sudut pengambilan untuk menghasilkan dataset yang lebih banyak. Setelah pengambilan gambar, citra daun yang dikumpulkan kemudian diproses untuk memastikan kualitas data. Proses ini meliputi pemeriksaan untuk mengidentifikasi dan menghapus data yang hilang atau tidak relevan. Selanjutnya, dataset yang terdiri dari 6.932 gambar dibagi menjadi tiga bagian yakni 80% untuk data pelatihan, 10% untuk data validasi, dan 10% untuk data pengujian. Dengan langkah-langkah ini, penelitian bertujuan untuk menghasilkan model klasifikasi yang akurat dalam mendeteksi penyakit pada tanaman padi berdasarkan citra daun yang telah dikumpulkan.

Analisis Data

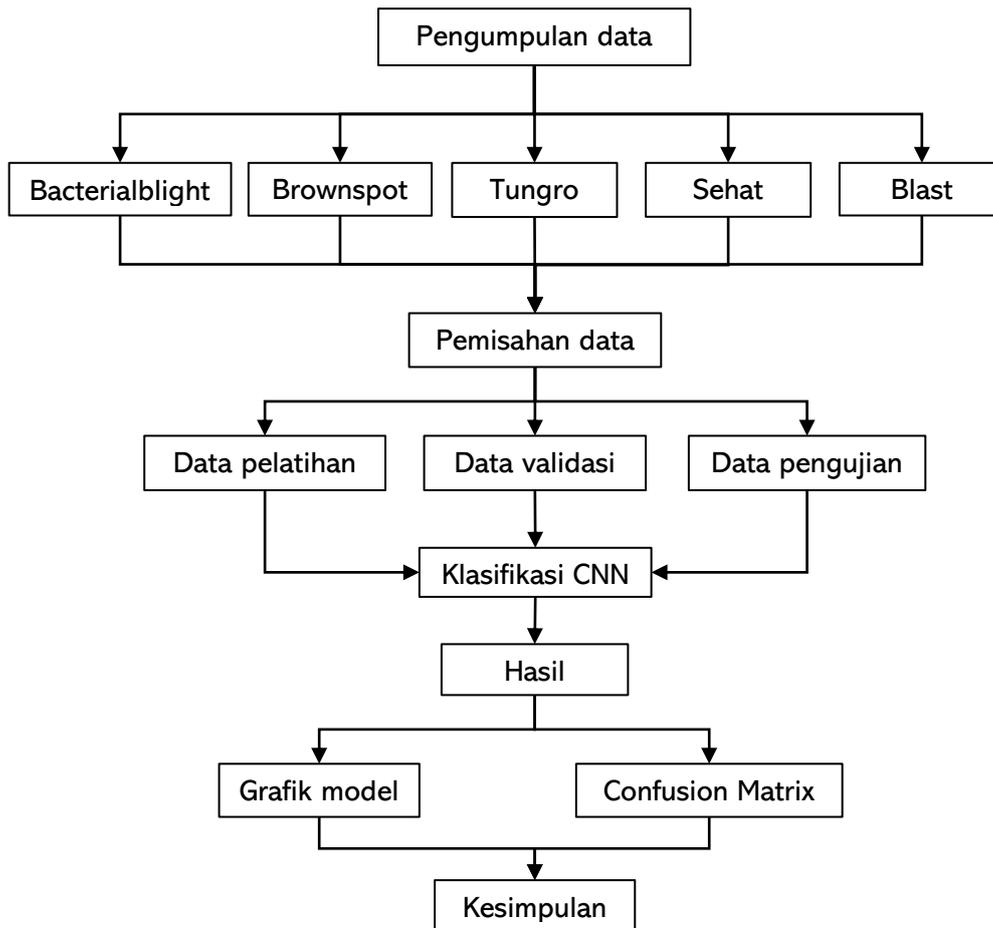
Model deep learning berbasis Convolutional Neural Network (CNN), yang dirancang dengan arsitektur Xception, digunakan untuk melakukan analisis data dalam penelitian ini.



Gambar 1. Foto kelas penyakit daun padi

Tabel 1. Jumlah Data Penyakit Daun Tanaman Padi

Jenis Penyakit	Jumlah Data	Sumber Data
Sehat	1,000	Kecamatan Sumpersari, Kabupaten Jember sethy, prabira Kumar (2024), "Rice Leaf Disease Image Samples", Mendeley Data, V2, doi: 10.17632/fwcj7stb8r.2
Blast	1,440	
Tungro	1,308	
Bacterial Blight	1,584	
Brown Spot	1,600	
Total	6,932	



Gambar 2. Alur Pengambilan data

Data yang telah dikumpulkan dibagi menjadi tiga subset yakni data pelatihan, data validasi, dan data pengujian, dengan proporsi masing-masing 80%, 10%, dan 10%. Analisis kinerja model melibatkan penggunaan metrik evaluasi seperti akurasi, presisi, recall, dan F1-Score, yang dihitung berdasarkan prediksi model terhadap data pengujian. Untuk mengetahui seberapa baik model melakukan klasifikasi, penggunaan fungsi kehilangan kategoris adalah crossentropy. Analisis statistik dilakukan menggunakan Python dengan pustaka seperti TensorFlow dan Keras untuk mengimplementasikan model serta menghitung metrik evaluasi.

Dalam penelitian ini menggunakan beberapa metrik dalam mengevaluasi kinerja model klasifikasi yang telah dibuat dan dikembangkan. Akurasi adalah metrik yang digunakan untuk mengukur seberapa baik model dalam melakukan klasifikasi, yang

dihitung berdasarkan Persamaan (1) sebagai rasio antara jumlah prediksi yang benar dengan jumlah total prediksi dikalikan dengan 100%. Presisi yang mengukur proporsi prediksi positif yang benar dihitung dengan Persamaan (2) yakni rasio antara true positives (TP) dengan jumlah true positives dan false positives (FP). Recall yang menggambarkan seberapa banyak data positif yang benar berhasil diprediksi dirumuskan dalam Persamaan (3) sebagai rasio antara TP dan jumlah TP serta false negatives (FN). F1-Score yang memberikan keseimbangan antara presisi dan recall dihitung menggunakan Persamaan (4) yang merupakan perhitungan dari kedua metrik tersebut. Terakhir, fungsi loss dalam klasifikasi dengan categorical crossentropy dapat dilihat pada Persamaan (5) yang menghitung kerugian berdasarkan log dari prediksi yang dihasilkan oleh model dibandingkan dengan label yang benar.

Berikut ini merupakan beberapa rumus yang digunakan dalam pengolahan data.

$$\text{Akurasi} = \frac{\text{Jumlah prediksi benar}}{\text{Jumlah total prediksi}} \times 100\% \quad (1)$$

$$\text{Presisi} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (3)$$

$$\text{F1} = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (4)$$

$$\text{Loss} = - \sum_{i=1}^N y_i \log(\hat{y}_i) \quad (5)$$

Confusion Matrix digunakan untuk menggambarkan kinerja dari model klasifikasi. Tabel 2 merupakan representasi dari confusion matrix yang digunakan dalam mengevaluasi kinerja dari suatu model klasifikasi.

Tabel 2. Confusion Matrix

	Prediksi Positif	Prediksi Negatif
Aktual Positif	TP	FN
Aktual Negatif	FP	TN

HASIL DAN PEMBAHASAN

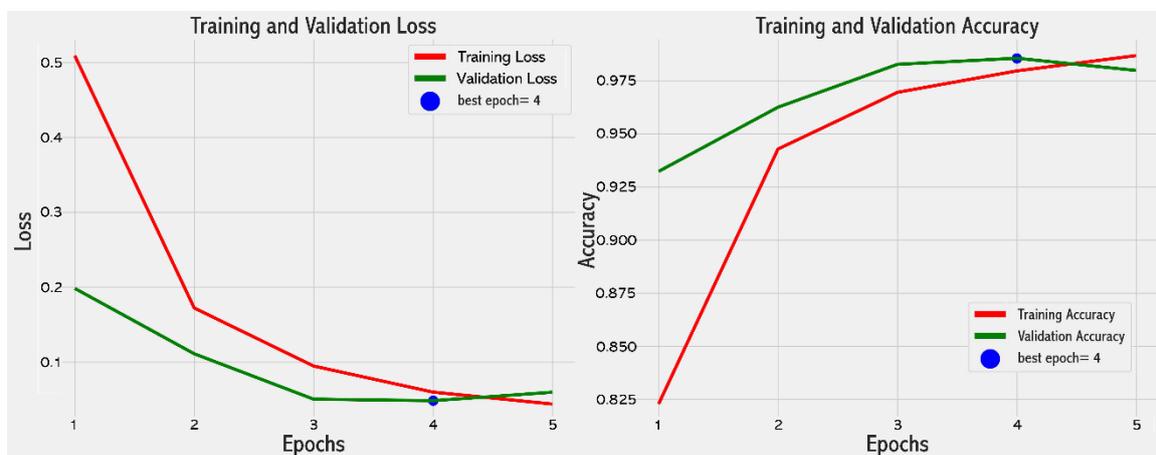
Tabel 3 menunjukkan hasil pelatihan model klasifikasi CNN *Xception* selama lima epoch, menunjukkan adanya peningkatan secara bertahap pada tingkat *accuracy* dan penurunan pada *loss*. Pada epoch pertama,

accuracy masih rendah pada nilai 0,6088 dengan *loss* yang tinggi yakni 1,2145, tetapi nilai *val accuracy* sudah cukup tinggi pada 0,9337, yang menunjukkan kemampuan generalisasi awal yang baik. Nilai *accuracy* meningkat seiring pelatihan yang berlangsung hingga pada epoch kelima, nilai *accuracy* meningkat menjadi 0,9792 dan *loss* menurun menjadi 0,0685. Hasil ini menunjukkan bahwa model CNN dapat belajar serta berfungsi dengan baik tanpa menunjukkan tanda-tanda *overfitting* yang signifikan.

Gambar 3 menunjukkan grafik training and validation loss serta grafik training and validation accuracy, untuk grafik training and validation loss terjadi penurunan kurva grafik dengan cepat, hal ini mengindikasikan bahwa model CNN belajar dengan cepat dari data pelatihan. Epoch ke-4 merupakan nilai validation loss terendah yang berarti pada tahap ini model dapat memprediksi data yang belum pernah dilihat sebelumnya

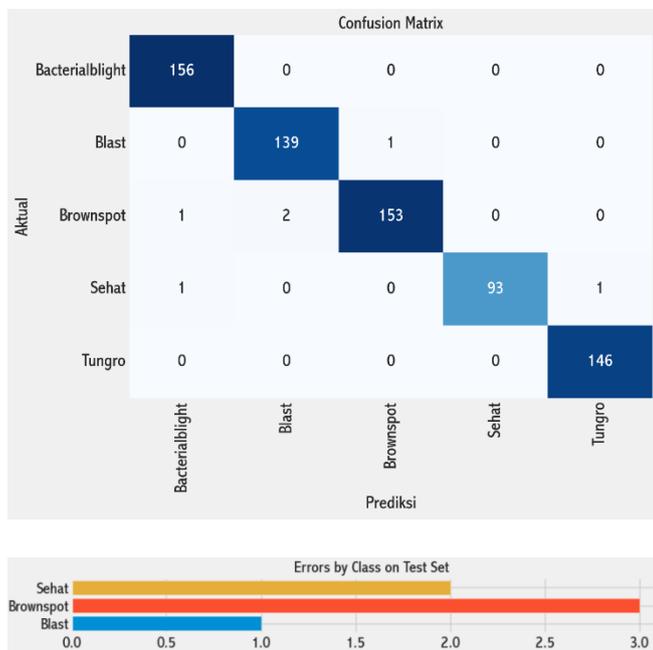
Tabel 3. Hasil pelatihan setiap epoch

Epoch	Accuracy	Loss	Val Accuracy	Val Loss
1	0,6088	1,2145	0,9337	0,2016
2	0,9154	0,2519	0,9597	0,1327
3	0,9622	0,1197	0,9755	0,0756
4	0,9758	0,0798	0,9928	0,0482
5	0,9792	0,0685	0,9813	0,0573



Gambar 3. Model training, validation dan loss pada CNN *Xception*

Setelah epoch ke-4, training loss cenderung menurun tetapi validation loss sedikit meningkat, yang terindikasi adanya potensi overfitting. Sedangkan pada grafik training and validation accuracy pada awal pelatihan cenderung meningkat, menunjukkan bahwa model dapat mempelajari pola dasar dengan mudah. Epoch ke-4 merupakan titik tertinggi nilai validation accuracy, dengan ini model telah menemukan konfigurasi yang optimal dalam menggeneralisasi data. Potensi overfitting juga terjadi setelah epoch ke-4 dimana validation accuracy mengalami penurunan sedikit dan training accuracy terus mengalami peningkatan.



Gambar 4. Confusion matrix CNN Xception

Gambar 4 menunjukkan confusion matrix yang menunjukkan bagaimana model Convolutional Neural Network (CNN) yang dibangun menggunakan arsitektur Xception melakukan klasifikasi penyakit tanaman padi. Setiap elemen dalam confusion matrix menggambarkan hubungan antara kondisi aktual dan prediksi pada model. Hasil pada kelas penyakit bacterial blight diprediksi sebanyak 156 sepenuhnya yang sesuai tetapi beberapa ada yang meleset dari hasil prediksi seperti pada Brownspot 1 data foto dan sehat 1 data foto. Pada bagian blast menghasilkan 139 prediksi yang benar, tetapi

ada 2 prediksi salah yang mengarah pada kelas brownspot. Total prediksi benar pada label brownspot berjumlah 153 data foto dan terjadi 1 kesalahan mengarah pada label blast, sedangkan pada data foto sehat semuanya terprediksi benar dengan jumlah 93 data. Terakhir pada label tungro ada sejumlah 146 data yang benar dengan 1 data kesalahan prediksi ke arah label sehat.

Hasil penelitian ini menunjukkan model CNN dengan arsitektur Xception mampu menghasilkan akurasi yang sangat tinggi yang berguna untuk klasifikasi penyakit tanaman padi. Pada tabel 3, dapat dilihat bahwa akurasi validasi mencapai 97,58% pada epoch keempat, dengan nilai loss yang terus menurun drastis hingga mencapai nilai 0,0798. Temuan ini didukung oleh hasil penelitian Abwabul Jinan *et al* [6], yang menggunakan CNN untuk mendeteksi penyakit tanaman padi seperti bacterial blight, brown spot, dan leaf spot yang merupakan penyebab penurunan hasil panen di Indonesia. Penelitian tersebut menggunakan gambar dengan resolusi 100x100 pixel yang menghasilkan akurasi yang cukup tinggi pada data pelatihan.

Peningkatan akurasi pada penelitian ini, pada posisi epoch ke-4 menunjukkan kemampuan model belajar secara otodidak dan progresif dari keempat data label yang sudah dipisah. Namun, pada posisi epoch ke-5 terjadi sedikit kenaikan akurasi validasi dari 97,58% menjadi 97,92%, semakin banyak jumlah epoch yang dijalankan akan berakibat adanya potensi overfitting terhadap data pelatihan, sebagaimana diungkapkan oleh Susi Yuliany *et al* [7]. Dalam penelitian mereka, overfitting menjadi tantangan yang paling sering terjadi dalam implementasi CNN, terutama pada data set yang kecil dan fitur label yang jumlahnya banyak. Penurunan ini dapat diperbaiki dengan teknik seperti dropout atau data augmentation, seperti yang pernah dilakukan oleh Umami S. R. dan Noveri L. M [10], untuk mengurangi overfitting pada klasifikasi jenis jamur.

Grafik akurasi dan loss pada gambar 3 dapat dilihat menunjukkan bahwa model belajar secara cepat pada *epoch* pertama, kemudian stabil pada *epoch* berikutnya. Pola pada grafik *epoch* sesuai dengan penelitian Mutaqin Akbar *et al* [13], yang menunjukkan peningkatan signifikan akurasi model CNN pada 10 *epoch* pertama dan stabil setelah dilakukan metode *hyper parameter tuning*. Selain itu hasil *confusion matrix* mengindikasikan bahwa sebagian besar kelas berhasil diklasifikasikan dengan benar, namun ada beberapa kesalahan pada kelas *blast* dan sehat. Hal ini bisa disebabkan oleh kemiripan fitur data citra antara kedua kelas, sebagai mana dikemukakan oleh Yestikan Dian Wulandari *et al* [16], yang mengimplementasikan metode *Xception* untuk klasifikasi daun cabai dan melaporkan bahwa fitur data citra memiliki kemiripan atau serupa antara daun sehat dan daun yang terindikasi penyakit yang dapat menyebabkan kesalahan pada proses klasifikasi.

Model *Xception* terbukti bahwa memiliki performa yang sangat unggul dibandingkan beberapa model CNN lainnya, seperti yang dicontohkan oleh Rio Juan H. B. dan Noveri L. M [9], yang menggunakan model arsitektur *MobileNet V2* dan mendapatkan akurasi pengujian lebih rendah 92% meskipun menggunakan teknik *transfer learning*. Keunggulan *Xception* pada penelitian ini konsisten dengan hasil yang dilaporkan oleh Yestikan Dian Wulandari *et al* [16], pada penggunaan model *pre-trained* seperti *ImageNet* yang dapat meningkatkan kemampuan generalisasi model terhadap data baru.

Meskipun hasil penelitian ini sangat baik, ada beberapa keterbatasan yang menjadi landasan utama seperti model hanya diuji pada data set spesifik tanpa variasi lingkungan seperti pencahayaan dan sudut gambar yang dapat mempengaruhi kondisi nyata. Penelitian yang dilakukan oleh Erlyna dan Harintaka [8], menunjukkan bahwa penggunaan citra resolusi tinggi UAV (*Unmanned Aerial Vehicle*) yang dapat meningkatkan akurasi pada aplikasi

lapangan. Selain itu model belum menggunakan metode *Advanced* seperti *fine tuning* yang diterapkan oleh Arya Prayoga *et al* [11], yang mampu mampu meningkatkan performa klasifikasi citra batik.

Penelitian ini memiliki kekuatan utama sebagai dasar pondasi dalam pengguna model *Xception* yang berbasis CNN yang memanfaatkan ekstraksi fitur visual kompleks dari citra daun padi. Hal ini terbukti dari akurasi validasi yang tinggi, yaitu 99,70%. Selain itu model berhasil menunjukkan kemampuan generalisasi yang baik pada data set yang sudah diberikan, meskipun hanya menggunakan resolusi gambar yang standar. Namun, penelitian ini juga memiliki keterbatasan yang belum memanfaatkan teknik seperti data *augmentation* atau *transfer learning* untuk meningkatkan kemampuan generalisasi, yang dapat membantu mengatasi tantangan adanya potensi *overfitting* dan keterbatasan data set. Penelitian ini juga belum mengeksplorasi pengaruh ukuran kernel atau jumlah lapisan konvolusi pada variasi arsitektur *Xception* terhadap hasil klasifikasi. Model ini juga hanya memvalidasi pada data set yang sama tanpa pengujian dengan data eksternal yang mengurangi kemampuan model untuk mengadaptasi pada data set baru atau berbeda.

KESIMPULAN

Penelitian ini berhasil mengembangkan berbasis *Convolutional Neural Network (CNN)* untuk klasifikasi penyakit daun padi melalui analisis citra daun. Hasil penelitian menunjukkan bahwa metode CNN mampu mencapai tingkat akurasi tinggi dalam mendeteksi gejala penyakit pada daun padi, seperti bercak, perubahan warna, dan kerusakan tekstur, yang berfungsi sebagai indikator awal penyakit tertentu. Dengan demikian, CNN terbukti efektif dalam memenuhi tujuan penelitian yaitu mengidentifikasi penyakit pada tanaman padi secara lebih cepat dan akurat dibandingkan inspeksi manual. Temuan utama dari penelitian ini menegaskan bahwa CNN dapat menjadi alat yang andal bagi petani untuk memantau kesehatan tanaman

secara *real-time*. Sistem berbasis CNN ini memungkinkan tindakan pengendalian yang lebih cepat dan tepat sasaran terhadap penyakit, yang pada gilirannya dapat meningkatkan hasil panen dan mendukung ketahanan pangan. Relevansi temuan ini meluas pada sektor pertanian yang lebih luas, khususnya dalam mendorong penerapan teknologi digital di lahan pertanian.

DEKLARASI

Penulis menyatakan bahwa penelitian ini telah dilaksanakan secara mandiri dan dengan itikad baik, tanpa adanya konflik kepentingan yang memengaruhi hasil atau interpretasi data. Semua langkah penelitian, analisis data, dan interpretasi hasil disusun secara objektif dan profesional, dengan mempertimbangkan asas transparansi dan integritas akademik. Lebih lanjut, penulis juga menegaskan bahwa karya tulis ini terbebas dari unsur SARA (Suku, Agama, Ras, dan Antargolongan), dengan tujuan utama untuk memperluas wawasan ilmiah di bidang pertanian, khususnya dalam penerapan metode *Machine Learning* pada klasifikasi penyakit tanaman padi. Harapannya, penelitian ini dapat memberikan kontribusi positif bagi pengembangan ilmu pengetahuan dan teknologi pertanian.]

REFERENSI

- [1] N. Istiqomah and M. Murinto, "Klasifikasi Penyakit Tanaman Padi Berbasis Citra Daun Menggunakan Convolutional Neural Network (CNN)," *JSTIE (Jurnal Sarjana Teknik Informatika) (E-Journal)*, vol. 12, no. 1, p. 18, 2024, doi: 10.12928/jstie.v12i1.27314.
- [2] Subiadi, S. Sipi, and F. R. A. Basundari, "Decrease in Production and Quality of Grain Due To Neck Blast Disease in Some Lowland Rice Varieties," *Journal of Tropical Plant Pests and Diseases*, vol. 19, no. 1, pp. 74–81, 2019, doi: 10.23960/j.hppt.11974-81.
- [3] Khairuddin, M. Machfudz, and F. Syakir, "Faktor-Faktor yang Mempengaruhi Fluktuasi Harga Beras di Kota Malang," *Seagri*, vol. 10, no. 4, 2022.
- [4] Sandi Ramadhan, L. Afifah, Satriyo Restu Adhi, and Budi Irfan, "INTENSITAS PENYAKIT TANAMAN PADI (*Oryza sativa* L.) VARIETAS CIHERANG PADA APLIKASI BEBERAPA TEKNIK PENGENDALIAN," *Jurnal Agrotech*, vol. 13, no. 2, pp. 127–134, 2023, doi: 10.31970/agrotech.v13i2.148.
- [5] A. Agustina, F. Yanto, E. Budianita, I. Iskandar, and F. Syafria, "Klasifikasi Penyakit Tanaman Padi Menggunakan Metode Cnn Arsitektur Densenet-121 Dan Augmentasi Data," *Journal Of Information Systems And Informatics Engineering*, vol. 8, no. 1, pp. 124–134, 2024.
- [6] A. Jinan, B. H. Hayadi, and U. P. Utama, "Klasifikasi Penyakit Tanaman Padi Menggunakan Metode Convolutional Neural Network Melalui Citra Daun (Multilayer Perceptron)," *Journal of Computer and Engineering Science*, vol. 1, no. 2, pp. 37–44, 2022.
- [7] S. Yuliany, Aradea, and Andi Nur Rachman, "Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN)," *Jurnal Buana Informatika*, vol. 13, no. 1, pp. 54–65, 2022, doi: 10.24002/jbi.v13i1.5022.
- [8] E. N. Arrofiqoh and H. Harintaka, "Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi," *Geomatika*, vol. 24, no. 2, p. 61, 2018, doi: 10.24895/jig.2018.24-2.810.
- [9] R. J. Hendri Butar-Butar and N. L. Marpaung, "Deep Learning untuk Identifikasi Daun Tanaman Obat Menggunakan Transfer Learning MobileNetV2," *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 8, no. 2, pp. 142–148, 2023, doi: 10.30591/jpit.v8i2.5217.
- [10] U. S. Rahmadhani and N. L. Marpaung, "Klasifikasi Jamur Berdasarkan Genus Dengan Menggunakan Metode CNN," *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 8, no. 2, pp. 169–173, 2023, doi: 10.30591/jpit.v8i2.5229.
- [11] A. Prayoga, Maimunah, P. Sukmasetya, Muhammad Resa Arif Yudianto, and Rofi Abul Hasani, "Arsitektur Convolutional

- Neural Network untuk Model Klasifikasi Citra Batik Yogyakarta," *Journal of Applied Computer Science and Technology*, vol. 4, no. 2, pp. 82–89, 2023, doi: 10.52158/jacost.v4i2.486.
- [12] U. UNGKAWA and G. AL HAKIM, "Klasifikasi Warna pada Kematangan Buah Kopi Kuning menggunakan Metode CNN Inception V3," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 11, no. 3, p. 731, 2023, doi: 10.26760/elkomika.v11i3.731.
- [13] M. Akbar, P. T. Prasetyaningrum, P. W. Setyaningsih, M. Ahsan, and A. E. Budianto, "Deteksi Leukemia Limfoblastik Akut menggunakan Convolutional Neural Network," *Jurnal Teknologi Sistem Informasi dan Aplikasi*, vol. 7, no. 1, pp. 292–297, 2024, doi: 10.32493/jtsi.v7i1.34168.
- [14] S. Auliaddina and T. Arifin, "Penggunaan Data Augmentasi dan Hyperparameter Tuning dalam Klasifikasi Jenis Batik menggunakan Model CNN," *Januari*, vol. 13, no. 1, pp. 114–128, 2024.
- [15] M. Albani and R. R. Andhi, "Klasifikasi Uang Rupiah Kertas Tidak Layak Edar Menggunakan CNN Xception Transfer Learning Berbasis Website," *INOVTEK Polbeng - Seri Informatika*, vol. 8, no. 2, p. 393, 2023, doi: 10.35314/isi.v8i2.3657.
- [16] Y. D. Wulandari, L. C. Munggaran, F. A. Setiawan, and I. A. Satya, "Chili Leaf Health Classification using Xception Pretrained Model," *Sistemasi*, vol. 13, no. 3, p. 1084, 2024, doi: 10.32520/stmsi.v13i3.3943.