

ANALISIS HASIL KLASIFIKASI PENYAKIT DAUN BAWANG MERAH MENGGUNAKAN CNN ARSITEKTUR EXCEPTION

Danar Putra Pamungkas*¹⁾, M. Farij Amrulloh²⁾

1. Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri, Indonesia
2. Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri, Indonesia

Article Info

Kata Kunci: *Convolutional Neural Network; Confusion Matrix; Klasifikasi Daun Bawang; Xception*

Keywords: *Convolutional Neural Network; Confusion Matrix; Classification of Leeks; Xception*

Article history:

Received 8 October 2024
Revised 1 November 2024
Accepted 3 December 2025
Available online 1 March 2025

DOI :

<https://doi.org/10.29100/jupi.v10i1.5875>

* Corresponding author.

Danar Putra Pamungkas

E-mail address:

danar@unpkediri.ac.id

ABSTRAK

Dalam beberapa dekade terakhir, industri pertanian telah mengalami transformasi signifikan dengan penerapan teknologi canggih seperti kecerdasan buatan (AI) dan pembelajaran mesin (ML). Tantangan utama dalam sektor ini adalah identifikasi dan klasifikasi penyakit tanaman secara akurat dan efisien. Salah satu solusi yang menjanjikan adalah penerapan Convolutional Neural Networks (CNN), khususnya arsitektur Xception yang terkenal efektif dalam tugas klasifikasi gambar. Penelitian ini mengeksplorasi implementasi Xception dalam klasifikasi penyakit daun bawang merah (*Allium ascalonicum*), yang merupakan tanaman penting namun rentan terhadap berbagai penyakit seperti bercak daun (*Alternaria porri*), layu bakteri (*Erwinia carotovora*), dan ulat Grayak (*Spodoptera exigua*). Dataset gambar daun bawang merah digunakan untuk menguji kinerja model Xception dalam mengidentifikasi berbagai jenis penyakit. Hasil penelitian menunjukkan bahwa model terbaik yang menggunakan batch size 16 dan epoch 100 mencapai akurasi 99.71% dan validasi 97.37%. Pengujian menggunakan confusion matrix terhadap 96 data uji menghasilkan 89 klasifikasi benar dan 7 klasifikasi salah, menunjukkan tingkat akurasi 92%. Penelitian ini berkontribusi dalam peningkatan efisiensi dan akurasi deteksi penyakit tanaman, mendukung pertanian presisi dan pengembangan sistem deteksi penyakit tanaman yang lebih maju dan terotomatisasi.

ABSTRACT

*In recent decades, the agricultural industry has undergone significant transformation with the application of advanced technologies such as artificial intelligence (AI) and machine learning (ML). A primary challenge in this sector is the accurate and efficient identification and classification of plant diseases. A promising solution is the application of Convolutional Neural Networks (CNN), specifically the Xception architecture, which is well-known for its effectiveness in image classification tasks. This study explores the implementation of Xception in the classification of diseases in shallot (*Allium ascalonicum*) leaves, a critical crop vulnerable to various diseases such as leaf spot (*Alternaria porri*), bacterial wilt (*Erwinia carotovora*), and armyworm (*Spodoptera exigua*). A dataset of shallot leaf images was used to test the performance of the Xception model in identifying different types of diseases. The study results showed that the best model, using a batch size of 16 and 100 epochs, achieved an accuracy of 99.71% and a validation accuracy of 97.37%. Testing using a confusion matrix on 96 test data resulted in 89 correct classifications and 7 incorrect classifications, indicating an accuracy rate of 92%. This research contributes to improving the efficiency and accuracy of plant disease detection, supporting precision agriculture and the development of more advanced and automated plant disease detection systems.*

I. PENDAHULUAN

DALAM beberapa dekade terakhir, industri pertanian telah mengalami transformasi signifikan melalui penerapan teknologi canggih, termasuk kecerdasan buatan (AI) dan pembelajaran mesin (ML). Salah satu tantangan utama dalam sektor ini adalah identifikasi dan klasifikasi penyakit tanaman secara akurat dan efisien. Dalam konteks ini, penerapan *Convolutional Neural Network* (CNN) telah menunjukkan potensi besar dalam meningkatkan kinerja sistem deteksi penyakit tanaman.

Salah satu arsitektur CNN yang menonjol adalah Xception, yang telah terbukti sangat efektif dalam berbagai tugas klasifikasi gambar [1]-[3]. Arsitektur Xception, yang merupakan kependekan dari "*Extreme Inception*," memperkenalkan konsep *depthwise separable convolutions* yang memungkinkan peningkatan efisiensi dan akurasi dalam pemrosesan gambar [4]. Konsep ini memisahkan proses konvolusi menjadi dua langkah: *depthwise convolution*, yang melakukan konvolusi pada setiap channel input secara terpisah, dan *pointwise convolution*, yang melakukan konvolusi 1x1 untuk menggabungkan output dari *depthwise convolution*. Pendekatan ini mengurangi jumlah parameter dan komputasi yang diperlukan, sehingga meningkatkan efisiensi tanpa mengorbankan akurasi [5]. Penelitian terbaru menunjukkan bahwa Xception dapat menghasilkan hasil yang unggul dibandingkan dengan arsitektur CNN lainnya seperti Inception-V3 dan ResNet50 dalam berbagai aplikasi klasifikasi gambar [6]-[7].

Di bidang pertanian, penyakit pada tanaman bawang merah (*Allium ascalonicum*) menjadi masalah serius yang dapat mengurangi produktivitas dan kualitas hasil panen [8]. Deteksi dini dan klasifikasi yang akurat dari penyakit daun bawang merah sangat penting untuk mencegah penyebaran penyakit dan mengurangi kerugian ekonomi [9]. Beberapa penyakit utama yang sering menyerang daun bawang merah termasuk penyakit bercak daun (*Alternaria porri*), penyakit layu bakteri (*Erwinia carotovora*), dan ulat Grayak (*Spodoptera exigua*) [10]- [12].


Penelitian sebelumnya telah menggunakan berbagai metode konvensional untuk mendeteksi penyakit tanaman, termasuk analisis visual oleh ahli pertanian dan penggunaan perangkat lunak deteksi berbasis fitur. Namun, metode ini sering kali memerlukan waktu yang lama, mahal, dan kurang akurat terutama pada skala besar. Oleh karena itu, penerapan CNN dalam deteksi penyakit tanaman menjadi semakin populer karena kemampuannya untuk mengenali pola-pola kompleks dalam gambar daun dengan akurasi tinggi [13].

Penelitian lain mengenai klasifikasi menggunakan arsitektur Xception, diantaranya klasifikasi tentang jenis rempah dengan judul "Klasifikasi Jenis Rempah Menggunakan Convolutional Neural Network dan Transfer Learning". Penelitian tersebut membandingkan beberapa arsitektur CNN yaitu Xception, MobileNetV2, DenseNet201, VGG16, VGG19, dan ResNet50. Dari hasil penelitian tersebut dapat disimpulkan bahwa arsitektur Xception adalah yang terbaik dengan hasil akurasi *F1-Score* terbaik mencapai 96.99% [14]. Lalu penelitian oleh Tresia Aprilia dan Mursalim, tentang perbandingan Inception dan Xception menunjukkan bahwa hasil akurasi Xception lebih baik dibandingkan Inception dengan akurasi sebesar 99.67% [15].

Penelitian ini bertujuan untuk mengeksplorasi implementasi CNN arsitektur Xception dalam klasifikasi penyakit daun bawang merah. Dengan menggunakan dataset gambar daun bawang merah, peneliti menguji kinerja model Xception dalam mengidentifikasi berbagai jenis penyakit dengan tujuan untuk meningkatkan efisiensi dan akurasi deteksi penyakit tanaman di lapangan. Untuk mendapatkan hasil yang optimal, peneliti akan menggunakan berbagai parameter yang ada pada arsitektur Xception. Selain itu, penelitian ini akan menguji kinerja model Xception dengan tujuan kedepannya dapat digunakan sebagai model pembuatan sistem deteksi penyakit tanaman yang lebih efisien dan akurat, serta mampu diimplementasikan dalam skala besar. Hasil penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam bidang pertanian presisi dan menjadi dasar bagi pengembangan sistem deteksi penyakit tanaman yang lebih maju dan terotomatisasi.

II. METODE PENELITIAN

Pada penelitian ini mempunyai tahap - tahap penelitian yang dapat dilihat pada Gambar 1.



Gambar. 1. Tahapan Penelitian

A. Pengumpulan Data

Pengumpulan data dilakukan secara mandiri yang diperoleh melalui proses pengambilan dataset dengan cara difoto langsung. Dataset gambar daun bawang yang dikumpulkan terdiri dari empat kelas yaitu normal, ulat, busuk bawah dan jamur daun. Masing - masing kelas memiliki 60 gambar daun bawang. Jadi total keseluruhan data adalah 240 data dengan format *JPG*. Contoh data gambar yang digunakan dapat dilihat pada Gambar 2.

Pemilihan jumlah gambar (60 per kelas) dipilih untuk menjaga keseimbangan antar kelas sehingga model tidak bias terhadap salah satu kelas tertentu. Meskipun jumlah gambar relatif kecil, penelitian sebelumnya telah menunjukkan bahwa model CNN seperti Xception mampu memberikan hasil yang baik meskipun dengan dataset yang terbatas dan diperlukan parameter untuk mendukung performa model dalam menangannya [16].



Gambar. 2. Dataset Daun Bawang

B. Preprocessing Data

Pada tahap ini, dilakukan perbaikan pada data yang diperoleh. Data tersebut akan melalui proses *preprocessing* terlebih dahulu sebelum diolah lebih lanjut. Tahap persiapan yang dilakukan mencakup *cropping* bagian daun, mengubah ukuran gambar menjadi 224x224 piksel, serta membagi data menjadi tiga bagian: data pelatihan sebesar 70%, data validasi sebesar 10%, dan data uji sebesar 20%. Proses *cropping* bertujuan untuk fokus pada bagian penting dari daun dan menghilangkan latar belakang yang tidak relevan, yang dapat membantu model untuk lebih fokus pada fitur-fitur yang signifikan untuk klasifikasi penyakit [17]. Perubahan ukuran gambar ke 224x224 piksel juga membantu dalam mengurangi beban komputasi dan mempercepat proses pelatihan model, sementara tetap mempertahankan detail penting yang diperlukan untuk deteksi penyakit. Ukuran 224x224 piksel dipilih karena merupakan ukuran standar yang sering digunakan dalam banyak arsitektur CNN, termasuk Xception, yang memungkinkan model untuk menangkap fitur penting dalam gambar tanpa mengorbankan resolusi yang terlalu tinggi atau terlalu rendah.

Selanjutnya, proses augmentasi data dalam penelitian ini melibatkan berbagai transformasi pada data gambar, termasuk *random flip horizontal*, skala, rotasi acak, *zoom* acak dan kontras acak. Transformasi ini bertujuan untuk meningkatkan variasi dalam dataset dan membantu model untuk lebih robust terhadap variasi yang mungkin ditemui dalam data nyata, sehingga meningkatkan kemampuan generalisasi model [18].

C. Pembuatan Model

Setelah data melalui tahap preprocessing, langkah selanjutnya adalah pembuatan model CNN menggunakan arsitektur Xception. Arsitektur Xception dipilih karena kemampuannya dalam menangani kompleksitas gambar dengan lebih baik melalui penggunaan *depth wise separable convolutional* [19]. Model Xception diinisialisasi dengan bobot yang sudah terlatih pada dataset ImageNet, kemudian lapisan akhir dihapus dan diganti dengan lapisan yang sesuai dengan jumlah kelas pada dataset daun bawang (empat kelas). Selanjutnya, ditambahkan lapisan *fully connected* baru dengan jumlah *neuron* sesuai dengan jumlah kelas dan aktivasi *softmax* untuk klasifikasi multi kelas.

Model Xception diinisialisasi dengan bobot yang sudah terlatih pada dataset ImageNet. Lapisan akhir dari model Xception yang awalnya digunakan untuk klasifikasi pada dataset ImageNet dihapus. Lapisan ini diganti dengan lapisan baru yang sesuai dengan jumlah kelas pada dataset daun bawang merah, yaitu empat kelas (normal, ulat, busuk bawah, dan jamur daun). Ditambahkan lapisan *fully connected* baru dengan jumlah neuron yang sesuai

dengan jumlah kelas (empat neuron) dan aktivasi softmax untuk klasifikasi multi-kelas. Lapisan ini akan bertanggung jawab untuk menghasilkan probabilitas kelas untuk setiap input gambar. Sebagian besar lapisan awal dari model Xception yang sudah terlatih pada ImageNet dibekukan (tidak dilatih ulang) untuk mempertahankan fitur-fitur dasar yang sudah dipelajari. Hanya lapisan-lapisan terakhir yang dilatih ulang untuk menyesuaikan model dengan dataset daun bawang merah.

Model kemudian dikompilasi menggunakan *optimizer Adam*, dengan *loss function categorical cross-entropy*, dan matrik evaluasi akurasi. Arsitektur Xception yang juga merupakan deep learning sering kali memerlukan banyak waktu dan sumber daya komputer untuk pelatihan, sehingga algoritme pengoptimalan menjadi perhatian utama. *Adam Optimizer* menggunakan lebih sedikit sumber daya dan membuat model menjadi lebih cepat, yang dapat mempercepat kecepatan pembelajaran dan meningkatkan efeknya [20]. *Categorical cross-entropy* dipilih karena sangat cocok untuk masalah klasifikasi multi-kelas, seperti klasifikasi penyakit daun bawang merah, yang melibatkan lebih dari dua kelas (normal, ulat, busuk bawah, dan jamur daun). *Categorical cross-entropy* dirancang untuk menangani masalah klasifikasi multi-kelas dengan baik [21]. Ini bekerja dengan menghitung jarak antara distribusi probabilitas output dari model dan distribusi target yang diinginkan.

D. Evaluasi Model

Model yang telah dilatih akan diuji menggunakan data uji untuk menilai kinerjanya dalam mengklasifikasikan gambar daun bawang ke dalam empat kelas yang telah ditentukan. Model akan dievaluasi dalam berbagai skenario untuk memastikan performanya di berbagai kondisi dan menilai konsistensi hasil yang diperoleh. Evaluasi model akan dilakukan dengan menggunakan matriks konfusi, yang memungkinkan dilakukannya analisis mendalam terhadap kinerja model dengan menampilkan jumlah positif benar, negatif benar, positif palsu, dan negatif palsu untuk setiap kelas. Dari matriks ini, kita dapat menghitung metrik evaluasi seperti akurasi, presisi, recall, dan skor F1. Hasil evaluasi ini akan digunakan untuk menentukan sejauh mana model dapat digeneralisasikan pada data baru yang belum terlihat. Persamaan untuk menghitung metrik evaluasi ini dapat dilihat pada Persamaan 1 sampai dengan 4.

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

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

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

$$F1\ Score = 2 \frac{recall * precision}{recall + precision} \quad (4)$$

III. HASIL DAN PEMBAHASAN

Analisis CNN arsitektur Xception untuk klasifikasi penyakit daun bawang merah dengan berbagai variasi parameter inisialisasi dibahas pada bagian hasil dan pembahasan. Berdasarkan penelitian sebelumnya, sejumlah penelitian belum mencapai akurasi maksimal karena tidak adanya arsitektur CNN [22]. Oleh karena itu, parameter yang tercantum pada Tabel 1 akan digunakan dalam penelitian ini. Dengan menggunakan matriks konfusi, hasil pengujian dievaluasi nilai loss, akurasi, presisi, recall, skor f-1, dan prediksi gambar penyakit daun bawang merah. Analisis dan hasil pengujian diharapkan dapat memberikan lebih banyak wawasan tentang seberapa baik model CNN arsitektur Xception menangani masalah klasifikasi penyakit daun bawang.

TABEL I
 HYPERPARAMETER YANG DIGUNAKAN


Parameter	Xception
Batch Size	16, 32
Epoch	50, 75, 100
Dropout	0.2
Learning Rate	0.00001
Optimizer	Adam

Melatih model CNN menggunakan arsitektur Xception melibatkan evaluasi performa model setelah melalui tahap pelatihan dengan data yang tersedia. Selama pelatihan, parameter model seperti ukuran *batch size* dan *epoch* disesuaikan berdasarkan data pelatihan sehingga model dapat mengenali pola dan fitur dalam data tersebut Hasil dari proses pelatihan ini disajikan pada Tabel 2.

TABEL II
 HASIL PELATIHAN MODEL CNN ARSITEKTUR XCEPTION

Ukuran Gambar	Batch Size	Epoch	Training Accuracy	Validation Accuracy
224	16	50	94.80%	95.74%
224	16	75	98.27%	97.37%
224	16	100	99.71%	97.37%
224	32	50	93.06%	94.74%
224	32	75	94.80%	94.74%
224	32	100	97.11%	94.74%


Hasil pelatihan model CNN dengan arsitektur Xception dalam 6 percobaan seperti pada Tabel 2 bertujuan mencapai akurasi terbaik untuk model yang sedang dikembangkan. Proses tahap ini menggunakan parameter seperti *batch size* dan jumlah *epoch* yang berpotensi mempengaruhi kinerja model. Dengan melakukan beragam eksperimen menggunakan kombinasi parameter yang berbeda, penulis dapat memahami bagaimana model merespons perubahan tersebut. Setiap percobaan melibatkan latihan model CNN Xception dengan konfigurasi parameter yang berbeda. Setelah pelatihan, akurasi dicatat selama fase latihan dan validasi, kemudian hasilnya dievaluasi dan dibandingkan untuk menemukan konfigurasi parameter terbaik. Hasil ini dianalisis dengan grafik akurasi dan *loss* selama latihan untuk memahami dampak perubahan parameter, mengenali *overfitting* atau *underfitting*, serta menemukan parameter yang menghasilkan akurasi tinggi dan stabil pada data validasi. Dari keenam percobaan, percobaan ketiga menunjukkan akurasi tertinggi. Gambar 3 di bawah ini menampilkan hasil dari percobaan ketiga.



Gambar 3. Dataset Daun Bawang

Hasil pelatihan model CNN menggunakan arsitektur Xception mendapatkan tingkat akurasi yang sangat tinggi, seperti yang terlihat pada Gambar 3. Selama proses pelatihan, model berhasil mencapai akurasi 99,71%, menunjukkan kemampuan yang sangat baik dalam memahami data yang digunakan untuk pelatihan. Tingginya tingkat akurasi ini menggambarkan bahwa model dapat dengan efektif mengidentifikasi pola dan fitur pada data. Selain itu, model mencapai tingkat akurasi sebesar 97,37% selama fase validasi. Tingkat akurasi yang tinggi ini menunjukkan bahwa model dapat secara akurat memprediksi data yang tidak digunakan dalam proses pelatihan dan juga dapat menggeneralisasi dengan baik terhadap data baru (data validasi).

Setelah pelatihan selesai, model CNN dengan arsitektur Xception dievaluasi untuk menilai keberhasilannya dalam mengklasifikasikan penyakit daun bawang merah. Pengujian dilakukan pada 96 sampel uji yang terpisah dari data pelatihan. Model yang diujikan merupakan hasil dari tahap pelatihan dengan *batch size* 16 dan *epoch* 100, yang mencapai akurasi pelatihan 99,71% dan validasi 97,37%. Hasil pengujian ditampilkan dalam bentuk *confusion matrix* pada Gambar 4 di bawah ini.



Gambar. 4. Hasil dari *confusion matrix*

Gambar 4 menunjukkan hasil uji *confusion matrix* yang berhasil dilakukan untuk mengklasifikasikan penyakit daun bawang merah. Pada hasil uji diatas, Semua 20 gambar yang sebenarnya adalah "Busuk Bawah" berhasil diklasifikasikan dengan benar oleh model (true positives). Tidak ada gambar dari kelas lain yang salah diklasifikasikan sebagai "Busuk Bawah" (false positives) dan tidak ada gambar "Busuk Bawah" yang salah diklasifikasikan sebagai kelas lain (false negatives). Dari 32 gambar yang sebenarnya adalah "Jamur Daun," model berhasil mengklasifikasikan 30 gambar dengan benar (true positives) dan salah mengklasifikasikan 2 gambar sebagai "Normal" (false negatives). Tidak ada gambar dari kelas lain yang salah diklasifikasikan sebagai "Jamur Daun" (false positives). Dari 21 gambar yang sebenarnya adalah "Normal," model berhasil mengklasifikasikan 19 gambar dengan benar (true positives) dan salah mengklasifikasikan 2 gambar sebagai "Jamur Daun" (false positives). Tidak ada gambar dari kelas lain yang salah diklasifikasikan sebagai "Normal" (false negatives). Semua 25 gambar yang sebenarnya adalah "Ulat" berhasil diklasifikasikan dengan benar oleh model (true positives). Tidak ada gambar dari kelas lain yang salah diklasifikasikan sebagai "Ulat" (false positives) dan tidak ada gambar "Ulat" yang salah diklasifikasikan sebagai kelas lain (false negatives).

Analisa pada kelas yang diklasifikasikan false positive dan false negatif, untuk beberapa gambar daun yang normal memiliki kemiripan visual dengan gejala awal dari infeksi jamur daun, seperti bercak-bercak kecil yang belum berkembang sepenuhnya. Ini menyebabkan model kesulitan dalam membedakan antara daun yang benar-benar normal dan yang terkena jamur daun pada tahap awal. Sedangkan untuk gambar daun yang terinfeksi jamur daun memiliki gejala yang tidak terlalu jelas atau tertutupi oleh karakteristik visual lainnya, sehingga model salah mengklasifikasikan gambar tersebut sebagai normal. Gejala infeksi yang ringan atau tidak menonjol dapat menyebabkan model gagal mengenali infeksi dengan benar. Perhitungan jumlah kesalahan komponen dengan jumlah yang digunakan dapat dilihat pada Tabel 3 berdasarkan hasil di atas.

TABEL III
 HASIL PENGUJIAN CONFUSION MATRIX

Pengujian Confusion Matrix	
Benar	Salah
94	2
Akurasi = $\frac{94}{96} \times 100\% = 97\%$	

TABEL IV
 HASIL CLASSIFICATION REPORT

Gambar	Precision	Recall	F1 Score	Support
Busuk Bawah	1.00	1.00	1.00	20
Jamur Daun	1.00	0.94	0.97	32
Normal	0.90	1.00	0.95	19
Ulat	1.00	1.00	1.00	25

Tabel 4 menunjukkan bahwa nilai precision untuk kelas "Busuk Bawah," "Jamur Daun," dan "Ulat" adalah 100%, yang menunjukkan bahwa semua data uji dari kelas-kelas tersebut diprediksi dengan benar sebagai kelas-

kelas tersebut, artinya tidak ada data dari kelas lain yang salah diklasifikasikan sebagai ketiga kelas tersebut. Nilai precision 90% untuk kelas "Normal" berarti bahwa hanya 90% dari kelas tersebut yang diprediksi dengan benar dari keseluruhan data yang diprediksi sebagai kelas tersebut. Kelas "Normal" memiliki nilai precision yang lebih rendah dibandingkan kelas lainnya karena terdapat kelas "Normal" yang terprediksi di kelas lain. Ini dikarenakan pada daun normal mungkin memiliki tanda-tanda awal dari infeksi dapat mirip dengan karakteristik daun yang sehat, terutama jika infeksinya belum berkembang sepenuhnya.

Hasil diatas menunjukkan bahwa model terbaik yang didapatkan adalah model yang menggunakan parameter terbaik yang ditemukan pada saat pelatihan yaitu, *batch size* 16 dan *epoch* 100, dengan akurasi mencapai 99.71% dan *validation* mencapai 97.37%. Pada pengujian *confusion matrix* hasil yang didapatkan untuk data uji yang berjumlah 96 yaitu, 94 kelas benar dan 2 kelas salah. Ini menunjukkan bahwa model memiliki tingkat akurasi 97%. Akurasi yang tinggi sebesar 99.22% untuk pelatihan juga didapatkan oleh Albani dan rekannya dalam penelitiannya menggunakan CNN Exception [23]. Pada penelitian lain tentang perbandingan metode Xception, InceptionV3 dan VGG16 yang dilakukan oleh Wahid dan rekan – rekannya, akurasi yang didapatkan metode Xception juga cukup baik yaitu sebesar 99% untuk training dan 91% validation [24].

Dengan hasil penelitian sebelumnya dan penelitian ini, penggunaan CNN arsitektur Xception terbukti efektif dalam membuat model untuk klasifikasi penyakit daun bawang merah. Dengan demikian, dalam penelitian ini Xception dengan akurasi sebesar 99.71% dapat dipilih sebagai model terbaik untuk klasifikasi penyakit daun bawang merah. Model dapat memberikan akurasi yang tinggi dan prediksi yang akurat. Meskipun masih ada kelas yang diklasifikasikan tidak tepat dengan kelas aslinya dikarenakan keterbatasan variasi gambar dari dataset. Oleh karena itu, berdasarkan hasil penelitian ini terdapat saran untuk klasifikasi penyakit daun bawang ini yaitu, penambahan jumlah dataset pada tiap kelas agar variasi data yang akan diklasifikasikan menjadi lebih banyak dan nantinya dapat diprediksi secara benar.

IV. KESIMPULAN

Berdasarkan tahapan - tahapan pelatihan dan pengujian model yang dilakukan, melibatkan klasifikasi penyakit daun bawang dengan empat kelas, yaitu busuk bawah, jamur daun, normal dan ulat. Dapat disimpulkan bahwa dengan menggunakan arsitektur Xception klasifikasi penyakit daun bawang merah berhasil diterapkan dan mendapatkan hasil akhir model yang memiliki akurasi pelatihan 99.71% dan validasi 97.37%.

DAFTAR PUSTAKA

- [1] R. Kurniawan, P. B. Wintoro, Y. Mulyani, dan M. Komarudin, "Implementasi Arsitektur Xception Pada Model Machine Learning Klasifikasi Sampah Anorganik," *J. Inform. dan Tek. Elektro Terap.*, vol. 11, no. 2, 2023.
- [2] R. B. N. Kholis dan F. Utaminingrum, "Rancang Bangun Sistem Klasifikasi Sampah Anorganik Kantor menggunakan Deep Learning Arsitektur Xception berbasis NVIDIA Jetson Nano," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 6, no. 6, hal. 2681–2686, 2022.
- [3] T. Tjahyamulia dan H. Bunyamin, "Analisa Model Convolutional Neural Networks Lanjutan Terhadap Model Klasifikasi Pakaian," *J. Strateg. Maranatha*, vol. 5, no. 2, hal. 378–392, 2023.
- [4] A. Nurhopipah, J. Suhaman, dan A. Widiyanto, "Exploring Pre-Trained Model and Language Model for Translating Image to Bahasa," *IJCCS (Indonesian J. Comput. Cybern. Syst.)*, vol. 17, no. 4, hal. 347–358, 2023.
- [5] L. Dang, P. Pang, and J. Lee, "Depth-wise separable convolution neural network with residual connection for hyperspectral image classification," *Remote Sensing*, vol. 12, no. 20, p. 3408, 2020.
- [6] T. A. Tresni dan M. Salim, "Analisa Perbandingan Inception dan Xception Berbasis CNN untuk Klasifikasi Wajah Hewan," *J. Tek. Inform. dan Desain Komun. Vis.*, vol. 3, no. 1, hal. 34–41, 2024.
- [7] M. F. Naufal dan S. F. Kusuma, "Analisis Perbandingan Algoritma Machine Learning dan Deep Learning untuk Klasifikasi Citra Sistem Isyarat Bahasa Indonesia (SIBI)," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 10, no. 4, hal. 873–882, 2023.
- [8] M. Rahmiyati, S. Hartanto, dan N. W. H. Sulastiningsih, "Pengaruh aplikasi actinomyces terhadap serangan Fusarium oxysporum Schlecht. f. sp. cepae (Hanz.) Synd. et Hans. penyebab penyakit layu pada bawang merah (*Allium ascalonicum* L. var. Menten)," *Biosci. J. Ilm. Biol.*, vol. 9, no. 1, hal. 248–260, 2021.
- [9] K. W. Kayohana, M. W. Alfiansyah, dan M. R. M. Rizki, "RANCANG BANGUNAN SISTEM PAKAR DIAGNOSA PENYAKIT DAN HAMA TANAMAN BAWANG MERAH DAN CABAI MENGGUNAKAN METODE CERTAINTY FACTOR," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 5, hal. 3533–3540, 2023.
- [10] D. Deden dan W. Wijaya, "Efektivitas Agen Hayati (*Rhodospseudomonas palustris*) untuk Mengendalikan Penyakit Bercak Daun (*Alternaria porri*) pada Tanaman Bawang Merah (*Allium ascalonicum* L.)," *AGROSCRIPT J. Appl. Agric. Sci.*, vol. 5, no. 2, hal. 92–100, 2023.
- [11] A. A. Nawangsih dan K. H. Mutaqin, "The Potentials of Cabbage Phyllospheric Bacteria as Biocontrol Agents of Soft Rot Disease Caused by *Pectobacterium carotovorum* on Chinese Cabbage," *J. Fitopatol. Indones.*, vol. 18, no. 3, hal. 115–124, 2022.
- [12] A. LESMANA, "PENGARUH PESTISIDA NABATI TERHADAP ULAT GRAYAK (*Spodoptera litura*) SERTA KETERJADIAN PENYAKIT MOLER PADA TANAMAN BAWANG MERAH (*Allium ascalonicum* L.)," 2021.
- [13] A. Pratiwi dan A. Fauzi, "IMPLEMENTATION OF DEEP LEARNING ON FLOWER CLASSIFICATION USING CNN METHOD," *J. Tek. Inform.*, vol. 5, no. 2, hal. 487–495, 2024.
- [14] A. E. Putra, M. F. Naufal, dan V. R. Prasetyo, "Klasifikasi Jenis Rempah Menggunakan Convolutional Neural Network dan Transfer Learning," *JEPIN (Jurnal Edukasi dan Penelit. Inform.)*, vol. 9, no. 1, hal. 12–17, 2023.
- [15] T. A. Tresni dan M. Salim, "Analisa Perbandingan Inception dan Xception Berbasis CNN untuk Klasifikasi Wajah Hewan," *J. Tek. Inform. dan Desain Komun. Vis.*, vol. 3, no. 1, hal. 34–41, 2024.

- [16] [1] L. Brigato dan L. Iocchi, "A close look at deep learning with small data," in *2020 25th International Conference on Pattern Recognition (ICPR)*, IEEE, 2021, hal. 2490–2497.
- [17] S. Siaulhak, A. S. Saruman, dan F. E. Susilawati, "Deteksi Pengurangan Noise pada Citra Digital menggunakan Metode Frequency Domain Code Matlab," *Proceeding KONIK (Konferensi Nas. Ilmu Komputer)*, vol. 5, hal. 550–560, 2021.
- [18] R. Z. Fadillah, A. Irawan, M. Susanty, dan I. Artikel, "Data Augmentasi Untuk Mengatasi Keterbatasan Data Pada Model Penerjemah Bahasa Isyarat Indonesia (BISINDO)," *J. Inform.*, vol. 8, no. 2, hal. 208–214, 2021.
- [19] H. Herimanto, "Perbandingan Matriks Loss Pada Model Deep Learning Resnet50 dan Xception dalam Deteksi Objek," *J. MEDIA Inform. BUDIDARMA*, vol. 7, no. 4, hal. 1994–2002, 2023.
- [20] X. Jiang, B. Hu, S. Chandra Satapathy, S.-H. Wang, dan Y.-D. Zhang, "Fingerspelling Identification for Chinese Sign Language via AlexNet-Based Transfer Learning and Adam Optimizer," *Sci. Program.*, vol. 2020, no. 1, hal. 3291426, 2020.
- [21] C. Nisa dan F. Candra, "Klasifikasi Jenis Rempah-Rempah Menggunakan Algoritma Convolutional Neural Network: Classification of Spice Types Using the Convolutional Neural Network Algorithm," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 1, hal. 78–84, 2024.
- [22] F. Huda dan M. P. K. Putra, "Klasifikasi Jenis Buah Pisang Menggunakan Algoritma Convolutional Neural Network," *J. Artif. Intell. Technol. Inf.*, vol. 1, no. 3, hal. 100–105, 2023.
- [23] M. Albani dan R. R. Andhi, "Klasifikasi Uang Rupiah Kertas Tidak Layak Edar Menggunakan CNN Xception Transfer Learning Berbasis Website," *J. Inovtek Polbeng Seri Inform.*, vol. 8, no. 2, hal. 393–406, 2023.
- [24] M. I. Wahid, A. Lawi, dan A. M. A. Siddik, "Perbandingan Kinerja Model Ensembled Transfer Learning Pada Klasifikasi Penyakit Daun Tomat," in *Seminar Nasional Teknik Elektro dan Informatika (SNTEI)*, 2023, hal. 286–291.