

Klasifikasi Hama Ulat Pada Citra Daun Sawi Berbasis *Convolutional Neural Network* Dengan Model *Xception*

Muhammad Ilham Rasyid¹, Lulu Mawaddah Wisudawati^{2*}
 Teknik Informatika, Universitas Gunadarma, Depok, Indonesia
 *e-mail *Corresponding Author*: lulu_mawadah@staff.gunadarma.ac.id

Abstract

Mustard plants belong to the Cruciferae (cabbage) family. Mustard cultivation cannot be separated from disease and pest threats. The main pests and diseases in mustard plants are caper, armyworms, grasshoppers, and snails. This research aims to classify caterpillar pests in mustard leaf images using the Xception architecture model based on Convolutional Neural Network. The mustard leaf dataset used consisted of 500 images of mustard leaves without pests and 500 images of mustard leaves containing caterpillar pests. The preprocessing process includes image cropping, image normalization, image augmentation and median filtering processes. The classification stage uses the Convolution Neural Network method with the Xception architecture. The results of classification using the Xception architectural model with trials on training data with 600 training data, 200 test data and 200 validation data produced the highest accuracy value of 96%, sensitivity value of 96% and specificity value of 97%.

Keywords: *Mustard plants; Median filtering; Classification; Convolutional neural network; Xception*

Abstrak

Tanaman sawi merupakan famili *Cruciferae* (Kubis-kubisan). Budidaya tanaman sawi tidak akan terlepas dari penyakit dan ancaman hama. Hama dan penyakit utama pada tanaman sawi yaitu kaper, ulat grayak, belalang, dan siput. Penelitian ini bertujuan untuk mengklasifikasi hama ulat pada citra daun sawi dengan model arsitektur *Xception* berbasis *Convolutional Neural Network*. Dataset daun sawi yang digunakan berjumlah 500 citra daun sawi tanpa hama dan 500 citra daun sawi yang terdapat hama ulat. Proses *preprocessing* meliputi tahapan *cropping* citra, normalisasi citra, augmentasi citra dan proses median filtering. Tahapan klasifikasi menggunakan metode *Convolution Neural Network* dengan arsitektur *Xception*. Hasil dari klasifikasi dengan model arsitektur *Xception* dengan uji coba pada pelatihan data dengan 600 data latih, 200 data uji dan 200 data validasi menghasilkan nilai akurasi paling tinggi sebesar 96%, nilai sensitifitas 96% dan nilai spesifisitas 97%.

Kata Kunci: *Tanaman sawi; Median filtering; Klasifikasi; Convolutional Neural Networ; Xception*

1. Pendahuluan

Tanaman sawi masih satu keluarga dengan kubis-krop, kubis-bunga, broccoli, dan lobak atau rades yaitu famili *Cruciferae*. Oleh karena itu, sifat morfologis tanamannya hampir sama, terutama pada sistem perakaran, stukturbatang, bunga, buah (panjang) maupun bijinya. Pada proses pertumbuhan apabila mengalami gangguan akan mengalami penghambatan pertumbuhan yang menyebabkan kerusakan atau kematian, maka semua bentuk kehidupan di dunia akan terganggu. Organisme pengganggu tanaman terdiri dari hama, mikroorganisme patogenik, dan gulma. Dalam budidaya tanaman sayur tidak akan terlepas dari penyakit dan ancaman hama yang sering menyerang. Hama yang menyerang tanaman ini mengakibatkan gagal panen dan menurunnya produksi tanaman sayuran. Hama dan penyakit utama pada tanaman sawi yaitu ulat daun (*crodolomia binotalis*), ulat tritip (*Putella xylostella*), Ulat Tanah (*Agrotis ipsilon Hufn*), Ulat Grayak (*Spodoptera litura*).

Machine learning adalah cabang ilmu komputer yang berfokus pada pengembangan algoritma dan model komputasional yang memungkinkan komputer untuk belajar dari data dan pengalaman, serta melakukan tugas-tugas tertentu tanpa perlu diprogram secara eksplisit.

Dalam *machine learning*, komputer menggunakan pola-pola yang ditemukan dalam data untuk membuat prediksi, mengenali pola, mengambil keputusan, atau melakukan tugas-tugas lainnya [1]. Pencegahan kerusakan pertumbuhan tanaman dapat dilakukan dengan menggunakan pendekatan *deep learning* yang dapat mempelajari pola-pola dan pengetahuan dari data yang diberikan kemudian digunakan untuk membuat prediksi atau pengambilan keputusan. *Convolutional Neural Network* (CNN) adalah jenis *neural network* yang dirancang khusus untuk memproses data yang memiliki struktur grid, seperti gambar dan video. CNN mendeteksi dari cara kerja visual cortex manusia, di mana neuron-neuron di dalamnya melakukan operasi konvolusi pada sinyal masukan untuk menghasilkan representasi visual yang lebih abstrak [2].

Klasifikasi hama pada tumbuhan mulai berkembang saat ini terutama menggunakan algoritma mesin learning dan CNN. Kamal et. al [3] memperkenalkan metode klasifikasi menggunakan SVM untuk penyakit daun kelapa sawit yang memperoleh akurasi 97,00% dan 95,00% dalam mengklasifikasikan penyakit daun chimaera dan antraknosa dan memanfaatkan k-means clustering untuk mensegmentasi gambar. Leong et. al memperkenalkan metode identifikasi menggunakan SVM untuk penyakit daun tanaman yang memperoleh akurasi 96,63% [4]. Rasidul Hasan et al [5], melakukan penelitian dengan meningkatkan metode dalam mendiagnosis hama pada tanaman sawi dengan menggunakan CNN Data set yang digunakan dibagi kedalam 9 kelas menggunakan teknik augmentasi dan hasil akurasi yang didapatkan yaitu sebesar 97.11% menggunakan 2388 citra uji. CNN telah banyak diimplementasikan dalam pengenalan penyakit pada hama tanaman [6][7][8]. Metode tersebut lebih efisien dibandingkan dengan metode tradisional karena dapat otomatis melakukan generate seleksi fitur. Peneliti Frawan et al. [9] melakukan penelitian klasifikasi penyakit jagung dari citra daun menggunakan *deep transfer*. Penelitian ini juga menggunakan model *xception* untuk proses pelatihan dan menghasilkan hasil sebesar 99,9%. Peneliti Xiaofei Chao et al. [10] dalam penelitiannya terkait identifikasi penyakit pada daun apel menggunakan Xception dengan modul *Squeeze-and-Excitation* (SE) mendapatkan nilai akurasi sebesar 99, 4%. Dalam ketiga penelitian tersebut tidak terdapat proses *pre-processing* yang memungkinkan adanya noise atau derau pada citra tersebut. Hal tersebut juga dapat mempengaruhi nilai akurasi.

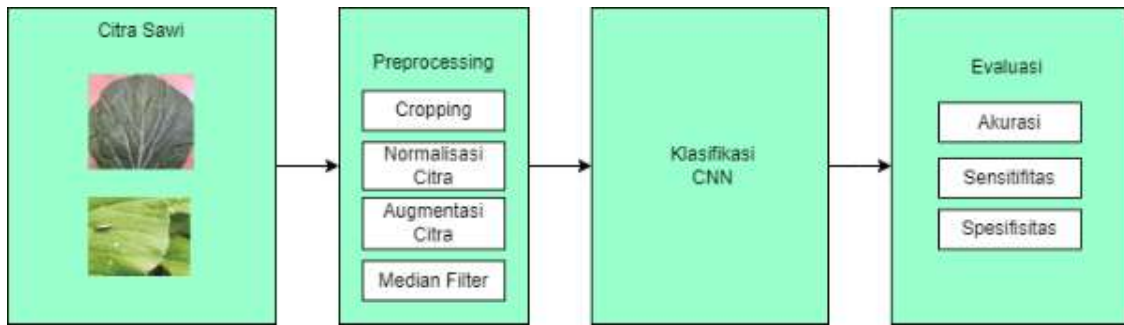
Peneliti Irawan [11] melakukan penelitian klasifikasi jenis aglaonema menggunakan metode *convolutional neural network*. Peneliti melakukan pembagian 70 digunakan untuk data latih dan 30 digunakan untuk data uji dan melakukan *resize* citra mendapatkan akurasi sebesar 96% untuk klasifikasi jenis aglaonema berdasarkan citra daun. Begitu juga dengan peneliti Jasim [12] yang menggunakan tahapan normalisasi dengan melakukan penyamaan ukuran piksel menjadi 128x128 dalam klasifikasi penyakit pada tanaman seperti tomat dan kentang. Dan hasil akurasi yang didapatkan sebesar 98% menggunakan *convolutional neural network* sebagai pengklasifikasiannya. Selanjutnya peneliti Rendra Soekarta [13] melakukan klasifikasi penyakit tanaman tomat dengan menggunakan *convolutional neural network* dengan model VGG 16 dapat mengklasifikasikan penyakit tanaman tomat dengan tingkat *accuracy training* mencapai 98 % dan *accuracy validation* mencapai 82 %. Akan tetapi data yang di deteksi tidak konsisten sehingga dilakukan pengembangan dengan melakukan augmentasi citra untuk menambahkan dataset citra.

Berdasarkan kelebihan dan kelemahan peneliti-peneliti terdahulu, maka dilakukan pengembangan penelitian dalam tahapan *pre-processing* yaitu dengan melakukan *cropping* citra secara manual untuk mengambil bagian citra daun sawi yang terdapat hama dan daun sawi tidak terdapat hama. Setelah itu dilakukan normalisasi citra untuk menyamakan ukuran citra. Kemudian dilakukan augmentasi citra menambahkan variasi data citra dan dilakukan proses *median filter* untuk menghilangkan *noise* atau derau pada citra. Penelitian ini juga dilakukan pengembangan pada metode klasifikasi menggunakan *convolutional neural network* dengan model arsitektur Xception dalam proses klasifikasi hama pada citra tanaman daun sawi. Diharapkan dengan adanya pengembangan algoritma dan metode tersebut dapat meningkatkan akurasi dalam mengklasifikasi hama. Penelitian ini terbagi kedalam beberapa bagian yaitu pendahuluan yang berisi latar belakang penelitian, kemudian metode penelitian, hasil dan pembahasan dan terakhir adalah kesimpulan dan saran.

2. Metodologi

2. 1 Gambaran Umum Sistem

Gambaran umum klasifikasi hama ulat pada citra tanaman daun sawi dapat dilihat pada Gambar 1.



Gambar 1. Gambaran Umum

Gambaran umum dimulai dengan citra sawi sebagai citra input. Proses selanjutnya pada tahap *preprocessing* dilakukan *cropping* untuk mengambil bagian citra daun sawi yang terdapat ulat dan tidak terdapat ulat, normalisasi citra untuk penyamaan ukuran, menggunakan teknik augmentasi dan menggunakan teknik median filter untuk menghilangkan *noise* atau derau pada citra. Dilakukan *convolutional neural network* menggunakan arsitektur model *Xception* untuk klasifikasi citra. Evaluasi menjadi tahapan akhir untuk melihat nilai akurasi, sensitifitas dan spesifisitas.

2.2 Dataset Citra Daun Sawi

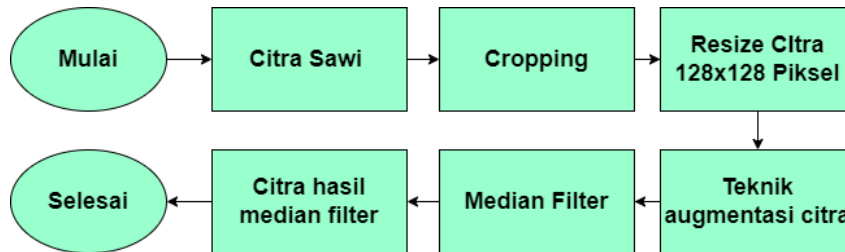
Citra Daun Sawi yang digunakan dalam penelitian ini berjumlah 1000 citra berformat PNG (*Portable Network Graphics*). Akuisisi citra dilakukan dengan 2 cara yaitu dilakukan dengan mengambil secara langsung menggunakan smartphone dan mengambil citra sawi dari *google images*. Citra Sawi yang diambil berupa daun pada tanaman sawi yang masih bagus (tidak terdapat hama) berjumlah 500 citra dan citra daun sawi yang terdapat hama berjumlah 500 citra. Dapat dilihat pada Tabel 1 Ciri-ciri citra yang terdapat hama ditandai dengan adanya lubang pada daun sawi akibat dirusak oleh hama seperti ulat.

Tabel 1. Dataset citra sawi

No	Citra Sawi Terdapat Ulat	Citra Sawi Tidak Terdapat Ulat
1		
2		
3		
4		
5		

3.2 Pre-processing

Preprocessing adalah langkah yang dilakukan untuk meningkatkan kualitas citra sebelum diproses lebih lanjut. Jika citra tidak melalui proses *preprocessing* terlebih dahulu, hasil pembelajaran atau pelatihan data akan terpengaruh terhadap akurasi.



Gambar 2. *Preprocessing*

Pada Gambar 2 merupakan tahapan *pre-processing* yang terdiri dari *cropping*, *resize* citra dengan menyamakan ukuran piksel citra menjadi 128x128 piksel. Selanjutnya adalah, teknik augmentasi citra digunakan untuk menambahkan dataset pada data pelatihan dan tahapan terakhir adalah teknik median *filter* yang digunakan untuk menghilangkan noise pada citra

2.3 Cropping

Pada tahapan *cropping* dilakukan dengan mengambil hanya bagian citra sawi terdapat hama ulat dan bagian citra sawi tidak terdapat hama ulat. *Cropping* citra juga membantu dalam proses identifikasi citra agar lebih cepat nantinya. *Cropping* citra dilakukan dengan alat bantu *software snipping tools*. Pada Tabel 2 citra yang telah dilakukan *cropping* dan dapat dilihat bahwa hanya bagian citra sawi yang terdapat ulat dan citra sawi yang tidak terdapat ulat yang nantinya akan dijadikan dataset dalam proses klasifikasi.











Tabel 2. *Cropping* Citra

No	Citra Asli	Citra <i>Cropping</i>
1.		
2.		
3.		
4.		
5.		

2.4 Resize Citra

Tahapan selanjutnya adalah melakukan penyamaan ukuran citra (*resize citra*). Citra daun sawi dilakukan normalisasi dengan menyamakan ukuran citra menjadi 128x128 piksel. Hal tersebut bertujuan untuk membantu konsistensi agar tidak terjadi perbedaan ukuran dalam proses klasifikasi. Pada Tabel 3 merupakan hasil citra yang dilakukan *resize* atau menyamakan ukuran menjadi 128x128 piksel.













Tabel 3. *Resize Citra*

No	<i>Resize Citra Pada Tanaman Daun Sawi Terdapat Ulat</i>	<i>Resize Citra Pada Tanaman Daun Sawi Tidak Terdapat Ulat</i>
1.		
2.		
3.		
4.		
5.		

2.5 Augmentasi Citra

Augmentasi citra merupakan teknik yang digunakan untuk meningkatkan pembelajaran mendalam pelatihan citra pada variasi citra. Parameter augmentasi citra yang digunakan pada penelitian antara lain variasi rotasi secara acak, distorsi *shear* dan *flipping* (pembalikan citra secara *horizontal*). Augmentasi dilakukan dengan cara melakukan rotasi citra secara acak, perubahan citra secara horizontal dan cara distorsi *shear* dengan melakukan pergeseran posisi citra asli ke sisi tertentu.

Tabel 4. Augmentasi Citra

No	Citra Sawi Yang Dilakukan Rotasi Secara Acak	Yang Augmentasi	Citra Sawi Yang Dilakukan Augmentasi pergeseran horizontal	Citra Sawi Yang Dilakukan Augmentasi <i>Distorsi Shear</i>
1.				
2.				
3.				
4.				

No	Citra Dilakukan Rotasi Secara Acak	Sawi Augmentasi Acak	Yang Dilakukan Augmentasi pergeseran horizontal	Citra Sawi Yang Dilakukan Augmentasi	Yang Dilakukan Augmentasi <i>Distorsi Shear</i>
5.					

Pada Tabel 4 diatas dapat dilihat hasil dari augmentasi citra. Parameter yang digunakan pada augmentasi citra yaitu:

- 1) Rotasi setiap gambar dalam dataset pelatihan dapat dirotasi secara acak dengan sudut antara -15 derajat hingga +15 derajat dan membantu model lebih tahan terhadap variasi rotasi objek.
- 2) Pembalikan citra secara *horizontal* setiap gambar dalam dataset pelatihan memiliki 50% kemungkinan untuk di-flip secara *horizontal* dan berguna untuk meningkatkan variasi data dan membuat model lebih tahan terhadap perubahan arah pandang objek.
- 3) *Distorsi shear* Berguna untuk melatih model agar lebih tangguh terhadap objek yang miring atau miring dalam gambar.

2.6 Median Filter

Metode *median filter* adalah salah satu teknik *filtering* citra *non linear* yang berfungsi untuk memperhalus suatu citra dan menghilangkan *noise* atau gangguan yang berupa bintang putih. Cara kerja metode ini dilakukan dengan mengganti nilai piksel yang diacu dalam suatu bidang operasi dengan suatu formula yang memanfaatkan nilai piksel tetangganya. Untuk *median filter* ini, data yang digunakan untuk menghitung median terdiri dari kumpulan data yang ganjil. Hal ini disebabkan dengan jumlah data yang ganjil maka piksel yang akan diproses dapat berbeda ditengah. Pada penelitian ini menggunakan dimensi 3x3 yang nantinya akan dimasukkan kedalam matriks 128x128 piksel. Pada Tabel 5 diketahui matriks berdimensi 3x3 berisi piksel utama berukuran 128 piksel dan piksel sekitarnya.

Tabel 5. Nilai Hasil Median Filter





110	120	130
115	125	114
118	128	138







Kemudian diurutkan nilai-nilai dari nilai yang terkecil hingga terbesar dengan berurutan. Setelah diurutkan, terdapat blok yang berisikan 9 nilai yang sudah di urutkan.

110	114	115	118	120	125	128	130	138
-----	-----	-----	-----	-----	-----	-----	-----	-----

Setelah dilakukan urutan pada nilai dilakukan mencari nilai tengah pada nilai tersebut. Dapat dilihat diatas hasil nilai *mediannya* adalah 120. Nilai 120 tersebut menggantikan nilai 125 sehingga piksel utamanya akan memiliki warna yang berbeda dengan sebelumnya. Berikut pada Tabel 6 merupakan hasil citra yang sudah dilakukan *median filtering*. Hasil median filtering menunjukkan bahwa citra lebih halus dan noise yang terdapat pada citra menghilang.

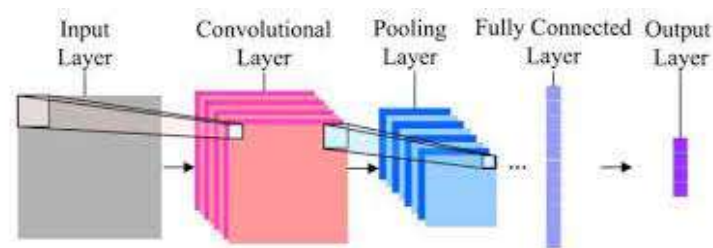
Tabel 6. Hasil Median Filter

No	Citra Asli	Citra Hasil Median Filter
1.		
2.		

No	Citra Asli	Citra Hasil Median Filter
3.		
4.		
5.		

2.7 Convolutional Neural Network

CNN terdiri dari beberapa layer yang berbeda, termasuk layer konvolusi, *layer pooling*, dan *layer fully connected* (lihat gambar 3). Pada layer konvolusi, filter konvolusi digunakan untuk melakukan ekstraksi fitur dari gambar, yaitu mengidentifikasi pola atau fitur pada gambar, seperti garis, sudut, atau bentuk yang lebih kompleks. *Convolutional Layer* merupakan layer inti dari CNN dimana sebagian besar proses konvolusi dilakukan disini. Pada lapisan ini, operasi matematis konvolusi dilakukan antara input citra dan *filter* dengan ukuran tertentu. Pada *layer pooling*, data yang dihasilkan pada layer konvolusi dikompresi untuk mengurangi dimensi data dan mempercepat pemrosesan.

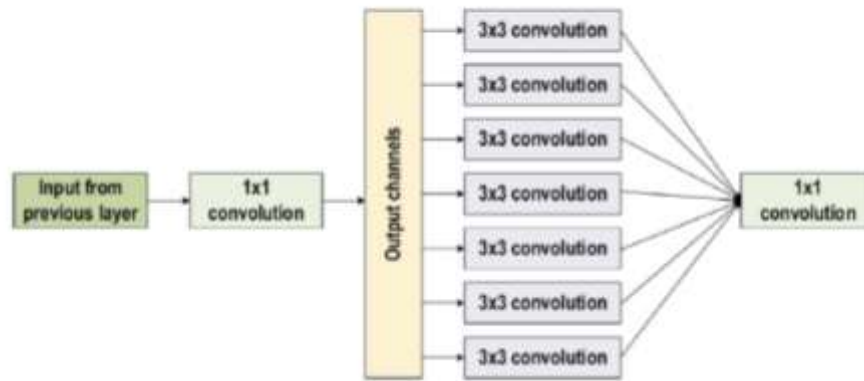


Gambar 3. Arsitektur Convolutional Neural Network

Pada *layer fully connected*, data yang telah melalui layer konvolusi dan *pooling* diproses lebih lanjut untuk melakukan klasifikasi atau regresi [13]. CNN telah menjadi salah satu teknik paling populer dalam *deep learning*, dan telah digunakan dalam banyak aplikasi seperti klasifikasi gambar, segmentasi citra, pengenalan wajah, dan lain sebagainya.

Xception (Extreme Inception) adalah arsitektur *Convolutional Neural Network* (CNN) yang dikembangkan oleh François Chollet [14]. *Xception* memperkenalkan pendekatan baru dalam penggunaan operasi konvolusi yang disebut "*depthwise separable convolution*", yang bertujuan untuk mengurangi kompleksitas komputasional dan jumlah parameter dalam jaringan saraf konvolusi. Arsitektur pada model berbasis pada konsep *Depthwise Separable Convolution*. *Depthwise Separable Convolution* ini memberikan kelebihan komputasi yang lebih hemat pada model.

Tujuan utama *Xception* adalah layer konvolusi yang dapat dipisahkan secara mendalam. Arsitektur Model *Xception* dapat dilihat pada Gambar 4., dimana model *xception* menyesuaikan dengan blok awal yang membuat lebih lebar dan dapat menukar satu dimensi (3x3) dari konvolusi 1 x 1 untuk mengurangi kompleksitas komputasi. Jaringan *Xception* menjadi lebih efektif secara komputasi melalui penggunaan saluran *decoupling* dan korespondensi spasial.



Gambar 4. Arsitektur Xception

2.8 Skema uji Coba

Pada proses pelatihan data ini dilakukan dengan menggunakan arsitektur model xception, dimana model ini merupakan pengembangan dari arsitektur Convolutional Neural Network. Distribusi Data Latih, Data Uji dan Data Validasi dilakukan dengan beberapa skema seperti 60:20:20, 70:20:10 dan 80:10:10 (lihat Tabel 7)

Tabel 7. Skema Data latih, Data Uji dan Data Validasi

skema	Data uji	Data latih	Data validasi
1.	600	200	200
2.	700	200	100
3.	800	100	100

2.9 Evaluasi

Tahapan evaluasi pada klasifikasi citra sawi bertujuan untuk mengukur kinerja suatu model klasifikasi atau menilai sejauh mana model dapat melakukan klasifikasi dengan akurat dan efisien. Evaluasi yang digunakan dalam klasifikasi citra ini adalah meliputi:

- 1) *Confusion Matrix* [15]. Digunakan untuk menghitung berbagai metrik evaluasi berdasarkan kelas prediksi dan kelas sebenarnya pada data uji.
- 2) Akurasi. Akurasi dihitung sebagai persentase jumlah prediksi yang benar (kelas yang diprediksi sesuai dengan label sebenarnya) dibagi dengan jumlah total citra dalam dataset. Adapun rumus mencari akurasi sebagai berikut:

$$Akurasi = \frac{TP+TN}{TP+TN+FN+FP} \times 100\% \dots\dots\dots (1)$$

- 3) Sensitivitas. Mengukur sejauh mana model klasifikasi mampu mendeteksi daun sawi yang benar-benar terdapat ulat (kelas positif) dari seluruh jumlah daun sawi yang sebenarnya terdapat ulat. Adapun rumus sensitifitas sebagai berikut:

$$Sensitifitas = \frac{TP}{TP+FN} \times 100\% \dots\dots\dots (2)$$

- 4) Spesifisitas. Mengukur sejauh mana model klasifikasi mampu mendeteksi daun sawi tidak terdapat ulat dengan benar. Adapun rumus sensitifitas sebagai berikut:

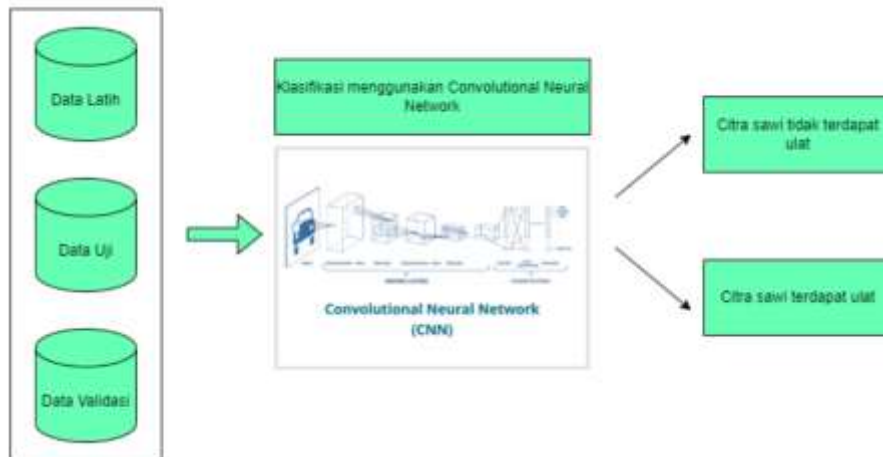
$$Spesifisitas = \frac{TN}{TN+FP} \times 100\% \dots\dots\dots (3)$$

3. Hasil dan Pembahasan

3.1 Klasifikasi Citra Tanaman Sawi Hama Ulat

Proses klasifikasi yang dilakukan pada penelitian ini menggunakan Convolutional Neural Network (CNN) dengan arsitektur model Xception. Convolutional Neural Network (CNN)

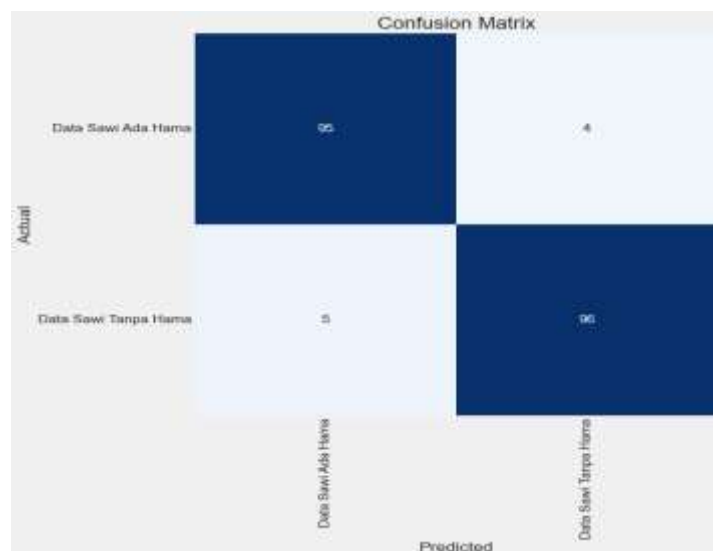
digunakan untuk melakukan proses training dan testing secara bersamaan. Pengujian terhadap model dilakukan dengan cara dilakukan proses pelatihan serta proses pengujian. Proses pelatihan dilakukan dengan menggunakan model *Xception* dari pengembangan arsitektur *Convolution Neural Network* menggunakan layer dan parameter yang sudah disesuaikan. Proses uji coba dilakukan evaluasi sejauh mana model klasifikasi citra dapat mengklasifikasi citra daun sawi yang terdapat hama dan tidak terdapat hama dengan benar dan menguji tingkat akurasi yang dilakukan pada distribusi pelatihan. Gambar 5 memperlihatkan tahapan klasifikasi, dimana terdapat 3 database yaitu data latih, data uji dan data validasi digunakan dalam proses klasifikasi. Hasil klasifikasi yang didapatkan berupa citra sawi tidak terdapat hama ulat dan citra sawi terdapat hama ulat.



Gambar 5. Klasifikasi Citra Tanaman Sawi Hama Ulat

3.2 Hasil Evaluasi

Pada hasil klasifikasi citra sawi menggunakan *convolutional Neural Network* dilakukan untuk mendeteksi atau mengklasifikasi citra sawi terdapat hama dan citra sawi tidak terdapat hama secara benar dengan *confusion matrix*. Hasil evaluasi terbaik dilakukan dengan skema 1 yaitu skema pelatihan 60:20:20.



Gambar 6. Hasil *Confusion Matrix*

Pada Gambar 6 dapat dilihat hasil *confusion matrix* pada skema 60:20:20 yaitu hasil sebanyak 96 citra sawi yang terdapat ulat yang diklasifikasikan secara benar (*true positive*), 95 citra sawi tidak terdapat ulat yang diklasifikasikan secara benar (*true Negative*), 4 citra sawi

yang terdapat ulat yang salah diklasifikasi sebagai tidak terdapat ulat (*false positive*) dan 5 citra sawi tidak terdapat ulat yang salah diklasifikasi sebagai citra daun sawi yang terdapat ulat (*false negative*). Hasil perhitungan nilai akurasi, sensitifitas dan spesifitas seperti berikut:

Tabel 8. Hasil Pengujian data

Skema	Skema Uji Coba	Akurasi	Sensitifitas	Spesifitas
1	60:20:20	96%	96%	97%
2	70:20:10	93%	94%	92%
3	80:10:10	94%	97%	90%

Berdasarkan data pada Tabel 8 menunjukkan hasil akurasi terbesar pada skema 1 sebesar 96 %, sensitifitas sebesar 96 % dan spesifitas sebesar 97% dengan skema uji pelatihan data latih sebanyak 600 citra, 200 citra untuk data uji dan 200 citra untuk data validasi. Dapat disimpulkan bahwa pengembangan metode dalam penelitian ini dapat memberikan peningkatan nilai akurasi. Klasifikasi CNN dengan arsitektur model *xception* terbukti dapat meningkatkan tingkat akurasi pada proses klasifikasi citra. Hasil akurasi juga berpengaruh pada metode *preprocessing* yang digunakan, klasifikasi yang digunakan, jumlah data yang digunakan serta citra yang digunakan.

4. Simpulan

Dari hasil penelitian mengenai klasifikasi hama pada citra tanaman daun sawi menggunakan *Convolutional Neural Network* dapat disimpulkan Hasil evaluasi pada klasifikasi hama pada citra tanaman daun sawi menggunakan CNN dengan skema 60:20:20 menggunakan model arsitektur *Xception* menghasilkan nilai akurasi tertinggi. Pada skema ini data yang digunakan sebanyak 600 citra, data uji 200 citra dan data validasi 200 citra, menghasilkan akurasi sebesar 96%, Sensitifitas 96% dan Spesifitas sebesar 97%.

Berdasarkan hasil pada penelitian dilakukan diharapkan pada penelitian selanjutnya selanjutnya menggunakan metode lain seperti *Support Vector Machine* (SVM) atau *K-Nearest Neighbors* (KNN) untuk melakukan klasifikasi. Menggunakan metode seperti *Gray Level Co-occurrence Matrix* (GLCM) atau metode analisis tekstur lainnya untuk membandingkan perolehan hasil nilai akurasi serta mengidentifikasi perbedaan antara daun dengan dan tanpa hama berdasarkan teksturnya.

Daftar Referensi

- [1] C.L.P. Chen, "Deep learning for pattern learning and recognition", *10th Jubilee International Symposium on Applied Computational Intelligence and Informatics*, Timisoara, Romania, pp. 17-17, 2015. doi: 10.1109/SACI.2015.7208200.
- [2] M. Jogin, Mohana, M. S. Madhulika, G. D. Divya, R. K. Meghana and S. Apoorva, "Feature Extraction using Convolution Neural Networks (CNN) and Deep Learning", *3rd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT)*, Bangalore, India, pp. 2319-2323, 2018. doi:10.1109/RTEICT42901.2018.9012507.
- [3] M.M Kamal, A. N. I. Masazhar, and F. A. Rahman, "Classification of Leaf Disease from Image Processing Technique", *Indonesian Journal of Electrical Engineering and Computer Science*, vol.10, pp. 191-200, 2018. DOI: <http://doi.org/10.11591/ijeecs.v10.i1.pp191-200>
- [4] K. K. Leong and L. L. Tze, "Plant Leaf Diseases Identification using Convolutional Neural Network with Treatment Handling System", *2020 IEEE International Conference on Automatic Control and Intelligent Systems (I2CACIS)*, Shah Alam, Malaysia, pp. 39-44, 2020. doi: 10.1109/I2CACIS49202.2020.9140103.
- [5] R. H. Hridoy, A. D. Arni and M. A. Hassan, "Recognition of Mustard Plant Diseases Based on Improved Deep Convolutional Neural Networks", *2022 IEEE Region 10 Symposium (TENSYP)*, Mumbai, India, pp. 1-6, 2022. doi: 10.1109/TENSYP54529.2022.9864487.
- [6] Kawasaki, Y.; Uga, H.; Kagiwada, S.; Iyatomi, H., "Basic study of automated diagnosis of viral plant diseases using convolutional neural networks", *In Proceedings of the International Symposium on Visual Computing*, Las Vegas, NV, USA, pp. 638–645, December 2015. doi:10.1007/978-3-319-27863-6_59

-
- [7] S. H. Lee, C. S. Chan, P. Wilkin and P. Remagnino, "Deep-plant: Plant identification with convolutional neural networks", *2015 IEEE International Conference on Image Processing (ICIP)*, Quebec City, QC, Canada, pp. 452-456, 2015. doi: 10.1109/ICIP.2015.7350839.
- [8] Mohanty, S.P.; Hughes, D.P.; Salathe, M., "Using Deep Learning for Image-Based Plant Disease Detection", *Front. Plant. Sci.* Vol 7, 1419, 2016. doi: 10.3389/fpls.2016.01419.
- [9] M. Fraiwan, E, Faouri, N. Khasawneh, "Classification of Corn Diseases from Leaf Images Using Deep Transfer Learning", *Plants*, Basel, Switzerland, vol. 11,20 2668. 11 Oct. 2022. doi:10.3390/plants11202668
- [10] Chao X, Hu X, Feng J, Zhang Z, Wang M, He D., "Construction of Apple Leaf Diseases Identification Networks Based on Xception Fused by SE Module", *Applied Sciences*. 11(10):4614, 2021. <https://doi.org/10.3390/app11104614>
- [11] [Y. P. Irawan, I. Susilawati, "Klasifikasi Jenis Aglaonema Berdasarkan Citra Daun Menggunakan Convolutional Neural Network (CNN)", *Jurnal Information System and Artificial Intelligence*, Vol.2, No. 2, Mei 2022.
- [12] M. A. Jasim and J. M. AL-Tuwaijari, "Plant Leaf Diseases Detection and Classification Using Image Processing and Deep Learning Techniques", *2020 International Conference on Computer Science and Software Engineering (CSASE)*, Duhok, Iraq, pp. 259-265, 2020. doi: 10.1109/CSASE48920.2020.9142097.
- [13] R. Soekarta, N. Nurdjan, and A. Syah, "Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode Convolutional Neural Network (CNN)", *Jurnal Teknik Informatika*, 8(2), pp. 143–151, Mar. 2023. doi: 10.33506/insect.v8i2.2356.
- [14] F. Chollet, "Xception: Deep Learning with Depthwise Separable Convolutions", *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, 20, pp. 1800-1807, 2017. doi: 10.1109/CVPR.2017.195.
- [15] K.M. Ting, "Confusion Matrix". In: *Sammur, C., Webb, G.I. (eds) Encyclopedia of Machine Learning*. Springer, Boston, MA, 2010. https://doi.org/10.1007/978-0-387-30164-8_157