



**KLASIFIKASI CORAK DAUN AGLAONEMA MENGGUNAKAN METODE
ARTIFICIAL NEURAL NETWORK DENGAN ALGORITMA BACKPROPAGATION**

**LEAF PATTERN CLASSIFICATION OF AGLAONEMA USING ARTIFICIAL
NEURAL NETWORK WITH BACKPROPAGATION ALGORITHM**

Alya Firdaus Pratiwi*, Program Studi Matematika Universitas Negeri Yogyakarta,
Indonesia

Nur Hadi Waryanto, Program Studi Matematika Universitas Negeri Yogyakarta, Indonesia

*e-mail: alyafirdaus.2018@student.uny.ac.id

Abstrak

Penelitian ini bertujuan mengklasifikasikan corak daun Aglaonema menggunakan *Artificial Neural Network* (ANN) dengan algoritma *Backpropagation*, serta meninjau pengaruh dari perbandingan rasio dataset, pemilihan fungsi aktivasi, dan arsitektur model *Backpropagation* terhadap hasil akurasi klasifikasi ANN *Backpropagation*. Data citra daun Aglaonema diolah menggunakan ekstraksi fitur GLCM (*Graylevel co-occurrence matrix*) sebagai input klasifikasi. Terdapat beberapa tahapan dalam penelitian ini, yaitu pengambilan data citra daun Aglaonema, pengolahan citra digital pada tahap *preprocessing* data dan ekstraksi fitur tekstur GLCM, pembagian dataset dengan perbandingan 70:30 dan 80:20, membuat arsitektur model ANN *Backpropagation*, serta evaluasi model untuk memperoleh akurasi terbaik dalam klasifikasi. Hasil pengujian menunjukkan akurasi ANN *Backpropagation* mencapai 40% hingga 92%, dengan arsitektur terbaik 20-400-200-100-50-10 menggunakan fungsi aktivasi ELU (*Exponential Linear Unit*) pada *hidden layer* dan sigmoid pada *output layer*. Hasil evaluasi menunjukkan *recall* 95%, *precision* dan *F1-score* 93%.

Kata kunci: klasifikasi, Aglaonema, pengolahan citra digital, *Artificial Neural Network*, dan *Backpropagation*.

Abstract

This study aims to classify the patterns of Aglaonema leaves using Artificial Neural Network (ANN) with the Backpropagation algorithm, while also examining the influence of dataset ratio comparison, activation function selection, and Backpropagation model architecture on the accuracy of ANN Backpropagation classification results. The Aglaonema leaf image data is processed using Graylevel co-occurrence matrix (GLCM) feature extraction as the input for classification. Several stages are involved in this study, including collecting Aglaonema leaf image data, digital image processing in the preprocessing data stage, GLCM texture feature extraction, dataset division with ratios of 70:30 and 80:20, designing the ANN Backpropagation model architecture, and evaluating the model to achieve the best accuracy in classification. The test results show that the accuracy of ANN Backpropagation reaches 40% to 92%, with the best architecture being 20-400-200-100-50-10 using Exponential Linear Unit (ELU) activation function in the hidden layer and sigmoid in the output layer. The evaluation results demonstrate a recall of 95%, precision and F1-score both at 93%.

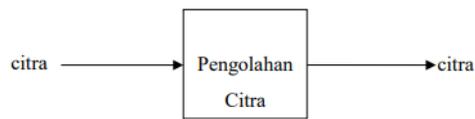
Keywords: classification, Aglaonema, digital image processing, *Artificial Neural Network*, and *Backpropagation*

PENDAHULUAN

Ilmu tumbuhan mengalami perkembangan pesat dan telah menjadi bidang ilmu mandiri. Salah satu aspek yang dipelajari adalah morfologi tumbuhan. Tanaman Aglaonema memiliki variasi corak daun yang beragam, yang semakin kompleks akibat persilangan oleh

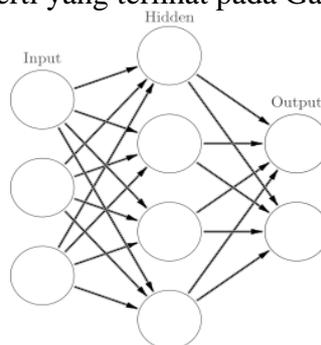
para botanis. Daun Aglaonema dikatakan daun alami bila tanpa adanya persilangan (spesies). Daun yang berasal dari hasil persilangan Aglaonema spesies memiliki corak daun yang beragam dan menarik disebut hybrid (Apriansi & Suryani, 2019). Aglaonema atau dengan nama lain “sri rezeki” merupakan salah satu tanaman hias yang sedang banyak digemari. Aglaonema sp. merupakan salah satu tanaman hias daun yang terkenal di Indonesia. Ada sekitar 30 spesies aglaonema di Indonesia, dimana tanaman hias ini relatif mudah untuk dibudidayakan karena Aglaonema dapat tumbuh dengan mudah dan perlu memperhatikan beberapa faktor seperti kelembaban, media tanam, dan cahaya matahari (Apriansi & Suryani, 2019).

Citra yang baik adalah citra yang memiliki kualitas tinggi dan sesuai dengan gambar aslinya. Namun seringkali citra mengalami penurunan kualitas citra seperti terlalu kontras, terjadinya cacat pada citra (derau), kurang tajam warnanya, terlalu lembut dan lain sebagainya. Citra adalah suatu kumpulan *pixel* (*picture elements*) atau titik-titik yang berwarna dengan bentuk dua dimensi (Hutahaean & Desmon, 2019). Agar dapat diolah dengan komputer, maka suatu citra harus direpresentasikan secara numerik dengan nilai-nilai diskrit. Representasi citra dari fungsi kontinu menjadi nilai-nilai diskrit disebut digitalisasi. Citra yang dihasilkan inilah yang disebut citra digital (*digital image*). Pengolahan citra merupakan cabang ilmu dalam *Artificial Intelligence* yang menggunakan objek citra dalam bentuk digital untuk penyelesaian kasusnya. Sedangkan, pengolahan citra digital adalah suatu cara yang akan menghasilkan citra sesuai dengan keinginan pengguna yang bertujuan memperbaiki kualitas citra agar mudah diinterpretasi oleh manusia atau mesin komputer yang dapat berupa foto maupun gambar bergerak (Effendi et al., 2017).



Gambar 1. Teknik Pengolahan Citra

Artificial Neural Network menjadi solusi yang tepat di beberapa bidang yang membutuhkan kecerdasan buatan untuk tugas-tugas seperti klasifikasi dan pengenalan pola. Klasifikasi merupakan salah satu area eksplorasi dan aplikasi yang paling dinamis dari jaringan saraf (K & Sasithra, 2014). *Artificial Neural Network* (ANN) atau jaringan saraf tiruan merupakan salah satu metode yang bekerja dengan cara meniru perilaku jaringan saraf (*neuron*) atau cara kerja otak manusia. Metode ini dirancang untuk memecahkan masalah yang tidak dapat diselesaikan dengan komputasi konvensional. Pada dasarnya klasifikasi ANN dilakukan untuk pengenalan pola yang dilatih untuk mengidentifikasi masalah yang diberikan dengan dua fase yaitu *training* dan *testing*. Selama proses *training*, jaringan dilatih untuk mengklasifikasi data berdasarkan model yang sudah dibangun selama pelatihan agar menghasilkan *error* terkecil (Li, 2017). Klasifikasi menggunakan ANN memerlukan 3 tahapan utama yaitu input layer sebagai sumber data masukan, hidden layer sebagai prosesnya dan output layer sebagai hasil akhir dari klasifikasinya seperti yang terlihat pada Gambar 2.

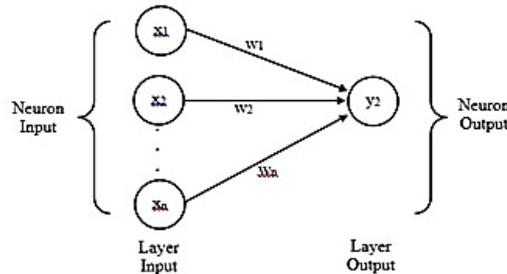


Gambar 2. Arsitektur Klasifikasi ANN

Keberhasilan penerapan ANN membutuhkan kehati-hatian dalam memilih parameter yang sesuai dan signifikansi variasinya tergantung pada permasalahan dan subjek yang berbeda (Bashashati et al., 2015). *Artificial Neural Network* memiliki beberapa arsitektur jaringan yang sering digunakan dalam berbagai aplikasi (Letelay, 2016) antara lain:

a) Jaringan Tunggal

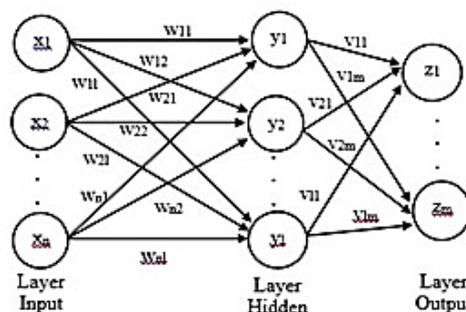
Jaringan tunggal hanya memiliki satu lapisan yang terdiri dari 1 layer input, 1 layer bobot koneksi, dan 1 layer output. Masukan neuron pada jaringan tunggal terhubung lurus dengan sekumpulan keluaran. Sinyal mengalir searah dari lapisan masukan sampai lapisan keluaran. Model yang menganut jaringan tunggal yaitu hopfield, ADALINE, perceptron, dan LVQ. Berikut merupakan gambar untuk jaringan tunggal.



Gambar 3. *Artificial Neural Network* dengan lapisan Tunggal

b) Jaringan Multi Layer

Jaringan multi memiliki tiga tahapan yaitu input layer, hidden layer, dan output layer. Jaringan multi ini biasanya lebih banyak digunakan karena dapat menyelesaikan permasalahan yang bersifat kompleks, meskipun dalam masa training membutuhkan waktu yang cukup lama dikarenakan banyaknya perhitungan node pada setiap layer-nya. Model yang menganut jaringan multi *layer* yaitu MADALINE dan *Backpropagation*. Berikut merupakan gambar untuk jaringan multi *layer*.



Gambar 4. *Artificial Neural Network* dengan Lapisan Multi Layer

Salah satu model jaringan dalam *Artificial Neural Network* adalah *backpropagation*. *Backpropagation* dapat digunakan untuk klasifikasi karena dapat mengenali pola dan memberikan respons terhadap pola masukan (Santoso & Krisitianto, 2020). Berbeda dengan *Artificial Neural Network* jaringan tunggal, *backpropagation* menambahkan *hidden layer* dalam melatih jaringan untuk memperoleh *output* yang sesuai. Untuk melatih jaringan *backpropagation* harus melalui empat fase, yaitu inisialisasi bobot, *feedforward*, *backpropagation error*, dan penyesuaian bobot. Algoritma *backpropagation* menggunakan *error output* dalam mengubah nilai bobot-bobotnya pada arah mundur (*backward*). Untuk mendapatkan *error* ini, maka tahap perambatan maju (*forwardpropagation*) perlu dikerjakan terlebih dahulu (Rahayu et al., 2018).

Pengambilan gambar daun *Aglaonema* dan pemrosesan dilakukan menggunakan algoritma yang dikembangkan dengan bantuan *software* seperti Matlab, RStudio, atau Python.

Software tersebut mengubah gambar menjadi vektor biner yang mewakili piksel gambar, lalu data ini diolah menggunakan analisis ANN untuk membandingkannya dengan pola yang telah dipilih. Penelitian ini menggunakan *software* Python dengan bantuan OpenCV (*Open Computer Vision*), yang secara sederhana melakukan proses pengolahan citra dan tracking objek. *OpenCV (Open Source Computer Vision Library)* merupakan sebuah *library open source* yang dikembangkan oleh intel untuk menyederhanakan *programming* terkait citra digital (Sari et al., 2017). Hal ini bertujuan untuk memberikan kemampuan pengolahan visual pada komputer yang mirip dengan manusia, dan hasilnya akan digunakan untuk proses klasifikasi data citra daun.

METODE

Penelitian ini dilaksanakan melalui beberapa tahapan sistematis untuk mengklasifikasikan corak daun *Aglaonema* menggunakan metode Artificial Neural Network (ANN) dengan algoritma Backpropagation. Adapun tahapan metode dalam penelitian ini meliputi:

1. Pengambilan Data Citra

Data citra daun *Aglaonema* dikumpulkan dengan menggunakan teknik fotografi digital. Setiap citra mewakili berbagai jenis corak daun *Aglaonema*, baik spesies alami maupun hasil persilangan (hibrida). Total data citra yang digunakan dalam penelitian ini berjumlah 240 gambar dari 10 jenis daun *Aglaonema*.

2. Preprocessing Data

Proses preprocessing dilakukan untuk meningkatkan kualitas citra dan mempersiapkannya sebelum tahap ekstraksi fitur. Tahapan preprocessing meliputi:

- Segmentasi citra untuk memisahkan objek daun dari latar belakang.
- Konversi citra menjadi skala keabuan (*grayscale*).
- Cropping untuk memilih area relevan dari citra.
- Resizing citra ke ukuran seragam.

3. Ekstraksi Fitur Tekstur dengan GLCM

Citra daun yang telah diproses kemudian diekstraksi fitur teksturnya menggunakan metode *Gray-Level Co-occurrence Matrix (GLCM)*. Ekstraksi dilakukan berdasarkan empat orientasi sudut dan menghasilkan enam fitur tekstur utama: Dissimilarity, Correlation, Homogeneity, Contrast, Angular Second Moment (ASM), dan Energy. Seluruh fitur yang dihasilkan kemudian dinormalisasi menggunakan metode decimal scaling untuk menghasilkan nilai dalam rentang seragam.

4. Pembagian Dataset

Dataset dibagi ke dalam dua skema rasio data:

- 70% data untuk pelatihan (training) dan 30% untuk pengujian (testing).
- 80% data untuk pelatihan (training) dan 20% untuk pengujian (testing).

5. Perancangan Arsitektur ANN Backpropagation

Arsitektur model ANN yang digunakan bervariasi dalam jumlah neuron pada *input layer*, *hidden layer*, dan *output layer*. Beberapa konfigurasi model diuji, di antaranya:

- Model dengan layer size 24-14-7-10 dan 24-12-8-10.
- Model kompleks dengan layer size 20-400-200-100-50-10. Fungsi aktivasi yang digunakan pada hidden layer adalah ReLU dan ELU, sedangkan pada output layer digunakan fungsi sigmoid.

6. Pelatihan dan Pengujian Model

Proses pelatihan dilakukan menggunakan algoritma Backpropagation dengan parameter:

- Epoch sebanyak 5000 hingga 10000 iterasi.
- Regularizers sebesar 0,001.

- Dropout rate sebesar 0,01 untuk mengurangi risiko overfitting.

Proses pelatihan dan pengujian dilakukan menggunakan perangkat lunak Python dengan bantuan library OpenCV untuk pengolahan citra dan library TensorFlow/Keras untuk pembangunan model ANN.

7. Evaluasi Kinerja Model

Kinerja model dievaluasi berdasarkan metrik-metrik klasifikasi, yaitu:

- Akurasi
- Precision
- Recall
- F1-score

Selain itu, analisis dilakukan terhadap confusion matrix dan classification report untuk menilai distribusi prediksi dan mendeteksi kesalahan klasifikasi pada masing-masing kelas corak daun. Tahapan-tahapan di atas dilakukan untuk mendapatkan konfigurasi model ANN Backpropagation terbaik dalam mengklasifikasikan corak daun *Aglaonema* berdasarkan ekstraksi fitur tekstur citra digital.

PEMBAHASAN

Sejumlah 240 citra daun *Aglaonema* melalui proses *preprocessing* sebelum tahap klasifikasi. Proses tersebut meliputi segmentasi citra untuk memisahkan objek dan latar belakang, dilanjutkan dengan normalisasi label dan deskripsi. Kemudian, citra diubah menjadi *grayscale* untuk ekstraksi fitur GLCM. Setelah itu, dilakukan proses *cropping* untuk memilih bagian relevan dari citra dan *resizing* untuk mengubah ukuran citra. Semua tahap ini berfungsi mempersiapkan citra sebelum digunakan dalam tahap klasifikasi. Setiap label mewakili jenis daun yang memiliki corak yang unik dan dapat dikenali. Dengan melakukan klasifikasi, kita dapat mengelompokkan dan mengidentifikasi daun-daun *Aglaonema* ke dalam kategori yang sesuai berdasarkan karakteristik corak yang dimiliki oleh setiap jenisnya.

Tabel 1. Jumlah Sampel dari 10 Jenis Daun *Aglaonema*

Jenis Daun <i>Aglaonema</i>	Label	Jumlah Sampel
Butterfly L	BL	24
Commutatum Schott	CS	24
Emerald	E	24
Golden Hope	GH	24
Legacy	L	24
Pictum Tricolor	PT	24
Rotundum	R	24
Red Kochin	RK	24
Siam Aurora	SA	24
Silver King	SK	24

Untuk proses ekstraksi fitur corak daun *Aglaonema* menggunakan GLCM (*Gray-Level Co-occurrence Matrix*). Berdasarkan hasil ekstraksi fitur untuk data citra corak daun *Aglaonema*, diperoleh ekstraksi fitur tekstur dengan metode GLCM (*Gray-Level Co-occurrence Matrix*). Dari hasil ekstraksi fitur GLCM untuk tiap data citra menghasilkan 24 fitur data dengan 4 variasi sudut ($0^\circ, 45^\circ, 90^\circ, 135^\circ$) dan 6 variasi fitur ekstraksi, meliputi *Dissimilarity*, *Correlation*, *Homogeneity*, *Contrast*, *ASM (Angular Second Moment)*, dan *Energy*. Dengan menggunakan fitur-fitur ini, data citra berubah menjadi representasi numerik, sehingga mempermudah proses klasifikasi dengan ANN *Backpropagation*. Hasil dari ekstraksi fitur GLCM perlu dinormalisasi untuk mengubah rentang nilai fitur menjadi skala yang

seragam. Hal ini penting karena fitur-fitur yang diekstraksi dari citra dapat memiliki rentang nilai yang berbeda-beda, tergantung pada karakteristik dan skala intensitas citra. Normalisasi data menggunakan *decimal scaling* dengan hasil data dalam rentang antara -1 hingga 1, tergantung pada faktor skala yang digunakan.

Hasil pengujian dan performa model dievaluasi untuk menentukan efektivitasnya dalam mengklasifikasikan citra corak daun *Aglaonema*. Fungsi aktivasi, rasio dataset, *layer size*, dan *epoch* memiliki pengaruh pada hasil pengujian. Hasil dari pengujian tersebut disajikan dalam Tabel 2.

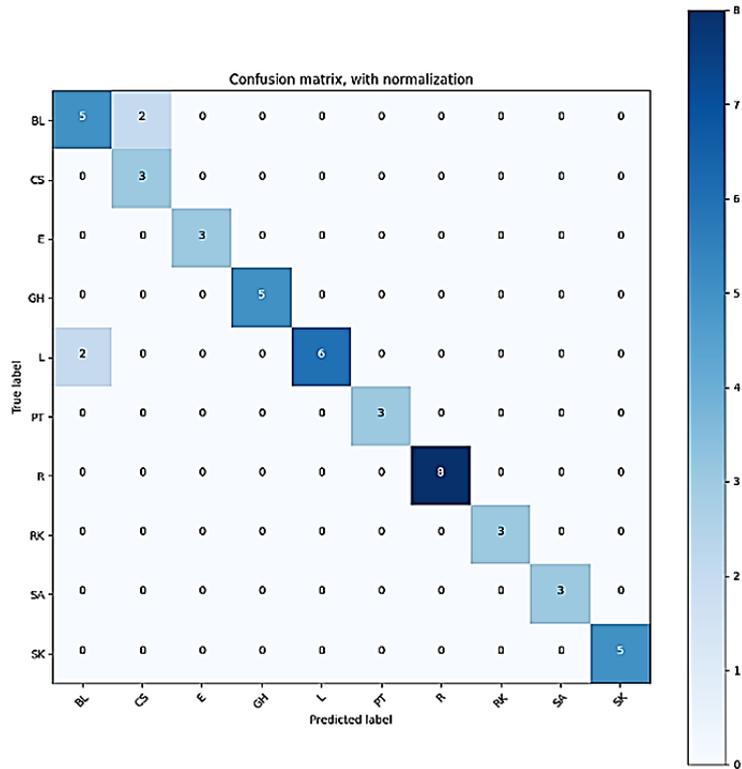
Tabel 2. Hasil Pengujian Model Klasifikasi ANN *Backpropagation*

Activation	Rasio Data	Layer Size	Accuracy	Precision	Recall	F1-Score
ReLU, Sigmoid	70:30	24-14-7-10	0,82	0,85	0,83	0,82
			0,67	0,68	0,68	0,64
		24-12-8-10	0,72	0,75	0,76	0,73
	80:20	24-14-7-10	0,76	0,78	0,75	0,77
			0,83	0,87	0,87	0,86
		24-12-8-10	0,85	0,89	0,89	0,87
ELU, Sigmoid	70:30	20-400-200- 100-50-10	0,73	0,79	0,77	0,75
			0,83	0,85	0,87	0,83
		0,40	0,58	0,41	0,35	
	80:20	20-400-200- 100-50-10	0,75	0,78	0,76	0,75
			0,62	0,74	0,63	0,57
		0,53	0,58	0,53	0,43	
		0,50	0,55	0,51	0,46	
		0,92	0,93	0,95	0,93	
		0,71	0,81	0,67	0,62	
		0,69	0,75	0,64	0,57	

Dalam hasil klasifikasi berdasarkan Tabel 2, variasi model termasuk penggunaan fungsi aktivasi ELU pada *hidden layer* dan sigmoid pada *output layer*, serta jumlah neuron dalam layer yang bervariasi. Hasil pengujian menunjukkan akurasi tertinggi sebesar 92%, dengan precision 93%, recall 95%, dan F1-score 93%. Namun, terdapat juga model dengan akurasi terendah 40%, menggunakan konfigurasi serupa. Penentuan parameter seperti epoch (5000 atau 10000), regularizers (0,001), dan dropout (0,01) mempengaruhi hasil akurasi. Parameter yang digunakan dalam proses training model klasifikasi ANN *Backpropagation* dapat dilihat pada Tabel 3.

Tabel 3. Parameter dalam Proses *Training*

Activation	Rasio Data	Layer Size	Epoch	Regularizers	Dropout
ReLU, Sigmoid	70:30	24-14-7-10	5000	0,001	0,01
			10000	0,001	0,01
		24-12-8-10	5000	0,001	0,01
		10000	0,001	0,01	
	80:20	24-14-7-10	5000	0,001	0,01
			10000	0,001	0,01
		24-12-8-10	5000	0,001	0,01
		10000	0,001	0,01	
ELU, Sigmoid	70:30	20-400-200-100-50-10	5000	-	-
			10000	-	-
	80:20	20-400-200-100-50-10	5000	0,001	0,01
			10000	0,001	0,01
		5000	-	-	
		10000	-	-	
			5000	0,001	0,01
			10000	0,001	0,01



Gambar 1. Visualisasi *Confusion Matrix*

Dari Gambar 5, hasil prediksi menunjukkan 44 dari data *testing* terdeteksi dengan benar dan 4 terdeteksi salah. *Confusion matrix* yang menunjukkan distribusi nilai terbesar pada diagonal dari pojok kiri atas hingga kanan bawah menandakan performa model yang baik. Meskipun *confusion matrix* memberikan informasi rinci tentang prediksi yang benar dan salah, metrik evaluasi lainnya diperlukan untuk memberikan gambaran menyeluruh tentang kinerja keseluruhan model dalam klasifikasi.

	precision	recall	f1-score	support
BL	0.71	0.71	0.71	7
CS	0.60	1.00	0.75	3
E	1.00	1.00	1.00	3
GH	1.00	1.00	1.00	5
L	1.00	0.75	0.86	8
PT	1.00	1.00	1.00	3
R	1.00	1.00	1.00	8
RK	1.00	1.00	1.00	3
SA	1.00	1.00	1.00	3
SK	1.00	1.00	1.00	5
accuracy			0.92	48
macro avg	0.93	0.95	0.93	48
weighted avg	0.93	0.92	0.92	48

Gambar 2. *Output Classification Report* pada Data *Testing*

Dalam *classification report*, terdapat metrik evaluasi seperti *precision*, *recall*, dan *F1-score* untuk setiap kelas dalam data *testing*. Laporan ini menunjukkan hasil prediksi yang kurang akurat pada beberapa kelas citra corak daun *Aglaonema*. Evaluasi klasifikasi pada data *testing* mengindikasikan perbedaan yang signifikan dalam jumlah data antar kelas. Kelas seperti L dan R memiliki jumlah data yang lebih besar daripada kelas lain seperti CS, E, PT, RK, SA, dan SK. Distribusi data yang tidak seimbang ini mempengaruhi penilaian performa

model, yang diukur dengan nilai makro-F1 untuk memberikan bobot yang setara pada setiap kelas tanpa memperhitungkan distribusi data. Model klasifikasi ANN *Backpropagation* menunjukkan kemampuan yang baik dalam mengidentifikasi kelas dalam tugas klasifikasi. Dengan *macro-averaged precision* 93%, model cenderung memberikan sedikit kesalahan dalam mengklasifikasikan sampel. Tingkat *recall* 95% mengindikasikan kemampuan model mengenali sebagian besar sampel positif yang sebenarnya. Dengan *macro-averaged F1-score* 93%, model ini memiliki kinerja baik dalam mengklasifikasikan secara akurat dan komprehensif, menunjukkan keseimbangan yang baik antara presisi dan *recall* untuk semua kelas dalam klasifikasi *multi-class*.

Dari hasil keseluruhan data *testing*, diperoleh nilai akurasi sebesar 92%. Artinya, model klasifikasi *Artificial Neural Network Backpropagation* berhasil memprediksi dengan benar 92% dari total data pada tahap pengujian. Hal ini menunjukkan bahwa model memiliki kemampuan yang baik dalam mengklasifikasikan data citra corak daun *Aglaonema* dengan akurasi yang tinggi. Melalui *confusion matrix* pula dapat dihitung nilai akurasi secara manual.

$$\text{Accuracy} = \frac{\sum \text{Data deteksi benar}}{\sum \text{Total data testing}} = \frac{44}{48} \times 100\% = 91,67\%$$

Jadi, akurasi dari 44 data yang terdeteksi benar dari total 48 jumlah data uji adalah sebesar 91.67%. berdasarkan hasil dari *confusion matrix* dan *classification report* pada data *testing*, terlihat bahwa terdapat kesalahan prediksi pada data citra corak daun *Aglaonema*. Hal ini mungkin disebabkan oleh beberapa faktor, seperti variasi corak daun yang sulit dibedakan, kualitas citra yang buruk, dan jumlah dataset yang terbatas. Kesalahan prediksi pada model klasifikasi juga dapat disebabkan oleh nilai parameter yang tidak optimal selama pelatihan model. Faktor-faktor seperti fungsi aktivasi, rasio dataset, *layer size*, dan *epoch* memiliki pengaruh signifikan pada hasil pengujian. Selain itu, parameter seperti *regularizers* dan *dropout* juga berperan dalam meningkatkan performa model. Meskipun demikian, terdapat kesalahan prediksi pada beberapa data citra, yang dapat disebabkan oleh variasi corak yang sulit dibedakan, kualitas citra yang buruk, keterbatasan jumlah dataset, dan nilai parameter yang tidak optimal selama *training* model. Dalam keseluruhan, model klasifikasi ANN *Backpropagation* memiliki potensi yang baik untuk klasifikasi data citra corak daun *Aglaonema*.

SIMPULAN

Berdasarkan hasil penelitian dan pembahasan, model ANN *Backpropagation* mampu mengklasifikasikan corak daun *Aglaonema* secara optimal. faktor-faktor seperti fungsi aktivasi, rasio dataset, *layer size*, dan *epoch* memiliki pengaruh besar pada hasil pengujian. *Regularizers* dan *dropout* juga memengaruhi performa model.

UCAPAN TERIMA KASIH

Terimakasih kepada koor Prodi Matematika dan seluruh Dosen Departemen Pendidikan Matematika FMIPA UNY yang telah memberikan ilmu hingga terselesainya jurnal ini.

DAFTAR PUSTAKA

- Apriansi, M., & Suryani, R. (2019). KARAKTERISASI TANAMAN AGLAONEMA DI DATARAN TINGGI REJANG LEBONG. *Jurnal Agroqua*.
- Bashashati, H., Ward, R. K., Birch, G. E., & Bashashati, A. (2015). Comparing Different Classifiers in Sensory Motor Brain Computer Interfaces. *PLoS ONE*.

- Effendi, M., Fitriyah, & Effendi, U. (2017). Identifikasi Jenis dan Mutu Teh Menggunakan Pengolahan Citra Digital dengan Metode Jaringan Syaraf Tiruan. . *Jurnal Teknotan Vol. 11 No. 2*.
- Hutahaean, & Desmon, H. (2019). Teknologi Identifikasi Objek Berbasis Drone Menggunakan Algoritma Sift Citra Digital. *Jurnal Teknik Informatika UNIKA Santo Thomas*.
- K, S., & Sasithra, S. (2014). Review on Classification Based on Artificial Neural Networks. . *The International Journal of Ambient Systems and Applications*, .
- Letelay, K. (2016). KLASIFIKASI DATA MENGGUNAKAN JARINGAN SYARAF TIRUAN MODEL FRNN (FULLY RECURRENT NEURAL NETWORK). *Jurnal MIPA - Penelitian Dan Pengembangan (JMIPA)*, 20(1), 63-73.
- Li, Z. (2017). A Data Classification Algorithm of Internet of Things Based on Neural Network. *International journal of online and biomedical engineering*.
- Rahayu, D., Wihandika, R. C., & Perdana, R. S. (2018). Implementasi Metode Backpropagation Untuk Klasifikasi Kenaikan Harga Minyak Kelapa Sawit. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, .
- Santoso, B., & Krisitianto, R. P. (2020). Implementasi Penggunaan Opencv Pada Face Recognition Untuk Sistem Presensi Perkuliahan Mahasiswa. *SISTEMASI*.
- Sari, D. P., Rasyad, S., Evelina, E., & Amperawan, A. (2017). Identifikasi Huruf Braille Berbasis Image Processing Secara Real Time. *Jurnal Ampere*.