

## ***Strawberry Fruit Disease Identification Using Digital Image Processing Using GLCM With Artificial Neural Network Method***

Identifikasi Penyakit Buah Stroberi Menggunakan Pengolahan Citra Digital Menggunakan GLCM Dengan Metode Jaringan Syaraf Tiruan

**Immanuel Puspa Wardaya<sup>1</sup>, Arief Hermawan<sup>2</sup>**

<sup>1,2</sup> Informatika, Universitas Teknologi Yogyakarta, Indonesia

<sup>1\*</sup> immanuel.5200411349@student.uty.ac.id, <sup>2</sup> ariefdb@uty.ac.id

### ***Informasi Artikel***

*Received: December 2020*

*Revised: January 2021*

*Accepted: January 2021*

*Published: February 2021*

*Menggunakan style info*

### ***Abstract (menggunakan style abstract)***

*Purpose: This research aims to identify strawberry fruit diseases using digital image processing using GLCM with the backpropagation artificial neural network method.*

*Design/methodology/approach: Using images that have been preprocessed grayscale, crop, and resize and then processed using GLCM for training using backpropagation artificial neural networks.*

*Findings/result: Based on 250 image data that is processed by GLCM and classified using a backpropagation artificial neural network, it can be concluded that the best accuracy rate is obtained from ReLU activation with a training data accuracy value of 95% and test data accuracy of 54%.*

*Originality/value/state of the art: This research uses a combination of primary data with kaggle data by using a comparison of several experiments by changing the loss, optimizer and activation parameters.*

### ***Abstrak (menggunakan style abstrak)***

**Tujuan:** Penelitian ini bertujuan untuk mengidentifikasi penyakit buah stroberi dengan menggunakan pengolahan citra digital menggunakan GLCM dengan metode jaringan syaraf tiruan backpropagation.

**Perancangan/metode/pendekatan:** Menggunakan citra yang telah di preprocessing grayscale, crop, dan resize lalu diolah menggunakan GLCM untuk dilakukan training menggunakan jaringan syaraf tiruan backpropagation.

**Hasil:** Berdasarkan 250 data citra yang di lakukan proses GLCM dan diklasifikasikan menggunakan jaringan syaraf tiruan backpropagation dapat disimpulkan bahwa tingkat akurasi terbaik didapatkan dari aktivasi ReLU dengan nilai akurasi data training 95% dan akurasi data test 54%.

*Keywords: Artificial Neural Network; GLCM; Strawberry Disease Detection; Backpropagation*

**Kata kunci:** Jaringan Syaraf Tiruan; GLCM; Deteksi Penyakit Stroberi; Backpropagation

---

Keaslian/ *state of the art*: Penelitian ini menggunakan perpaduan antara data primer dengan data kaggle dengan menggunakan perbandingan dari beberapa percobaan dengan mengubah parameter loss, optimizer dan activation.

---

## 1. Pendahuluan

Stroberi merupakan salah satu jenis tanaman subtropis. Stroberi dibudidayakan pada daerah tertentu, umumnya di dataran tinggi. Buah stroberi sama seperti buah pada umumnya juga memiliki penyakit. Beberapa penyakit buah stroberi yaitu anthracnose fruit, powdery mildew fruit, dan gray mold.

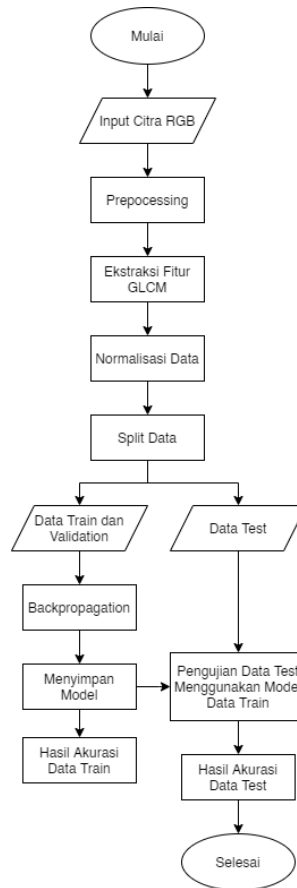
Pengetahuan penyakit buah stroberi masih sangat jarang diketahui oleh petani buah stroberi. Minimnya pengetahuan serta kurangnya ahli dilapangan mengakibatkan kurangnya perhatian petani buah stroberi atas kualitas dari buah stroberinya itu sendiri. Mendatangkan ahli bukanlah suatu solusi karena waktu dan biaya yang harus dikeluarkan tidaklah sedikit.

Dengan adanya perkembangan teknologi, maka alat pendeteksi penyakit pada buah stroberi dapat dibuat dengan mudah dan cepat. Penggunaan metode syaraf tiruan dapat digunakan untuk mengidentifikasi penyakit buah stroberi menggunakan pengolahan citra digital. Jaringan Syaraf Tiruan dapat menyelesaikan masalah yang kompleks serta sulit dipahami [1]. Dengan pemanfaatan metode jaringan syaraf tiruan, diharapkan dapat memudahkan para petani buah dalam mengidentifikasi adanya penyakit pada buah strawberry tanpa adanya seorang ahli yang hadir.

Pengidentifikasian dilakukan menggunakan alat yang dapat mengambil citra buah stroberi dan secara otomatis membedakan jenis penyakit dan apakah citra merupakan buah stroberi atau bukan. Dalam penelitian ini beberapa aktivasi digunakan untuk menentukan kinerja algoritma jaringan syaraf tiruan *backpropagation*. Penelitian ini bertujuan untuk mencari akurasi aktivasi terbaik pada algoritma jaringan syaraf tiruan *backpropagation* dengan menggunakan aktivasi ReLU, sigmoid, tanh, dan ELU untuk mengidentifikasi penyakit buah stroberi.

## 2. Metode/Perancangan

Kerangka sistem yang dibuat pada penelitian ini dapat dilihat pada Gambar 1. Kerangka sistem yang dibuat terdiri dari sekumpulan data buah stroberi dan buah lain, *pre-processing*, ekstraksi fitur GLCM, normalisasi data, split data, *training* model dengan algoritma *backpropagation*, menyimpan model hasil *training*, dan pengujian model menggunakan data *test* dengan hasil akhir akurasi data *training* dan data *test*. Langkah-langkah yang dilakukan dalam penyelesaian permasalahan yang pada penelitian ini adalah sebagai berikut:








**Gambar 1.** Kerangka Sistem

### 2.1. Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah 250 citra dimana sebanyak 123 citra diambil dari dataset Kaggle dengan judul “Strawberry Disease Detection Dataset” dan 127 citra merupakan data primer. Data Kaggle diambil pada tanggal 4 Oktober 2022 dan data primer diambil pada tanggal 27 Februari 2023. **Tabel 1** menampilkan detail informasi data dalam penelitian ini, yang terdiri dari jumlah data perkelas serta sumber datanya, nama label kelasnya, dan contoh data.

**Tabel 1.** Informasi Data


| Kelas      | Contoh Data                                                                         | Jumlah Data Kaggle | Jumlah Data Primer |
|------------|-------------------------------------------------------------------------------------|--------------------|--------------------|
| Antracnose |  | 50                 | 0                  |
| Gray Mold  |  | 50                 | 0                  |

|                  |                                                                                   |    |    |
|------------------|-----------------------------------------------------------------------------------|----|----|
| Powdery Mildew   |  | 23 | 27 |
| Buah Lain        |  | 0  | 50 |
| Strwaberry Sehat |  | 0  | 50 |

Pada metode dibahas tentang metode, tahapan, maupun model yang digunakan dalam penelitian yang dilakukan.

## 2.2. Pre-processing

Pada *pre-processing*, citra diolah dengan *grayscale*, *crop*, dan *resize* agar data citra dapat memiliki ukuran lebih kecil dan sama dan berbentuk *grayscale*. Berikut tahapan dari *pre-processing* yang divisualisasikan pada **Gambar 2**.



**Gambar 2.** Tahap Pre-processing

Pada dasarnya, citra *grayscale* adalah proses menggabungkan ketiga lapisan matriks citra yaitu R-layer, G-layer, dan B-layer menjadi satu lapisan matriks *grayscale* tunggal. Dalam citra ini, unsur warna tidak lagi ada, yang tersisa hanya tingkat keabuan [2]. Tingkat intensitas dalam citra *grayscale* bervariasi antara dua nilai ekstrem. Putih memiliki intensitas paling tinggi, yang direpresentasikan dengan nilai 255, sedangkan hitam memiliki intensitas paling rendah, yang direpresentasikan dengan nilai 0 [3]. Rumus konversi citra RGB ke *grayscale* dirumuskan sebagai berikut:

$$Gray = ((R * 0.2989) + (G * 0.5870) + (B * 0.1140)) \quad (1)$$

Pada penelitian ini dilakukan *grayscale* citra dengan tujuan agar dapat diproses pada tahap ekstraksi fitur GLCM.

*Cropping* adalah sebuah proses dimana ukuran citra diperkecil dengan cara memotong bagian-bagian citra yang berada pada koordinat tertentu di dalam area yang ditentukan dalam citra tersebut. Dalam proses *cropping*, bagian-bagian citra di luar area yang ditentukan akan

dihilangkan, sementara bagian dalam area tersebut akan tetap dipertahankan. Dengan demikian, citra akan terlihat lebih kecil dan hanya berisi informasi yang terdapat dalam area yang dipilih. [4]. *Cropping* dilakukan untuk meningkatkan performa komputasi yang terjadi [5]. Pada penelitian ini citra dilakukan *cropping* dengan ukuran 2/3 tinggi dan 2/3 lebar citra asli agar memiliki ukuran yang lebih kecil.

*Resize* merupakan proses untuk mengubah ukuran piksel dan dimensi gambar dengan mempertimbangkan keperluan penelitian agar semua data memiliki ukuran yang seragam [6]. Pada penelitian ini *resize* dilakukan dengan mengubah ukuran menjadi 128x128 piksel sebelum proses ke GLCM.

### 2.3. GLCM

*Grey Level Co-occurrence Matrix* yang disingkat GLCM merupakan sebuah metode untuk menganalisis tekstur dan mengekstraksi fitur dari gambar. Teknik yang digunakan dalam GLCM merupakan teknik tertua dalam analisis tekstur. GLCM memiliki dua parameter utama, yaitu jarak dan arah [7]. Dalam metode GLCM, proses kerjanya melibatkan pembentukan *co-occurrence* data citra, diikuti dengan penentuan karakteristik fungsional matriks antar piksel [8]. Dalam metode ekstraksi fitur GLCM, fitur-fitur diekstraksi dengan menggunakan intensitas yang spesifik pada jarak  $d$  serta sudut orientasi  $\theta$  dalam sebuah gambar. Jarak diwakili dalam satuan piksel, sementara sudut diwakili dalam derajat. Proses ekstraksi fitur GLCM dilakukan dalam empat arah sudut yang berbeda, yaitu dengan interval  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ , dan  $135^\circ$  [9]. Pada penelitian ini ekstraksi ciri yang digunakan yaitu:

$$Dissimilarity = \sum_{i,j=0}^{levels-1} P_{ij} |i - j| \quad (2)$$

$$Homogeneity = \sum_{i,j=0}^{levels-1} \frac{P_{ij}}{1+(i-j)^2} \quad (3)$$

$$Contrast = \sum_{i,j=0}^{levels-1} P_{ij} (i - j)^2 \quad (4)$$

$$ASM = \sum_{i,j=0}^{levels-1} P_{ij}^2 \quad (5)$$

$$Energy = \sqrt{ASM} \quad (6)$$

$$Correlation = \sum_{i,j=0}^{levels-1} P_{ij} \left[ \frac{(i-\mu_i)(j-\mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (7)$$

### 2.4. Normalisasi Data

Normalisasi data adalah proses untuk membuat rentang nilai data menjadi seragam, terlepas dari variasi dan rentang nilai yang besar. Dengan menerapkan normalisasi, data akan memiliki satuan yang seragam dan nilai yang lebih kecil, serta akan terbebas dari nilai ekstrem yang tidak wajar (outlier) [10]. Skala nilai atribut data yang baru membantu kinerja komputasi dari klasifikasi karena dapat menghapus noise yang tinggi dengan relevansi yang rendah [11].

### 2.5. Split Data

*Split* data merupakan proses yang digunakan untuk membagi data menjadi tiga bagian, yaitu *training data*, *validation data*, dan *test data*. *Training data* digunakan untuk melatih model, sedangkan *validation data* digunakan untuk melakukan validasi model dengan mengubah

parameter yang telah dibuat. *Test data* digunakan untuk mengevaluasi dan menguji performa dari model yang telah dilatih [12].

## 2.6. Backpropagation

Metode *backpropagation* adalah suatu teknik yang digunakan jaringan saraf tiruan untuk pengenalan pola yang kompleks. *Backpropagation* melatih jaringan dengan mencapai keseimbangan antara kemampuan jaringan dalam mengenali pola yang dipelajari selama pelatihan dan kemampuan jaringan untuk memberikan respons yang benar terhadap pola input yang mirip dengan pola yang telah dipelajari. Proses pelatihan metode *backpropagation* terdiri dari tiga fase yaitu fase propagasi maju, fase propagasi mundur, dan fase penyesuaian bobot. Ketiga fase ini diulang secara berulang sampai kondisi berhenti terpenuhi. Kondisi berhenti yang sering digunakan adalah jumlah iterasi, tingkat kesalahan, atau target kesalahan yang ditentukan. [13].


ReLU, yang merupakan singkatan dari *Rectified Linear Unit*, merupakan sebuah fungsi aktivasi non-linear yang digunakan dalam *deep neural network*. ReLU berfungsi untuk menghindari masalah hilangnya gradien dan juga mempercepat proses pelatihan [14]. Output *ReLU* adalah nilai maksimum antara nol dan nilai input. Jika input negatif, output akan menjadi nol, sedangkan jika input positif, output akan sama dengan nilai input tersebut [15].

*Softmax* adalah sebuah metode klasifikasi yang digunakan ketika terdapat beberapa kelas yang lebih dari satu. *Softmax* merupakan suatu fungsi yang dapat mengubah vektor 'x' dengan nilai-nilai real menjadi vektor dengan bentuk yang sesuai [16]. Ketika softmax digunakan untuk model multi-klasifikasi maka nilai probabilitas menghasilkan nilai yang tinggi [17].

## 3. Hasil dan Pembahasan

### 3.1. Hasil Pre-processing

Tahapan pre-processing pada penelitian ini berupa grayscale, crop, dan resize dapat dilihat pada gambar berikut ini:



**Gambar 2.** Citra Grayscale (Kiri), Citra Crop (Tengah) dan Citra Resize (Kanan)

Terlihat pada hasil *pre-processing* dimana *grayscale*, *crop*, dan *resize* dilakukan secara berurutan. *Grayscale* yang dihasilkan cukup jelas membedakan buah stroberi dengan *background* dan bayangan. *Crop* yang dilakukan memfokuskan pada tengah gambar dan *resize* dapat berjalan dengan baik tanpa adanya penurunan kualitas citra.

### 3.2. Hasil GLCM

Tahapan berikutnya setelah dilakukan pre-processing yaitu ekstraksi fitur GLCM. Ekstraksi fitur GLCM yang digunakan pada sistem ini menghitung *dissimilarity*, *correlation*,

homogeneity, contrast, ASM, dan energy dari sudut 0, 45, 90, dan 135. Kemudian dihasilkan GLCM seperti Gambar 3.

|   | dissimilarity_0 | dissimilarity_45 | dissimilarity_90 | dissimilarity_135 | correlation_0 | correlation_45 | correlation_90 | correlation_135 | homogeneity_0 | homogeneity_45 | ... | co |
|---|-----------------|------------------|------------------|-------------------|---------------|----------------|----------------|-----------------|---------------|----------------|-----|----|
| 0 | 21.549797       | 20.521657        | 16.023946        | 20.440492         | 0.686709      | 0.711659       | 0.818862       | 0.718033        | 0.076383      | 0.076147       | ... | !  |
| 1 | 16.429370       | 16.118366        | 14.532647        | 15.874870         | 0.599402      | 0.595580       | 0.683667       | 0.621549        | 0.071819      | 0.073158       | ... | !  |
| 2 | 21.869982       | 23.850546        | 22.335366        | 22.532908         | 0.691124      | 0.630472       | 0.679142       | 0.666278        | 0.052151      | 0.047571       | ... | !  |
| 3 | 17.843750       | 19.299688        | 15.045605        | 15.894121         | 0.658709      | 0.625091       | 0.742196       | 0.701973        | 0.186706      | 0.169836       | ... | !  |
| 4 | 21.977960       | 23.309964        | 22.039062        | 23.543314         | 0.689415      | 0.651177       | 0.670550       | 0.628930        | 0.060433      | 0.052446       | ... | !  |

Gambar 3. Hasil GLCM

Setelah didapatkan hasil GLCM, nilai tersebut akan dilakukan *split* data dengan perbandingan data training, data validasi, dan data test sebesar 60:20:20. Normalisasi data yang digunakan pada penelitian ini adalah *Min Max Normalization* dan didapatkan hasil seperti Gambar 4.

```
array([[0.43242329, 0.46012954, 0.40881929, ..., 0.07423953, 0.07724314,
        0.05881154],
       [0.67530825, 0.75193019, 0.78761344, ..., 0.31085252, 0.21436937,
        0.18510133],
       [0.48238212, 0.51294351, 0.43419947, ..., 0.03151509, 0.04524131,
        0.0229567 ],
       ...,
       [0.25537903, 0.24822411, 0.23316624, ..., 0.2091934 , 0.19054579,
        0.172765 ],
       [0.2845057 , 0.28159118, 0.31777349, ..., 0.18433932, 0.15143385,
        0.14730816],
       [0.52499176, 0.5986339 , 0.64175251, ..., 0.25075073, 0.22442847,
        0.23946674]])
```

Gambar 4. Hasil Normalisasi Data


### 3.3. Hasil Training dan Validasi

Pada penelitian ini training dilakukan menggunakan algoritma jaringan syaraf tiruan backpropagation untuk mengklasifikasi 5 kelas yaitu penyakit buah stroberi *antracnose*, penyakit buah stroberi *graymold*, penyakit buah stroberi *powdery mildew*, buah stroberi sehat, dan buah lain. Algoritma jaringan syaraf tiruan backpropagation diuji coba menggunakan beberapa aktivasi untuk memperoleh hasil akurasi terbaik dengan aktivasi output yang digunakan adalah *softmax* agar sistem dapat mengklasifikasi 5 kelas dengan lebih baik. Setiap *node* akan dilakukan dropout sebesar 0.5 untuk menghindari *overfitting*. Pada penelitian ini *loss sparse categorical crossentropy* digunakan untuk mengoptimalkan klasifikasi 5 kelas yang digunakan. *Optimizer* adam dipilih karena adam merupakan *optimizer* terbaik untuk penelitian ini, adam juga terkenal baik dalam penggunaannya pada jaringan syaraf tiruan. Aktivasi yang digunakan antara lain *ReLU*, *Sigmoid*, *Tanh*, dan *ELU*. Tabel 2 menunjukkan parameter-parameter yang tidak diubah pada penelitian ini.


Tabel 2. Parameter Tetap

| Parameter         | Yang Digunakan                  |
|-------------------|---------------------------------|
| Node              | 512, 256, 128, 64, 5            |
| Dropout           | 0.5                             |
| Optimizer         | Adam                            |
| Learning rate     | 0.001                           |
| Loss              | Sparse Categorical Crossentropy |
| Output Activation | Softmax                         |
| Batch Size        | 32                              |
| Epoch             | 1000                            |


Hasil akurasi dan loss dari proses *training* menggunakan aktivasi *ReLU*, *Sigmoid*, *Tanh*, dan *ELU* ditunjukkan pada **Gambar 5** sampai **Gambar 8**.




**Gambar 5.** Hasil Training dan Validasi ReLU



**Gambar 6.** Hasil Training dan Validasi Sigmoid



**Gambar 7.** Hasil Training dan Validasi Tanh



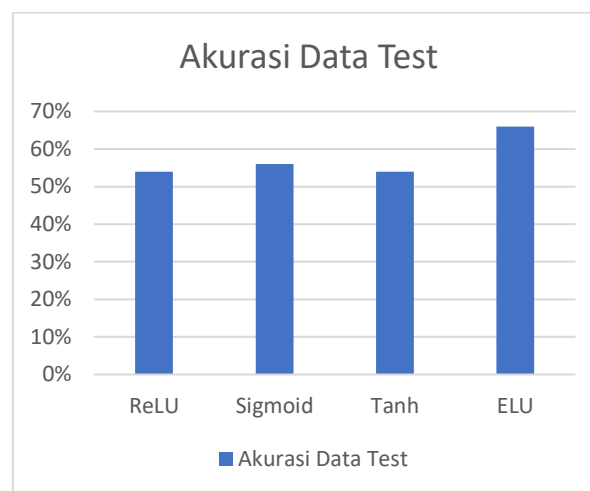
**Gambar 8.** Hasil Training dan Validasi ELU



Berdasarkan hasil dari proses *training* diatas dengan 1000 epoch, *training* menggunakan aktivasi ReLU menghasilkan akurasi terbaik dengan akurasi data *training* sebesar 95% dan akurasi data *validation* sebesar 67%. Untuk *training* menggunakan aktivasi sigmoid, tanh, dan ELU memiliki akurasi yang tidak sebaik aktivasi ReLU. Hasil akurasi aktivasi sigmoid adalah akurasi data *training* sebesar 68% dan akurasi data *validation* sebesar 67%, untuk hasil akurasi aktivasi tanh adalah akurasi data *training* sebesar 87% dan akurasi data *validation* sebesar 60%, dan untuk hasil akurasi aktivasi ELU adalah akurasi data *training* sebesar 88% dan akurasi data *validation* sebesar 64%. Namun dapat dilihat dari pada **Gambar 5** sampai **Gambar 8**, grafik loss dari data *validation* untuk aktivasi ReLU, tanh, dan ELU, setelah mengalami penurunan pada epoch awal, loss justru mengalami peningkatan, tidak seperti loss pada aktivasi sigmoid yang cenderung menurun.

### 3.4. Hasil Testing

Setelah melakukan *training* pada model jaringan syaraf tiruan, selanjutnya dilakukan *testing* menggunakan data *test* yang belum pernah dilatih sebelumnya. *Testing* dilakukan dengan menggunakan aktivasi *ReLU*, *Sigmoid*, *Tanh*, dan *ELU*. Grafik perbandingan hasil akurasi *testing* dapat dilihat pada **Gambar 9**.



**Gambar 9.** Akurasi Data Test

Berdasarkan hasil dari proses *testing* menggunakan model yang telah dilatih, *testing* menggunakan aktivasi ELU menghasilkan akurasi terbaik dimana akurasi data *test* sebesar 66%. Untuk hasil proses *testing* aktivasi ReLU, sigmoid, dan tanh mendapatkan hasil yang tidak sebaik aktivasi ELU. Aktivasi ReLU menghasilkan akurasi data *test* sebesar 54%, aktivasi sigmoid menghasilkan akurasi data *test* sebesar 56%, dan aktivasi tanh menghasilkan akurasi data *test* sebesar 54%.

## 4. Kesimpulan dan Saran

Berdasarkan penelitian yang telah dilakukan dapat diambil kesimpulan yaitu untuk mendeteksi penyakit buah strawberry dengan menggunakan pengolahan citra digital dapat dilakukan dengan membuat sistem menggunakan metode jaringan syaraf tiruan backpropagation yang menggunakan ekstraksi fitur GLCM. Proses *training* dilakukan menggunakan *node* sebanyak 5 dengan masing-masing jumlah *node* sebesar 512, 256, 128, 64, dan 5 *node output, dropout*

sebesar 0.5, *optimizer* adam, *learning rate* 0.001, loss *Sparse Categorical Crossentropy*, *Output Activation Softmax*, dan *epoch* sebanyak 1000 didapatkan hasil terbaik dengan menggunakan aktivasi ReLU dengan akurasi data *training* sebesar 95% , akurasi data *validation* sebesar 67%, dan akurasi data *test* sebesar 54%.

Beberapa hal yang dapat diperhatikan untuk pengembangan yaitu akurasi data *validation* dan akurasi data *test* yang masih kecil bila dibanding dengan akurasi data *train*.

## Daftar Pustaka

- [1] M. Effendi, F. Fitriyah, and U. Effendi, "Identifikasi Jenis dan Mutu Teh Menggunakan Pengolahan Citra Digital dengan Metode Jaringan Syaraf Tiruan", *Teknotan: Jurnal Industri Teknologi Pertanian*, vol. 11, no. 2, pp. 67-76, 2017.
- [2] S. Bhahari and Rachmat, "Transformasi Citra Biner Menggunakan Metode Thresholding Dan Otsu Thresholding", *Jurnal Sistem Informasi Dan Teknologi Informasi*, vol. 7, no. 2, pp. 195-203, 2018, doi: 10.36774/jusiti.v7i2.254.
- [3] M. R. Kumaseh, L. Latumakulitan, and N. Nainggolan, "Segmentasi Citra Digital Ikan Menggunakan Metode Thresholding". *Jurnal Ilmiah Sains*, vol. 13, no. 1, pp. 75-78, 2013, doi: 10.35799/jis.13.1.2013.2057.
- [4] A. Pandey and K. Jain, "An intelligent system for crop identification and classification from UAV images using conjugated dense convolutional neural network", *Computers and Electronics in Agriculture*, vol. 192, 106543, 2022, doi: 10.1016/j.compag.2021.106543.
- [5] Rikendry and A. Maharil, "Perbandingan Arsitektur VGG16 Dan ResNet50 Untuk Rekognisitulisan Tangan Aksara Lampung", *Jurnal Informatika dan Rekayasa Perangkat Lunak (JATIKA)*, vol. 3, no. 2, pp. 236-243, 2022, doi: 10.33365/jatika.v3i2.2030.
- [6] R. Prabowo, A. Roudhoh, and Afifah, "Klasifikasi Image Tumbuhan Obat Sirih dan Binahong Menggunakan Metode Convolutional Neural Network(CNN)", *Jurnal Komputasi*, vol. 10, no. 2, pp. 48-54, 2022.
- [7] S. Singh, D. Srivastava, and S. Agarwal, "GLCM and Its Application in Pattern Recognition", *2017 5th International Symposium on Computational and Business Intelligence (ISCBI)*, pp. 20-25, 2017, doi: 10.1109/ISCBI.2017.8053537.
- [8] M. A. Rahman, N. Hidayat, and A. A. Supianto, "Komparasi Metode Data Mining K-Nearest Neighbor Dengan Naïve Bayes Untuk Klasifikasi Kualitas Air Bersih (Studi Kasus PDAM Tirta Kencana Kabupaten Jombang)", *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 2, no. 12, pp. 6346-6353, 2018.
- [9] K. Adi, C. E. Widodo, A. P. Widodo, R. Gernowo, A. Pamungkas, and R. A. Syifa, "Detection Lung Cancer Using Gray Level Co-Occurrence Matrix (GLCM) and Back Propagation Neural Network Classification". *Journal of Engineering Science and Technology Review*, vol. 11, no. 2, pp. 8-12, 2018.
- [10] R. G. F. Junior, N. Hidayat, and A. A. Soebroto, "Prediksi Omzet Penjualan Jersey menggunakan Metode Regresi Linier (Studi Kasus CV. Quattro Project Bululawang)", *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 6, no. 10, pp. 4598-4603, 2022.
- [11] A. Khoirunnisa, Adiwijaya, and A. A. Rohmawati, "Implementing Principal Component Analysis and Multinomial Logit for Cancer Detection based on Microarray Data Classification," *2019 7th International Conference on Information and Communication Technology (ICoICT)*, pp.1-6, 2019, doi: 10.1109/ICoICT.2019.8835320.
- [12] R. D. Jonathan, M. J. Hasugian, E. M. Sartika, "Perbandingan Deteksi Letak Polip pada Citra Colonoscopy menggunakan CNN dengan Arsitektur RetinaNet", *ELKOMIKA*:

- Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 10, no. 4, pp. 946 – 960, 2022.
- [13] F. Rahmadani, A. M. H. Pardede, and Nurhayati, “Jaringan Syaraf Tiruan Prediksi Jumlah Pengiriman Barang Menggunakan Metode Backpropagation (Studi Kasus: Kantor Pos Binjai)”, *Jurnal Teknik Informatika Kaputama (JTIK)*, vol. 5, no. 1, pp. 100-106, 2021.
- [14] S. Qiu, X. Xu, and B. Cai, "FReLU: Flexible Rectified Linear Units for Improving Convolutional Neural Networks", *2018 24th International Conference on Pattern Recognition (ICPR)*, pp. 1223-1228, 2018, doi: 10.1109/ICPR.2018.8546022.
- [15] J. Sanjaya, and M. Ayub, “Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan *Random Crop, Rotate, dan Mixup*”, *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 6, no. 2, pp. 311-323, 2020
- [16] A. Willyanto, D. Alamsyah, and H. Irsyad, “Identifikasi Tulisan Tangan Aksara Jepang Hiragana Menggunakan Metode CNN Arsitektur VGG-16”, *Jurnal Algoritme*, vol. 2, no. 1, pp. 1–11, 2021.
- [17] P. N. Andono, E. H. Rachmawanto, “Deteksi Karakter Hiragana Menggunakan Metode Convolutional Neural Network”, *Jurnal Nasional Pendidikan Teknik Informatika : JANAPATI*, vol. 11, no. 3, pp. 183-192, 2022, doi: 10.23887/janapati.v11i3.50144.