

# Identifikasi Penyakit Tanaman Jagung Berdasarkan Citra Daun Menggunakan Convolutional Neural Network

*Identification of Corn Plant Diseases Based on Leaf Image Using Convolutional Neural Network*

Bima Widiyanto<sup>1</sup>, Ema Utami<sup>2</sup>, Dhani Ariatmanto<sup>3</sup>

<sup>1,2,3</sup>Magister Informatika, Universitas AMIKOM Yogyakarta

E-mail: <sup>1</sup>bimawidiyanto@students.amikom.ac.id, <sup>2</sup>ema.u@amikom.ac.id,

<sup>3</sup>dhaniari@amikom.ac.id

## Abstrak

Komoditas jagung di Indonesia menjadi tanaman pangan terbesar kedua setelah padi sebagai sumber karbohidrat. Namun dikarenakan keterbatasan kemampuan petani dan faktor lingkungan menyebabkan upaya penanganan tanaman jagung akibat adanya serangan organisme pengganggu tanaman menjadi terhambat. Penelitian ini mengusulkan upaya deteksi secara dini terhadap jenis penyakit pada daun tanaman jagung menggunakan metode *Convolutional Neural Network* (CNN) yang dikenal sebagai algoritma pembelajaran mesin berkinerja tinggi dalam mengklasifikasikan jenis penyakit tanaman ke dalam beberapa kelas seperti *Blight*, *Common Rust*, *Grey Leaf Spot*, dan *Healthy*. Selain itu, transformasi warna citra dari RGB, HSV dan *Grayscale*, proses segmentasi dengan *Region of Interest* (ROI) serta dilengkapi dengan penerapan ekstraksi fitur tekstur dengan menggunakan GLCM telah mampu menghasilkan tingkat akurasi sebesar 94% dan nilai loss rate yang relatif kecil yaitu 0.1742. Hasil penelitian ini menunjukkan bahwa penggunaan metode CNN terbukti secara efisien & efektif dalam melakukan identifikasi jenis penyakit tanaman.

Kata kunci: Penyakit Jagung, Machine Learning, Convolutional Neural Network, GLCM, Image Processing

## Abstract

*Corn in Indonesia is the second largest food crop after rice as a source of carbohydrates. However, due to the limited ability of farmers and environmental factors, efforts to handle corn plants due to attacks by plant-disturbing organisms need to be improved. This study proposes an early detection of disease types on corn plant leaves using the Convolutional Neural Network (CNN) method, which is known as a high-performance machine learning algorithm for classifying plant disease types into several classes such as Blight, Common Rust, Gray Leaf Spot, and Healthy. In addition, image colour transformation from RGB, HSV and Grayscale, segmentation process with Region of Interest (ROI) and equipped with the application of texture feature extraction using GLCM has been able to produce an accuracy rate of 94% and a relatively small loss rate value of 0.1742. The results of this study indicate that the use of the CNN method is proven to be efficient & effective in identifying plant disease types.*

Keywords: Corn Disease, Machine Learning, Convolutional Neural Network, GLCM, Image Processing

## 1. PENDAHULUAN

Perkembangan teknologi di zaman sekarang telah memberikan banyak manfaat terhadap keberlangsungan setiap sektor bisnis termasuk sektor pertanian. Diperkirakan bahwa penggunaan teknologi modern di sektor pertanian ini dapat meningkatkan nilai pendapatan ekonomi hingga US\$ 6,6 miliar per tahun. Dengan pemanfaatan teknologi pengolahan citra digital menjadi sebuah terobosan baru yang diyakini mampu memberikan perubahan yang positif bagi para petani seperti

adanya teknologi yang mampu mengidentifikasi penyakit pada tanaman secara cepat dan akurat tanpa dengan biaya operasional yang tinggi [1]. Pencegahan serangan penyakit tanaman yang terlambat akan menghambat dalam stabilitas produksi. Bukan hanya menurunkan kualitas dan produktivitas panen, tetapi juga sering kali menimbulkan fuso bahkan berimbas pada gangguan sistem pengadaan pangan hampir seluruh dunia.

Tanaman jagung merupakan jenis tanaman serelia dan bahan pangan yang dijadikan sebagai sumber karbohidrat selain padi dan gandum. Melansir data dari Food and Agriculture Organization (FAO), produksi jagung cenderung meningkat sejak tahun 2010 - 2018 dengan mencapai 30,25 juta ton pada tahun 2018. Namun, pada 2019 produksi jagung mengalami penurunan 25% menjadi 22,59 juta ton dan pada tahun 2020 kembali mengalami penurunan 0,38% menjadi 22,5 juta ton. Tingkat produktivitas tanaman jagung selalu mengalami fluktuasi dikarenakan pengaruh jumlah penawaran dan permintaan yang terus berubah-ubah. Sebagaimana yang diketahui bahwa komoditas jagung memiliki peran strategis dalam perekonomian di Indonesia namun banyak hal yang menjadi penyebab dalam upaya peningkatan jumlah produksi jagung salah satunya adanya serangan organisme pengganggu tanaman yang bisa melanda kapan saja [2]. Sampai saat ini upaya dalam penanggulangan untuk mencegah dan menanggulangi organisme pengganggu tanaman seperti hama dan penyakit pada tanaman jagung terus dilakukan. Namun mengingat faktor lingkungan seperti halnya cuaca, suhu dan kelembaban dapat menyebabkan perkembangan penyakit pada tanaman jagung pun akan semakin berkembang [3]. Selain itu, pola penanganan dalam upaya mengidentifikasi jenis penyakit tanaman jagung apakah berpenyakit karat daun, hawar daun *Helminthosporium*, busuk batang, atau busuk tongkol yang dilakukan oleh para petani saat ini masih melalui pengamatan secara manual serta membutuhkan seorang ahli penyakit tanaman dan tentu membutuhkan biaya operasional yang tinggi. Identifikasi jenis penyakit tanaman dengan tepat dan akurat menjadi sebuah tantangan sekaligus perhatian khusus untuk dapat diselesaikan. Maka diperlukan peranan teknologi yang mampu mengidentifikasi penyakit tanaman jagung dalam hal ini memanfaatkan teknologi citra daun.

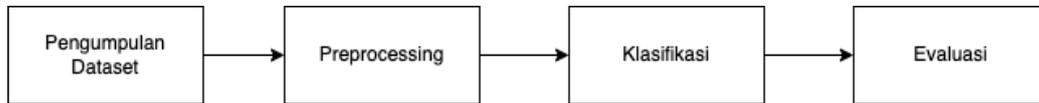
Pemanfaatan teknologi khususnya dalam pengolahan citra dengan menerapkan berbagai metode kecerdasan buatan sampai saat ini terus dilakukan. Terdapat beberapa studi kasus penelitian yang terkait menggunakan berbagai metode yang berbeda. Wafa, Akhyari, dkk. [4] melakukan penelitian menggunakan algoritma *Convolutional Neural Network* dengan menggunakan arsitektur VGG-16 untuk mendiagnosis penyakit pada daun tanaman jagung. Dari penelitian yang telah dilakukan menghasilkan tingkat akurasi sebesar 90%. Dalam penelitian Suhendra, R, dkk. [5] dilakukan pengujian klasifikasi menggunakan algoritma SVM untuk membedakan daun tanaman jagung yang sehat dengan yang terkena penyakit. Dalam proses *preprocessing* dilakukan ekstrasi fitur menggunakan metode GLCM dan dilakukan pembagian dataset antara data *training* dan data *validation*. Hasil pengujian yang diperoleh menunjukkan bahwa rata-rata akurasi mencapai 99.5% dengan menggunakan fitur kombinasi warna dan tekstur.

Penelitian Rosadi, M. I., & Lutfi, M. [6] mengusulkan algoritma *Convolutional Neural Network pre-trained* model dalam mendeteksi penyakit daun jagung. Metode *transfer learning* digunakan pada penelitian ini dengan memanfaatkan kembali model pernah dibuat. Hasil yang diperoleh dalam penelitian ini sebesar 85% pada akurasi data *training* dan 88% pada data *validation*. Nurcahyati, A. D, dkk. [7] mengusulkan penelitian menggunakan algoritma *Convolutional Neural Network* untuk klasifikasi jenis penyakit pada daun tanaman jagung dengan membandingkan 6 jenis algoritma optimasi yaitu RMSProp, AdaGrand, SGD, Adam, Adamax, dan Adadelta. Dari penelitian ini algoritma optimasi Adam menghasilkan nilai akurasi tertinggi sebesar 94% dengan memanfaatkan ukuran kernel pada CNN 3x3.

Melihat kondisi tersebut menjadi perhatian khusus bagi peneliti untuk menyajikan suatu solusi dalam hal ini memanfaatkan teknologi yang mampu mengidentifikasi jenis penyakit pada daun tanaman jagung secara cepat dan tepat dengan menggunakan metode *Convolutional Neural Network*, yang bertujuan dapat merumuskan langkah penanganan yang tepat pada tanaman jagung yang berpenyakit, sehingga segera dapat dilakukan tindakan yang tepat menjaga stabilitas produksi tidak terganggu.

## 2. METODE PENELITIAN

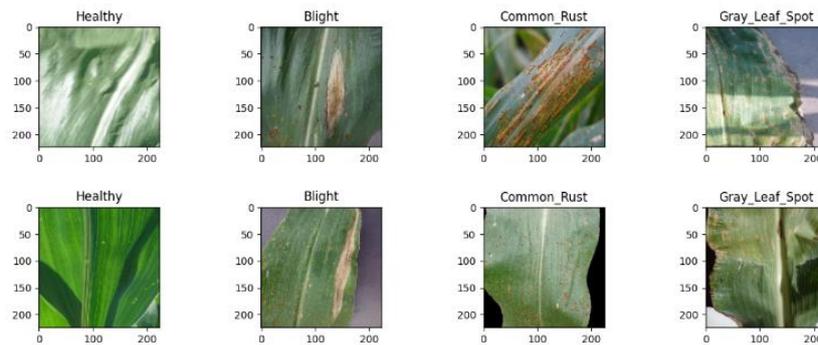
Metode penelitian yang digunakan dalam penelitian ini meliputi pengumpulan dataset citra penyakit daun jagung, *preprocessing* pada dataset, pembuatan model klasifikasi, pengujian performa dari model yang sudah dirancang. Alur metode penelitian yang dilakukan dapat dilihat pada Gambar 1:



Gambar 1. Alur Metode Penelitian.

### 2.1 Pengumpulan Dataset

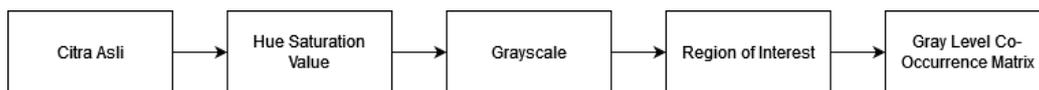
Data yang digunakan dalam penelitian ini menggunakan dataset dari layanan penyedia data bersifat publik yang bersumber dari [www.kaggle.com](http://www.kaggle.com) dengan judul Corn or Maize Leaf Disease Dataset yang dikontribusikan oleh Smaranjit Ghose. Data yang digunakan berupa citra yang terdiri 4188 citra penyakit daun tanaman jagung terbagi kedalam 4 kelas yaitu *Blight*, *Common Rust*, *Grey Leaf Spot*, dan *Healthy*. Dataset ini telah digunakan pada beberapa penelitian sebelumnya diantaranya yaitu [8], dan [9]. Dalam penelitian ini menerapkan proporsi data *training* dan data *validation* dengan skenario pembagian 80% untuk data *training* dan 20% untuk data *validation*. Pada Gambar 2 menunjukkan contoh dataset penyakit daun jagung berdasarkan kelas penyakit yang digunakan dalam penelitian ini.



Gambar 2 Contoh Citra Daun Penyakit Jagung.

### 2.2 Preprocessing

Tahap *preprocessing* merupakan tahapan yang dilakukan pada sebelum proses klasifikasi dengan tujuan untuk meningkatkan sebuah kualitas dataset dalam proses *training* dan *testing*, sehingga menghasilkan tingkat akurasi yang tinggi. Dalam penelitian ini menerapkan beberapa tahapan *preprocessing* yaitu mengonversi semua citra ke HSV (*Hue Saturation Value*), kemudian mengonversi citra HSV ke *Grayscale*. Selanjutnya yaitu proses segmentasi ROI (*Region of Interest*) pada citra *Grayscale*, kemudian melakukan ekstraksi fitur tekstur GLCM pada citra yang telah di segmentasi ROI. Pada gambar 3 merupakan alur tahapan metode yang digunakan pada proses *preprocessing*.



Gambar 3. Alur Tahapan Preprocessing.

#### 1) Citra Grayscale

Sebuah gambar dalam format RGB pada dasarnya terdiri dari tiga komponen warna yaitu Merah, Hijau, dan Biru [10]. Setiap komponen warna memiliki tingkat intensitas yang

direpresentasikan oleh angka bulat antara 0 hingga 255. Pada citra *Grayscale*, hanya satu jenis warna yang digunakan untuk merepresentasikan gambar tersebut. Warna pada *Grayscale* diubah menjadi skala abu-abu atau tingkat kecerahan yang beragam, berkisar dari 0 hingga 255. Angka 0 menggambarkan warna hitam, sedangkan angka 255 menggambarkan warna putih. Citra dalam format RGB dapat diubah menjadi citra *Grayscale* menggunakan rumus persamaan 1.

$$Grayscale = 0,299 R + 0,587 G + 0,144 B \quad (1)$$

## 2) Citra Hue Saturation Value (HSV)

HSV merupakan representasi warna yang terdiri dari 3 komponen yaitu *Hue* merupakan skala yang mewakili jenis warna dari 0 sampai 360°. *Saturation* menggambarkan berapa variasi warna, semakin berwarna semakin tinggi nilainya. *Value* menunjukkan nilai pencahayaan warna [11]. Namun pada nilai yang sangat rendah, sulit untuk membedakan warna. HSV merupakan warna yang diturunkan dari citra RGB, sehingga untuk mendapatkan citra HSV diperlukan untuk mengonversi dari citra RGB [12]. Untuk mendapatkan ruang warna pada HSV, perlunya untuk menganalisis nilai warna RGB pada setiap piksel citra sesuai fitur yang diinginkan dengan nilai toleransi warna HSV [13]. Persamaan *Hue Saturation Value* menggunakan pada persamaan 2, 3, 4 dan 5.

$$\theta = \cos^{-1} \left\{ \frac{\frac{1}{2}[(R-G) + (R+B)]}{[(R-G)^2 + (R-B)(G-B)]^{\frac{1}{2}}} \right\} \quad \theta \quad (2)$$

Menghitung nilai *Hue*

$$H = \begin{cases} \theta & \text{jika } B \leq G \\ 360 - \theta & \text{jika } B > G \end{cases} \quad (3)$$

Menghitung nilai *Saturation*

$$S = \begin{cases} \theta & \text{jika } V = 0 \\ 1 - \frac{(r,g,b)}{V} & \text{jika } V > 0 \end{cases} \quad (4)$$

Menghitung nilai *Value*

$$V = \max(r, g, b) \quad (5)$$

## 3) Gray Level Co-Occurrence Matrix (GLCM)

Metode *Gray Level Co-Occurrence Matrix* (GLCM) adalah sebuah metode analisis yang digunakan untuk mengambil informasi tekstur dari citra dengan menganalisis hubungan antara piksel-piksel yang berdekatan. Metode ini didasarkan pada statistik orde ke-2 dan menghasilkan sebuah matriks yang merepresentasikan hubungan antara dua pixel tetangga yang memiliki intensitas keabuan, jarak, dan sudut tertentu [14]. Perbedaan dengan pengukuran tekstur orde pertama adalah bahwa pada pengukuran orde kedua, hubungan antara pasangan dua piksel citra asli juga diperhitungkan [15]. Berikut merupakan penjelasan dari beberapa fitur pada GLCM:

### 1. Homogeneity

Fitur *Homogeneity* mengukur sejauh mana variasi intensitas keabuan yang seragam dalam citra. Semakin tinggi nilai *Homogeneity*, semakin seragam intensitas keabuan dalam citra.

$$Dissimilarity = \sum \left( \frac{P(i,j)}{1+|i-j|} \right) \quad (6)$$

### 2. Correlation

Fitur *Correlation* mengukur hubungan linier antara intensitas keabuan piksel dalam citra. Nilai *Correlation* mendekati 1 jika terdapat hubungan linier yang kuat antara piksel-piksel tetangga dalam citra.

$$Correlation = \sum \left[ \frac{(i-\mu)(j-\mu)P(i,j)}{\sigma^2} \right] \quad (7)$$

### 3. Contrast

Fitur *Contrast* menggambarkan tingkat perbedaan antara intensitas keabuan piksel-piksel tetangga dalam citra.

$$Contrast = \sum |i - j|^2 P(i, j) \quad (8)$$

### 4. Energy

Fitur *Energy* mengukur seberapa kuat tekstur dalam citra. Semakin tinggi nilai *Energy*, semakin kuat tekstur yang terlihat dalam citra.

$$Energy = \sum P(i,j)^2 \tag{9}$$

5. ASM

ASM adalah ukuran yang sama dengan fitur *Energy*. Ini menggambarkan jumlah total energi atau kekuatan tekstur dalam citra.

$$ASM = \sum P(i,j)^2 \tag{10}$$

6. Dissimilarity

Fitur Dissimilarity mengukur seberapa berbedanya intensitas keabuan antara piksel-piksel tetangga dalam citra.

$$Dissimilarity = \sum |i - j| P(i,j) \tag{11}$$

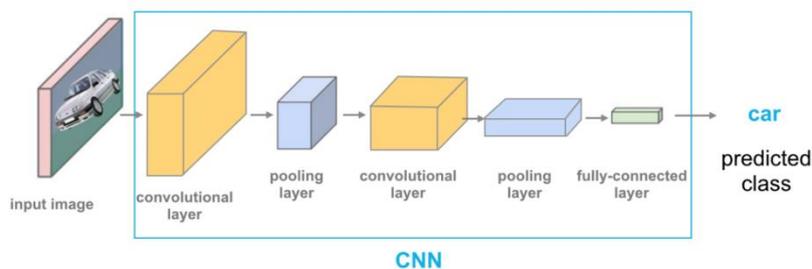
4) Region of Interest (ROI)

*Region of Interest* (ROI) merupakan salah satu segmentasi yang digunakan dalam pengolahan citra yang mengacu pada area atau wilayah tertentu dalam sebuah citra digital yang mengandung informasi yang diinginkan. Tujuan penggunaan ROI dalam pengolahan citra adalah untuk meningkatkan efisiensi dan akurasi dengan fokus pada wilayah tertentu yang membawa informasi penting dengan menghapus *background* pada citra. Sehingga area citra yang dianggap lebih penting akan memiliki kualitas yang lebih tinggi dibandingkan dengan area sekitarnya [16].

2.3 Training Model

Pada penelitian ini menggunakan Convolution Neural Network (CNN) untuk membangun model yang digunakan untuk mengidentifikasi penyakit tanaman jagung. Pada proses ini menggunakan 80% dari dataset yang dimiliki, *batch size* sebesar 32, serta menggunakan 50 *epoch*.

Convolution Neural Network (CNN) merupakan pengembangan dari metode Multilayer Perception (MLP) yang dirancang untuk mengolah data skala besar dan diaplikasikan untuk mengolah citra tiga dimensi [17]. CNN merupakan metode pemrosesan gambar yang digunakan untuk mengenali benda atau mendeteksi suatu objek [18]. CNN merupakan Neural Network yang sangat efektif dalam melakukan klasifikasi dan pengenalan gambar dengan memberikan sebuah label pada data yang sudah dikelompokkan. CNN mampu menangkap informasi kontekstual yang terkandung di dalam citra seperti pixel yang saling berdekatan, yang berarti model CNN dapat melakukan ekstraksi ciri pada sebuah citra secara mandiri. Arsitektur umum yang sering dijumpai pada CNN dapat dilihat pada Gambar 3.



Gambar 3 Contoh Arsitektur *Convolutional Neural Network*.

2.4 Evaluasi

Pada tahap ini, dilakukannya pengujian atau *evaluasi* model yang sudah dilakukan proses *training* sebelumnya agar mengetahui tingkat nilai akurasi dari model yang sudah dibangun. Pada proses *evaluasi* ini menggunakan 20% dari dataset yang dimiliki dengan menggunakan 50 *epoch*. Pada proses *evaluasi* ini menggunakan metode *Confusion Matrix* yang merupakan sebuah tabel yang digunakan untuk menggambarkan kinerja dari suatu model klasifikasi tentang sejauh mana model dapat mengklasifikasikan data dengan benar atau dengan kesalahan [19]. Contoh tabel *confusion matrix* ditunjukkan pada tabel 1.

Tabel 1 Confusion Matix

	Kelas Prediksi	
	Benar	Salah
Benar	TP (True Positive)	FP (False Positive)
Salah	FN (False Negative)	FN (True Negative)

Rumus yang digunakan *confusion matrix* untuk menghitung *accuracy*, *precision*, *recall*, dan *F1-score* sebagai berikut.

$$accuracy = \frac{TP+FN}{total} \quad (12)$$

$$precision = \frac{TP}{TP+FP} \quad (13)$$

$$recall = \frac{TP}{TP+FN} \quad (14)$$

$$F1\ Score = \frac{precision \times recall}{precision + recall} \quad (15)$$

### 3. HASIL DAN PEMBAHASAN

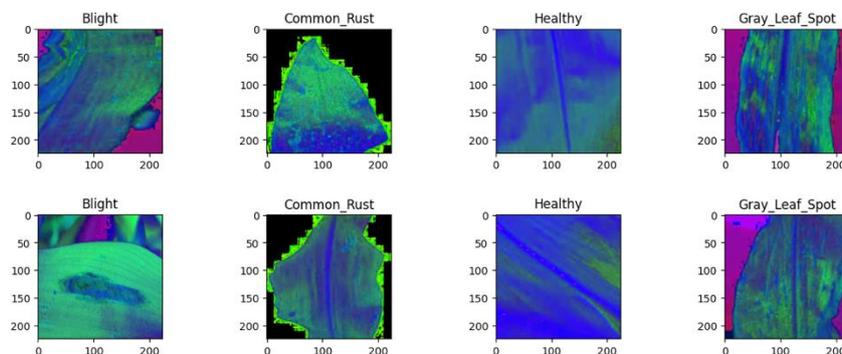
#### 3.1 Hasil Preprocessing

Pada penelitian ini dilakukan tahapan percobaan terhadap citra daun jagung. Pada tahap pertama, dilakukan proses transformasi citra warna yang semula RGB (*Red, Green, Blue*) menjadi menjadi ke *Hue Saturation Value* (HSV). Hasil dari tahap ini dapat ditampilkan pada Gambar 4.

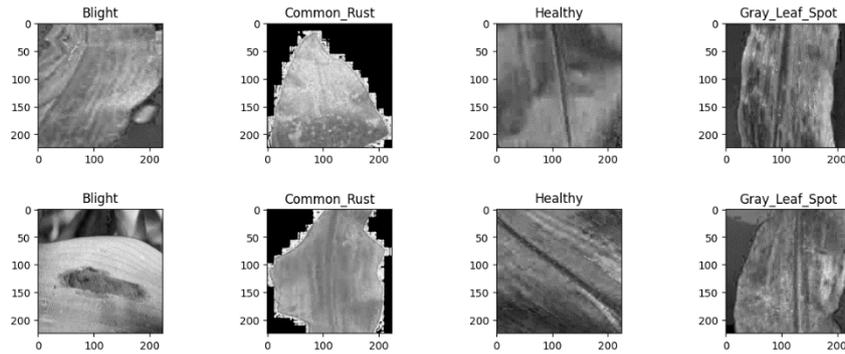
Selanjutnya, pada tahap kedua, dilakukan transformasi kembali dari citra HSV ke citra *grayscale* atau citra dengan skala keabuan. Hal ini penting dalam penelitian ini karena bertujuan untuk mengurangi dimensi citra, yang akan memudahkan dalam pengolahan dan proses analisis selanjutnya. Gambar hasil transformasi ke *grayscale* ini dapat dilihat pada Gambar 5.

Pada tahap ketiga merupakan proses *Region of Interest* (ROI) yaitu proses untuk mendapatkan area yang paling relevan pada citra daun jagung yang terdampak oleh penyakit dan dilakukan penghapusan *background* pada citra, sehingga akan memperoleh informasi akurat dan penting untuk mengidentifikasi penyakit dengan akurasi yang lebih tinggi. Hasil dari tahap ketiga dapat dilihat pada Gambar 6.

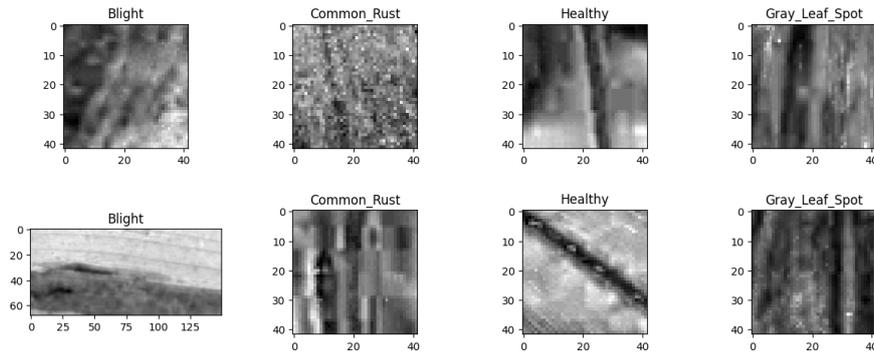
Pada tahap terakhir dilakukan proses ekstraksi fitur tekstur pada citra dengan menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM). Pada penelitian ini memanfaatkan 4 sudut diantaranya sudut 0°, 45°, 90°, 135° terhadap pada masing-masing fitur yaitu *dissimilarity*, *correlation*, *homogeneity*, *contrast*, *ASM*, dan *energy*. Pada Tabel 2 merupakan hasil ekstraksi fitur tekstur yang menghasilkan 24 data fitur tekstur.



Gambar 4 Tahap Pertama Tranformasi Citra RGB ke HSV.



Gambar 5 Tahap Kedua Tranformasi Citra HSV ke Grayscale.



Gambar 6 Tahap Ketiga Segmentasi Region of Interest.

Tabel 2 Tahap Keempat Hasil GLCM untuk 24 Data Fitur & 1 Kolom Label

	Dissimilarity_0	Dissimilarity_45	Dissimilarity_90	Dissimilarity_135	Correlation_0	...	Energy_135	Label
0	15.952632	28.923219	28.729508	28.322581	0.573167	...	0.019046	Blight
1	10.862934	11.468144	8.914414	11.015235	0.426575	...	0.030143	Blight
2	8.904762	8.029778	5.072716	9.168283	-0.095937	...	0.044736	Blight
3	12.068855	13.722299	8.175032	7.450831	0.603012	...	0.056704	Blight
4	7.492921	6.809557	6.944659	7.689058	0.540737	...	0.037763	Blight
5	8.342342	8.628809	5.375804	8.423823	0.375414	...	0.037937	Blight
6	8.616474	8.491690	6.943372	8.015928	0.058248	...	0.044661	Blight

### 3.2 Hasil Klasifikasi

Selanjutnya melakukan proses pengujian kinerja terhadap model yang dibangun menggunakan *Convolutional Neural Network*. Pada proses *training* model menggunakan *batch size* ukuran 32, *epoch* sebesar 50, dan pada penelitian ini menggunakan metode *optimizer adam* pada penelitian ini. *Epoch* adalah proses *training* dan *testing* dalam membangun model CNN yang berperan sebagai *hyperparameter* bertujuan untuk menentukan berapa kali proses *training* ini bekerja melewati seluruh dataset baik secara *forward* maupun *backward*. Hasil pengujian model yang dibangun berupa akurasi *training*, akurasi *validation*, dan *loss rate* ditunjukkan pada Tabel 3.

Tabel 3 Hasil Pengujian Model

Epoch	Akurasi	Akurasi Validasi	Loss Rate
1	0.5364	0.6742	1.2309
2	0.6406	0.6623	1.0959
3	0.6651	0.5823	1.9034
-----	-----	-----	-----
48	0.9182	0.9248	0.2203
49	0.9096	0.9308	0.1831
50	0.9203	0.9451	0.1742

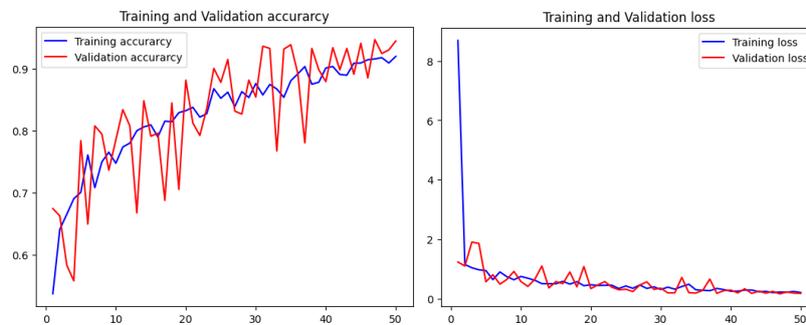
Berdasarkan pada tabel 3, terlihat bahwa hasil penggunaan model CNN yang sudah dibangun menghasilkan tingkat akurasi sebesar 94%. Selain itu, dengan menggunakan model CNN yang dibangun mampu memperoleh *loss rate* yang kecil yaitu 0.1742.

Dalam proses pembangunan model CNN, dilakukannya analisis terhadap metrik *loss rate* dan akurasi pada setiap *epoch*. Tujuannya adalah untuk menentukan apakah model yang sedang dikembangkan mengalami *overfitting* atau tidak. Jika terdapat perbedaan yang signifikan antara akurasi pada tahap *training* dan *validation*, maka hal tersebut menunjukkan adanya kecenderungan *overfitting* pada model tersebut [20]. Berdasarkan model CNN yang telah dibangun, tampaknya perbedaan nilai akurasi antara tahap *training* dan tahap *validation* tidak begitu signifikan, kecuali pada awal *epoch*. Sehingga dapat disimpulkan bahwa model CNN yang telah dibangun tidak mengalami *overfitting*.

Tabel 4 Hasil Pengujian *Confusion Matrix*

	Precision	Recall	F1-Score
Blight	0.99	0.93	0.96
Common Rust	0.92	0.98	0.95
Grey Leaf Spot	0.83	0.83	0.83
Healthy	0.98	0.98	0.98
Rata-Rata	0.93	0.93	0.93

Berdasarkan pada table 4 menjelaskan bahwa performa rata-rata yang dihasilkan menggunakan pengujian *confusion matrix* yang terdiri dari 3 (tiga) metrik yaitu *precision*, *recall*, dan *F1-score* menunjukkan nilai yang memiliki besaran sama yaitu 93%, hal ini menandakan bahwa model CNN yang dibangun memiliki kinerja yang seimbang sehingga mampu mengklasifikasikan data *false positive* & *false negative* dengan benar. Melalui hasil ini, model CNN memiliki tingkat akurasi yang baik dalam mengidentifikasi penyakit jagung berdasarkan citra daun.



Gambar 8 Grafik Akurasi dan Loss Pada Hasil Training dan Validasi.

Pada gambar 8, terlihat perubahan dalam akurasi dan tingkat *loss rate* pada model CNN yang dibuat untuk mengklasifikasikan ekstraksi fitur tekstur GLCM. Dengan memanfaatkan fitur-fitur seperti *dissimilarity*, *correlation*, *homogeneity*, *contrast*, *ASM*, dan *energy* mampu menghasilkan akurasi yang tinggi dengan tingkat *loss rate* yang rendah. Namun, pada grafik akurasi menunjukkan bahwa selama proses *training* model CNN mengalami perubahan kinerja pada setiap *epoch*. Penelitian di masa mendatang diharapkan dapat meningkatkan kinerja model secara keseluruhan.

#### 4. KESIMPULAN DAN SARAN

Penerapan model *Convolutional Neural Network* (CNN) yang mampu mendeteksi jenis penyakit berdasarkan citra daun pada tanaman jagung merupakan tahap awal yang bersifat segera & menjadi penting dilakukan setelah adanya gejala yang tampak pada daun. Melalui penelitian ini dapat disimpulkan bahwa model yang dibangun terbukti dapat mengidentifikasi jenis penyakit



tanaman jagung apakah *Blight*, *Common Rust*, *Grey Leaf Spot*, atau *Healthy*. Penyakit tanaman jagung yang terdeteksi secara dini menghasilkan langkah penanganan yang tepat untuk ditindaklanjuti sehingga tidak mengakibatkan terganggunya stabilitas produksi.

Adapun hasil penelitian yang diperoleh menunjukkan penggunaan model CNN memiliki performa yang bagus dengan nilai akurasi yang baik sebesar 94% serta memperoleh tingkat loss rate yang relatif kecil yaitu 0.1742 yang berarti identifikasi penyakit pada citra daun jagung telah dilakukan secara akurat dan tepat. Pada penelitian ini terdapat alur penelitian dalam menjalankan tujuannya yang terdiri dari *data collection*, *image pre-processing*, *data training*, dan *classification*. Pada tahapan *image pre-processing* dilakukan proses transformasi warna citra dari RGB, HSV dan *Grayscale*, proses segmentasi dengan ROI serta dilengkapi dengan penerapan ekstraksi fitur tekstur dengan menggunakan GLCM.

Kendati demikian penelitian saat ini masih dapat ditingkatkan dalam mengidentifikasi penyakit pada daun tanaman jagung dengan menambahkan beberapa proses *image pre-processing* lainnya sehingga hasil *noise* yang dihasilkan semakin kecil dan perlunya melakukan perbandingan dengan algoritma *Neural Network* lainnya. Sehingga bisa didapatkan hasil perbandingan tingkat kesensitifan dan kecepatan dalam melakukan identifikasi citra penyakit pada daun tanaman.

#### DAFTAR PUSTAKA

- [1] D. Iswantoro and D. Handayani UN, "Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode Convolutional Neural Network (CNN)," *Jurnal Ilmiah Universitas Batanghari Jambi*, vol. 22, no. 2, p. 900, Jul. 2022, doi: 10.33087/jiubj.v22i2.2065.
- [2] M. A. Ulhaq and R. Masnilah, "Pengaruh Penggunaan Beberapa Varietas dan Aplikasi *Pseudomonas fluorescens* untuk Mengendalikan Penyakit Bulai (*Peronosclerospora maydis*) pada Tanaman Jagung (*Zea mays L.*)," *Jurnal Pengendalian Hayati*, vol. 2, no. 1, p. 1, Mar. 2019, doi: 10.19184/jph.v2i1.17131.
- [3] I. Syahriani *et al.*, "Identifikasi Penyakit pada Batang Tanaman Jagung (*Zea Mays*) di Kecamatan Panyabungan Kabupaten Mandailing Natal, Sumatera Utara," in *Prosiding SEMNAS BIO*, 2021.
- [4] M. Wafa Akhyari, A. Suyoto, and F. Wahyu Wibowo, "Klasifikasi Penyakit Pada Daun Jagung Menggunakan Convolutional Neural Network," 2021.
- [5] R. Suhendra, I. Juliwardi, and Sususi, "Identifikasi dan Klasifikasi Penyakit Daun Jagung Menggunakan Support Vector Machine," vol. 1, no. 1, pp. 29–35, 2022, [Online]. Available: <http://jurnal.utu.ac.id/JTI>
- [6] M. I. Rosadi, M. Lutfi, and S. Artikel, "Identifikasi Jenis Penyakit Daun Jagung Menggunakan Deep Learning Pre-Trained Model," 2021, doi: 10.35891/explorit.
- [7] A. D. Nurcahyati, R. Makhfuddin Akbar, and S. Zahara, "Klasifikasi Citra Penyakit Pada Daun Jagung Menggunakan Deep Learning Dengan Metode Convolution Neural Network (CNN)," vol. 2, no. 2, pp. 43–51, 2022, [Online]. Available: <http://ejurnal.unim.ac.id/index.php/submit>
- [8] G. Geetharamani and A. P. J., "Identification of plant leaf diseases using a nine-layer deep convolutional neural network," *Computers & Electrical Engineering*, vol. 76, pp. 323–338, Jun. 2019, doi: 10.1016/J.COMPELECENG.2019.04.011.
- [9] D. Singh, N. Jain, P. Jain, P. Kayal, S. Kumawat, and N. Batra, "PlantDoc: A Dataset for Visual Plant Disease Detection," Nov. 2019, doi: 10.1145/3371158.3371196.
- [10] S. Sunardi, A. Yudhana, and S. Saifullah, "Identification of Egg Fertility Using Gray Level Co-Occurrence Matrix and Backpropagation," *Adv Sci Lett*, vol. 24, pp. 9151–9156, Dec. 2018, doi: 10.1166/asl.2018.12115.
- [11] R. Fadholi, Y. A. Sari, and F. Abdurrachman Bachtiar, "Pengenalan Citra Makanan Tradisional menggunakan Fitur Hue Saturation Value dan Fuzzy k-Nearest Neighbor," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 3, no. 7, pp. 6556–6566, 2019, [Online]. Available: <http://j-ptiik.ub.ac.id>

- [12] A. K. Saputro and D. N. Purnamasari, "Identifikasi Jenis Plastik Berdasarkan Reflektansi Cahaya Menggunakan Transformasi Ruang Warna HSV Identification Of Plastic Type Based on Light Reflection In HSV Colorspace Conversion," *Jurnal SimanteC*, vol. 11, no. 1, 2022.
- [13] M. M. Chandra and Yoannita, "Klasifikasi Jenis Bunga Menggunakan Metode SVM Berdasarkan Citra Dengan Fitur HSV," *Jurnal Indonesia Sosial Teknologi*, vol. 4, pp. 255–264, 2023.
- [14] M. A. Rohman, P. Mudjirahardjo, and M. A. Muslim, "Implementasi Metode Convolutional Neural Network Dan Ekstraksi GLCM Pada Klasifikasi Kanker Paru," *Jurnal Ilmiah Teknik Elektro*, vol. 23, no. 4, 2021.
- [15] Felix, S. Faisal, T. F. M. Butarbutar, and P. Sirait, "Implementasi CNN dan SVM untuk Identifikasi Penyakit Tomat via Daun," *OKTOBER 2019 IJCCS*, vol. 20, pp. 1–5, 2019.
- [16] A. H. Pratomo, W. Kaswidjanti, and S. Mu'arifah, "Implementasi Algoritma Region Of Interest (ROI) Untuk Meningkatkan Performa Algoritma Deteksi Dan Klasifikasi Kendaraan," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 7, no. 1, pp. 155–162, 2020, doi: 10.25126/jtiik.202071718.
- [17] M. Segal-Rozenhaimer, A. Li, K. Das, and V. Chirayath, "Cloud detection algorithm for multi-modal satellite imagery using convolutional neural-networks (CNN)," *Remote Sens Environ*, vol. 237, p. 111446, 2020, doi: <https://doi.org/10.1016/j.rse.2019.111446>.
- [18] L. Qian, L. Hu, L. Zhao, T. Wang, and R. Jiang, "Sequence-Dropout Block for Reducing Overfitting Problem in Image Classification," *IEEE Access*, vol. PP, p. 1, Mar. 2020, doi: 10.1109/ACCESS.2020.2983774.
- [19] D. Normawati and S. A. Prayogi, "Implementasi Naïve Bayes Classifier Dan Confusion Matrix Pada Analisis Sentimen Berbasis Teks Pada Twitter," 2021.
- [20] A. A. Devi Putri, S. Hasanah, M. S. Bahrul, and N. Suciati, "Analisis Penggunaan Pra-proses pada Metode Transfer Learning untuk Mendeteksi Penyakit Daun Singkong," *Techno.COM*, vol. 22, no. 2, pp. 336–347, 2023.