

## Image Processing Classification of Rice Leaf Color Images Using the Convolutional Neural Network Method

Muhammad Kholilurrahman<sup>1)</sup>, Wahyul Amien Syafei<sup>2)</sup>, Oky Dwi Nurhayati<sup>3)</sup>

<sup>1)</sup>Program Studi Magister Sistem Informasi, Program Pascasarjana, Universitas Diponegoro Semarang, Indonesia

<sup>2,3)</sup>Departemen Teknik Komputer, Fakultas Teknik Universitas Diponegoro, Semarang, Indonesia  
e-mail: ti15.0003@gmail.com

### ABSTRACT

The agricultural sector is essential to meet the world's food needs, for example, in rice farming in Indonesia, problems that occur in rice plants are usually not only caused by fertilization but also the result of various diseases. The aim of this study to classify nitrogen fertilizer requirements and plant diseases was made based on leaf color using the Convolutional Neural Network (CNN) method which can be used to increase the accuracy of observations because it is objective. This study uses the Kaggle dataset with a total of 1600 data divided by 4 criteria. The data set was then divided into 70 percent of the training section, 15 percent of the validation section, and 15 percent of the test section, then pre-processed the rice leaf image with color image features and GLCM. The preprocessing results are processed using the CNN method to provide results for detecting plant diseases and the need for appropriate nitrogen fertilization. The calculation of plant diseases using the CNN method offers the highest accuracy of 98.33%. The highest accuracy for the nitrogen requirement problem was 81.67%, but with a very low precision value of 4.55%. Calculating plant diseases using the CNN method can provide satisfactory results on rice leaf image datasets so that it can be used as a basis for improving seed quality.

**Keywords:** CNN; images of rice leaves; machine learning

## Klasifikasi Image Processing Pada Citra Warna Daun Padi Menggunakan Metode Convolutional Neural Network

### ABSTRAK

Sektor pertanian itu penting untuk memenuhi kebutuhan pangan Dunia, contohnya pertanian tanaman padi di Indonesia, masalah yang terjadi pada tanaman padi biasanya tidak hanya disebabkan oleh pemupukan tetapi juga akibat dari berbagai macam penyakit. Penelitian ini bertujuan untuk mengklasifikasi kebutuhan pupuk nitrogen dan penyakit tanaman berdasarkan warna daun menggunakan metode *Convolutional Neural Network* (CNN) yang dapat digunakan untuk meningkatkan akurasi pengamatan karena sifatnya objektif. Penelitian ini menggunakan dataset Kaggle dengan total 1600 data dibagi 4 kriteria. Kumpulan data kemudian dibagi menjadi 70 persen bagian pelatihan, 15 persen bagian validasi dan 15 persen bagian uji, kemudian dilakukan *preprocessing* citra daun padi dengan fitur citra berwarna dan GLCM. Hasil *preprocessing* tersebut diolah dengan metode CNN untuk memberikan hasil deteksi penyakit tanaman dan kebutuhan pemupukan nitrogen yang tepat. Penghitungan penyakit tanaman dengan metode CNN memberikan akurasi tertinggi sebesar 98,33%. Akurasi tertinggi untuk masalah kebutuhan nitrogen sebesar 81,67%, namun dengan nilai presisi yang sangat rendah yaitu sebesar 4,55%. Penghitungan penyakit

tanaman menggunakan metode CNN dapat memberikan hasil yang memuaskan pada dataset citra daun padisehingga dapat dijadikan dasar untuk meningkatkan kualitas bibit.

**Kata kunci:** CNN; gambar daun padi; machine learning

(Article History: Received 24-08-2023; Accepted 27-10-2023; Published 27-10-2023)

## PENDAHULUAN

Hasil fotosintesis pada daun padi dapat mengukur kualitas tanaman padi sehingga mempengaruhi hasil panen (Makino, 2021). Warna daun tanaman padi dapat dijadikan acuan untuk mengukur kandungan nitrogen pada tanaman padi (Budiono *et al.*, 2019). Pengelolaan pupuk nitrogen di sawah merupakan tugas yang sangat penting karena berbagai bentuk kehilangan nitrogen di sawah seperti denitrifikasi, infiltrasi dan luapan di lahan basah menyebabkan efisiensi penggunaan nitrogen menjadi rendah. Sebaliknya, penggunaan nitrogen yang berlebihan membuat padi lebih rentan terhadap hama dan penyakit (Maurya *et al.*, 2020). Bagan Warna Daun (BWD) digunakan sebagai alat untuk mengukur kebutuhan nitrogen tanaman padi. Sayangnya alat ukur BWD masih bersifat konvensional (Bhupenchandra *et al.*, 2021).

Kajian terkait CNN, BWD dan penyakit tanaman padi. Di antara penelitian lain oleh (Zhu *et al.*, 2022) yang bertujuan untuk menyelidiki arsitektur CNN tingkat lanjut dengan modul perhatian terintegrasi untuk meningkatkan fitur adaptif dalam model gambar hiperspektral pada skala objek. Tingkat akurasi pada penelitian ini sebesar 95,73%. Studi tindak lanjut (Pandey & Jain, 2022) dengan tujuan untuk mencapai akurasi klasifikasi penyakit daun yang lebih tinggi dan yang kedua adalah untuk mencapai tingkat kepercayaan tertinggi. Hasil penelitian ini menghasilkan tingkat akurasi 97,33%, dengan sensitivitas 96,57%, spesifisitas 99,94% dan tingkat positif palsu 0,063%. Sathyavani *et al.* (2022), menunjukkan bahwa model CNN *DenseNet-BC* menghasilkan tingkat akurasi sebesar 96% dibandingkan metode konvensional. Penelitian selanjutnya oleh (Krishnamoorthy *et al.*, 2021) menggunakan salah satu model dalam CNN, yaitu *InceptionResNetV2* untuk mengenali penyakit pada gambar daun padi. Hasilnya menunjukkan bahwa model CNN dapat mengklasifikasi dengan akurasi yang baik sebesar 95,67%.

Penelitian selanjutnya oleh Debnath & Saha, (2022) untuk mendeteksi dini penyakit bercak coklat pada padi sawah menggunakan CNN. Dataset yang digunakan berupa citra tanaman padi yang terkena penyakit bercak coklat yang diambil secara manual di lapangan dari berbagai sudut dan lokasi di India. Hasil deteksi penyakit bercak coklat pada padi sawah menggunakan CNN mencapai akurasi uji 97,7% yang menunjukkan kemampuan untuk mengurangi kerugian produksi nasional dan secara global.

Berdasarkan latar belakang tersebut, maka penelitian ini melakukan penghitungan dengan metode *Convolutional Neural Network* (CNN) untuk meningkatkan tingkat akurasi pengamatan karena sifatnya yang objektif. Alasan pemilihan metode tersebut karena banyak digunakan pada penelitian beberapa tahun terakhir. Metode CNN merupakan tipe jaringan *Deep Learning* yang paling banyak digunakan serta berfokus pada citra warna (Alzubaidi *et al.*, 2021). Pembahasan dibatasi pada jenis penyakit dan kandungan nitrogen yang dipengaruhi oleh warna daun (Wei *et al.*, 2022).

Kebaruan penelitian ini terletak pada menggabungkan dua masalah yaitu penyakit tanaman dan kebutuhan pupuk nitrogen agar mendapatkan kualitas tanaman yang lebih baik. Penelitian ini bertujuan untuk menghasilkan penghitungan klasifikasi kebutuhan pupuk nitrogen dan penyakit tanaman berdasarkan warna daun menggunakan metode *Convolutional Neural Network* (CNN) yang dapat digunakan untuk meningkatkan akurasi pengamatan karena sifatnya objektif.









## METODE PENELITIAN

### Bagan Warna Daun (BWD)

Pupuk nitrogen merupakan unsur terbesar yang menjadi unsur hara esensial bagi pertumbuhan dan perkembangan tanaman. Bagan Warna Daun (LCC) memungkinkan petani memperkirakan kebutuhan nitrogen sebenarnya dari tanaman mereka untuk menggunakan pupuk secara efisien dan meningkatkan hasil padi.

Cara pengaplikasian : ambil ujung daun padi, ikat ke BWD, lalu sesuaikan dengan bagan kebutuhan pupuk Administrasi Layanan Pertanian yang disajikan pada Tabel 1 (Bhupenchandra *et al.*, 2021).

**Tabel 1.** Kebutuhan Pupuk BWD

Skala Warna BWD	Kriteria Nilai Pembacaan Warna BWD	Rekomendasi Takaran Pupuk Urea (Kg/Ha)
	$\leq 1$	175-200
	2	175
	3	150
	4	125
	5	100
	6	75
	7	50
	$\geq 8$	0-50

Dari Tabel 1 diketahui jika pembacaan warna BWD sesuai angka atau kurang dari 1 maka kebutuhan pupuk urea adalah 175-200 kg. Angka BWD didasarkan pada seberapa hijau daunnya, semakin hijau angkanya semakin tinggi kebutuhan urea yang dianjurkan. Hingga mencapai 8 atau lebih, dibutuhkan 50 kg pupuk meski tanpa urea (Bhupenchandra *et al.*, 2021).

### Metode GLCM (*Gray Level Co-Occurrence Matrix*)

Tekstur adalah salah satu ciri dari suatu citra yang dapat dilihat atau dikenali oleh mata tetapi tidak mudah untuk diidentifikasi. Beberapa fungsi pencitraan dapat digunakan untuk memperoleh karakteristik citra. Karakteristik citra tersebut dapat digunakan antara lain

untuk menyusun database citra berbasis kelompok tertentu, membuat aplikasi pengenalan objek citra, atau membuat program aplikasi pencarian citra. Tiga fitur citra yang biasa digunakan sebagai fitur citra adalah: warna, bentuk, dan tekstur. Salah satu cara untuk mengekstrak fitur tekstur adalah dengan menggunakan matriks konkurensi skala abu-abu (GLCM). Matriks GLCM biasanya berbentuk persegi 8x8. Sebelum mengubah citra menjadi GLCM, terlebih dahulu dilakukan kuantisasi range untuk mendapatkan ukuran matriks 8x8. Matriks GLCM berisi data kejadian bersama skala abu-abu piksel untuk tetangga dalam arah 0°, 45°, 90°, dan 135°. Matriks GLCM dengan parameter orde pertama (d=1). GLCM menggunakan saluran warna menggunakan *Hue, Saturation, Value* (HSV). GLCM memiliki empat gambaran umum termasuk kontras, korelasi, energi dan homogenitas. Nilai energi digunakan untuk mengukur konsentrasi pasangan intensitas dalam matriks *co-occurrence*. Nilai energi meningkat jika pasangan piksel terpusat pada banyak koordinat, dan sebaliknya menurun jika lokasi tersebar. Nilai energi diberikan dalam persamaan (Pulung & Rudy, 2020) (1).

$$Energy = \sum_{i_1=1}^m \sum_{i_2=1}^n (p^2(i_1, i_2)) \quad (1)$$

Dengan  $i_1$  adalah indeks pada kolom,  $i_2$  adalah indeks pada baris,  $p$  adalah jumlah kemunculan,  $n$  adalah jumlah matriks dalam baris, dan  $m$  adalah jumlah matriks dalam kolom. Nilai kontras digunakan untuk mengukur derajat perbedaan intensitas pada citra. Nilai kontras meningkat jika variasi intensitas pada citra tinggi dan sebaliknya jika variasi intensitas rendah. Nilai kontras ditunjukkan pada persamaan (2).

$$Contrast = \sum_{i_1=1}^m \sum_{i_2=1}^n ((i_1 - i_2)^2 * p(i_1, i_2)) \quad (2)$$

Nilai keseragaman merupakan ukuran keseragaman variasi intensitas pada suatu citra. Nilai keseragaman meningkat jika variasi intensitas pada citra lemah dan sebaliknya jika variasi kuat. Nilai homogen disajikan dalam persamaan (3).

$$Homogeneity = \sum_{i_1=1}^m \sum_{i_2=1}^n \left( \frac{p(i_1, i_2)}{1 + |i_1 - i_2|} \right) \quad (3)$$

Korelasi mengukur sejauh mana intensitas piksel dalam gambar cenderung berkorelasi linier satu sama lain pada jarak dan arah tertentu. Korelasi memberikan informasi tentang tingkat keteraturan tekstur atau kekacauan pada citra. Perhitungan GLCM diawali dengan menyiapkan citra grayscale yang diubah menjadi matriks berukuran 8x8. Gambar di sini berisi objek dengan orientasi berbeda. Selain itu, proses kuantisasi skalar seragam 3-bit dilakukan untuk mengurangi variasi intensitas warna pada citra. Langkah selanjutnya adalah membangun matriks GLCM dengan tingkat keabuan 3-bit dan pitch piksel 1 (ordo 1) pada arah 0°, 45°, 90°, dan 135°. (Veronica et al., 2019; Pulung & Rudy, 2020).

$$Correlation = \sum_{i_1=1}^m \sum_{i_2=1}^n \frac{(i_1 - \mu_{i_1})(i_2 - \mu_{i_2}) * p(i_1, i_2)}{\sigma_{i_1} * \sigma_{i_2}} \quad (4)$$

$$\sigma_{i_1} = \sqrt{\sum_{i_1} \sum_{i_2} (i_1 - \mu_{i_1})^2 * p(i_1, i_2)} \quad (5)$$

$$\sigma_{i_2} = \sqrt{\sum_{i_1} \sum_{i_2} (i_2 - \mu_{i_2})^2 * p(i_1, i_2)} \quad (6)$$

$$\mu_{i_1} = \sum_{i_1} \sum_{i_2} i_1 * p(i_1, i_2) \quad (7)$$


$$\mu_{i_2} = \sum_{i_1} \sum_{i_2} i_2 * p(i_1, i_2) \quad (8)$$

Sebelum menghitung korelasi, terlebih dahulu dihitung  $\mu$  sebagai rata-rata atau mean dan  $\sigma$  sebagai nilai simpangan untuk mendapatkan nilai korelasi.

### Algoritma Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah metode pembelajaran mesin yang menggunakan pengenalan objek. Metode ini berlaku untuk arsitektur VGG19 yang memiliki fitur untuk meningkatkan *throughput*. (Priyanka and Kumara, 2021)

Langkah-langkah CNN:



**Gambar 1.** arsitektur VGG19

Dari Gambar 1 diketahui proses CNN *forward looking* dikenal dengan proses *convolution*, *activation with RELU*, *pooling*, dan *fully connected layer* (Priyanka and Kumara, 2021). Fase pembelajaran CNN meliputi fase inialisasi dan fase prediksi. Data masukan berupa citra biner dan keluaran berupa ramalan untuk mengklasifikasikan daun padi menurut penyakit dan kebutuhan pupuk.

#### 1. Inialisasi

Langkah inialisasi termasuk mendeklarasikan parameter dan bobot. Definisi parameter meliputi penentuan jumlah *epoch* maksimum, nilai *learning rate*, dan *error* minimum. Perintah bobot digunakan untuk menentukan nilai bobot awal untuk filter lapisan *convolutional*, *hidden*, dan *fully connected*. Semua bobot diisi dengan metode inialisasi He.

#### 2. Feedforward

Pada fase pencarian, pemrosesan CNN dilakukan dari data input asli melalui konvolusi, aktivasi, agregasi, dan lapisan yang terhubung sepenuhnya untuk menghasilkan vektor unik kategorikal akhir.

##### a. Convolution Layer

Pada langkah ini dilakukan konvolusi antara matriks citra *input* dan matriks *filter*. *Filter i* ini dilewatkan melalui gambar yang menghasilkan *output array* peta fitur. Peta atribut akan dihasilkan sebagai hasil dari persamaan (9).

$$n_{out} = \left( \frac{n_{in} - k + 2p}{s} \right) + 1 \tag{9}$$

Adapun rumus operasi konvolusi adalah pada Persamaan (10).

$$FM[i]_{j,k} = \left( \sum_m \sum_n N_{[j-m, k-n]} F_{[m,n]} \right) + bF \tag{10}$$

Setelah dilakukan proses konvolusi selesai, aktifkan pemicu menggunakan fungsi *Networked Rectifier Linear Unit* (ReLU). Setiap piksel pada feature map dimasukkan ke dalam fungsi ReLU, dimana piksel dengan nilai kurang dari 0 akan diganti dengan 0, dengan rumus  $f(x) = \max(0,x)$  (Fauzi et al., 2019; Wulandari & Yasin, 2020)

##### b. Pooling Layer

Pengelompokan layer digunakan untuk memperkecil ukuran *feature map*. Jenis pengelompokan yang digunakan adalah pengelompokan maksimal, di mana nilai terbesar dalam jendela tertentu dipilih. Prosesnya mirip dengan lapisan konvolusi, yaitu menyeret jendela ke permukaan gambar, tetapi di sini jendela digunakan sebagai referensi untuk memilih nilai maksimum di area tertentu. Proses ini akan menghasilkan *output* berupa *array* peta fitur berisi nilai maksimum yang dipilih (Fauzi et al., 2019).

### c. *Fully-Connected Layer*

*Fully-connected layer* terdiri dari *input layer*, *hidden layer*, dan *output layer*. Ditampilkan pada tahap berikut (Fauzi *et al.*, 2019):

#### i. *Input Layer*

Lapisan *input* adalah kombinasi dari semua *array* peta fitur yang diperoleh dari sintesis lapisan. Kemudian semua piksel dari matriks yang diperoleh pada bidang perakitan ditumbuhkan menjadi *vektor* dengan jumlah piksel. Kemudian semua nilai dari lapisan input digunakan untuk menghitung lapisan tersembunyi.

#### ii. *Hidden Layer*

Perhitungan di kelas ini mengalikan nilai lapisan *input* dengan bobot yang telah diinisialisasi sebelumnya, lalu menambahkan nilai selisihnya. Rumusnya ada di Persamaan (11).

$$z_{in_i} = \sum_{j=1}^n X_j * V_{j,i} + V_{0,i} \quad (11)$$

Setelah menyelesaikan perhitungan, masukkan fungsi aktivasi ReLU, yang akan memberikan nilai keluaran  $Z$  untuk semua hasil perhitungan. Hasil perhitungan ini digunakan dalam proses perhitungan pada *output layer*.

#### iii. *Output Layer*

Perhitungan di lapisan ini mengalikan nilai yang dihitung dari lapisan tersembunyi dengan bobot yang diinisialisasi sebelumnya, lalu menambahkan nilai selisihnya. Rumus perhitungan diberikan dalam persamaan (12).

$$y_{in_i} = \sum_{j=1}^m Z_j * W_{j,i} + W_{0,i} \quad (12)$$

Setelah perhitungan selesai, masukkan fungsi aktivasi softmax untuk semua hasil perhitungan untuk mendapatkan nilai keluaran  $Y$ . Rumus perhitungan untuk fungsi softmax diberikan pada Persamaan (13).

$$Y_i = \frac{e^{y-in_i}}{\sum_{i=1}^m e^M} \quad (13)$$

### Metode *Confusion Matrix*

Metode *Confusion Matrix* digunakan pada tahap pengujian. Menghitung keakuratan atau relevansi data baru yang dimasukkan ke dalam aplikasi menggunakan data yang telah dilatih sebelumnya. Metode perhitungan akurasi yang digunakan adalah metode *Confusion Matrix*. Ada empat rumus untuk menghitung akurasi: Akurasi, presisi, recall dan loss. Rumus untuk menghitung akurasi, presisi, recall, dan loss pada matriks konfusi menggunakan persamaan (14), persamaan (15), persamaan (16) dan persamaan (17).

$$Akurasi = \sum_{i=1}^L \frac{TP_i + TN_i}{TP_i + TN_i + FP_i + FN_i} \times 100\% \quad (14)$$

$$Presicion = \sum_{i=1}^L \frac{TP_i}{TP_i + FP_i} \times 100\% \quad (15)$$

$$Recall = \sum_{i=1}^L \frac{TP_i}{TP_i + FN_i} \times 100\% \quad (16)$$

$$Loss = \sum_{i=1}^L \frac{FP_i + FN_i}{TP_i + TN_i + FP_i + FN_i} \times 100\% \quad (17)$$

Proses penelitian diawali dengan pengumpulan kumpulan data sebagai bahan penelitian. Bahan penelitian yang digunakan dalam penelitian ini adalah citra daun padi dari dataset Kaggle *RiceDiseaseDataset.zip*. Dataset citra daun padi terdiri dari 1600 data yang terbagi menjadi 4 kriteria penyakit dengan masing-masing kriteria berjumlah 400 data.

Kemudian dari 1600 data dibagi 70% sebagai data latih, 15% sebagai data validasi dan 15% sebagai data uji. Hasilnya membagi data menjadi 280 data pada data pelatihan untuk setiap kriteria, 60 data pada data validasi untuk setiap kriteria, dan 60 data pada data uji untuk setiap kriteria. Data juga dibagi menjadi 70% dari 1600 data sebagai data training baru sebesar 1120 data, 15% bagian sebesar 240 data masing - masing sebagai data validation dan data testing berdasarkan BWD. Gambar daun padi diproses terlebih dahulu untuk mengubah gambar menjadi data yang berharga. *Preprocessing* dimulai dengan pembersihan data, yang melibatkan pembersihan data dengan menghapus gambar latar belakang dari dataset. Karena jika proses pembersihan data tidak dilakukan, maka kebisingan sekitar akan diperhitungkan dan hasil yang didapat akan banyak berubah sehingga menimbulkan hasil yang tidak diinginkan. Setelah pembersihan data selesai, maka dijalankan proses GLCM (*Gray Level Co-Occurrence Matrix*) yaitu suatu cara untuk mengekstrak fitur tekstur dari citra yang dapat digunakan sebagai salah satu parameter angka dalam metode penelitian komputasi (Veronica et al., 2019). Parameter yang diperoleh dari proses GLCM adalah kontras, homogenitas, energi dan entropi. Kemudian dilakukan pula ekstraksi warna yaitu dari warna merah, hijau, biru dan HSV. Setelah *preprocessing* selesai dilakukan training terhadap data training sebelumnya sebesar 70% dengan menggunakan metode CNN. Setelah pelatihan selesai, perhitungan dilanjutkan pada data validation untuk mengetahui kinerja model yang dibuat. Selanjutnya dilakukan prosedur komputasi menggunakan metode CNN pada data testing untuk menentukan tingkat kualitas tanaman padi dari kandungan nitrogen berdasarkan BWD dan penyakit tanaman, yang selanjutnya akan digunakan untuk menentukan kualitas tanaman padi yang tepat. Hasil perhitungan dari data testing digunakan sebagai acuan dalam pengujian data dengan metode *Convusion Matrix*.

Penelitian ini menggunakan perangkat keras, perangkat lunak dan bahan untuk memenuhi kebutuhan sistem digunakan sebagai berikut:

1. Perangkat keras komputer desktop Asus TUF core i7 1211, Memory RAM 32GB
2. VsCode
3. Python
4. Windows 11 Home
5. Dataset gambar daun padi *RiceDiseaseDataset.zip*. (1600 data dengan 400 data tiap kriteria dan terdapat 4 kriteria)

## **HASIL DAN PEMBAHASAN**

Proses sebelum dilakukannya penghitungan metode CNN dilakukan proses *preprocessing* untuk mendapatkan berbagai kriteria dari parameter citra. Tabel 2. Menampilkan hasil penghitungan *preprocessing* pada citra warna RGB dan GLCM. Proses *preprocessing* dilakukan sebelum dilakukannya training pada metode CNN. Proses menghasilkan beragam jenis citra warna yaitu *red*, *green*, *blue* dan GLCM yaitu *Contrast*, *Correlation*, *Energy* dan *Homogeneity*.

Dari perhitungan pada metode CNN untuk mendeteksi penyakit padi dan mendeteksi kebutuhan nitrogen tanaman padi. Hasil menjalankan CNN terlihat pada Tabel 3. Tabel 3 menunjukkan proses pelatihan sebanyak 10 kali pengulangan untuk menghasilkan nilai akurasi yang diharapkan. Oleh karena itu, dapat disimpulkan bahwa semakin tinggi tingkat akurasi maka proses training data akan semakin lama dan ekstensif. Sebaliknya, jika tingkat akurasinya rendah, prosesnya dipercepat. Terbukti dalam 10 repetisi latihan membutuhkan

waktu 10 jam 14 menit 5,6 detik. Dengan 2 proses latihan non inkremental yaitu latihan ke 4 dan latihan ke 7. Namun mengalami peningkatan dalam 10 latihan terakhir dengan akurasi maksimal 86,719%.

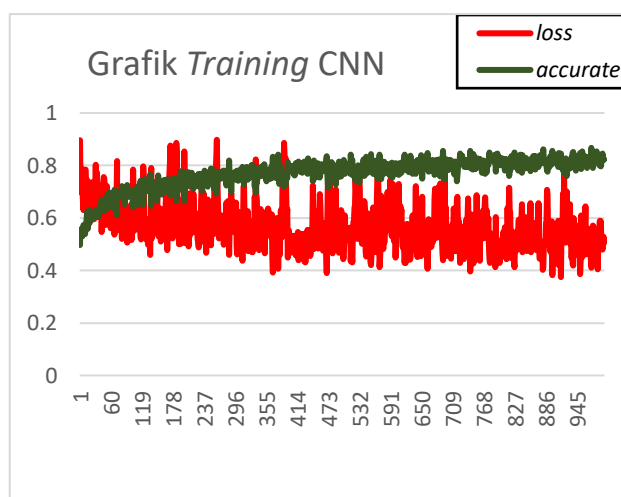
**Tabel 2.** Hasil *Preprocessing*

<i>No.</i>	<i>Nama File</i>	<i>Blue</i>	<i>Red</i>	<i>Green</i>	<i>Contrast</i>	<i>Correlation</i>	<i>Energy</i>	<i>Homogeneity</i>
<b>1</b>	IMG_3046.jpg	78,8 8199 0477 5112 1	93,3 5232 5601 9673 4	146,1 01612 82011 646	7,442505 9721648 88	0,350 53453 15739 3016	0,921508 3776804 862	0,954124 7308320 443
	IMG_20190_420_1_94918.jpg	63,7 1667 0348 0483 4	107, 3438 9546 8583 58	146,8 45770 68471 563	3,704371 0471290 368	0,351 67157 48580 339	0,907410 8349775 175	0,937924 6947868 712
	IMG_20190_420_1_94917.jpg	62,9 8980 3766 8868 94	114, 8897 9006 2043 25	146,1 20786 99858 432	3,727386 3883383 03	0,398 75585 98094 311	0,888142 1764785 774	0,925656 0292821 597
...	...	...	...	...	...	...	...	...
<b>1598</b>	IMG_20190_419_1_70936.jpg	55,7 193	43,8 898	64,27 67	5,80121	0,557 35	0,88551	0,91414
<b>1599</b>	IMG_20190_419_1_70734.jpg	53,7 724	39,5 468	64,35 62	7,87531	0,881	0,77545	0,84902
<b>1600</b>	IMG_20190_419_1_72200.jpg	65,3 949	41,8 645	63,42 53	10,4089	0,907 82	0,80698	0,85782



**Tabel 3.** Hasil *running Training CNN*

Training ke-	Waktu		Rentang Akurasi
	menit	detik	akhir
1	60	46,7	0,725
2	52	13,7	0,77812
3	55	57,5	0,81875
4	89	13	0,84062
5	62	53,2	0,84062
6	53	0,5	0,84375
7	50	36,3	0,85625
8	49	43,3	0,85625
9	55	10,9	0,86094
10	84	30,5	0,86719
Total waktu	10 jam 14 menit	5,6 detik	



**Gambar 2.** Grafik peningkatan akurasi berdasarkan akurasi yang tersimpan di model secara aktual.

Gambar 2 menunjukkan grafik peningkatan akurasi pelatihan total selama 1000 kali proses pelatihan. Terlihat bahwa nilai loss yang dominan menurun dan nilai eksaknya berfluktuasi namun selalu meningkat. Hasil perhitungan CNN adalah Tabel 4 untuk masalah kebutuhan pupuk nitrogen dan Tabel 5 untuk masalah penyakit padi menurut metode CNN. Hasil pengujian ditunjukkan pada Tabel 5. Validasi Model dilakukan setelah proses training selesai dan setiap masalah mendapat tingkat akurasi yang sama sekitar 75%.

Tabel 4 menunjukkan data berdasarkan kebutuhan pupuk yang dibandingkan antara aturan BWD dengan hasil perhitungan CNN. Data merupakan data eksperimen dengan total 240 data yang terbagi dalam 8 kriteria. Data tiap kriteria dengan nomor yang seragam karena diambil dari data penyakit pohon diganti dengan aturan BWD Sebagian besar data terdapat pada kriteria 5 BWD dengan total 45 data.

**Tabel 4.** Hasil penghitungan metode CNN pada data Testing berdasarkan kebutuhan pupuk nitrogen

		<b>Kriteria Prediksi (Rule)</b>							
		<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>	<b>7</b>	<b>8</b>
<b>Aktual</b>	<b>0</b>	1	1	8	7	10	5	10	3
	<b>1</b>	2	1	4	4	2	8	1	2
	<b>2</b>	3	2	1	3	6	4	4	3
	<b>3</b>	1	4	1	1	13	5	8	0
	<b>4</b>	1	2	5	5	1	3	3	2
	<b>5</b>	1	7	5	4	6	1	2	0
	<b>6</b>	2	2	7	6	4	6	1	3
	<b>7</b>	1	3	5	6	3	7	7	1
<b>Total</b>		12	22	36	36	45	39	36	14

**Tabel 5.** Hasil penghitungan metode CNN pada data Testing berdasarkan penyakit tanaman padi

		<b>Kriteria Prediksi (Rule)</b>			
		<b>BrownSpot</b>	<b>Healthy</b>	<b>Hispa</b>	<b>LeafBlast</b>
<b>Aktual</b>	BrownSpot	59	1	0	2
	Healthy	1	52	3	1
	Hispa	0	4	53	4
	LeafBlast	0	3	4	53
<b>Total</b>		60	60	60	60

Tabel 5 memperlihatkan data berbasis penyakit daun pada tanaman padi yang dibandingkan antara label yang teridentifikasi dengan hasil perhitungan CNN. Total data uji data adalah 240 data yang terbagi dalam 4 kriteria, dengan 60 data per kriteria. data dengan nilai sebenarnya tertinggi berada pada kriteria BrownSpot dengan total 59 data.

**Tabel 6** Tabel Hasil Pengujian CNN

<b>Permasalahan</b>	<b>Kriteria</b>	<b>Akurasi %</b>	<b>Presisi %</b>	<b>Recall %</b>	<b>Loss %</b>
<i>Kebutuhan Pupuk</i>	<i>1</i>	77,08	8,33	2,22	22,92
	<i>2</i>	81,67	4,55	4,17	18,33
	<i>3</i>	60,42	2,78	3,85	25
	<i>4</i>	72,08	2,78	3,03	27,92
	<i>5</i>	72,92	2,22	4,55	27,08
	<i>6</i>	73,75	2,56	3,85	26,25
	<i>7</i>	72,91	2,78	3,23	27,08
	<i>8</i>	81,25	7,14	3,03	18,75
<i>Penyakit tanaman</i>	<i>BrownSpot</i>	98,33	98,33	95,16	1,67
	<i>Healthy</i>	94,58	86,67	91,16	5,41
	<i>Hispa</i>	93,75	88,33	86,89	6,25
	<i>Leafblast</i>	94,17	88,33	88,33	5,83

Tabel 6 menunjukkan cara menghitung matriks confusion tentang kebutuhan pupuk nitrogen dan penyakit tanaman menurut metode CNN. Akurasi perhitungan metode CNN yang paling tinggi terdapat pada permasalahan penyakit daun pada padi dengan penyakit bercak coklat dengan akurasi sebesar 98,33%. Akurasi tertinggi untuk masalah kebutuhan nitrogen dengan akurasi sebesar 81,67%, namun dengan nilai presisi yang sangat rendah yaitu sebesar 4,55%. Masalah kebutuhan pupuk nitrogen juga memiliki nilai presisi yang sangat rendah. Nilai presisi kebutuhan nitrogen yaitu antara 2,22% dan 8,33%.

### KESIMPULAN

Akurasi perhitungan metode CNN yang paling tinggi terdapat pada permasalahan penyakit daun padi dengan penyakit bercak coklat dengan akurasi sebesar 98,33%. Akurasi tertinggi untuk masalah kebutuhan nitrogen dengan akurasi sebesar 81,67%, namun dengan nilai presisi yang sangat rendah yaitu sebesar 4,55%. Penghitungan penyakit tanaman menggunakan metode CNN dapat memberikan hasil yang memuaskan pada dataset citra daun padi.

### DAFTAR PUSTAKA

- Alzubaidi, L., Zhang, J., Humaidi, A.J., Dujaili, A. Al, Duan, Y., Shamma, O. Al, Santamaria, J., Fadhel, M.A., Amidie, M. Al dan Farhan, L. (2021). *Review of deep learning : concepts , CNN architectures , challenges , applications , future directions*, Springer International Publishing.
- Bhupenchandra, I., Athokpam, H.S., Singh, N.B., Singh, L.N., Devi, S.H., & OLivia, L.C. (2021). Leaf color chart (LCC): An instant tool for assessing nitrogen content in plant: A review Article. *The Pharma Innovation Journal*, 10(4),1100-1104.
- Budiono, R., Adinurani, P.G., & Soni, P. (2019). Effect of new NPK fertilizer on lowland rice (*Oryza sativa* L.) growth, *IOP Conference Series: Earth and Environmental Science*, 293, (1).
- Debnath, O., & Saha, H.N. (2022). An IoT-based intelligent farming using CNN for early disease detection in rice paddy. *Microprocessors and Microsystems*, 94, (August), 104631.
- Fauzi, S., Eosina, P., & Laxmi, G. F. (2019). Implementasi *Convolutional Neural Network* Untuk Identifikasi Ikan Air Tawar. *Seminar Nasional Teknologi Informasi*, 2, 163-167.
- Krishnamoorthy, N., Narasimha, Prasad, L.V., Pavan, K.C.S., Subedi, B., Abraha, H.B., & Sathishkumar, V.E. (2021). Rice leaf diseases prediction using deep neural networks with transfer learning. *Environmental Research*, 198, 111275.
- Makino, A., 2021, Photosynthesis improvement for enhancing productivity in rice, *Soil Science and Plant Nutrition*, 67(5), 513–519.
- Maurya, R., Singh, T.D., Jones, H., Kurkalang, S.M., & Momin, G. (2020). Effect of nitrogen fertilization on rice: A review, 9 (3), 2127–2130.
- Pandey, A., & Jain, K. (2022). A robust deep attention dense convolutional neural network for plant leaf disease identification and classification from smart phone captured real world images. *Ecological Informatics* 70 (June), 101725.
- Priyanka, A.A.J.V., & Kumara, I.M.S. (2021). Classification Of Rice Plant Diseases Using the Convolutional Neural Network Method. *Lontar Komputer: Jurnal Ilmiah Teknologi Informasi*, 12(2), 123-130.

- Pulung, Indah & Rudy. (2020). Implementasi Deep Learning Menggunakan Convolutional Neural Network (CNN) Pada Ekspresi Manusia. *Jurnal Algor*, 2(1), 12-21.
- Sathyavani, R., JaganMohan, K., & Bhuvaneshwaran, K. (2022). Classification of nutrient deficiencies in rice crop using denseNet-BC. *Materials Today: Proceedings*, 56(4), 1783–1789.
- Veronica, L., Al Amin, I.H., Hartono, B. & Kristianto, T. (2019). Ekstraksi Fitur Tekstur Menggunakan Matriks GLCM pada Citra dengan Variasi Arah Obyek. *Prosiding SENDI\_U978–979*.
- Wei, T., Wang, X., Li, X. dan Zhu, S., 2022, Engineering Applications of Artificial Intelligence Fuzzy subspace clustering noisy image segmentation algorithm with adaptive local variance & non-local information and mean membership linking. *Engineering Applications of Artificial Intelligence*, 110 (January), 104672.
- Wulandari & Yasin. (2020). Klasifikasi Citra Digital Bumbu dan Rempah dengan Algoritma *Convolutional Neural Network* (CNN). *Jurnal Gaussian*, 9(3), 273-282.
- Zhu, F., Cai, J., He, M., & Li, X. (2022). Channel and band attention embedded 3D CNN for model development of hyperspectral image in object-scale analysis. *Chemometrics and Intelligent Laboratory Systems*, 224 (June 2021), 104537.