

KLASIFIKASI PENYAKIT TANAMAN PADI MENGGUNAKAN METODE CNN ARSITEKTUR DENSENET-121 DAN AUGMENTASI DATA

Auliyah Agustina¹, Febi Yanto^{2*}, Elvia Budianita³, Iwan Iskandar⁴, Fadhilah Syafria⁵

¹⁻⁵ Fakultas Sains dan Teknologi, Universitas Islam Negeri Sultan Syarif Kasim, Panam, Jl. HR. Soebrantas No.Km. 15, RW.15, Simpang Baru, Kota Pekanbaru, Riau, Indonesia
e-mail : 12050120402@students.uin-suska.ac.id¹, febiyanto@uin-suska.ac.id^{2*}, elvia.budianita@uin-suska.ac.id³, iwan.iskandar@uin-suska.ac.id⁴, fadhilah.syafria@uin-suska.ac.id⁵

Abstrack

Rice (*Oryza sativa*) is a type of food crop where rice, as a result of the rice plant, is the main food ingredient for the majority of the Indonesian population. In the rice cultivation process, disease challenges often become a significant threat. The spread of the disease causes an economic downturn, such as in 2023 a decline of 0.22%. Apart from that, the lack of knowledge and insight of farmers in identifying and diagnosing types of rice diseases is the cause of the lack of rice production. Therefore, it is necessary to have a classification of rice diseases using DenseNet-121 and data augmentation. This research uses a deep learning approach, namely Convolutional Neural Network (CNN) with DenseNet-121 architecture and crop data augmentation. DenseNet is currently widely used for classification, DenseNet utilizes dense connections between layers, reduces the number of parameters, strengthens propagation, and promotes feature reuse. Using a dataset originating from the Kaggle site which consists of 3 types of rice plant diseases, namely brown spot, blast, and blight with each class consisting of 250 images so that all data amounts to 750 images. The best results from several tests obtained the best accuracy of 99.17% and loss of 0.0355 using the DenseNet-121 model, data division of 90;10 using a learning rate of 0.001 and dropout of 0.01 and using data augmentation, while the accuracy results were without augmentation. The best accuracy results were obtained, namely 95.00% with a data division of 90;10, a learning rate of 0.01 and a dropout of 0.1.

Keywords – Deep Learning, DenseNet-121, and Augmentation.

Abstrak

Padi (*Oryza sativa*) merupakan salah satu jenis tanaman pangan dimana beras sebagai hasil tanaman padi, menjadi bahan pangan utama untuk sebagian besar penduduk Indonesia. Dalam proses budidaya padi, tantangan penyakit seringkali menjadi ancaman yang signifikan. Menyebarnya penyakit menyebabkan penurunan ekonomi, seperti pada tahun 2023 penurunan 0,22%. Selain itu minimnya pengetahuan dan wawasan petani dalam mengidentifikasi dan mendiagnosa jenis penyakit padi menjadi penyebab kurangnya hasil produksi padi. Oleh karena itu perlu adanya suatu klasifikasi penyakit padi menggunakan DenseNet-121 dan augmentasi data. Penelitian ini menggunakan pendekatan *deep learning* yakni Convolutional Neural Network (CNN) dengan arsitektur DenseNet-121 dan augmentasi data *crop*. DenseNet saat ini banyak digunakan untuk klasifikasi, DenseNet memanfaatkan koneksi padat antar lapisan, mengurangi jumlah parameter, memperkuat propagasi, dan mendorong pemanfaatan kembali fitur. Menggunakan dataset yang berasal dari situs Kaggle yang terdiri dari 3 jenis penyakit tanaman padi yaitu *brown spot*, *blast*, dan *blight* dengan setiap kelas terdiri dari 250 citra sehingga semua data berjumlah 750 citra. Hasil terbaik dari beberapa pengujian diperoleh akurasi terbaik sebesar 99,17% dan loss 0,0355 menggunakan model DenseNet-121, pembagian data 90;10 dengan menggunakan learning rate 0,001 dan dropout 0,01 serta menggunakan augmentasi data, sedangkan untuk hasil akurasi tanpa augmentasi diperoleh hasil akurasi terbaik yaitu 95,00% dengan pembagian data 90;10, learning rate 0,01 dan dropout 0,1.

Kata Kunci – Deep Learning, DenseNet-121, dan Augmentasi.

1. PENDAHULUAN

Pertanian sebagai bagian dari sektor industri, memiliki peran penting dalam memastikan pemenuhan kebutuhan makanan pokok masyarakat, termasuk tanaman pangan (Lamba et al., 2021). Padi (*Oryza sativa*) merupakan salah satu jenis tanaman pangan yang menduduki peringkat ketiga setelah jagung dan gandum dalam produksi biji-bijian. Beras, sebagai hasil dari tanaman padi, menjadi bahan pangan utama bagi sebagian besar penduduk Indonesia (Khoiruddin et al., 2022). Oleh karena itu penting bagi komunitas pertanian untuk menjamin ketahanan pangan bagi populasi yang begitu besar.

Dalam proses budidaya padi, tantangan penyakit seringkali menjadi ancaman yang signifikan. Menyebarnya penyakit menyebabkan dampak ekonomi yang besar untuk para petani setiap tahun (Shrivastava et al., 2019). Apabila terjadi keterlambatan dalam penanganan dan diagnosis gejala, maka dapat mengakibatkan penurunan produksi tanaman padi (Shrivastava & Pradhan, 2021). Minimnya pengetahuan dan wawasan petani dalam mengidentifikasi dan mendiagnosa jenis penyakit padi menjadi penyebab kurangnya hasil produksi padi (Khoiruddin et al., 2022).

Penelitian mengenai penyakit padi telah dilakukan sebelumnya dengan menggunakan pendekatan machine learning dan deep learning. Penelitian menggunakan metode Naïve Bayes dan berhasil menghasilkan model klasifikasi dengan akurasi sebesar 76.0% (Burhanuddin, 2024). Penelitian deteksi penyakit padi yang mendapat hasil terbaik dengan menggunakan metode KNN dengan nilai akurasi 87% (Purnamawati et al., 2020). Selanjutnya penelitian deteksi penyakit padi menggunakan metode CNN dengan arsitektur MobileNetV1 mendapatkan hasil akurasi sebesar 92% (Saputra et al., 2021).

Pada penelitian Ibrahim pada tahun 2018 telah membandingkan kinerja deep learning dan machine learning dalam tugas klasifikasi, dimana metode deep learning berhasil mengungguli metode machine learning. Deep learning telah menunjukkan hasil yang menjanjikan untuk tugas klasifikasi bahkan untuk kasus yang kompleks (Sabri et al., 2018). Deep learning menggunakan konsep pembelajaran representasi yang memungkinkan model menggunakan data masukan mentah dalam berbagai tugas, termasuk klasifikasi. Artinya, deep learning memiliki kemampuan untuk mengekstrak fitur secara otomatis didalam model itu sendiri (Wakili et al., 2022).

Dalam perkembangan deep learning yang semakin banyak diminati saat ini, Convolutional Neural Network (CNN) adalah metode yang umum digunakan untuk analisis dan klasifikasi gambar (Mikołajczyk & Grochowski, 2018). CNN mencapai hasil akurasi yang tinggi dalam tugas klasifikasi. Salah satu arsitektur dalam CNN yang saat ini banyak digunakan yaitu DenseNet. DenseNet memanfaatkan koneksi padat antar lapisan, mengurangi jumlah parameter, memperkuat propagasi, dan mendorong pemanfaatan kembali fitur (Wakili et al., 2022). Arsitektur CNN terbaru yang dimodifikasi yaitu DenseNet-121 digunakan pada penelitian untuk memprediksi COVID-19 memperoleh hasil 95% (Hasan et al., 2021). Hui et al., melakukan percobaan terhadap 11 model berbobot ringan, salah satunya adalah DenseNet-121. Penelitian tersebut mengatakan bahwa DenseNet-121 mengungguli model lainnya dan mencapai akurasi 89% (Hui et al., 2022). DenseNet digunakan dalam berbagai aplikasi deep learning, termasuk klasifikasi gambar, deteksi objek, dan segmentasi gambar.

Metode deep learning memerlukan data pelatihan dalam jumlah besar untuk mencapai akurasi yang tinggi dan menghindari overfitting. Untuk memecahkan masalah tersebut dilakukan augmentasi data (Suharjito et al., 2021). Augmentasi bertujuan untuk memperluas variasi data dan meningkatkan kemampuan generalisasi model deep learning (DLY et al., 2023). Tujuan dari augmentasi data juga memungkinkan mesin untuk belajar dan mengenali berbagai citra yang beragam, sekaligus meningkatkan jumlah data yang tersedia (Alfredo & Suharjito, 2022). Augmentasi data juga merupakan cara yang dapat digunakan untuk mengurangi overfitting pada model. Ada berbagai metode augmentasi data diantaranya transformasi geometri (transisi, flipping, cropping, rotasi dan lain-lain), penghapusan acak, Generative Adversal Network (GAN). Shorten & Khoshgoftaar, mengatakan bahwa augmentasi data cropping telah terbukti mampu mencapai akurasi yang jauh lebih tinggi dibandingkan transformasi geometri sederhana lainnya (Shorten & Khoshgoftaar, 2019).

<https://doi.org/10.35145/joisie.v8i1.4256>

JOISIE licensed under a Creative Commons Attribution-ShareAlike 4.0 International License (CC BY-SA 4.0)


Optimasi merupakan teknik dalam mengoptimalkan akurasi dalam melakukan klasifikasi untuk mencapai hasil yang ideal (Sgd et al., 2022). Fungsi optimasi adalah fungsi yang dipakai untuk memperbaiki proses belajar pada suatu system. Adam adalah gabungan antara RMSprop dan momentum. Adam merupakan hasil dari turunan metode SGD yang menggunakan estimasi adaptif dari momen orde pertama dan kedua (Miranda et al., 2020). Penelitian yang dilakukan oleh Irfan membandingkan optimasi Stochastic Gradient Descent (SGD), ADADELTA, dan Adam pada Jaringan Saraf Tiruan untuk klasifikasi data aritmia. Hasilnya menunjukkan bahwa Jaringan Saraf Tiruan yang dioptimalkan dengan Adam menghasilkan akurasi yang lebih tinggi dibandingkan dengan SGD dan ADADELTA. Metode optimizer Adam juga secara luas diterapkan dalam teknik Deep Learning untuk pengenalan gambar. Model yang dilatih menggunakan optimizer Adam mencapai akurasi sebesar 83,5% (Irfan et al., 2022). Penelitian lain membandingkan 3 optimizer dengan hasil training SGD sebesar 0.7577, ADAM sebesar 0.96547 dan RMSprop. Hasil tersebut berarti optimizer ADAM mendapatkan hasil akurasi terbaik (Wikarta et al., 2020).

Adapun beberapa penelitian terkait lainnya yang digunakan sebagai landasan teori yaitu penelitian klasifikasi penyakit tanaman padi menggunakan arsitektur EfficientNet B3 mencapai akurasi pelatihan sebesar 99% dengan loss pelatihan 0,012, sedangkan arsitektur MobileNet V3 mencapai akurasi 57% dengan loss 0,007. (Anggiratih et al., 2021). Penelitian Shrivastava (Shrivastava et al., 2019) mengenai klasifikasi penyakit padi menggunakan *deep learning* metode CNN mendapatkan hasil akurasi 91,37%. Penelitian menggunakan arsitektur DenseNet-121 dalam prediksi Covid-19 mendapatkan hasil akurasi 92% (Hasan et al., 2021).

Berdasarkan beberapa penelitian yang telah dilakukan diatas, penelitian ini akan menggunakan metode CNN dengan arsitektur DenseNet-121 untuk mengetahui hasil akurasi dari klasifikasi penyakit padi dengan menggunakan citra daun padi yang terdiri dari 3 kelas yaitu Blast, Brown spot, dan Bacterial Leaf Blight (BLB). Penelitian ini akan melakukan proses augmentasi data dan optimasi agar mendapatkan hasil akurasi yang terbaik

2. METODE PENELITIAN


Pada penelitian ini, metode klasifikasi yang digunakan adalah DenseNet-121. Pada penelitian ini dilakukan 2 bentuk klasifikasi yaitu menggunakan data augmentasi dan data tanpa augmentasi. Penelitian ini melakukan percobaan sebanyak 54 skema dengan membandingkan nilai learning rate dan dropout terhadap data augmentasi dan tanpa augmentasi. Dataset yang digunakan pada penelitian ini adalah citra penyakit daun padi yang diambil dari situs kaggle yang terdiri dari 3 kelas yaitu Blast, Brown spot, dan Bacterial Leaf Blight (BLB). Berikut tahapan penelitian yang dilakukan untuk klasifikasi penyakit padi.



Gambar 1 Tahapan Penelitian

A. Pengumpulan Data

Pada penelitian ini dataset yang digunakan merupakan citra daun padi yang diambil dari situs kaggle. Data ini terdiri dari 3 kelas yaitu Blast, Brown spot, dan Bacterial Leaf Blight (BLB). Setiap kelas memiliki jumlah data yang sama yaitu 250 gambar. Sehingga jumlah data keseluruhan yaitu 750 gambar. Selain itu, terdapat data tambahan dari proses augmentasi yang dilakukan dengan augmentasi crop. Gambar 2 berikut merupakan kelas dataset penyakit daun padi.



Gambar 2 Dataset Penyakit Padi


B. Preprocessing Data

Proses preprocessing berupa resize bertujuan untuk memperkecil ukuran citra dengan memperkecil ukuran citra menjadi 224x224 piksel sesuai dengan ukuran input gambar pada algoritma DenseNet-121. Dan proses rescale yang bertujuan untuk mengubah nilai piksel dari rentang antara 0 dan 255 menjadi rentang antara 0 dan 1.

C. Augmentasi

Augmentasi data bertujuan untuk memperbanyak jumlah dataset sehingga model yang dilatih akan lebih maksimal maka dari itu dilakukan augmentasi data dengan metode random crop. Augmentasi bertujuan untuk memperluas variasi data dan meningkatkan kemampuan generalisasi model deep learning (DLY et al., 2023). Data citra dari hasil augmentasi adalah 750 citra yang berisi 250 citra untuk setiap kelas yaitu Blast, Brown spot, dan Bacterial Leaf Blight (BLB). Tabel I merupakan dataset sebelum dan setelah dilakukan augmentasi.

Tabel I Augmentasi

Sebelum Agumentasi	Setelah Augmentasi
	
	

D. Pembagian Data

Dari dataset yang ada, data dibagi menjadi data latih, data uji, dan data validasi. Pembagian data *training* dan data *testing* dilakukan dengan skala (90:10), (80:20), dan (70:30) baik pada data

yang telah di-augmentasi maupun yang tidak di-augmentasi. Data validasi diambil sebanyak 20% dari seluruh data citra. Tabel II merupakan hasil pembagian data.

Tabel II Pembagian Data


Pembagian Data	Data Latih	Data Uji	Data Validasi
Data Asli			
90 ; 10	540	60	150
80 ; 20	480	120	150
70 ; 30	420	180	150
Data asli + Augmentasi			
90 ; 10	1080	120	300
80 ; 20	960	240	300
70 ; 30	840	360	300

E. Convolution Neural Network (CNN)

Deep Learning adalah bagian dari Pembelajaran Mesin yang memanfaatkan jaringan saraf tiruan untuk mengolah data dalam jumlah besar (Suharjito et al., 2021), (Kumar et al., 2024). Teknik Pembelajaran Mendalam menawarkan arsitektur yang kuat untuk Pembelajaran Terawasi (Azhar et al., 2021). Deep learning menggunakan konsep pembelajaran representasi yang memungkinkan model menggunakan data masukan mentah dalam berbagai tugas, termasuk klasifikasi. Artinya, deep learning memiliki kemampuan untuk mengekstrak fitur secara otomatis didalam model itu sendiri (Wakili et al., 2022). Metode Deep Learning yang saat ini menunjukkan hasil paling menonjol dalam pengenalan citra adalah Convolutional Neural Network (CNN). CNN adalah jenis jaringan saraf yang dirancang khusus untuk memproses data dengan struktur grid, seperti gambar. CNN dapat diterapkan pada berbagai bidang, seperti pengenalan wajah, analisis dokumen, klasifikasi gambar, klasifikasi video, dan sebagainya. Struktur arsitektur CNN menciptakan hierarki ekstraksi fitur, di mana filter dilatih untuk mencapai tujuan spesifik. Arsitektur CNN dibagi menjadi 2 bagian besar, yaitu *Feature Extraction Layer* dan *Fully Connected Layer*.

F. Arsitektur DenseNet-121

Densenet merupakan salah satu arsitektur dari CNN yang saat ini sering digunakan. Dense Convolutional Network (DenseNet) merupakan arsitektur jaringan saraf tiruan (neural network) yang dirancang untuk memaksimalkan penggunaan fitur dan meningkatkan aliran informasi melalui lapisan-lapisan dalam jaringan (Wakili et al., 2022). Dense Convolutional Network (DenseNet) menghubungkan setiap lapisan atau blok dengan setiap lapisan atau blok lainnya menggunakan mekanisme umpan maju (Liao et al., 2023).



Gambar 3 Arsitektur DenseNet

Setiap lapisan memanfaatkan batch normalization, aktivasi ReLU, dan konvolusi dengan filter 3x3. Batch normalization diimplementasikan untuk mempercepat proses pelatihan dan meningkatkan

learning rate ketika model dibangun. Input setiap blok adalah matriks yang menggambarkan piksel citra, kemudian diproses melalui batch normalization untuk mengurangi potensi overfitting selama pelatihan.

Layers	Output Size	DenseNet-121	DenseNet-169	DenseNet-201	DenseNet-264
Convolution	112 × 112	7 × 7 conv, stride 2			
Pooling	56 × 56	3 × 3 max pool, stride 2			
Dense Block (1)	56 × 56	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$
Transition Layer (1)	56 × 56	1 × 1 conv			
Dense Block (2)	28 × 28	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$
Transition Layer (2)	28 × 28	1 × 1 conv			
Dense Block (3)	14 × 14	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 24$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 64$
Transition Layer (3)	14 × 14	1 × 1 conv			
Dense Block (4)	7 × 7	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 16$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$
Classification Layer	1 × 1	7 × 7 global average pool			
		1000D fully-connected, softmax			

Gambar 4 DenseNet Menggunakan 4 Blok

Lapisan dalam dense block terdiri dari normalisasi batch, aktivasi ReLU, dan konvolusi menggunakan filter 3x3. Di antara dua blok yang berdekatan terdapat lapisan transisi yang bertugas mengubah ukuran fitur melalui konvolusi dan pooling. Tahap klasifikasi menggunakan global average pooling, diikuti oleh aktivasi softmax.

G. Hyperparameter

Hyperparameter merupakan tahap dengan mengkombinasikan parameter uji. Hyperparameter bertujuan untuk menghasilkan akurasi yang lebih optimal dan mengurangi overfitting. Adapun hyperparameter yang akan digunakan adalah Optimizer dengan menggunakan Adam (Adaptive Momen Estimation). Learning rate yang digunakan 0,1 0,01 0,001, epoch 20, aktifasi menggunakan softmax dan dropout layer dengan rate 0,1 0,01 dan 0,001.

H. Confusion Matrix

Confusion matrix, yang juga dikenal sebagai matriks kebingungan, merupakan tabel yang digunakan untuk mengevaluasi kinerja model klasifikasi dengan mengukur seberapa baik model tersebut melakukan klasifikasi pada data uji. Confusion matrix dapat menghasilkan fitur matrix yang terdiri dari nilai *accuracy*, *precision*, *recall*, dan *F1-Score*.

a. Accuracy

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (1)$$

b. Precision

$$Precision = \frac{TP}{(TP + FP)} \quad (2)$$

c. Recall

$$Recall = \frac{TP}{(TP + FN)} \quad (3)$$

d. F1-Score

$$F1 \text{ score} = \frac{precision \times recall}{precision + recall} \quad (4)$$

3. HASIL DAN PEMBAHASAN

Bahasa pemrograman yang digunakan pada penelitian ini adalah *python*. Proses pengujian pada penelitian ini menggunakan *Google Colab* dalam menjalankan modelnya. Berikut *library* algoritma DenseNet-121 yang digunakan.

```
from keras.applications.densenet import DenseNet121
base_model=tf.keras.applications.DenseNet121(include_top=False,
weights="imagenet",input_tensor=Input(shape=(224,224,3)))
```

Gambar 5 *Lybrary* DenseNet-121

Adapun hasil keseluruhan dari pengujian yang dilakukan sebanyak 54 pengujian pada tabel III.

Tabel III Hasil Pengujian

Pembagian Data	Learning Rate	DropOut	Augmentasi	NO augmentasi
90;10	0,001	0,001	95,88%	93,33%
90;10	0,001	0,01	99,17%	90,00%
90;10	0,001	0,1	96,67%	91,67%
90;10	0,01	0,001	98,33%	88,33%
90;10	0,01	0,01	91,67%	86,67%
90;10	0,01	0,1	97,50%	95,00%
90;10	0,1	0,001	37,50%	35,00%
90;10	0,1	0,01	37,50%	35,00%
90;10	0,1	0,1	55,83%	26,67%
80;20	0,001	0,001	98,75%	90,00%
80;20	0,001	0,01	98,33%	91,67%
80;20	0,001	0,1	97,92%	90,83%
80;20	0,01	0,001	95,83%	92,50%
80;20	0,01	0,01	97,50%	89,17%
80;20	0,01	0,1	92,50%	91,67%
80;20	0,1	0,001	34,17%	30,00%
80;20	0,1	0,01	33,33%	30,00%
80;20	0,1	0,1	33,75%	32,50%
70;30	0,001	0,001	98,33%	94,44%
70;30	0,001	0,01	96,11%	90,00%
70;30	0,001	0,1	96,94%	92,78%
70;30	0,01	0,001	96,11%	91,67%
70;30	0,01	0,01	95,56%	88,89%
70;30	0,01	0,1	97,50%	89,44%
70;30	0,1	0,001	32,78%	30,56%
70;30	0,1	0,01	34,44%	33,89%
70;30	0,1	0,1	31,94%	30,00%


Dari hasil pengujian pada tabel diatas didapatkan dari proses klasifikasi menggunakan metode CNN arsitektur DenseNer-121, setiap pengujian dilakukan dengan pembagian data 90;10, 80;20, dan 70;30. Kemudian ditambahkan hyperparameter yaitu *learning rate* dan *dropout* dengan nilai 0.1, 0.01, dan 0.001 yang di uji secara bergatian. Sehingga hasil yang diperoleh setelah menambahkan learning rate dan dropout mengalami perubahan yang berbeda beda tergantung nilai parameter pada learning rate dan dropout yang digunakan. Selain itu, pengujian juga dilakukan dengan menambahkan augmentasi data. Adapun hasil akurasi tertinggi yaitu 99,17% pada pembagian data 90;10 dengan menggunakan augmentasi, sedangkan tanpa augmentasi pada pembagian 90;10 dihasilkan akurasi tertinggi 95,00%. Pembagian data 80;20 dihasilkan akurasi tertinggi yaitu 98,75% dengan

<https://doi.org/10.35145/joisie.v8i1.4256>

JOISIE licensed under a Creative Commons Attribution-ShareAlike 4.0 International License (CC BY-SA 4.0)


menggunakan augmentasi dan yang tidak menggunakan augmentasi sebesar 92,50%. Kemudian untuk pembagian 70;30 dihasilkan akurasi terbaik dengan menggunakan augmentasi sebesar 98,33% dan tanpa augmentasi sebesar 94,44%. Berdasarkan hasil pengujian yang telah dilakukan terbukti bahwa augmentasi data dapat meningkatkan akurasi pada percobaan yang dilakukan dengan membandingkan data augmentasi dan data tanpa diaugmentasi.

Dari hasil pengujian 54 skenario dengan mengubah parameter learning rate dan dropout pada algoritma DenseNet-121 didapatkan hasil pembagian data 90;10 lebih baik dibandingkan pembagian data 80;20 dan 70;30 dilihat dari akurasi yang diperoleh dari pengujian. Akurasi terbaik dengan menggunakan augmentasi sebesar 99,17% dengan pembagian data 90;10, learning rate 0,001 dan dropout 0,01. Sedangkan hasil tanpa augmentasi diperoleh akurasi terbaik sebesar 95,00% pada pembagian data 90;10 dan parameter uji learning rate 0,01 dropout 0,1 ditunjukkan pada gambar 6, 7, dan 9.



Gambar 6 Grafik Model Accuracy Dan Los Pada Augmentasi Data


Pada gambar 6 terdapat hasil pengujian dari pembagian data 90;10 dengan learning rate 0,001 dan dropout 0,01 menghasilkan akurasi terbaik dari pengujian menggunakan augmentasi sebesar 99.17% dan nilai loss 0,0355. Epoch terbaik diperoleh pada epoch ke-8 dari 20 epoch.



Gambar 7 Confusion Matrix Pada Data Augmentasi


Pada gambar 7 terdapat hasil confusion matrix pengujian dari pembagian data 90;10 dengan learning rate 0,001 dan dropout 0,01 dengan augmentasi data diperoleh hasil pada kelas penyakit Brown spot yang diprediksi penyakit brown spot sebanyak 42 dan penyakit brown spot diprediksi sebagai penyakit blight 1, pada kelas penyakit blast diprediksi penyakit blast 38 dan diprediksi

sebagai jenis penyakit lain adalah 0, dan kelas penyakit blight yang diprediksi penyakit blight sebanyak 39 dan diprediksi sebagai penyakit lain 0. Dan jumlah kelas terbanyak adalah brown spot.



Gambar 8 Grafik Model Accuracy Pada Data Tanpa Augmentasi

Pada gambar 8 terdapat hasil pengujian dari pembagian data 90;10 dengan learning rate 0,01 dan dropout 0,1 merupakan akurasi terbaik dari pengujian data tanpa augmentasi dengan akurasi 95,00% dan nilai loss 0,1854. Epoch terbaik diperoleh pada epoch ke-5 dari 20 epoch



Gambar 9 Confusion Matrix Pada Data Tanpa Augmentasi

Pada gambar 9 terdapat hasil confusion matrix pengujian dari pembagian data 90;10 dengan learning rate 0,01 dan dropout 0,1 tanpa augmentasi data diperoleh pada hasil kelas penyakit Brown spot yang diprediksi penyakit brown spot sebanyak 22 dan penyakit brown spot diprediksi sebagai penyakit blast adalah 1, pada kelas penyakit blast diprediksi penyakit blast berjumlah 19 dan diprediksi sebagai jenis penyakit brown spot adalah 2, dan kelas penyakit blight yang diprediksi penyakit blight sebanyak 16 dan diprediksi sebagai penyakit lain 0. Dan jumlah kelas terbanyak adalah brown spot.

4. SIMPULAN

Dari penelitian mengenai klasifikasi penyakit tanaman padi menggunakan Metode CNN dengan arsitektur DenseNet-121 dan augmentasi data dapat disimpulkan bahwa:

1. Dari uji coba yang dilakukan dengan menggunakan metode CNN arsitektur DenseNet-121 untuk mengetahui hasil akurasi dari klasifikasi penyakit padi diperoleh hasil akurasi klasifikasi menggunakan augmentasi data lebih baik dibanding tanpa augmentasi data. Hasil akurasi terbaik diperoleh pada klasifikasi penyakit padi menggunakan augmentasi data sebesar 99.17%,

<https://doi.org/10.35145/joisie.v8i1.4256>

JOISIE licensed under a Creative Commons Attribution-ShareAlike 4.0 International License (CC BY-SA 4.0)

sedangkan hasil akurasi tertinggi klasifikasi penyakit tanaman padi tanpa augmentasi data diperoleh 95.00%.

2. Uji coba yang dilakukan pada penelitian ini juga dipengaruhi oleh learning rate, dan dropout. Learning rate yang di gunakan yaitu 0.1, 0.01, dan 0.001, kemudian menggunakan dropout 0.1, 0.01, dan 0.001.
3. Pada penelitian yang dilakukan ini diperoleh hasil bahwa semakin rendah learning rate yang digunakan maka hasil akurasinya akan lebih baik, dan pada penelitian ini diperoleh hasil akurasi tertinggi pada pembagian data 90;10 sebesar 99.17% dengan learning rate 0.001 dan drpoout 0.01, pada pembagian data 80;20 diperoleh hasil tertinggi 98.75% dengan learning rate 0.001 dan dropout 0.001, selanjutnya pada pembagian data 70;30 diperoleh hasil akurasi tertinggi 98.33% dengan learning rate 0.001 dan dropout 0.001.
4. Berdasarkan hasil penelitian yang telah dilakukan dan diperoleh hasil akurasi yang baik dengan menggunakan data yang terdiri dari 3 jenis penyakit yaitu *brown spot*, *blast*, dan *blight* sehingga metode CNN arsitektur DenseNet-121 dapat digunakan untuk klasifikasi penyakit tanaman padi. Diharapkan peneliti selanjutnya dapat melakukan klasifikasi dengan lebih banyak jenis penyakit padi lainnya.

5. DAFTAR PUSTAKA

- Alfredo, I., & Suharjito. (2022). Perbaikan Model Alexnet Untuk Mendeteksi Kematangan Tbs Kelapa Sawit Dengan Menggunakan Image Enhancement Dan Hyperparameter Tuning. *Jurnal Ilmiah Teknologi Dan Rekayasa*, 27(1), 56–68. <https://doi.org/10.35760/tr.2022.v27i1.5973>
- Anggiratih, E., Siswanti, S., Octaviani, S. K., & Sari, A. (2021). Klasifikasi Penyakit Tanaman Padi Menggunakan Model Deep Learning Efficientnet B3 dengan Transfer Learning. *Jurnal Ilmiah SINUS*, 19(1), 75. <https://doi.org/10.30646/sinus.v19i1.526>
- Azhar, K. M., Santoso, I., & Adi, A. (2021). Implementasi Deep Learning Menggunakan Metode Convolutional Neural Network Dan Algoritma Yolo Dalam Low Vision. *Transient: Jurnal Ilmiah Teknik Elektro*, 10(3), 502–509.
- Burhanuddin, R. R. (2024). Klasifikasi Penyakit Padi Melalui Citra Daun Menggunakan Metode Naive Bayes. *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(2). <https://doi.org/10.23960/jitet.v12i2.4012>
- DLY, I. A., Jasril, J., Sanjaya, S., Handayani, L., & Yanto, F. (2023). Klasifikasi Citra Daging Sapi dan Babi Menggunakan CNN Alexnet dan Augmentasi Data. *Journal of Information System Research (JOSH)*, 4(4), 1176–1185. <https://doi.org/10.47065/josh.v4i4.3702>
- Hasan, N., Bao, Y., Shawon, A., & Huang, Y. (2021). DenseNet Convolutional Neural Networks Application for Predicting COVID-19 Using CT Image. *SN Computer Science*, 2(5), 1–11. <https://doi.org/10.1007/s42979-021-00782-7>
- Hui, W., Robert Jia, Z., Li, H., & Wang, Z. (2022). Galaxy Morphology Classification with DenseNet. *Journal of Physics: Conference Series*, 2402(1), 1–12. <https://doi.org/10.1088/1742-6596/2402/1/012009>
- Irfan, D., Rosnelly, R., Wahyuni, M., Samudra, J. T., & Rangka, A. (2022). Perbandingan Optimasi Sgd, Adadelata, Dan Adam Dalam Klasifikasi Hydrangea Menggunakan Cnn. *Journal of Science and Social Research*, 5(2), 244. <https://doi.org/10.54314/jssr.v5i2.789>
- Khoiruddin, M., Junaidi, A., & Saputra, W. A. (2022). Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network. *Journal of Dinda : Data Science, Information Technology, and Data Analytics*, 2(1), 37–45. <https://doi.org/10.20895/dinda.v2i1.341>
- Kumar, M., Mehta, U., & Cirrincione, G. (2024). Enhancing neural network classification using fractional-order activation functions. *AI Open*, 5(July 2023), 10–22. <https://doi.org/10.1016/j.aiopen.2023.12.003>
- Lamba, M., Gigras, Y., & Dhull, A. (2021). Classification of plant diseases using machine and deep learning. *Open Computer Science*, 11(1), 491–508. <https://doi.org/10.1515/comp-2020-0122>
- Liao, T., Li, L., Ouyang, R., Lin, X., Lai, X., Cheng, G., & Ma, J. (2023). Classification of asymmetry in mammography via the DenseNet convolutional neural network. *European Journal of Radiology Open*, 11(July), 100502. <https://doi.org/10.1016/j.ejro.2023.100502>
- Mikołajczyk, A., & Grochowski, M. (2018). Data augmentation for improving deep learning in image <https://doi.org/10.35145/joisie.v8i1.4256>

- classification problem. *2018 International Interdisciplinary PhD Workshop, IIPHDW 2018, August*, 117–122. <https://doi.org/10.1109/IIPHDW.2018.8388338>
- Miranda, N. D., Novamizanti, L., Rizal, S., Elektro, F. T., & Telkom, U. (2020). Convolutional Neural Network Pada Klasifikasi Sidik Jari Menggunakan Resnet-50 Classification of Fingerprint Pattern Using Convolutional Neural Network in Clahe Image. *Jurnal Teknik Informatika (JUTIF)*, 1(2), 61–68. <http://jutif.if.unsoed.ac.id/index.php/jurnal/article/view/18>
- Purnamawati, A., Nugroho, W., Putri, D., & Hidayat, W. F. (2020). Deteksi Penyakit Daun pada Tanaman Padi Menggunakan Algoritma Decision Tree, Random Forest, Naïve Bayes, SVM dan KNN. *InfoTekJar: Jurnal Nasional Informatika Dan Teknologi Jaringan*, 5(1), 212–215. <https://doi.org/10.30743/infotekjar.v5i1.2934>
- Sabri, N., Ibrahim, Z., & Isa, D. (2018). Evaluation of color models for palm oil fresh fruit bunch ripeness classification. *Indonesian Journal of Electrical Engineering and Computer Science*, 11(2), 549–557. <https://doi.org/10.11591/ijeecs.v11.i2.pp549-557>
- Saputra, R. A., Wasiyanti, S., Supriyatna, A., & Saefudin, D. F. (2021). Penerapan Algoritma Convolutional Neural Network Dan Arsitektur MobileNet Pada Aplikasi Deteksi Penyakit Daun Padi. *Swabumi*, 9(2), 184–188. <https://doi.org/10.31294/swabumi.v9i2.11678>
- Sgd, P. O., Irfan, D., Rosnelly, R., Wahyuni, M., Samudra, J. T., & Rangga, A. (2022). *Menggunakan Cnn*. 4307(June), 244–253.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0197-0>
- Shrivastava, V. K., & Pradhan, M. K. (2021). Rice plant disease classification using color features: a machine learning paradigm. *Journal of Plant Pathology*, 103(1), 17–26. <https://doi.org/10.1007/s42161-020-00683-3>
- Shrivastava, V. K., Pradhan, M. K., Minz, S., & Thakur, M. P. (2019). Rice plant disease classification using transfer learning of deep convolution neural network. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 42(3/W6), 631–635. <https://doi.org/10.5194/isprs-archives-XLII-3-W6-631-2019>
- Suharjito, Elwirehardja, G. N., & Prayoga, J. S. (2021). Oil palm fresh fruit bunch ripeness classification on mobile devices using deep learning approaches. *Computers and Electronics in Agriculture*, 188(July), 106359. <https://doi.org/10.1016/j.compag.2021.106359>
- Wakili, M. A., Shehu, H. A., Sharif, M. H., Sharif, M. H. U., Umar, A., Kusetogullari, H., Ince, I. F., & Uyaver, S. (2022). Classification of Breast Cancer Histopathological Images Using DenseNet and Transfer Learning. *Computational Intelligence and Neuroscience*, 2022. <https://doi.org/10.1155/2022/8904768>
- Wikarta, A., Sigit Pramono, A., & Ariatedja, J. B. (2020). Analisa Berbagai Optimizer Pada Convolutional Neural Network Untuk Deteksi Pemakaian Masker Pengemudi Kendaraan. *Seminar Nasional Informatika, 2020(Semnasif)*, 69–72.