

KLASIFIKASI KESEHATAN PADA TANAMAN PADI MENGUNAKAN CITRA *UNMANNED AERIAL VEHICLE* (UAV) DENGAN *METODE CONVOLUTIONAL NEURAL NETWORKS* (CNN)

Erwin Hermawan¹, Sahid Agustian², Dimas Mulya Saputra³

Teknik Informatika,

Universitas Ibn Khaldun Bogor

Alamat Jl. K.H. Sholeh Iskandar Raya Km. 2 Kota Bogor, Indonesia, 16162

Email: erwin.82@uika-bogor.ac.id¹, shudjimartsu@uika-bogor.ac.id², dms75551@gmail.com³

Abstrak

Indonesia merupakan Negara dengan mayoritas penduduknya menjadikan beras sebagai makanan utama. Dengan jumlah penduduk yang semakin meningkat tentunya perlu menjaga kualitas padi agar menurunkan risiko gagal panen. Pada tahun 2019, dinyatakan bahwa hampir 40% dari hasil panen dunia menghilang karena penyakit dan serangan hama. Unmanned Aerial Vehicle (UAV) merupakan salah satu teknologi yang sudah banyak digunakan untuk pengamatan dan pemetaan pada tanaman padi. Ukuran UAV yang kecil membuatnya dapat bermanuver lebih banyak sehingga membuat pemotretan lahan lebih mudah dan cepat. Penyakit-penyakit dan serangan hama ini dapat dideteksi dengan melihat pada bagian-bagian tanaman. Bagian yang paling mudah untuk dideteksi adalah pada bagian daun karena tanda-tanda penyakit akan terlihat dengan jelas. Namun, tidak mudah untuk mengenali penyakit-penyakit tersebut dibutuhkan tenaga ahli dalam mengidentifikasi penyakit melalui sebuah citra UAV dengan lebih akurat. Convolutional Neural Network (CNN) adalah salah satu metode deep learning yang sering digunakan dalam pengenalan citra digital. Hal ini dikarenakan CNN berusaha meniru cara pengenalan citra pada visual Cortex manusia. Metode CNN pada penelitian ini digunakan untuk mengklasifikasikan tanaman padi sehat dan tanaman padi sakit melalui citra UAV.

Kata Kunci : Citra UAV, *Convolutional Neural Networks*(CNN), *Deep Learning*, Padi.

Abstract

Indonesia is a country with a majority of the population making rice the main food. With an increasing population, of course, it is necessary to

maintain the quality of rice to reduce the risk of crop failure. In 2019, it was stated that nearly 40% of the world's crop was lost due to disease and pest infestation. Unmanned Aerial Vehicle (UAV) is a technology that has been widely used for the observation and mapping of rice plants. The UAV's small size allows it to maneuver more, making shooting land easier and faster. These diseases and pest attacks can be detected by looking at the plant parts. The easiest part to detect is on the leaves because the signs of the disease can be seen clearly. However, it is not easy to recognize these diseases, it requires experts to identify diseases through a more accurate UAV image. Convolutional Neural Network (CNN) is a deep learning method that is often used in digital image recognition. This is because CNN is trying to imitate the image recognition method in the human visual cortex. The CNN method in this study was used to classify healthy rice plants and diseased rice plants through UAV imagery.

Keywords: UAV Image, Convolutional Neural Networks (CNN), Deep Learning, Paddy.

I. PENDAHULUAN

Beras berasal dari padi atau gabah yang dibudidayakan sehingga menjadi makanan pokok seperti sekarang ini. Padi (*Oryza sativa L*) merupakan tanaman pangan yang sangat penting di Indonesia. Badan Pusat Statistik (BPS) mencatat produksi padi Indonesia mencapai 54,42 juta ton GKG pada 2020. Jika dikonversi menjadi beras, total produksi

GKG tersebut kira-kira setara dengan 31,36 juta ton beras. Angka ini menyusut 0,45% dari produksi tahun sebelumnya yang seberat 31,5 juta ton GKG pada tahun 2021 [1].

Keberhasilan panen dari tanaman padi tersebut dapat mempengaruhi industri pertanian di daerah bahkan di suatu negara, tetapi gagal panen dapat terjadi kapan saja salah satu penyebabnya adalah penyakit dan serangan hama. Hampir 40% dari hasil panen dunia hilang karena penyakit dan serangan hama, menurut survei pada tahun 2018. Penyakit-penyakit dan serangan hama ini dapat dideteksi dengan melihat pada bagian-bagian tanaman. Bagian yang paling mudah untuk dideteksi adalah pada bagian daun karena tanda-tanda penyakit akan terlihat dengan jelas. Namun, tidak mudah untuk mengenali penyakit-penyakit tersebut dibutuhkan tenaga ahli dalam mengidentifikasi penyakit. Oleh karena itu, tenaga ahli tersebut dapat digantikan dengan sebuah teknologi yang dapat mengenali jenis penyakit pada tanaman padi [2].

Unmanned Aerial Vehicle (UAV) adalah salah satu teknologi yang sudah banyak digunakan dalam dunia pertanian terutama sebagai fungsi pengamatan dan pemetaan lahan padi, Dengan menggunakan UAV pengamatan tumbuhan dapat dilakukan dengan waktu lebih cepat dan memakan biaya yang relatif lebih rendah. Ukuran UAV yang kecil membuatnya dapat bermanuver lebih banyak sehingga membuat pemotretan lahan lebih mudah dan cepat [3].

Terdapat penelitian terdahulu mengenai kesehatan tanaman padi dengan judul “Penerapan Algoritma *Convolutional Neural Network* Dan Arsitektur *MobileNet* Pada Aplikasi Deteksi Penyakit Daun Padi” telah melakukan penelitian bahwa klasifikasi gambar jenis penyakit daun padi menggunakan algoritma CNN dengan arsitektur *MobileNetV1* dan *Feature Extraction* memiliki akurasi yang baik sekali yaitu sebesar 92% namun dengan jumlah data cukup kecil dan penggunaan *epoch* yaitu 100, mengakibatkan nilai validasi kesalahan pada proses pelatihan, sehingga akan terjadi *overfitting* [4]. Selain itu, pada penelitian yang berjudul “Implementasi *Artificial Neural Network* (ANN) *Backpropagation* untuk klasifikasi jenis penyakit pada daun tanaman tomat” menyebutkan bahwa dari pemrosesan data tersebut menghasilkan akurasi terbaik sebesar 78%

pada *cross-validation* flods 4 dengan waktu yang dibutuhkan untuk memproses data selama 319,77 detik menggunakan aturan-aturan dengan *batchsize* sebesar 100, *hiddenlayers* yang didefinisikan sebagai a , bobot sebesar 0,3 pada *learningrate*, *validation threshold* sebesar 20 untuk mengakhiri validasi pengujian dan nilai *epoch* untuk melatih data sebesar 500. Dari perbandingan kedua metode di atas bahwa metode CNN lebih efisien dan akurat sebesar 92% dibandingkan metode ANN hanya sebesar 78%. [5].

Proses klasifikasi dalam mendeteksi citra penyakit tanaman padi perlu dibangun dalam sebuah sistem yang menerapkan metode *deep learning*, Banyak metode *deep learning* mampu menyeleksi fitur yang kompleks dan cepat namun algoritma *Convolutional Neural Network* (CNN) merupakan algoritma yang paling efisien dalam mengekstraksi fitur. Oleh karena itu, penelitian ini bertujuan untuk model klasifikasi mengenai penyakit pada tanaman padi menggunakan teknologi UAV dan metode CNN yang berada di Desa Bantar Urug Kecamatan Leuwiliang Kabupaten Bogor Provinsi Jawa Barat.

II. METODE PENELITIAN

2.1 Tahapan Penelitian

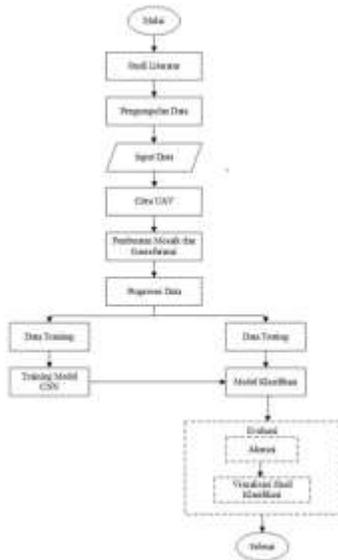
Yang digunakan dalam penelitian ini adalah metode pengumpulan data. Adapun metode penelitian yang diterapkan dalam dapat dilihat *flowchart* metode penelitian yang ditunjukkan pada Gambar 1.

2.2 Citra UAV

Citra UAV yang di hasilkan oleh DJI Phantom 4 Multispectral+ D-RTK 2 menghasilkan 1131 foto udara berupa RGB dan NIR Infrared. Berikut adalah hasil foto udara bisa dilihat pada Gambar 2.

2.3 Pembuatan Mosaik Dan Georeferensi

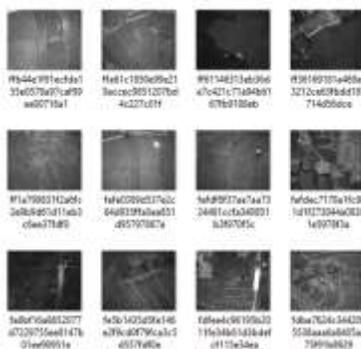
Pada tahapan ini tererdapat 1131 foto udara yang diambil menggunakan DJI Phantom 4 Multispectral kemudian akan diolah kembali dengan menggunakan software *DJI Terra* dari 1131 foto tersebut di import kedalam DJI terra kemudian menghasilkan output berupa Orthophoto/Orthomosaik. Berikut adalah orthophoto bisa dilihat pada Gambar 3.



Gambar 1. Metode Penelitian



Gambar 3. Orthophoto



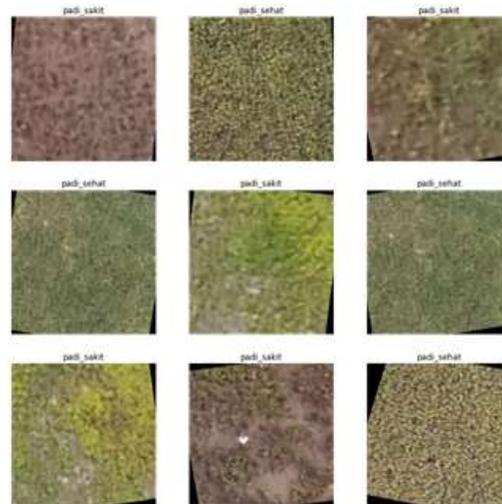
Gambar 2. Hasil Foto Udara DJI Phantom 4

2.4. Preproses Data

Data *Preprocessing* ini dimaksudkan untuk mempersiapkan data yang akan digunakan pada penelitian ini agar data yang diperoleh, dapat diproses dengan baik oleh model yang akan dibuat, yaitu model CNN.

2.5. Dataset dan Dataloader Preparation

Dataset citra padi yang di gunakan terdiri dari 550 citra yang terbagi ke dalam 2 kelas yaitu padi sehat dan padi sakit. Masing-masing kelas memiliki citra digital berformat *JPG. Berikut adalah *sample* data yang di gunakan pada penelitian dapat dilihat pada Gambar 4.



Gambar 4. Data Set Tanaman Padi

2.6. Data Tranformasi

Pada tahap ini dilakukan teknik data engineering. Pada Data Engineering ini untuk menyiapkan infrastruktur data yang akan digunakan ditahap training data atau pembuatan model prediksi. Berikut hal yang dilakukan antara lain :

1. Transformasi *Random Rotation*, hal ini dilakukan untuk mengatasi data yang sangat sedikit dan mengurangi *overfitting*.
2. Transformasi *Random Resize Crop*, hal ini dilakukan *cropping* pada citra tersebut menjadi 224×224 pixel.
3. Transformasi *Tensor*, dalam hal ini citra tersebut akan diubah ke dalam bentuk *tensor* agar dapat dibaca pada saat proses pembuatan model.

2.7. Dataset Splitting

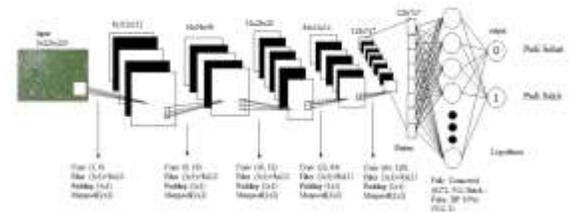
Dataset Splitting yaitu membagi dataset citra UAV padi sakit yang berjumlah 555 citra UAV ke dalam data *training*, data *validation* dan data *testing* dengan perbandingan 70 % untuk data *training*, 20% data *validation* dan 10% data *testing*. Adapun distribusi data tersebut dapat di lihat pada Tabel 1.

Tabel 1. Dataset Splitting

No	Kelas Citra UAV		Jumlah	Keterangan
	Padi Sehat	Padi Sakit		
1	231	154	385	<i>Training</i>
2	66	44	110	<i>Validation</i>
3	33	22	55	<i>Testing</i>
Σ	330	220	550	

2.8. Arsitektur dan Config

Pada tahap ini akan dilakukan pembuatan arsitektur model *config*. Arsitektur model CNN yang dibangun terdiri dari 5 lapisan *convolutional layer*, *relu*, *layer*, *padding*, dan *max pooling* pada *fiture learning*. Sedangkan pada lapisan *classification* terdapat 1 lapisan *flatten*, dan 2 lapisan *neural network* atau *fully connected* dan pada lapisan *softmax* terdiri atas 2 *output*. Adapun ilustrasi arsitektur CNN yang akan dibangun dapat dilihat pada Gambar 5.



Gambar 5. Arsitektur CNN yang akan dibangun

Setelah arsitektur model CNN dibuat, maka tahap selanjutnya adalah *config*. *Config* berfungsi untuk mengatur semua parameter yang akan digunakan. Beberapa parameter yang akan digunakan dan di *setting* untuk mendapatkan model dengan tingkat akurasi yang terbaik dalam model CNN.

2.9 Padi

Padi yang bahasa latinnya *Oryza sativa L* merupakan bahan utama pembuatan nasi yang merupakan makanan pokok bagi seluruh masyarakat Indonesia. Padi diolah menjadi beras kemudian menjadi nasi merupakan sumber karbohidrat bagi tubuh. Hasil dari budidaya padi ini sendiri berpengaruh terhadap perkembangan perekonomian secara menyeluruh, baik menyangkut pendapatan petani sendiri, pendapat daerah, maupun penyerapan tenaga kerja. Oleh karena itu pembangunan dibidang pertanian menjadi prioritas utama yang dilaksanakan di Indonesia [13].

2.10 Hama Tanaman Padi

Hama merupakan salah satu faktor yang menjadi kendala bagi petani. Perkembangan hama disebabkan adanya perubahan iklim. Di beberapa daerah serta produksi padi, perkembangan hama menjadi sangat pesat pada musim kemarau. Akibat dari serangan hama tersebut terjadi penurunan hasil produksi padi yang membuat petani rugi. Organisme Pengganggu Tanaman (OPT) yang paling penting pada tanaman padi adalah hama wereng. Hama tersebut mengganggu fase pertumbuhan tanaman padi semejak mulai persemaian (*vegetative*), nakan maupun berbunga (*generative*) sehingga dapat menimbulkan kerusakan berat sehingga hasil yang tinggi.

2.11 Citra Digital

Citra digital adalah representasi dari suatu citra yang dibentuk berdasarkan sampling dan kuantisasi

(jumlah pada citra yang akan diolah) yang diperoleh dari suatu mesin. Sampling menggambarkan matrik yang tersusun dari baris dan kolom. Dengan kata lain, pengambilan sampel suatu gambar mewakili ukuran piksel (titik) pada gambar, kuantisasi mewakili nilai tingkat kecerahan yang digambarkan menggunakan skala abu-abu sesuai dengan digit biner, dan kuantisasi kata-kata dalam gambar lain mewakili warna dalam jumlah gambar [15].

2.12 Penginderaan Jauh

Penginderaan jauh adalah ilmu dan seni untuk memperoleh informasi tentang suatu objek, daerah, atau fenomena melalui analisis data yang diperoleh dengan suatu alat tanpa kontak langsung dengan objek, daerah, atau fenomena yang dikaji [16].

2.13 Unmanned Aerial Vehicle (UAV)

UAV merupakan sistem tanpa awak (*Unmanned System*), yaitu sistem berbasis elektro-mekanik yang dapat melakukan misi-misi terprogram, dengan karakteristik yaitu tanpa awak pesawat, beroperasi pada mode mandiri baik secara penuh atau sebagian, dan sistem ini dirancang untuk dapat dipengaruhi secara berulang. Teknologi pemetaan tanpa awak menjadi pilihan alternatif disamping teknologi pemetaan pemetaan lainnya seperti seperti pemotretan udara baik skala besar dan kecil berawak serta pemetaan berbasis satelit. Teknologi ini sangat menjanjikan untuk diaplikasikan dikembangkan dan sesuai karakteristik topografi dan geografis Indonesia. UAV biasanya dilengkapi dengan alat atau sistem pengendali terbang melalui gelombang radio, navigasi presisi (Grounding Positioning System – GPS dan pengukuran Internal Unit), dan elektronik kontrol penerbangan, dan peralatan kamera resolusi tinggi.[3]

2.14 Deep Learning

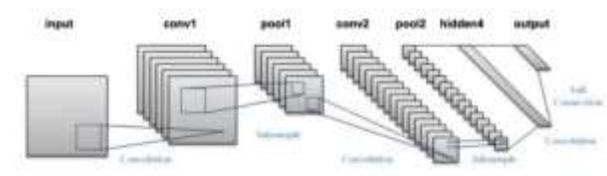
Deep Learning (DL) adalah teknik dalam *Neural Network* (NN) yang menggunakan teknik tertentu seperti *Restricted Boltzmann Machine* (RBM) untuk mempercepat proses pembelajaran dalam NN yang menggunakan lapis yang banyak atau lebih dari 7 lapis. Dengan adanya DL, waktu yang dibutuhkan untuk training akan semakin sedikit karena masalah hilangnya gradien pada propagasi balik akan semakin rendah. Beberapa jenis DL antara lain *Deep Auto*

Encoder, *Deep Belief Nets*, *Convolutional Neural Network*, dan lain lain [17].

2.15 Convolutional Neural Network (CNN)

CNN merupakan operasi yang menggabungkan lapisan-lapisan yang beroperasi secara paralel, hal ini terinspirasi dari sistem saraf biologis manusia. CNN mempresentasikan setiap neuronnya kedalam bentuk 2 dimensi, sehingga metode ini cocok digunakan dengan pemrosesan input berupa citra [18]. CNN merupakan jenis jaringan saraf tiruan yang berfungsi untuk memproses data yang memiliki jaringan seperti grid. Contohnya data deret waktu yang termasuk ke dalam grid 1D (satu dimensi) yang mengambil sampel pada interval waktu yang teratur, dan data gambar yang termasuk ke dalam grid 2D pixel (dua dimensi). CNN juga menggunakan operasi matematika yang disebut konvolusi. Konvolusi adalah jenis operasi linear khusus yang menggunakan konvolusi sebagai pengganti matriks umum dan jika dilihat dari jumlah layer yang digunakan adalah berlapis-lapis, maka CNN tersebut dinamakan dengan *Deep Convolutional Neural Network* atau biasa disingkat DCNN [19]

CNN sudah banyak digunakan dalam aplikasi pengenalan gambar dan video, sistem pemberi rekomendasi, klasifikasi gambar, analisis gambar medis, dan pemrosesan bahasa alami. CNN mempelajari filter dalam algoritma gambar biasa. Algoritma disini memiliki tujuan untuk mengelompokkan data berdasarkan data yang sudah ada. Arsitektur CNN terdiri dari *convolution layers*, *pooling layers*, dan *full connection layers*. Arsitektur *Convolutional Neural Network* terlihat pada Gambar 6.



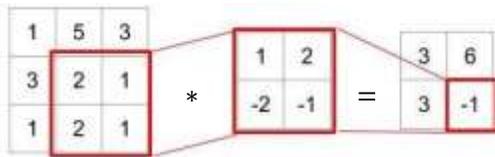
Gambar 6. Arsitektur Convolutional Neural Network

Sumber : (<https://towardsdatascience.com/>)

A. Convolutional Layer

Convolutional Layer merupakan lapisan pada CNN yang bertugas untuk melakukan proses lonvulasi dari citra digital dengan menggunakan filter telah ditentukan untuk mendapatkan feature map. Filter yang digunakan pada

proses Covolution Layer adalah berukuran 3x3. Proses dari konvolusi juga dapat ditentukan berdasarkan dari pergeseran filter yang dimasukkan atau yang biasa disebut dengan Stride yang bernilai 1 [11]. Yang bisa dilihat pada gambar 7.



Gambar 7. Convolutional Layer
 Sumber : (WiraDKP,2020)

B. Relu Layer

Retrifed Linear Unit atau biasa disebut ReLu layer adalah lapisan yang menerapkan fungsi aktivasi ReLu. Fungsi aktivasi ReLu ini mengambil sebuah nilai input dan membatasi nilainya sampai nol yaitu mengubah nilai negative menjadi nol berguna untuk menghilangkan nilai negative pada hasil layer sebelumnya. Adapun persamaan yang digunakan pada ReLu menggunakan persamaan 1 [11]. Proses pada ReLu dapat dilihat pada Gambar 8.

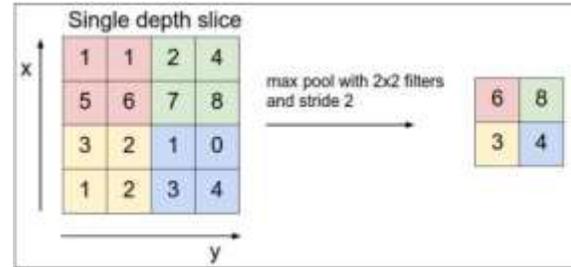


Gambar 8. Proses Relu
 Sumber : (Primatha, 2018)

C. Poling Layer

Lapisan Pooling digunakan untuk mengurangi ukuran citra. Lapisan Pooling yang sering digunakan adalah ukuran 2x2, dan diaplikasikan dengan langkah sebanyak 2, beroperasi pada setiap irisan dari

input. Bentuk ini bisa mengurangi Feature map dari ukuran asli [20]. Oprasi Poling seperti pada Gambar 9.

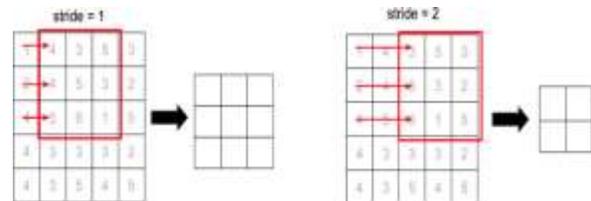


Gambar 9. proses operasi poling layer
 Sumber : (Nura Aljaafahri, 2018)

Jika nilai stride adalah satu, maka filter akan bergeser sebanyak satu piksel secara horizontal lalu vertikal. Semakin kecil stride yang digunakan, maka semakin detail informasi yang didapatkan dari sebuah input, namun membutuhkan komputasi lebih jika dibandingkan dengan stride yang besar [21].

D. Stride

Stride adalah parameter yang berfungsi untuk menentukan jumlah pergeseran filter pada saat proses convolution. Jika stride yang digunakan adalah 2, berarti convolution filter akan bergeser sebanyak 2 pixel secara horizontal lalu vertikal [22]. Adapun ilustrasi pada proses stride layer dapat dilihat pada gambar 10.

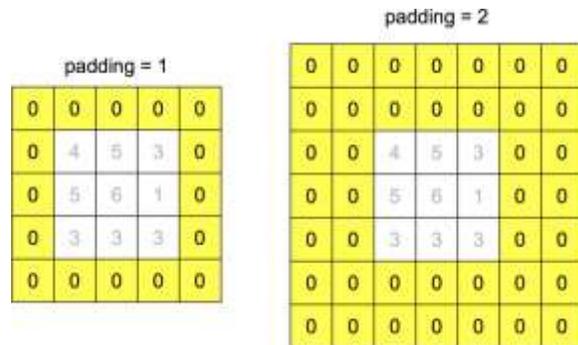


Gambar 10. Iluttrasi Stride Layer
 Sumber : (WiraDKP, 2020)

Pada gambar dapat dideskripsikan bahwa jika stride yang digunakan adalah 1, maka convolatuional filter akan bergeser pada setiap prosesnya sebanyak 1 pixel dan jika stride yang digunakan adalah 2, maka convolution filter akan bergeser pada setiap prosesnya sebanyak 2 pixel. Dari proses tersebut akan mempengaruhi jumlah pixel yang dihasilkan, semakin besar stride yang digunakan akan menyebabkan hasil konvolusi yang lebih kecil.

E. Padding

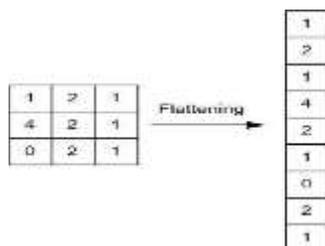
Padding Layer adalah parameter yang berfungsi untuk menentukan jumlah *pixel* atau yang bernilai 0 dan akan ditambahkan pada dtiap sisi dari *input*. Hal tersebut digunakan untuk memanipulasi dimensi *output* dari *feature map* yang akan berkurang pada saat proses *convolutional*. Sehingga akan mengembalikan dimensi yang sebenarnya yang sesuai dengan *input* [22]. Adapun ilustrasi pada proses *padding layer* dapat dilihat pada gambar 11.



Gambar 11. Proses Polling pada Layer
Sumber : (WiraDKP, 2020)

F. Flatten Layer

Flatten merupakan teknik yang digunakan untuk merubah hasil keluaran multidimensi dari proses ekstraksi fitur menjadi vektor. Proses tersebut dilakukan karena proses klasifikasi pada fully connected layer membutuhkan input berupa vector [21]. Ilustrasi dari *Flatten* dapat di lihat pada Gambar 12.

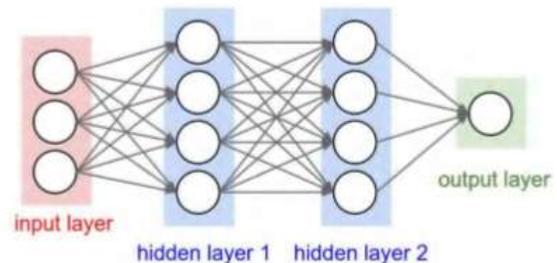


Gambar 12. Ilustrasi Flatten
Sumber : (Subramanian, 2018)

G. Fully Connected Layer

Fully connected layer adalah lapisan dimana semua neuron aktivasi dari lapisan sebelumnya terhubung semua dengan neuron di lapisan selanjutnya seperti halnya jaringan saraf tiruan biasa. Setiap aktivasi dari

lapisan sebelumnya perlu diubah menjadi data satu dimensi sebelum dapat dihubungkan ke semua neuron di *fully- connected layer*[23]. Ilustrasi *fully connected layer* dapat di lihat pada Gambar 13.



Gambar 13. Ilustrasi Fully Connected Layer
Sumber : (<https://towardsdatascience.com/>)

H. NLLoss (Negative Log -Likelihood Loss) Function

Loss function merupakan fungsi untuk menghitung kesalahan atau kerugian yang dihasilkan dari sebuah model atau menghitung seberapa baik model dalam melakukan tugas tertentu seperti regresi dan klasifikasi. Ada beberapa jenis *loss function* salah satunya adalah *Negative Log-Likelihood Loss Function* atau biasa disebut *NLLoss Function*. *NLLoss Function* berfungsi untuk mengatasi permasalahan pada klasifikasi yaitu, *multi-classification* dan digunakan untuk mengatasi *datasets* yang tidak seimbang atau *imbalanced datasets*. Bentuk persamaan *NLLoss Function* dapat dilihat pada persamaan 1.

$$L = -\log(y_i) \quad (1)$$

Dalam persamaan 1. di atas dideskripsikan bahwa (y_i) merupakan nilai probabilitas dari setiap kelas dari hasil klasifikasi *log-softmax*, sedangkan logartima yang digunakan adalah logaritma natural.

I. Confusion Matrix

Confusion Matrix merupakan metode yang digunakan untuk mengetahui atau mendeskripsikan kinerja dari proses klasifikasi yang dihasilkan dari sebuah model prediksi. Beberapa metode yang berada di dalam *confusion matrix* antara lain akurasi, *error rate*, *sensiticity* atau *recall*, *specificity*, *precision* dan *false*

positive rate. Tabel menunjukkan gambaran confusion matrix. Tabel confusion matrix dapat dilihat pada Tabel 2.

Tabel 2. Confusion Matrix

		Nilai Aktual	
		TRUE	FALSE
Nilai Prediksi	TRUE	TP (<i>True Positive</i>)	FP (<i>False Positive</i>)
	FALSE	FN (<i>False Negative</i>)	TN (<i>True Negative</i>)

Berdasarkan tabel di atas dapat dideskripsikan bahwa TP (*True Positive*) merupakan hasil prediksi yang sesuai dengan actual, yaitu keduanya benar, TN (*True Negative*) merupakan hasil prediksi salah dan nilai actual salah, FP (*False Positive*) merupakan hasil prediksi benar, namun hasil yang sebenarnya (actual) salah, dan FN (*True Negative*) merupakan hasil prediksi salah, namun yang sebenarnya (actual) benar.

J. Akurasi

Akurasi merupakan hasil perhitungan semua nilai prediksi yang benar dibagi dengan keseluruhan data. Nilai akurasi terbaik 1 dan nilai akurasi terburuk adalah 0 (rentang 0-1). Adapun persamaan untuk menghitung akurasi antara lain:

$$Akurasi = \frac{TP + TN}{TP + TN + FN + FP} \quad (2)$$

K. Error Rate

Error rate merupakan hasil perhitungan semua nilai prediksi yang salah dibagi dengan keseluruhan data. Nilai akurasi terbaik kebalikan dari akurasi, yaitu 0 dan nilai akurasi terburuk adalah 1. Adapun bentuk persamaan untuk menghitung error rate dapat dilihat pada persamaan 2.7

$$Akurasi = \frac{TP + TN}{TP + TN + FN + FP} \quad (3)$$

L. False Positive Rate

False Positive Rate atau (FPR) merupakan hasil perhitungan dari jumlah prediksi positif yang salah dibagi dengan keseluruhan dari jumlah kelas yang negatif. Nilai terbaik dari (FPR) adalah 0 dan nilai terbentuknya adalah 1. Adapun bentuk persamaan

untuk menghitung (FPR) dapat dilihat pada persamaan (4)

$$FPR = \frac{FP}{TN + FP} \quad (4)$$

M. Sensitivity (Recall/True Positive Rate)

Sensitivity atau Recall atau True positive Rate (TPR) merupakan hasil perhitungan dari jumlah prediksi positif yang benar dibagi dengan keseluruhan dari jumlah kelas yang positif. Nilai terbaik dari (TPR) adalah 1 dan nilai terbentuknya adalah 0. Adapun bentuk persamaan untuk menghitung (TPR) dapat dilihat pada persamaan 5.

$$TPR = \frac{TP}{TP + FN} \quad (5)$$

N. Precision (True Predictive Value)

Precision merupakan hasil perhitungan dari keseluruhan dari keseluruhan jumlah prediksi positif yang benar dibagi dengan keseluruhan jumlah kelas yang benar. Nilai terbaik precision adalah 1 dan nilai terburuknya adalah 0.

O. F1 Score

F1 score merupakan hasil perhitungan dari rata-rata precision dan recall. Nilai terbaik dari F1 score adalah 1 dan nilai terburuknya adalah 0. Adapun bentuk persamaan untuk menghitung F1 score dapat dilihat pada persamaan 6.

$$F1\ Score = \frac{1}{2} \left(\frac{1}{Precision} + \frac{1}{Recall} \right) \quad (6)$$

III. HASIL DAN PEMBAHASAN

3.1. Evaluasi Percobaan Model Skenario I

Epoch yang dilakukan pada penelitian ini adalah sebanyak 25. Nilai tertinggi berada pada epoch ke-25 yaitu 1.00 untuk training, kemudian dari epoch 20 sampai 25 nilai stabil berada di angka 0,91 untuk validation. Menunjukkan bahwa Arsitektur CNN yang telah dibuat sudah cukup baik membedakan antara tanaman padi sehat dan sakit.

Tabel 3. Performa Skenario I

Tabel 4. 4 Performa Skenario I pada Data Testing

Performa Kelas	Recall	Precision	F1-Score	Akurasi
Padi Sehat	0,94	1,00	0,97	0,96
Padi Sakit	1,00	0,92	0,96	

Berdasarkan percobaan atau eksperimen Maka, hasil akurasi dan *cost* yang diperoleh nilai akurasi 0,96%.

3.2. Evaluasi Percobaan Skenario II

Epoch yang dilakukan pada penelitian ini adalah sebanyak 35. Nilai tertinggi yaitu 0,99 untuk training, 0,91 untuk *validation*. Dan menunjukkan bahwa Arsitektur CNN yang telah dibuat sudah cukup baik membedakan antara tanaman padi sehat dan sakit.

Tabel 4. Performa Skenario II

Tabel 4. 7 Performa Skenario II pada Data Testing

Performa Kelas	Recall	Precision	F1-Score	Akurasi
Padi Sehat	0,94	0,97	0,95	0,95
Padi Sakit	0,95	0,91	0,93	

Berdasarkan percobaan atau eksperimen Maka, hasil akurasi dan *cost* yang diperoleh nilai akurasi 0,95%.

3.3. Evaluasi Percobaan Skenario III

Epoch yang dilakukan pada penelitian ini adalah sebanyak 50. Nilai tertinggi yaitu 1.00 untuk training, kemudian 0,91 untuk *validation*. Dan menunjukkan bahwa Arsitektur CNN yang telah dibuat sudah cukup baik membedakan antara tanaman padi sehat dan sakit.

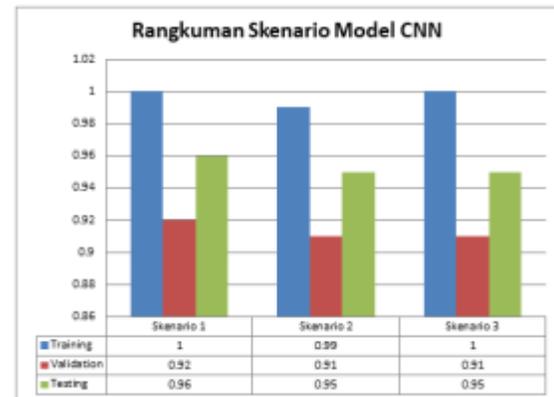
Tabel 5. Performa Skenario III

Tabel 4. 10 Performa Skenario III pada Data Testing

Performa Kelas	Recall	Precision	F1-Score	Akurasi
Padi Sehat	0,91	1,00	0,95	0,95
Padi Sakit	1,00	0,88	0,94	

Berdasarkan percobaan atau eksperimen Maka, hasil akurasi dan *cost* yang diperoleh nilai akurasi 0,95%.

3.4. Rangkuman Skenario Model CNN



Gambar 14. Rangkuman Skenario Model CNN

IV. KESIMPULAN

Berdasarkan hasil penelitian pengujian pada penerapan metode CNN untuk klasifikasi tanaman padi sehat dan sakit dapat diambil kesimpulan yaitu: didapatkan model *convolutional neural network* untuk membedakan tanaman padi sehat dan padi sakit. Pada penelitian ini digunakan sebanyak 3 skenario dengan rata-rata hasil testing pada skenario 1 sebesar 96%, untuk scenario 2 didapatkan nilai sebesar 95% dan untuk scenario 3 didapatkan nilai sebesar 95%. Menunjukkan bahwa Arsitektur CNN yang telah dibuat sudah cukup baik membedakan antara tanaman padi sehat dan sakit.

DAFTAR PUSTAKA

- [1] Kementerian Pertanian Republik Indonesia, “produksi padi 2020 dan potensi Januari-April 2021,” 2021. .
- [2] H. Prayoga Angjaya, K. Gunadi, and R. Adipranata, “Pengenalan Penyakit Pada Tanaman Pokok di Indonesia Dengan Metode Convolutional Neural Network.”
- [3] W. Fitasari, D. Useng, and A. Munir,

- “Pendugaan Produksi Dan Indeks Vegetasi Tanaman Padi Menggunakan Data Citra Platform Unmanned Aerial Vehicle (UAV) Dan Data Citra Satelit Landsat 8,” *J. Agritechno*, pp. 203–216, 2017, doi: 10.20956/at.v10i2.72.
- [4] R. A. Saputra, S. Wasiyanti, A. Supriyatna, and D. F. Saefudin, “Penerapan Algoritma Convolutional Neural Network Dan Arsitektur MobileNet Pada Aplikasi Deteksi Penyakit Daun Padi,” *Swabumi*, vol. 9, no. 2, pp. 184–188, 2021, doi: 10.31294/swabumi.v9i2.11678.
- [5] A. W. Putri, “Implementasi Artificial Neural Network (ANN) Backpropagation Untuk Klasifikasi Jenis Penyakit Pada Daun Tanaman Tomat,” *MATHunesa J. Ilm. Mat.*, vol. 9, no. 2, pp. 344–350, 2021, doi: 10.26740/mathunesa.v9n2.p344-350.
- [6] I. Rozak, “Analisis Dan Perancangan Sistem Informasi Geografis Pemetaan Hama Tanaman Padi,” *J. Inform. dan Rekayasa Perangkat Lunak*, vol. 2, no. 3, pp. 375–381, 2021, doi: 10.33365/jatika.v2i3.1239.
- [7] E. N. Arrofiqoh and H. Harintaka, “Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi,” *Geomatika*, vol. 24, no. 2, p. 61, 2018, doi: 10.24895/jig.2018.24-2.810.
- [8] Dwi Fitriana Sari and D. Swanjaya, “Implementasi Convolutional Neural Network Untuk Identifikasi Penyakit Daun Gambas,” *Semin. Nas. Inov. Teknol.*, vol. 04, no. 03, pp. 137–142, 2020.
- [9] A. Sukomono and A. P. Wijaya, “Identifikasi Tingkat Stres Tanaman Padi Dengan Rice Paddy Stress Index (Rpsi) Pada Citra Landsat-8,” *Geoid*, vol. 13, no. 1, p. 85, 2018, doi: 10.12962/j24423998.v13i1.3631.
- [10] N. Fadlia and R. Kosasih, “Klasifikasi Jenis Kendaraan Menggunakan Metode Convolutional Neural Network (Cnn),” *J. Ilm. Teknol. dan Rekayasa*, vol. 24, no. 3, pp. 207–215, 2019, doi: 10.35760/tr.2019.v24i3.2397.
- [11] S. Fauzi, P. Eosina, and G. F. Laxmi, “Implementasi Convolutional Neural Network Untuk Identifikasi Ikan Air Tawar,” *Semin. Nas. Teknol. Inf.*, pp. 163–167, 2019.
- [12] P. D.; Sukmawaty, “Jurnal Ilmiah Rekayasa Pertanian dan Biosistem, Vol.6, No. 1, Maret 2008,” *J. Ilm. Rekayasa Pertan. dan Biosist. Vol. 6, No. 2, Sept. 2018*, vol. 6, no. 1, pp. 27–38, 2018.
- [13] M. Ihsan, F. Agus, and D. M. Khairina, “Sistem Deteksi Penyakit Tanaman Padi,” *Sakti*, vol. 2, no. 1, 2017, [Online]. Available: <http://e-journals.unmul.ac.id/index.php/SAKTI/article/view/249>.
- [14] U. Alifah, “Pengaruh Pemberian Insektisida Nabati Dari Tanaman Maja (Aegle Marmelos) Terhadap Mortalitas Hama (Wereng Cokelat Dan Penggerek Batang Padi Kuning) Dan Respon Pertumbuhan Tanaman Padi,” vol. 3, no. 2, p. 6, 2021.
- [15] I. Machroz *et al.*, “Klasifikasi kematangan mangga menggunakan metode jaringan syaraf tiruan levenberg marquardt,” vol. 4, pp. 55–59, 2017.
- [16] R. Lasmi, S. Sawitri, and B. D. Yuwono, “Kajian Pemanfaatan Data Penginderaan Jauh Untuk Identifikasi Objek Pajak Bumi Dan Bangunan (Studi Kasus: Kecamatan Tembalang Kota Semarang),” *J. Geod. Undip*, vol. 4, no. 1, pp. 20–31, 2015.
- [17] Darussalam and G. Arief, “Jurnal Resti,” *Resti*, vol. 1, no. 1, pp. 19–25, 2017.
- [18] C. W. Arciniegas Paspuel, O. G., Álvarez Hernández, S. R., Castro Morales, L. G., & Maldonado Gudiño, “Identifikasi Obat-Obatan Menggunakan Metode Cnn (Convolutional Neural Network) Berbasis Android Skripsi,” p. 6, 2021.
- [19] M. R. Fauzi, “Deteksi Coronavirus Disease (Covid-19) Pada X-Ray Dan Ct-Scan Paru

-
- Menggunakan Deep Learning Dengan Algoritma Deep Convolutional Neural Network Proposal Program Studi Teknik Informatika,” 2020.
- [20] S. F. Alamsyah, “Implementasi Deep Learning Untuk Klasifikasi Tanaman Toga Berdasarkan Ciri Daun Berbasis Android,” *Ubiquitous Comput. its Appl. J.*, vol. 2, pp. 113–122, 2019, doi: 10.51804/ucaiaj.v2i2.113-122.
- [21] A. M. Syarifudin, “Klasifikasi Kanker Berdasarkan Data Rna Menggunakan Dilated Convolutional Neural Network Skripsi,” 2021.
- [22] S. Sena, “Pengenalan Deep Learning Part 6 : Deep Autoencoder,” *Medium.Com*, 2017. [https://medium.com/@samuelsena/pengenalan-deep-learning-part-6-deep-autoencoder-40d79e9c7866#:~:text=Autoencoder adalah model neural network,dari features \(Dimensionality Reduction\).](https://medium.com/@samuelsena/pengenalan-deep-learning-part-6-deep-autoencoder-40d79e9c7866#:~:text=Autoencoder adalah model neural network,dari features (Dimensionality Reduction).)
- [23] D. I. D. Merangin *et al.*, “Implementasi Convolutional Neural Networks Untuk Klasifikasi Citra Tomat Menggunakan Keras, 2021.