

# Classification of Spotted Disease on Sugarcane Leaf Image Using Convolutional Neural Network Algorithm

## Klasifikasi Penyakit Pada Citra Daun Tebu Menggunakan Algoritma Convolutional Neural Network

Wheny Lebdo Pratitis<sup>1</sup>, Kusrini<sup>2</sup>, Hanif Al Fata<sup>3</sup>

<sup>1</sup>Program Magister Teknik Informatika, Universitas AMIKOM Yogyakarta

<sup>2,3</sup>Universitas AMIKOM Yogyakarta, Indonesia

E-mail: \*<sup>1</sup> [wheny1015@students.amikom.ac.id](mailto:wheny1015@students.amikom.ac.id), <sup>2</sup>[kusrini@amikom.ac.id](mailto:kusrini@amikom.ac.id),  
<sup>3</sup>[hanif.a@amikom.ac.id](mailto:hanif.a@amikom.ac.id)

**Abstract** – Sugarcane is a plantation commodity that has a very important role because it is the main ingredient for making sugar and ethanol. However, the long planting period of approximately 1 year causes this plant to be susceptible to disease. Diseases in sugarcane can be identified directly by experts through the process of observing the leaves based on their knowledge and experience. An artificial intelligence (AI)-based technology approach is one of the latest solutions for obtaining disease information in plants. Therefore, this study proposes an automatic classification technique to classify disease spots on sugarcane leaves. The dataset downloaded from the Kaggle website consists of 864 images of sugarcane leaves which are divided into two classes, namely Sick and Healthy. To be able to produce an accurate classification model, the dataset is trained using a Convolutional Neural Network (CNN) algorithm based on a transfer learning model approach with pre-trained model architecture such as VGG-16. All weight parameters of VGG-16 are adopted and only change the last layer to match the output class. In addition, to overcome the limitations of the dataset that is owned, this study applies data augmentation techniques. The results of the research show that the classification model can classify diseases based on evaluation using the Confusion matrix with the respective parameter values, namely 98% accuracy, 100% precision, 97% recall, and 98% F1 Score.

**Keywords** — CNN, classification, sugarcane crops, transfer learning.

**Abstrak** – Tebu merupakan salah satu komoditas perkebunan yang memiliki peran yang sangat penting karena sebagai bahan utama membuat gula dan etanol. Akan tetapi, masa tanam yang lama kurang lebih 1 tahun menyebabkan tanaman ini rentan terkena penyakit. Penyakit pada tanaman tebu dapat diidentifikasi secara langsung oleh pakar melalui proses pengamatan pada daun berdasarkan pengetahuan dan pengalaman yang mereka miliki. Pendekatan teknologi berbasis kecerdasan buatan (AI) menjadi salah satu solusi mutakhir untuk mendapatkan informasi penyakit pada tanaman. Oleh karena itu, penelitian ini mengusulkan teknik klasifikasi otomatis untuk mengklasifikasikan bercak penyakit pada daun tebu. *Dataset* diunduh dari situs *Kaggle* terdiri dari 864 citra daun tebu yang terbagi menjadi dua kelas, yaitu Sakit dan Sehat. Untuk dapat menghasilkan model klasifikasi yang akurat *dataset* dilatih menggunakan algoritma *Convolutional Neural Network* (CNN) berdasarkan pendekatan model *transfer learning* dengan arsitektur *pre-trained model* seperti VGG-16. Semua parameter *weight* VGG-16 diadopsi dan hanya mengubah lapisan terakhir untuk menyesuaikan *output class*. Selain itu, untuk mengatasi ketebatasan *dataset* yang dimiliki, penelitian ini menerapkan teknik augmentasi data. Hasil dari penelitian menunjukkan model klasifikasi mampu mengklasifikasikan penyakit berdasarkan evaluasi menggunakan *Confusion matrix* dengan nilai parameter masing-masing yaitu 98% akurasi, 100% presisi, 97% *recall*, dan 98% F1 Score.

**Kata Kunci** — CNN, klasifikasi, tebu, transfer learning.

## 1. PENDAHULUAN

Tebu merupakan komoditas yang bermanfaat karena memiliki kemampuan untuk menghasilkan gula, etanol, produk biodegradable, energi, dan makanan untuk ternak, [1]. Tanaman tebu menyumbang sebesar 21% dengan nilai 1.9 miliar ton dari total produksi tanaman global yang dibudidayakan dan dipanen diseluruh dunia selama periode 2000-2019 [2]. Namun, karena musim tanamnya yang panjang, tebu rentan terhadap berbagai penyakit yang disebabkan oleh *patogen* termasuk jamur, bakteri, virus, dan organisme yang menyerupai fitoplasma, [3]. Penyakit tebu yang tidak diidentifikasi dan dicegah secara tepat waktu dapat dengan mudah menurunkan hasil dan kualitas tebu serta mengakibatkan kerugian finansial yang cukup besar bagi petani, [4]. Identifikasi penyakit secara konvensional biasanya dilakukan melalui pengamatan gejala visual secara langsung [5] secara terus menerus untuk mengkonfirmasi dan memvalidasi hasil diagnosis. Metode ini tidak hanya subjektif, dan tidak tepat dengan variasi gejala [5] dan penyakit [3] tetapi juga memakan waktu, melelahkan, dan tidak efisien, [6]. Oleh karena itu, untuk mengatasi permasalahan yang ada, penelitian ini mengusulkan untuk mengadopsi perkembangan teknologi berbasis *Artificial Intelligence* (AI) sebagai solusi ilmiah yang mutakhir.

*Computer vision* merupakan teknologi berbasis AI yang memiliki kemampuan seperti manusia yang dapat melihat, menganalisis suatu objek dalam sebuah gambar. *Computer vision* menggunakan suatu algoritma agar komputer bisa memahami dan menjelaskan tiap-tiap gambar yang diproses. Untuk memperoleh sebuah informasi yang akurat, *computer vision* bekerja dengan cara memasukkan data-data visual kedalam komputer dan kemudian komputer menganalisisnya untuk menemukan sebuah ciri khusus yang disebut pola melalui proses pembelajaran. Pola tersebut nantinya yang akan dijadikan sistem untuk mengenali suatu objek yang sama meskipun dalam kondisi yang berbeda.

*Deep learning* adalah cabang dari bidang pembelajaran mesin yang berbasis jaringan saraf tiruan yang mana terinspirasi dari struktur dan fungsi otak biologis. *Deep learning* telah membuat kemajuan besar dalam memecahkan masalah di dunia kecerdasan buatan. Metode ini secara signifikan meningkatkan *state-of-the-art* dalam berbagai bidang termasuk pengenalan suara, deteksi objek, dan pengenalan objek visual [7]. *Deep learning* untuk *computer vision* terutama masalah klasifikasi dan deteksi objek telah membuat kemajuan yang signifikan dalam beberapa tahun terakhir, [5].

*Convolutional Neural Networks* (CNN) merupakan salah satu algoritma *Deep learning* yang dirancang untuk memproses data dua dimensi. CNN adalah metode populer yang banyak diimplementasikan dalam tugas klasifikasi gambar, termasuk dalam jenis *Deep Neural Network* karena kedalamannya yang tinggi, yang mana berisi sejumlah lapisan untuk diproses. Berbeda dengan metode pengenalan gambar pada umumnya, CNN umumnya tidak memerlukan proses ekstraksi fitur manual. Ekstraksi fitur dilakukan secara otomatis bersamaan dengan proses pengembangan model, [8].

Terdapat beberapa penelitian terdahulu yang membahas penyakit tebu berdasarkan munculnya bercak suatu penyakit pada daun tebu, seperti penelitian Kumar, 2020 [9], mengusulkan sistem deteksi untuk mempresentasikan sistem penilaian keparahan penyakit pada tanaman tebu menggunakan teknik pengolahan gambar (*image processing*). Data terdiri dari 9 foto daun tebu seperti: *eye spot*, *red rot* dan *mosaic*. Teknik segmentasi diterapkan untuk melokalisasi dan memisahkan wilayah yang sakit dan tidak sakit menggunakan metode *K-means clustering*. Selain itu, untuk mengekstraksi fitur daun menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM) dan metode klasifikasi menggunakan SVM untuk mengklasifikasikan gambar ke dalam jenis penyakit. Hasil dari penelitian menunjukkan bahwa algoritma berkinerja baik dengan akurasi 97%. Shadab, et al., 2019, [5] menerapkan arsitektur *deep learning* yang telah dilatih sebelumnya dengan *dataset ImageNet* seperti VGG-19, *Resnet-34* dan *Resnet-50* untuk mengklasifikasikan 2.940 penyakit pada citra daun tebu ke dalam 6 jenis (*class*). Akurasi pengujian arsitektur VGG-19, *Resnet-34* dan *Resnet-50* menghasilkan nilai akurasi tertinggi masing-masing adalah 92%, 92,40% dan 92,80%. Militante et al., [4], mengusulkan sistem pengenalan untuk deteksi dan klasifikasi 13.842 penyakit pada citra daun tebu kedalam 7 kelas yang berbeda

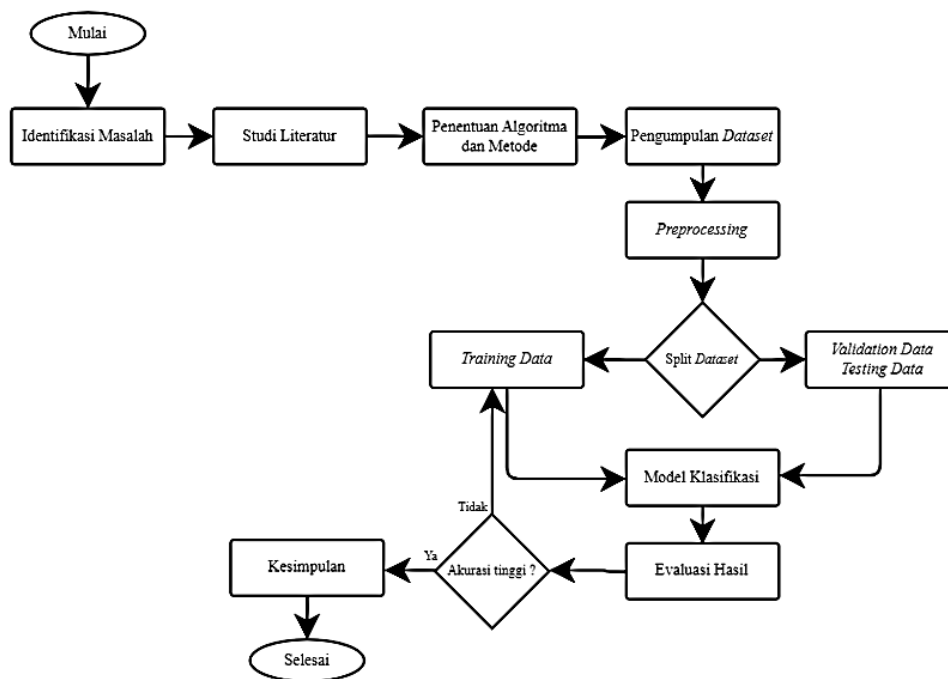
menggunakan metode *Deep learning*. Hasil penelitian menunjukkan model dapat mengklasifikasikan daun tebu ke dalam kategori sakit dan tidak sakit dengan nilai akurasi mencapai 95%.

Beberapa tahun terakhir CNN telah menunjukkan kemajuan yang luar biasa dalam tugas-tugas *computer vision*. Akan tetapi CNN membutuhkan *dataset* pelatihan yang banyak untuk menghindari kasus *overfitting*. Sehingga dengan mengadopsi model pembelajaran transfer memungkinkan CNN untuk belajar dengan data terbatas dengan mentransfer pengetahuan dari model yang telah dilatih sebelumnya pada *dataset* besar. Jadhav et al., 2019, mengusulkan pendekatan pembelajaran transfer menggunakan model arsitektur pra-terlatih CNN seperti, *AlexNet*, *GoogleNet*, *VGG16*, *ResNet101*, dan *DensNet20* untuk mengidentifikasi penyakit pada daun kedelai. Nilai akurasi yang dihasilkan untuk arsitektur yang dibangun untuk klasifikasi model masing-masing 95% *AlexNet*, 96.4% *GoogleNet*, 96.4% *VGG16*, 92.1% *ResNet101*, 93.6% *DensNet201*. Jesmar et al., 2020, mengusulkan penerapan *Deep Convolutional Models* (DCM) untuk mengklasifikasikan penyakit pada daun baroko. Hasil percobaan menunjukkan tingkat akurasi yang dihasilkan mencapai 97% *VGG16*, 95% *Xception*, dan 91% *ResNetV2-152*. Riyanto et al., 2021, mengusulkan metode CNN dengan model arsitektur *VGG-16* dengan pendekatan pengolahan citra untuk mengklasifikasikan daun berpenyakit dan daun sehat. Penelitian ini menerapkan segmentasi menggunakan algoritma *k-means clustering*. Hasil dari penelitian ini menunjukkan algoritma CNN dengan arsitektur *VGG16* menghasilkan nilai akurasi selama pengujian pada data uji sebesar 97,25%, sedangkan dengan menggunakan data citra uji di luar *dataset* diperoleh hasil akurasi sebesar 95%.

Berdasarkan beberapa penelitian yang sudah dijelaskan diatas, penulis tertarik melakukan penelitian menggunakan pendekatan algoritma CNN yang merupakan pengembangan lebih lanjut dari *Multilayer Perceptron* (MLP) [10] untuk mengklasifikasikan bercak penyakit pada citra daun tanaman tebu. Meskipun algoritma CNN dilaporkan memberikan hasil yang terbaik dalam beberapa penelitian sebelumnya, namun faktanya dalam proses pembelajaran CNN membutuhkan data yang tidak sedikit dan dibutuhkan sumber daya komputer yang besar. Oleh karena itu, dalam kasus ini model pembelajaran transfer diimplementasikan untuk meningkatkan kemampuan CNN untuk belajar dengan data yang terbatas dengan mentransfer pengetahuan dari model yang telah dilatih sebelumnya pada *dataset ImageNet*, seperti model arsitektur *VGG16*.

## 2. METODE PENELITIAN

Secara keseluruhan penelitian ini terdiri dari beberapa tahapan mulai dari identifikasi masalah, studi literatur, penentuan algoritma dan metode, pengumpulan data, *preprocessing*, penerapan algoritma *deep learning* sehingga membentuk model klasifikasi, evaluasi hasil dan kesimpulan, sebagaimana yang ditampilkan pada Gambar 1.



Gambar 1. Alur Penelitian

### 2.1. Identifikasi Masalah

Pada tahap awal peneliti mencari tahu permasalahan yang ada melalui sumber informasi berupa artikel dan berita-berita yang terkait dengan objek penelitian.

### 2.2. Studi Literatur

Tahap dimana penulis mencari tahu informasi dengan cara membaca, mempelajari, meneliti, mengkaji dari beberapa sumber *literature* berupa buku-buku (*text book*), jurnal, karya ilmiah, artikel, dan penelitian-penelitian sebelumnya yang juga memiliki hubungan terkait dengan penelitian yang akan dilakukan.

### 2.3. Penentuan Algoritma dan Metode

Pada tahap ini dilakukan penentuan metode dan algoritma yang digunakan untuk melatih model selama pembelajaran. Metode *Deep learning* dengan algoritma *Convolutional Neural Network* diusulkan untuk mengklasifikasikan penyakit pada citra daun tanaman Tebu.

### 2.4. Pengumpulan Data

*Dataset* yang digunakan untuk penelitian adalah citra daun tanaman Tebu yang diunduh dari situs *public Kaggle Dataset* [11]. Total jumlah *dataset* ada 864 gambar/kelas yang terbagi menjadi 2 jenis (kelas) yaitu Sakit dan Sehat. Berikut adalah contoh dari *dataset* tebu sebagaimana yang ditunjukkan pada Gambar 2.



a). Sehat



b). Sakit

Gambar 2. Contoh citra *dataset* tebu a). Sehat dan b). Sakit

### 2.5. Preprocessing

Setelah *dataset* terkumpul, maka untuk tahap berikutnya melakukan *preprocessing* data. *Preprocessing* gambar dilakukan untuk meningkatkan kualitas *dataset* citra sebelum melatihnya menggunakan *deep learning*, [12]. Proses diawali dengan dengan me-*resize* seluruh ukuran citra ke ukuran 224x224x3 pixel. Kemudian, melakukan *split data* untuk membagi *dataset* menjadi data *training* dan *testing* dengan rasio pembagian masing-masing 80:20. Kemudian, data *testing* dibagi lagi dengan data *validation* dengan rasio perbandingan 10:10, sebagaimana yang ditunjukkan pada Tabel 1.

Tabel 1 Rasio Dataset Citra Tebu

Kelas	Jumlah Gambar	Gambar Training	Gambar Validation	Gambar Testing
Sakit	437	342	50	45
Sehat	427	349	37	41

Tahap berikutnya melakukan augmentasi data untuk meningkatkan jumlah data yang digunakan dengan memperbanyak variasi data agar data citra yang digunakan sesuai dengan standar kriteria model arsitektur yang akan dibangun. Data augmentasi adalah teknik yang ampuh untuk menghindari *overfitting* dalam *computer vision* untuk menghasilkan lebih banyak data pelatihan, [13]. Augmentasi data dilakukan dengan menggunakan *library tensorflow Image Data Generator*. Ada lima parameter augmentasi data yang akan digunakan, yaitu *rotation*, *zoom*, *shear*, *rescale*, dan *horizontal flip*. Tujuan penggunaan augmentasi data adalah untuk meningkatkan jumlah data pelatihan secara *artificial* dengan membuat lebih banyak variasi gambar sehingga menghasilkan gambar baru [14] seperti yang ditunjukkan pada Tabel 2.

Tabel 2. Augmentasi Data

Augmentasi Data	Nilai
<i>Rescale</i>	1. / 255
<i>rotation_range</i>	20
<i>shear_range</i>	0.2
<i>zoom_range</i>	0.2
<i>horizontal_flip</i>	<i>True</i>

### 2.6. Training Data

Proses pelatihan (*training*) dilakukan terhadap *dataset* citra penyakit daun tanaman tebu menggunakan algoritma CNN. Proses pelatihan dilakukan dengan tujuan untuk mencari nilai akurasi terbaik dari model arsitektur yang diusulkan. Setiap arsitektur akan dilatih (*training and validation*) terhadap *dataset* yang telah melalui serangkaian tahap *preprocessing*. Selain itu, akan diterapkan

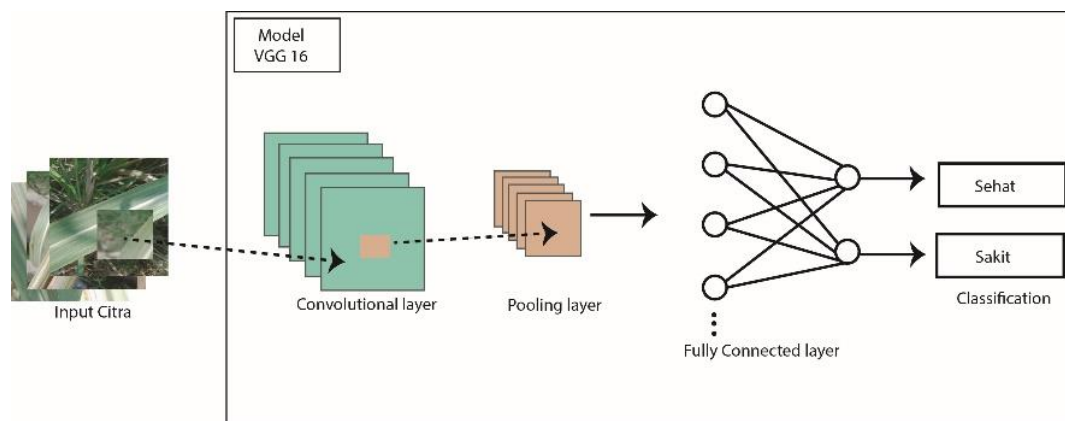
hyperparameter seperti *learning rate*, *batch size*, *optimizer* dan *categorical cross-entropy* untuk mengevaluasi *error-rate*.

## 2.7. Model Klasifikasi

Untuk menghasilkan model yang terbaik, penelitian ini mengadaptasi model *transfer learning*. *Transfer learning* sangat populer dalam *deep learning* karena dapat melatih jaringan dengan sejumlah kecil data dan akurasi yang tinggi [12]. Dalam pembelajaran mendalam, pembelajaran transfer mengacu pada penggunaan kembali jaringan yang telah dilatih sebelumnya pada pekerjaan baru. Parameter bobot yang dihasilkan atau model pra-pelatihan dari domain sumber selanjutnya digunakan dalam domain target [15].

Oleh karena itu, kami menggunakan menggunakan bobot yang telah dilatih sebelumnya dari *dataset ImageNet* yang terdiri dari 1000 kelas dengan total 1.2 juta gambar untuk melatih *dataset* tebu agar dapat mengklasifikasikan citra daun tebu menjadi dua kelas Sakit dan Sehat. Pada penelitian ini menggunakan arsitektur pra-trlatih VGG-16.

Model VGG16 [16] memiliki 16 lapisan yang terdiri dari 13 *convolutional layer* dan 3 *fully connected layer*. VGG-16 telah dilatih untuk mengklasifikasikan 1000 kelas pada *dataset* gambar *ImageNet*. Gambar 3 menunjukkan detail arsitektur model VGG16 untuk Klasifikasi penyakit pada citra tebu. Untuk mempertahankan bobot terlatih dari *ImageNet*, semua lapisan dibekukan. Sementara pelatihan dilakukan untuk melatih lapisan yang terakhir (*Fully Connected Layer*) dengan fungsi *softmax*. Dengan membatasi bobot untuk lapisan terakhir jaringan, kami dapat mempercepat waktu pelatihan tanpa mengorbankan akurasi pengklasifikasi [17]. Pembekuan bobot tersebut dinamakan *Fine-tuning*.



Gambar 3. Klasifikasi penyakit citra daun tebu menggunakan arsitektur VGG-16

*Fine-tuning* diterapkan untuk melatih lapisan *convolutional layer* (*trainable layer*). Pada penelitian ini hanya menggunakan *convolutional layer* pada blok8 dan membekukan lapisan yang lainnya. Selanjutnya pada bagian *output class* disesuaikan menjadi dua kelas berdasarkan kelas yang digunakan. Kemudian, RMSprop *optimizer* diterapkan dengan *learning rate* sebesar  $1e-4$  sebagai fungsi untuk mengevaluasi fungsi *loss*.

2.8. Evaluasi Hasil

Langkah berikutnya adalah melakukan pengujian atau evaluasi dari model hasil proses pembelajaran. Menurut (Sokolova & Lapalme, 2009) dalam penelitian [18] pengertian *Confusion matrix* adalah salah satu metode yang digunakan untuk mengevaluasi kinerja algoritma klasifikasi, sebagaimana yang ditunjukkan pada Tabel 3. Oleh karena itu, untuk mengukur performa model klasifikasi, penelitian ini menggunakan *Confusion Matrix* untuk menghasilkan parameter akurasi, presisi, *recall* dan *F1 Score* [19]. Dalam persamaan ini, TP mewakili positif sebenarnya, FN mewakili negatif palsu, FP mewakili positif palsu, dan TN mewakili negatif sebenarnya, sebagaimana yang ditunjukkan ditunjukkan pada persamaan 1-4.

Tabel 3 Evaluasi *Performance Confusion Matrix*

		Kelas Prediksi	
		Positive	Negative
Hasil Prediksi	Positive	TP ( <i>True Positive</i> )	FP ( <i>False Positive</i> )
	Negative	FN ( <i>False Negative</i> )	TN ( <i>True Negative</i> )

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \times 100\% \dots\dots\dots(1)$$

$$Precision = \frac{TP}{TP+FN} \times 100\% \dots\dots\dots(2)$$

$$Recall = \frac{TP}{TP+FP} \dots\dots\dots(3)$$

$$F1\ Score = 2 \times \frac{Recall \times Precision}{Recall+Precision} \dots\dots\dots(4)$$

2.9. Kesimpulan

Tahap berikutnya adalah kesimpulan. Kesimpulan merupakan hasil akhir yang menjelaskan mengenai keseluruhan hasil dari penelitian yang dilakukan. Secara sederhananya, kesimpulan menjawab pertanyaan yang telah diajukan pada rumusan masalah.


3. HASIL DAN PEMBAHASAN

Percobaan penelitian diimplementasikan pada spesifikasi perangkat keras *Processor: Intel® Core™ i5-7200U Processor (2.5 GHz, 3M Cache) up to 3.10 GHz*. Memori: 4GB dan GPU: *Intel HD Graphics 620 dan NVIDIA GeForce GT930MX 2GB*. Untuk penulisan kode program menggunakan bahasa pemrograman *Python* dengan tools *Google Colaboratory* pada spesifikasi RAM 12.68 GB.

Berikut ini adalah serangkaian proses yang dilakukan untuk mengklasifikasikan penyakit pada citra daun tanaman Tebu, adalah sebagai berikut:

3.1. Persiapan Data

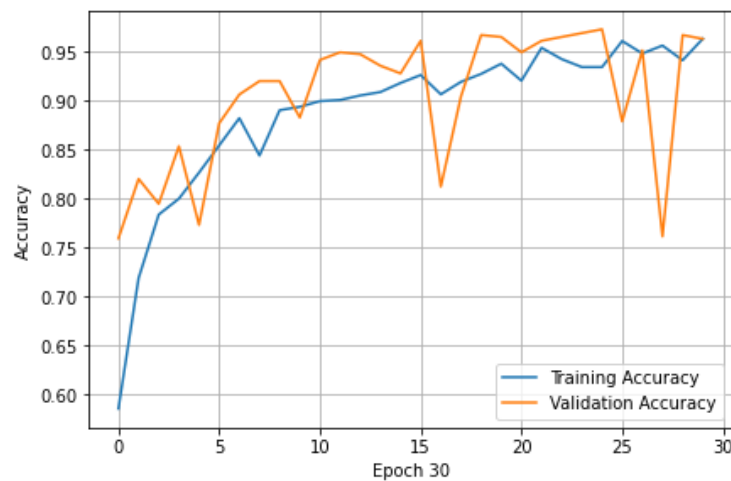
Tahap awal setelah pengumpulan *dataset* yaitu melakukan *preprocessing* citra dengan mengubah seluruh ukuran *dataset* menjadi 224x224x3 menggunakan *Python Image Library (PIL)*. Kemudian, *men-split dataset* menjadi tiga *folder* yaitu: 80% *training*; 10% *validation* dan 10%. Selanjutnya, karena CNN termasuk dalam metode *deep learning* maka untuk mendapatkan hasil yang optimal membutuhkan *dataset* pelatihan yang tidak sedikit. Proses berikutnya melakukan augmentasi data untuk menambah sumber daya *dataset* pelatihan secara *artificial*. Berikut contoh implementasi augmentasi data seperti yang ditunjukkan pada Gambar 4.



Gambar 4. Implementasi Augmentasi Data pada Citra Tebu

### 3.2. Training and Validation Accuracy

Pada tahap ini dilakukan uji coba untuk mengetahui akurasi model selama pelatihan dan validasi. Model pembelajaran dilatih menggunakan *hyperparameter* dengan *epoch* 50, ukuran *batch* adalah 32, tingkat pembelajaran adalah 0.0001, dan ukuran gambar *input* diatur ke  $224 \times 224 \times 3$ . Hasil pelatihan menggambarkan keakuratan algoritma kami pada *dataset* Tebu selama fase pelatihan, seperti yang ditunjukkan pada Gambar 5. Set pelatihan ditampilkan dalam grafik biru, sedangkan set validasi ditampilkan dalam grafik jingga. Nilai akurasi pelatihan tertinggi adalah 95% dan akurasi validasi sebesar 95%.

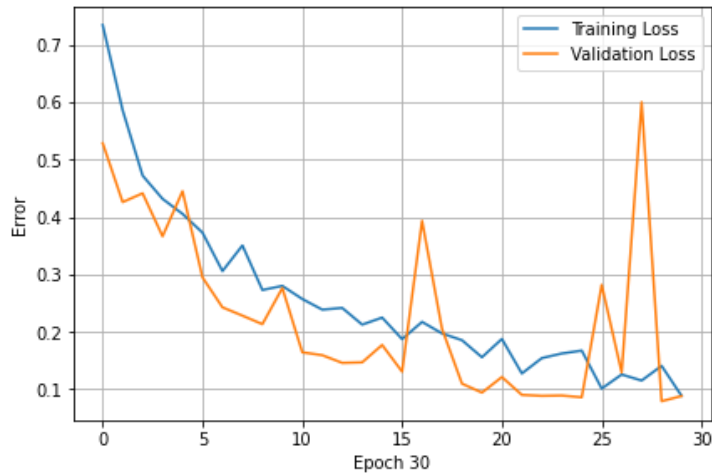


Gambar 5. Training dan Validation Accuracy

### 3.3. Training and Validation Loss

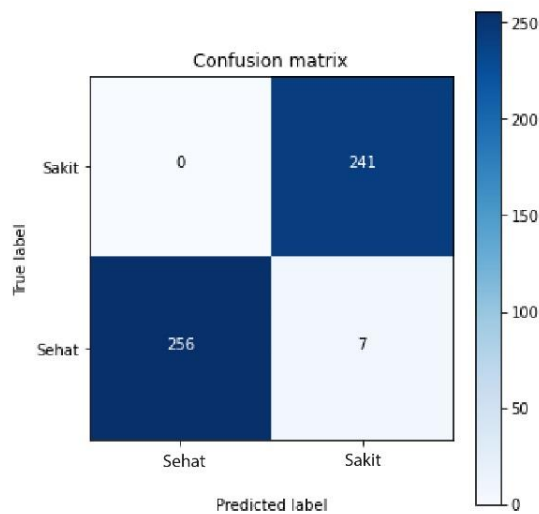
Pada tahap ini dilakukan uji coba untuk mengetahui *loss* model selama pelatihan dan validasi. Evaluasi dilakukan menggunakan skenario *epoch* 50 dengan ukuran *batch* 32. Hasil pelatihan menggambarkan hilangnya algoritma kami pada *dataset* Tebu selama fase pelatihan, seperti yang ditunjukkan pada Gambar 6. Set pelatihan ditunjukkan pada grafik biru, sedangkan set validasi ditampilkan dalam grafik jingga. Hasil nilai *loss* 0.08 pada masa pelatihan dan 0.09 pada masa validasi.





Gambar 6. Training dan Validation Loss

Kemudian, melakukan evaluasi model pembelajaran menggunakan *Confusion matrix*, sebagaimana yang ditunjukkan pada Gambar 7. Terdapat dua kelas/label yaitu Sakit dan Sehat, dari hasil perhitungan *confusion matrix*, untuk daun yang diprediksi Sehat nilai sebenarnya sehat ada 256 dan untuk label prediksi Sakit yang diprediksi sakit ada 241 daun dan yang diprediksi sehat ada 7 daun.



Gambar 7. Hasil *Confusion Matrix* Model Klasifikasi Gambar

#### 4. KESIMPULAN

Berdasarkan evaluasi percobaan yang telah dilakukan, dapat disimpulkan bahwa meskipun penelitian ini menggunakan sumber daya yang sedikit akan tetapi setelah mengadaptasi model pembelajaran transfer untuk melatih model menggunakan arsitektur VGG-16 model yang diusulkan dapat mengklasifikasikan penyakit pada citra daun tebu dengan hasil evaluasi berdasarkan perhitungan *Confusion matrix* yaitu 98% akurasi, 100% presisi, 97% *recall*, dan 98% *F1 Score* pada skenario *epoch* 50. Untuk penelitian mendatang, diharapkan dapat menggunakan arsitektur yang lebih besar dan jumlah kelas yang lebih banyak untuk memastikan bahwa skenario ini dapat dilakukan pada ukuran sistem yang lebih besar.

## DAFTAR PUSTAKA

- [1] R. Heinrichs, R. Otto, A. Magalhães, and G. C. Meirelles, “Importance of Sugarcane in Brazilian and World Bioeconomy,” *Econ. Complex. Evol.*, pp. 205–217, 2017, doi: 10.1007/978-3-319-58374-7\_11/COVER.
- [2] Food and Agriculture Organization (FAO), *World Food and Agriculture – Statistical Yearbook 2021*. 2021. doi: 10.4060/cb4477en.
- [3] A. Khan and M. S. Yadav, “Image Processing Based Disease Detection for Sugarcane Leaves,” vol. 3, pp. 497–502, 2017.
- [4] S. V. Militante, B. D. Gerardo, and R. P. M. J., “Sugarcane Disease Recognition using Deep Learning,” *2019 IEEE Eurasia Conf. IOT, Commun. Eng.*, pp. 575–578, 2019.
- [5] H. Shadab, M. Dwivedi, and A. Chakravarthy, “Disease Recognition in Sugarcane Crop Using Deep Learning,” no. September, 2019, doi: 10.13140/RG.2.2.21849.47209.
- [6] L. Li, S. Zhang, and B. I. N. Wang, “Plant Disease Detection and Classification by Deep Learning — A Review,” no. Ccv, 2021, doi: 10.1109/ACCESS.2021.3069646.
- [7] Y. Lecun, Y. Bengio, and G. Hinton, “Deep learning,” no. May, 2015, doi: 10.1038/nature14539.
- [8] I. W. S. E. P., A. Y. Wijaya, and R. Soelaiman, “Klasifikasi Citra Menggunakan Convolutional Neural Network ( Cnn ) pada Caltech 101,” vol. 5, no. 1, 2016.
- [9] A. Kumar, “Detection of Sugarcane Disease and Classification using Image Processing,” no. June, 2020, doi: 10.22214/ijraset.2019.5338.
- [10] C. Aj. Saputra, D. Erwanto, dan P. N. Rahayu, “Deteksi Kantuk Pengendara Roda Empat Menggunakan Haar Cascade Classifier Dan Convolutional Neural Network,” *JEECOM Journal of Electrical Engineering and Computer*, vol. 3, no. 1, 2021, doi: 10.33650/jeecom.v3i1.1510.
- [11] A. KHAN, “Red Rot Sugarcane Disease Leaf Dataset.” <https://www.kaggle.com/datasets/alihussainkhan24/red-rot-sugarcane-disease-leaf-dataset> (accessed Nov. 20, 2022).
- [12] V. Gautam et al., “A Transfer Learning-Based Artificial Intelligence Model for Leaf Disease Assessment,” *Sustain.*, vol. 14, no. 20, 2022, doi: 10.3390/su142013610.
- [13] K. Z. Thet, K. K. Htwe, and M. M. Thein, “Grape Leaf Diseases Classification using Convolutional Neural Network,” pp. 147–152.
- [14] L. Perez and J. Wang, “The Effectiveness of Data Augmentation in Image Classification using Deep Learning,” 2017, [Online]. Available: <http://arxiv.org/abs/1712.04621>
- [15] A. Mustafid, M. M. Pamuji, and S. Helmiyah, “A Comparative Study of Transfer Learning and Fine-Tuning Method on Deep Learning Models for Wayang Dataset Classification,” *IJID (International J. Informatics Dev.)*, vol. 9, no. 2, pp. 100–110, 2020, doi: 10.14421/ijid.2020.09207.
- [16] K. Das Bakshi, “Classification of Images on Furniture and Household Goods by Using Transfer Learning and Fine Tuning,” vol. 7, pp. 250–255, 2018.
- [17] K. Kusriani, S. Suputa, A. Setyanto, I. M. A. Agastya, H. Priantoro, and S. Pariyanto, “A comparative study of mango fruit pest and disease recognition,” *TELKOMNIKA (Telecommunication Comput. Electron. Control.)*, vol. 20, no. 6, p. 1264, 2022, doi: 10.12928/telkomnika.v20i6.21783.

- [18] A. Rohim, Y. A. Sari, and Tibyani, "Convolution neural network (cnn) untuk pengklasifikasian citra makanan tradisional," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 7, 2019.
- [19] A. Arisudin, M. Yahya, dan D. Erwanto, "Klasifikasi Aroma Teh Dengan Menggunakan Sensor Gas Berbasis Arduino Uno," *JASEE Journal of Application and Science on Electrical Engineering*, vol. 2, no. 02, 2021, doi: 10.31328/jasee.v2i02.198.

