

## Deteksi Penyakit Pada Daun Tanaman Ubi Jalar Menggunakan Metode Convolutional Neural Network

Sidik Suhendar<sup>1)</sup>, Adi Purnama<sup>2)</sup>, Esa Fauzi<sup>3)</sup>

<sup>1,2,3)</sup>Program Studi SI Informatika, Universitas Widyatama

Jl. Cikutra No.204A, Sukapada, Kec. Cibeunying Kidul, Kota Bandung, Jawa Barat 40125

Email : [sidik.suhendar@widyatama.ac.id](mailto:sidik.suhendar@widyatama.ac.id)<sup>1)</sup>, [adi.purnama@widyatama.ac.id](mailto:adi.purnama@widyatama.ac.id)<sup>2)</sup>, [esa.fauzi@widyatama.ac.id](mailto:esa.fauzi@widyatama.ac.id)<sup>3)</sup>

### ABSTRACT

Sweet potatoes are the world's third most important root crop and the fourth most popular staple food in developing countries, including Indonesia. Some diseases commonly found in sweet potato leaves are early blight (identified by leaves containing *batataezim*) and late blight (characterized by leaves that have chlorosis). These two diseases have different symptoms and require different treatments, but a slow identification process can lead to additional costs for plant care. This research will classify image data of sweet potato diseases using the Convolutional Neural Network (CNN) method. CNN is a derivative of the Multilayer Perceptron (MLP) designed to process image data with high network depth and is often used for classification tasks. The research uses a total of 750 images divided into 3 classes: images of healthy leaves, images of leaves with chlorosis, and images of leaves containing *batataezim*. Each leaf class will be labeled with 250 image data, and the labeled data will be further divided into training and testing sets. From these sets, prediction data will be obtained from the testing process during the CNN model training. The training accuracy resulted in a value of 98.17%, while the testing accuracy reached 98.67%. Additionally, the resulting loss values are remarkably low, at 0.04% for training and 0.03% for testing. The research findings will provide insights into the CNN method's ability to detect diseases in sweet potato plants, potentially impacting agricultural supervision, plant disease identification, and enabling more precise decisions regarding plant care actions.

**Keywords** : Convolutional Neural Networks (CNN), Image Identification, Image Processing, Plant Disease Classification

### ABSTRAK

Ubi jalar merupakan tanaman pangan umbi-umbian terpenting ketiga di dunia yang merupakan makanan pokok paling populer keempat di negara berkembang termasuk Indonesia. Beberapa penyakit yang sering ditemui pada daun ubi jalar yaitu *early blight* (ditandai dengan daun yang memiliki *batataezim*) dan *late blight* (ditandai dengan daun yang memiliki klorotik). Kedua penyakit ini memiliki gejala serta penanganan yang berbeda, namun proses identifikasi yang lambat dapat menyebabkan tambahan biaya untuk perawatan pada tanaman tersebut. Penelitian ini akan melakukan klasifikasi data citra penyakit ubi jalar menggunakan metode Convolutional Neural Network (CNN). CNN merupakan turunan dari Multilayer Perceptron (MLP) yang dirancang untuk memproses data citra dengan kedalaman jaringan yang tinggi dan sering digunakan untuk menyelesaikan tugas klasifikasi. Data yang digunakan pada penelitian ini berjumlah 750 citra yang terbagi menjadi 3 kelas yaitu citra daun sehat, citra daun yang memiliki klorotik, dan citra daun yang memiliki *batataezim*. Setiap kelas daun akan diberikan label sebanyak 250 data citra, dan selanjutnya data yang sudah dilabeli akan dibagi menjadi data latih dan data uji. Dari data latih dan data uji tersebut didapatkan data prediksi dari hasil pengujian pada proses training model CNN. Hasil akurasi Train menghasilkan nilai sebesar 98.17% serta Test menghasilkan nilai 98.67%. Serta nilai loss yang dihasilkan relatif sangat kecil yakni untuk Train sebesar 0.04% dan Test senilai 0.03%. Hasil penelitian akan memberikan wawasan tentang kemampuan metode CNN dalam mendeteksi penyakit pada tanaman ubi jalar, yang dapat memiliki implikasi penting dalam pengawasan pertanian, identifikasi penyakit tanaman, dan pengambilan keputusan untuk tindakan perawatan tanaman yang lebih tepat.

**Kata Kunci** : Convolutional Neural Networks (CNN), Identifikasi Citra, Pengolahan Citra, Klasifikasi Penyakit Tanaman

## 1. Pendahuluan

Ubi jalar merupakan tanaman pangan umbi-umbian terpenting ketiga di dunia dan makanan pokok paling populer keempat di negara berkembang termasuk Indonesia. Di Indonesia, ubi jalar menjadi makanan pokok masyarakat Indonesia bagian timur, seperti di Papua. Ubi jalar mengandung serat, kalium, magnesium, zat besi, vitamin A, vitamin C, vitamin D, vitamin E, serta vitamin B6 yang bermanfaat mencegah penyakit jantung dan stroke (Singh et al., 2019). Beberapa penyakit ubi jalar di Indonesia di antaranya kudis, layu *fusarium*, bercak daun, hawar daun, busuk hitam, layu bakteri dan nematoda. Selain itu, ubi jalar juga dilaporkan terserang penyakit yang disebabkan oleh virus.

Dari perubahan yang terjadi pada daun ubi jalar dapat dideteksi penyakit apa yang menyerangnya. Penyakit yang umum menyerang tanaman ubi jalar di Indonesia dengan gejala yang tampak pada daunnya yaitu hama tungau merah (*tetranychus urticae koch*), bercak daun cokelat (*brown leaf-spot*), bercak daun baur (*diffuse leaf-spot*), bercak daun putih (*white leaf-spot*), dan bakteri hawar daun (*cassava bacteriak blight*) (Hartini, 2008).

Kumar, dkk. (2021) melakukan penelitian menggunakan *Support Vector Machine* (SVM) sebagai fitur ekstraksi dan untuk proses identifikasi menggunakan metode *Convolutional Neural Network* (CNN). Hasil dari penelitian tersebut diperoleh akurasi tertinggi pada penyakit bercak daun coklat dan penyakit stik (batang) coklat sebesar 98%. (Kumar et al., 2021) Selanjutnya ada penelitian lain yang masih berkaitan dengan kerusakan tanaman dengan gejala yang tampak pada daun (Mungki Astiningrum et al., 2020).

Pada penelitian lain, terdapat topik penelitian tentang identifikasi jenis penyakit tembakau berdasar dari citra daun menggunakan ekstraksi fitur *Gray Level Co-occurrence Matrix* (GLCM) berbasis hubungan piksel ketetanggaan dan SVM dengan *gaussian* (RBF) dan *polynomial*. Akurasi tertinggi yang diperoleh sebesar 80% pada *kernel polynomial* (Permadi & Harjoko, 2015). Selain itu masih ada lagi penelitian berkaitan dengan penggunaan ekstraksi fitur GLCM untuk melakukan identifikasi penyakit cabai dari gejala bercak daun dan munculnya *conidia* dengan proses identifikasi menggunakan *Probabilistic Neural Network* (PNN) dengan akurasi yang dihasilkan sebesar 94,74% untuk pengenalan bercak daun, sedangkan untuk pengenalan *conidia* akurasi yang didapat sebesar 95,31% (Hamidah et al., 2016).

Penelitian ini bertujuan untuk membuat sistem yang dapat membantu para petani atau pengelola pertanian dalam mengidentifikasi penyakit pada daun ubi jalar dengan memanfaatkan data gambar daun ubi jalar. Identifikasi daun pada tanaman ubi jalar ini dibagi menjadi tiga bagian yaitu tanaman ubi jalar dengan daun sehat atau normal, *late blight* daun yang mengandung

*batataezim*, dan *early blight* atau daun yang memiliki klorotik. Maka pada penelitian ini akan melakukan identifikasi ini menggunakan algoritma CNN yang merupakan salah satu dari metode *Deep Learning*. Data yang digunakan berupa data penyakit pada daun tanaman ubi jalar yang didapat pada lokasi penelitian.

### 1.1. Penyakit Daun Ubi Jalar

Penyakit bercak daun pada ubi jalar, meskipun tidak menimbulkan kerugian yang signifikan, tetap menjadi perhatian penting dalam budidaya tanaman ini. Penyakit ini sering disebut sebagai bercak daun coklat (*Brown leaf spot*) dan pertama kali diidentifikasi oleh Cooke pada tahun 1883 di Timor. Setelah itu, Zimmermann menemukan keberadaan penyakit ini di Afrika Timur pada tahun 1904. Sejak saat itu, penyakit bercak daun telah tersebar di berbagai negara yang menanam ubi jalar, termasuk Indonesia.

### 1.2. Machine Learning

Pembelajaran mesin (*Machine Learning*) adalah bidang kecerdasan buatan yang menggunakan teknik statis untuk memberikan kemampuan sistem komputer untuk “belajar” dari data, tanpa diprogram secara eksplisit. Pembelajaran mesin diciptakan pada tahun 1959 oleh Arthur Samuel. Pembelajaran mesin ini menggunakan sejumlah besar data pelatihan untuk mengidentifikasi korelasi antara banyak variabel untuk belajar memproses data yang masuk.

### 1.3. Convolution Neural Network

*Convolutional Neural Network* (CNN) adalah pengembangan dari *Multilayer Perceptron* (MLP) yang didesain untuk mengolah data dua dimensi. CNN termasuk dalam jenis *Deep Neural Network* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. Masukan (*input*) dan keluaran (*Output*) dari setiap tahap adalah terdiri dari beberapa *array* yang biasa disebut *feature map*. Setiap tahap terdiri dari tiga layer yaitu konvolusi, fungsi aktivasi layer dan *Pooling layer*.

### 1.4. Convolution Layer

Lapisan konvolusi menggunakan filter untuk mengekstraksi objek dari citra *input*. Filter ini berisi bobot yang digunakan untuk mendeteksi karakter dari objek seperti tepi, kurva, atau warna. Konvolusi akan menghasilkan transformasi linear dari citra *input* yang sesuai dengan informasi spasial pada data. Filter diaplikasikan secara berulang sehingga menghasilkan serangkaian bidang *receptive*. Terdapat parameter yang dapat diubah untuk memodifikasi sifat tiap lapisan, yaitu ukuran filter, *stride* dan *padding*.

*Stride* mengontrol bagaimana filter diterapkan pada data *input* dengan bergerak sepanjang ukuran *piksel* yang telah ditentukan. *Padding* adalah penambahan ukuran *piksel* dengan nilai tertentu disertai data *input* agar hasil dari bidang *receptive* tidak terlalu kecil sehingga tidak

banyak informasi yang hilang. Nilai ini biasanya nol sehingga disebut dengan *zero padding*. Hasil dari bidang *receptive* berupa data tunggal. *Output* dari proses konvolusi ini dijadikan sebagai *input* untuk lapisan konvolusi selanjutnya (Castelluccio et al., 2015).

1.5. Operasi *Pooling*

Operasi *Pooling* (*Pooling operation*) adalah salah satu komponen penting dalam jaringan saraf *konvolusional*. Tujuannya adalah untuk mengurangi dimensi data, mengurangi *overfitting*, dan mempercepat proses pelatihan jaringan. Operasi *Pooling* dilakukan pada lapisan konvolusi atau lapisan konvolusi lanjutan. Terdapat dua jenis operasi *Pooling* yang umum digunakan dalam CNN, yaitu *Max Pooling* dan *Average Pooling*.

1.6. *Flatten*

*Flattening* adalah teknik untuk mengubah hasil dari proses yang memiliki ukuran dua dimensi menjadi satu dimensi vektor. *Flattening* bertujuan sebagai langkah awal *inputan* untuk masuk ke proses selanjutnya yaitu *neural network*. Dengan *Flatten*, jaringan saraf *konvolusional* dapat digunakan untuk berbagai tugas, termasuk klasifikasi gambar, deteksi objek, segmentasi gambar, dan banyak lagi pemahaman tentang bagaimana *Flatten* berinteraksi dengan lapisan-lapisan lain.

1.7. *K-Fold*

Konsep dasar *K-fold cross-validation* adalah membagi data menjadi K sub-bagian yang disebut "fold." Setiap *fold* digunakan secara bergantian sebagai data pengujian, sementara sisa *fold* digunakan sebagai data pelatihan. Proses *K-fold cross-validation* memungkinkan untuk menghitung kinerja model secara lebih umum dan mencegah model dari *overfitting* atau *underfitting* pada satu data tertentu.

*k-fold cross-validation* adalah alat yang sangat berharga dalam pemilihan model, penyetelan parameter, dan evaluasi kinerja model. Dengan teknik ini, penelitian ilmiah dan pengembangan model statistik dapat dilakukan dengan tingkat kepercayaan yang lebih tinggi (Tempola et al., 2018).

1.8. *Confusion Matrix*

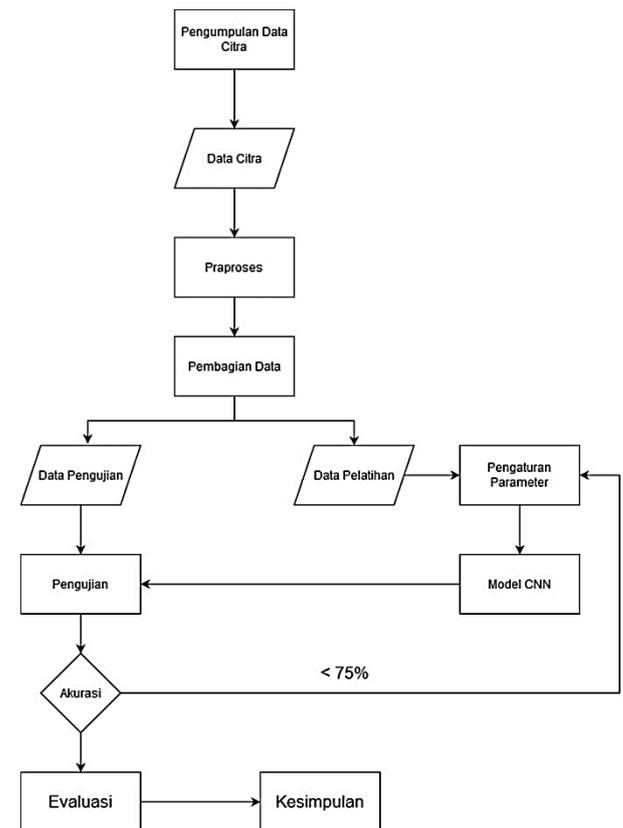
*Confusion matrix* adalah alat yang sangat penting dalam mengukur kinerja suatu sistem klasifikasi. Ini memberikan wawasan yang mendalam tentang bagaimana model klasifikasi melakukan prediksi dan seberapa baik model tersebut dalam mengklasifikasikan data. *Confusion matrix* terdiri dari empat variabel kunci: *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*. TP, yang merupakan singkatan dari *True Positive*, mewakili situasi ketika sistem klasifikasi berhasil memprediksi suatu kejadian sebagai positif, dan prediksi tersebut ternyata benar.

*Confusion matrix* membantu dalam memahami sejauh mana model klasifikasi rentan terhadap jenis kesalahan tertentu. Informasi yang diberikan oleh TP, TN, FP, dan FN adalah landasan untuk menghitung

berbagai metrik evaluasi kinerja seperti akurasi, presisi, *recall*, *F1-score*, dan lainnya. Dengan demikian, *confusion matrix* adalah alat yang penting dalam mengevaluasi keberhasilan model klasifikasi dan membantu dalam pengambilan keputusan yang lebih baik dalam berbagai aplikasi, termasuk pengenalan pola, analisis data, dan pemodelan prediktif (Narkhede, 2018)

2. Pembahasan

Metode Penelitian yang dibangun bertujuan untuk menentukan klasifikasi dari *input* citra daun yang dimasukkan menggunakan CNN. Pada Gambar 1 dapat dilihat gambaran umum identifikasi dengan menggunakan CNN.



Gambar 1. Blok diagram sistem identifikasi dengan CNN.

2.1. *Data Preparation*

Tahapan pertama adalah menyiapkan data dari hasil pengambilan data secara mandiri dari lokasi penelitian, tepatnya di Desa Cilembu Sumedang. Data yang sudah ada akan diolah, dikumpulkan sehingga siap digunakan. Proses pengambilan citra menggunakan Citra Sekunder. Seperti yang terlihat pada Tabel 1, citra yang diambil terdiri dari 3 kelas yaitu daun sehat, Klorotik, dan *Batataezim* dengan karakteristik citra yang berbeda - beda. Proses dimulai saat data awal dimasukkan, kemudian dilakukan proses *grouping* atau pengelompokan data untuk mendapatkan data yang akan di uji.

Data yang dianalisis dalam penelitian ini disediakan dalam format berkas gambar JPEG. pengumpulan data yang mencakup total 750 citra daun tanaman ubi jalar. Dalam upaya untuk merinci perbedaan visual antara

jenis-jenis daun yang berbeda, setiap jenis daun direpresentasikan oleh 250 citra, dan Selanjutnya data yang sudah dikelompokkan akan dibagi menjadi data latih dan data uji. Dari data latih dan data uji tersebut didapatkan data prediksi dari hasil pengujian pada proses *training model CNN*.

**Tabel 1. Data Klasifikasi**

No	Kelas	Gambar
1.	Bercak daun putih (Klorotik)	
2.	Bercak daun kuning (Batataezim)	
3.	Daun Sehat	

2.2. Praproses

Pengolahan citra digital merupakan pemrosesan gambar 2 dimensi yang menggunakan komputer. Citra digital merupakan sebuah larik (*array*) yang berisi nilai-nilai real maupun kompleks yang dimaksud dengan deretan bit tertentu (Darma, 2010).

Seluruh proses persiapan data ini bertujuan untuk mengorganisir dan mengatur data dengan rapi, sehingga data dapat diakses dan dimanfaatkan dengan efisien. Kemudian, data tersebut siap untuk digunakan dalam langkah-langkah berikutnya, seperti eksplorasi data, pemrosesan, dan pengembangan model. Dengan persiapan data yang baik, penelitian akan berjalan lebih lancar dan efisien, memungkinkan untuk mencapai tujuan penelitian dengan hasil yang lebih baik.

2.3. Pembagian Data

Membagi data menjadi dua bagian, yaitu data pelatihan (*train*) dan data validasi (*validate*) dengan perbandingan 80/20 (Lihat Tabel 2). Data pelatihan dan validasi akan digunakan untuk melatih dan menguji model. mencetak jumlah total gambar dalam data pelatihan dan data validasi. Proses ini membantu dalam memahami sebaran data dan persiapan untuk proses pelatihan dan validasi model.

**Tabel 2. Hasil Pembagian Data**

Pembagian Data			
Kategori	Perbandingan Data	Data training	Data Validation
<i>Batataezim</i>	80:20	205	45
<i>Klorotik</i>	80:20	196	54
<i>Healthy</i>	80:20	199	51

2.4. Pengaturan Parameter

Pada proses ini, melakukan transformasi dan *adjustment* pada data secara seragam. Proses ini

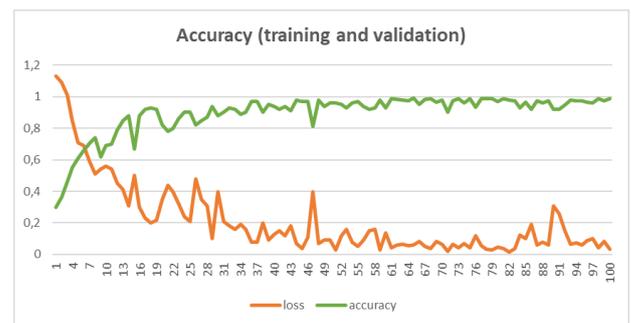
bertujuan untuk meningkatkan variasi data *Train* dengan mengubah data yang ada menjadi bentuk baru, yang secara efektif menambah jumlah sampel yang tersedia untuk pelatihan. Teknik ini digunakan untuk membantu mengatasi masalah *overfitting* dan memperbaiki performa model yang dibangun.

Dengan menggunakan fungsi-fungsi *preprocessing* seperti *rotation*, *rescale*, *share range*, *horizontal flip*, dll. proses *augmentasi* bagian *Train* dan *Test* dengan jumlah yang tertera agar datanya seragam. Terlihat pada Tabel 3, *input\_shape = (128, 128, 3)* merupakan parameter untuk menentukan ukuran dan dimensi *input* gambar yang akan dimasukkan menyatakan bahwa *input* gambar akan berukuran 128 x 128 piksel, dengan 3 *channel* warna (RGB).

**Tabel 3. Model Convolution Neural Network**

Layer (Type)	Output Shape	Param #
Conv2d (Conv2D)	(None, 128, 128, 48)	1344
Max_Pooling2d (MaxPooling2D)	(None, 63, 63, 48)	0
Conv2d_1 (Conv2D)	(None, 61, 61, 48)	20784
Max_Pooling2d_1 (MaxPooling2D)	(None, 30, 30, 48)	0
Conv2d_2 (Conv2D)	(None, 28, 28, 32)	13856
Max_Pooling2d_2 (MaxPooling2D)	(None, 14, 14, 32)	0
Flatten (Flatten)	(None, 6272)	0
Dropout (Dropout)	(None, 6272)	0
Dense (Dense)	(None, 128)	802944
Dense_1 (Dense)	(None, 64)	8256
Dense_2 (Dense)	(None, 3)	195

2.5. Pengujian Klasifikasi CNN



**Gambar 2. Proses Pengujian**

Gambar 2 merupakan suatu proses pelatihan yang telah selesai. Proses ini memakan waktu 78 jam untuk mencapai 100 *Epoch*. Perlu diketahui bahwa rata-rata per *epoch*-nya memakan waktu 400–500 detik atau setara 6–8 menit. Mengetahui akurasi dan *loss*-nya pada setiap *epoch* yang dilalui. Apabila diteliti, setiap *epoch*-nya rata-rata mengalami inflasi yang tidak terlalu signifikan namun cenderung konstan. Hal ini menandakan mesin mengerjakan tugasnya dengan sangat baik tanpa mengalami permasalahan seperti *overfitting* dan *underfitting*.

**Tabel 4.** Hasil Pengujian

Calculating model CNN accuracy	
Final Loss	0.03 %
Final Accuracy	98.67 %

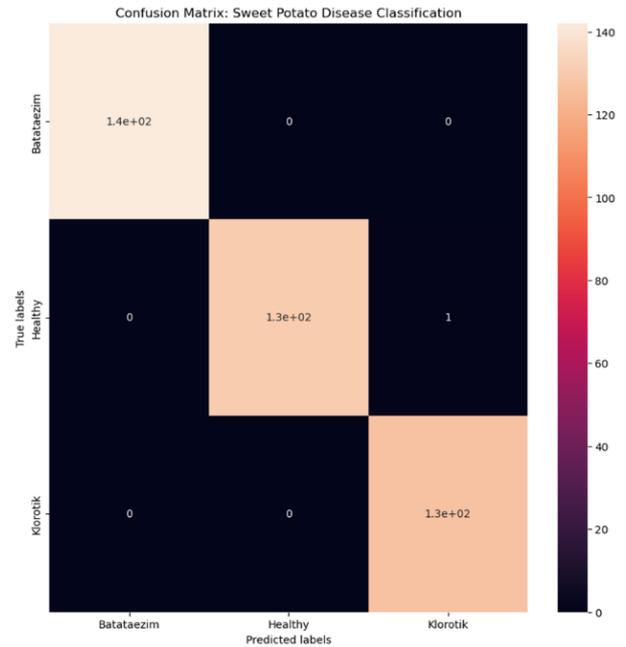
Dapat diketahui bahwa, akurasi pada *Train* dan *Test* menghasilkan akurasi yang sangat baik. Sesuai dengan yang tertulis pada Tabel 4, akurasi *Train* menghasilkan nilai sebesar 98.17% serta *Test* menghasilkan nilai sebesar 98.67%. Serta sebaliknya, nilai *loss* yang dihasilkan relatif sangat kecil yakni untuk *Train* sebesar 0.04 % dan *Test* sebesar 0.03%. Jadi, ketika akurasi tinggi dan *loss* kecil berarti model mampu mengklasifikasikan sebagian besar data dengan benar dan secara umum, prediksi model sangat dekat dengan nilai sebenarnya.

2.6. Evaluation

Model yang digunakan telah menghasilkan keluaran seperti apa yang diharapkan. Pada Tabel 5 *Classification Report* dapat mengetahui nilai matriks yang dihasilkan pada setiap kelas data yang berbeda. Jika dilihat dari matriks Presisi, kelas *Batataezim* dan *Healthy* mampu menghasilkan nilai paling tinggi sebesar 100%. Matriks *recall* paling tinggi diperoleh oleh kelas *Batataezim* dan *Klorotik* dengan nilai 100%, F1-Score terbaik diraih oleh semua kelas *presentase* 100%, serta akurasi keseluruhan sebesar 100%. Dapat disimpulkan bahwa kelas *Batataezim* mampu menghasilkan nilai terbaik dari kelas atau jenis penyakit yang lainnya.

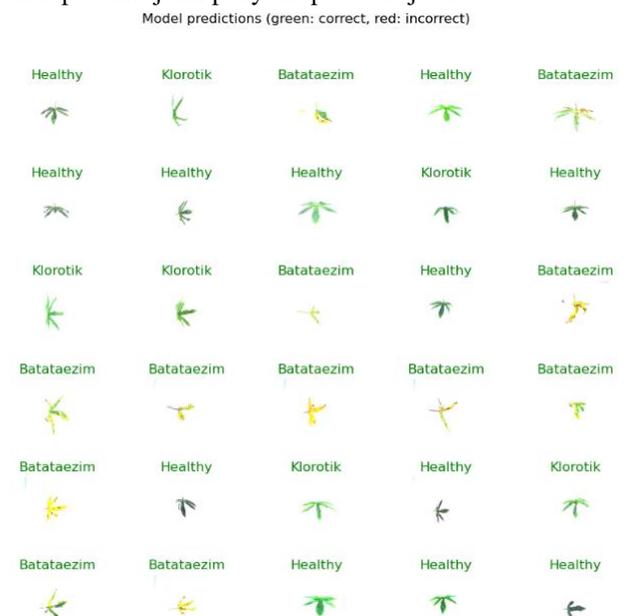
**Tabel 5.** Classification Report

	Precision	Recall	F1-Score	Support
<b>Batataezim</b>	1.00	1.00	1.00	142
<b>Healthy</b>	1.00	0.99	1.00	131
<b>Klorotik</b>	0.99	1.00	1.00	127
<b>Accuracy</b>			1.00	400
<b>Macro avg</b>	1.00	1.00	1.00	400
<b>Weighted avg</b>	1.00	1.00	1.00	400

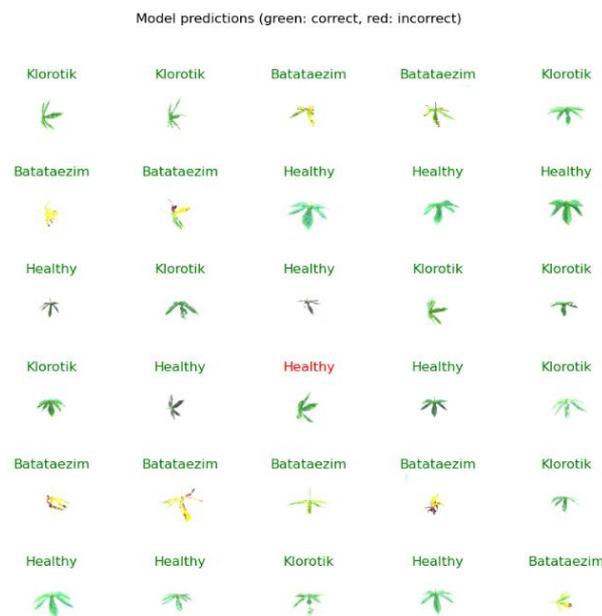


**Gambar 3.** Diagram confusion matrix

Terlihat pada *Diagram Confusion Matrix* (Gambar 3) merepresentasikan seberapa besar model dapat mengklasifikasikan dengan baik pada setiap kelasnya. Representasi warna menyatakan bahwa semakin pekat warna tersebut maka semakin banyak pula nilainya. Hasil dari *Classification Report* tadi selaras dengan grafik ini. Kelas *Batataezim* mampu menghasilkan nilai paling banyak di antara yang lainnya, dan setelah itu disusul oleh kelas *Healthy* dan *klorotik*. Jika diteliti lebih jauh, kesalahan prediksi terbanyak terdapat pada kelas *Klorotik* yang seharusnya dikategorikan kelas *Healthy* senilai 1, kemudian sebaliknya pada kelas *Healthy* yang seharusnya termasuk ke dalam kelas *Klorotik* sebanyak 1. secara keseluruhan, model ini sangat baik untuk memprediksi jenis penyakit pada ubi jalar.



**Gambar 4.** Model Predictions Correct



**Gambar 5.** Model Predictions Incorrect

Model prediksi digambarkan dengan mengidentifikasi kelas setiap data citra yang dijadikan data uji. Gambar 4 menggambarkan hasil prediksi data uji yang sesuai dengan harapan. Penamaan ditandai dengan label yang berwarna hijau. Sementara Gambar 5 Terdapat hasil prediksi yang tidak sejalan dengan indikator yang ditunjukkan pada data sehat, yang ditandai dengan warna merah pada label gambarnya.

### 3. Kesimpulan

Kinerja metode CNN dalam pengolahan citra daun ubi jalar. Proses ini melibatkan pemahaman dalam mendeteksi akurasi data, evaluasi kinerja model, dan dokumentasi keseluruhan proses yang dihasilkan. Tingkat akurasi metode CNN dalam mendeteksi penyakit pada daun ubi jalar dalam penelitian ini, melibatkan citra daun ubi jalar berdasarkan 3 klasifikasi penyakit dan 750 sampel data, berhasil mencapai tingkat akurasi sebesar 98,67%. Serta nilai *loss* yang dihasilkan relatif sangat kecil yakni untuk *Train* sebesar 0.04 % dan *Test* senilai 0.03%. Jadi, ketika akurasi tinggi dan *loss* kecil berarti secara umum model mampu mengklasifikasikan sebagian besar data dengan benar, Hasil penelitian akan memberikan wawasan tentang kemampuan metode CNN dalam mendeteksi penyakit pada tanaman ubi jalar, yang dapat memiliki implikasi penting dalam pengawasan pertanian, identifikasi penyakit tanaman, dan pengambilan keputusan untuk tindakan perawatan tanaman yang lebih tepat.

### Daftar Pustaka

Singh, U. P., Chouhan, S. S., Jain, S., & Jain, S. (2019). *Multilayer convolution neural network for the classification of mango leaves infected by*

*anthracnose disease*. IEEE access, 7, 43721-43729.

Hartini, R. (2008). *Hukum Kepailitan Edisi Revisi Berdasarkan Undang-Undang Nomor 37 Tahun 2004 Tentang Kepailitan dan Penundaan Kewajiban Pembayaran Utang*.

Kumar, R., Baloch, G., Buriro, A. B., & Bhatti, J. (2021). *Fungal blast disease detection in rice seed using machine learning*. *International Journal of Advanced Computer Science and Applications*, 12(2).

Astiningrum, M., Arhandi, P. P., & Ariditya, N. A. (2020). *Identifikasi penyakit pada daun tomat berdasarkan fitur warna dan tekstur*. *Jurnal Informatika Polinema*, 6(2), 47-50.

Permadi, J., & Harjoko, A. (2018). *Identifikasi Penyakit Cabai Berdasarkan Gejala Bercak Daun dan Penampakan Conidia Menggunakan Probabilistic Neural Network*. SEMNASKIT 2015.

Hamidah, N., Legowo, A. M., & Anwar, S. (2015). *Tepung ubi kayu (manihot esculenta) dan tepung tempe kedelai mempengaruhi pengembangan volume dan mutu gizi protein roti tawar*. *Jurnal Gizi Indonesia (The Indonesian Journal of Nutrition)*, 4(1), 55-62.

Castelluccio, M., Poggi, G., Sansone, C., & Verdoliva, L. (2015). *Land use classification in remote sensing images by convolutional neural networks*. arXiv preprint arXiv:1508.00092.

Narkhede, S. (2018). *Understanding confusion matrix*. *Towards Data Science*, 180(1), 1-12.

Darma, P. (2010). *Pengolahan Citra Digital*, CV. Andi Offset, Yogyakarta.

Tempola, F., Muhammad, M., & Khairan, A. (2018). *Perbandingan Klasifikasi Antara KNN dan Naive Bayes pada Penentuan Status Gunung Berapi dengan K-Fold Cross Validation*. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 5(5), 577-584.