

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Pada era digital saat ini, klasifikasi citra menjadi salah satu komponen penting dalam pengembangan sistem berbasis kecerdasan buatan. Proses klasifikasi citra memungkinkan suatu sistem untuk melakukan identifikasi serta pembedaan objek secara otomatis berdasarkan pola maupun karakteristik visual tertentu. Klasifikasi citra memiliki peranan penting karena tanpa adanya proses ini, kumpulan data citra dalam jumlah besar hanya akan menjadi data mentah yang sulit dimanfaatkan secara optimal. Kondisi tersebut menyebabkan proses analisis menjadi lebih kompleks, meningkatkan potensi kesalahan manusia, serta menyulitkan integrasi ke dalam sistem pengambilan keputusan berbasis otomatis. Melalui proses klasifikasi, setiap citra dapat diberikan label sesuai dengan kategori yang relevan, sehingga mampu meningkatkan efisiensi serta konsistensi dalam pengolahan data visual. Secara umum, klasifikasi citra dibedakan menjadi dua pendekatan utama, yaitu klasifikasi terbimbing (*supervised*) dan klasifikasi tidak terbimbing (*unsupervised*). Klasifikasi terbimbing diterapkan pada data yang telah memiliki label, sehingga model dapat mempelajari pola dari data tersebut dan melakukan prediksi terhadap data baru. Sebaliknya, klasifikasi tidak terbimbing digunakan untuk mengidentifikasi pola atau struktur tertentu pada data yang belum memiliki label, salah satunya melalui teknik *clustering* [1].

Sebelum dilakukan proses klasifikasi, citra digital perlu melewati beberapa tahapan pengolahan citra (*image processing*) agar informasi visual yang terkandung di dalamnya dapat dikenali serta dipahami oleh komputer. Tahap berikutnya adalah *pra*-pemrosesan, yang mencakup, perubahan ukuran citra (*resizing*), serta augmentasi data seperti rotasi dan pencerminan guna meningkatkan variasi data latih[2]. Selanjutnya dilakukan proses ekstraksi fitur, yaitu tahapan untuk mengubah informasi visual menjadi representasi numerik yang dapat diproses oleh algoritma pembelajaran mesin. Citra hasil pengolahan tersebut kemudian direpresentasikan dalam bentuk matriks numerik (*array*) yang menggambarkan intensitas piksel maupun karakteristik visual lainnya. Representasi numerik ini selanjutnya menjadi dasar dalam proses klasifikasi, baik dengan pendekatan

*machine learning* maupun *deep learning*[3]. Pada penerapan modern, pendekatan *deep learning*, khususnya Convolutional Neural Network (CNN), banyak digunakan karena mampu mengekstraksi serta mengenali pola visual secara otomatis tanpa memerlukan rekayasa fitur secara manual, serta memberikan hasil yang lebih stabil dan akurat pada data dalam jumlah besar.

*Convolutional Neural Network (CNN)* adalah jenis jaringan saraf tiruan yang dirancang untuk mengolah data berbentuk *grid* seperti citra digital. *CNN* secara otomatis mengekstraksi fitur visual penting seperti tepi, dan bentuk melalui lapisan *convolution*, aktivasi (*ReLU*), *pooling*, dan *fully connected* [4]. Kombinasi lapisan-lapisan ini memungkinkan *CNN* membangun representasi fitur secara bertingkat, dari yang sederhana hingga kompleks.

Daun cabai jamu (*Piper retrofractum Vahl*) memiliki karakteristik visual tertentu yang membedakannya dengan daun tanaman lain yang sudah diteliti. Pada kondisi sehat, daun berwarna hijau merata dan tidak menunjukkan perubahan bentuk. Namun ketika terserang penyakit, muncul gejala seperti bercak berwarna coklat keabu-abuan pada bercak daun serta perubahan bentuk daun yang menggulung atau menyempit pada keriting daun. Perbedaan antar kondisi tersebut sering kali terlihat samar karena warna daun masih relatif mirip dan perubahan bentuk tidak selalu ekstrem, sehingga menyulitkan proses identifikasi penyakit secara visual [5].

Kesamaan visual antar kelas penyakit daun cabai jamu menjadi tantangan dalam proses klasifikasi citra, karena perbedaan antar kondisi sering kali hanya tampak pada detail visual yang halus seperti pola bercak, tekstur permukaan, atau perubahan bentuk daun[5]. Permasalahan ini semakin kompleks karena citra diperoleh langsung dari kamera dan masih berupa data mentah yang tidak dapat langsung digunakan untuk masuk ke arsitektur model untuk klasifikasi citra yang mensyaratkan citra dengan ukuran yang seragam, tersusun dalam struktur data numerik, serta terfokus pada objek daun. Oleh karena itu, diperlukan proses pra-pemrosesan citra yang berfokus pada penyeragaman dan pemfokusan objek daun agar informasi visual penting tetap terjaga dan dapat dimanfaatkan secara optimal dalam proses klasifikasi penyakit daun cabai jamu.

Pendekatan *deep learning*, khususnya *Convolutional Neural Network* (CNN), banyak digunakan dalam klasifikasi citra karena mampu mengenali pola visual secara otomatis tanpa memerlukan ekstraksi fitur manual. *CNN* mampu mempelajari fitur sederhana seperti tepi dan warna, hingga fitur kompleks seperti tekstur dan bentuk daun secara bertingkat. Kemampuan ini menjadikan CNN lebih sesuai untuk menangani citra daun yang memiliki perbedaan visual tipis antar kelas. Dengan demikian, penggunaan CNN menjadi pendekatan yang relevan untuk mengatasi permasalahan klasifikasi penyakit daun cabai jamu.

Berbagai arsitektur *CNN* telah dikembangkan untuk meningkatkan efisiensi dan *accuracy* klasifikasi citra. Beberapa arsitektur populer meliputi *AlexNet*, *VGGNet*, *GoogLeNet (Inception)*, *ResNet*, *MobileNet*, dan *DenseNet*. Masing-masing arsitektur memiliki karakteristik dan keunggulan tersendiri, tergantung pada kompleksitas tugas, ukuran data, dan keterbatasan komputasi. Dalam penelitian ini, digunakan *InceptionV3*, yaitu pengembangan dari arsitektur *GoogLeNet* yang dikembangkan oleh *Google Brain* [6].

Pemilihan *InceptionV3* sebagai arsitektur *CNN* dalam penelitian ini didasarkan memiliki ukuran *input* yang lebih besar yaitu  $299 \times 299$  piksel, dibandingkan dengan arsitektur lain seperti *VGG* ( $224 \times 224$  piksel)[7]. Penggunaan ukuran *Resize* yang tinggi ini memberikan beberapa keuntungan penting, antara lain memungkinkan model menangkap lebih banyak detail visual seperti tekstur halus dan pola gejala penyakit yang kecil, meningkatkan potensi *accuracy* klasifikasi. *Inception* di generasi awal memiliki 22 layer dan ukuran filter mulai dari  $1 \times 1$ ,  $3 \times 3$  sampai  $5 \times 5$  lalu pada tahun 2015 *Google* meningkatkan model *Inception* menjadi *Inception V3* yang memiliki total 48 lapisan layer [8]. Dalam hal ini menjadikan *Inception V3* cocok digunakan dalam berbagai implementasi klasifikasi citra.

Proses klasifikasi menggunakan *InceptionV3* diawali dengan memasukkan citra yang telah dikonversi menjadi data numerik ke dalam jaringan[3]. Data ini kemudian melewati beberapa lapisan *convolution* awal yang bertugas mengenali fitur visual dasar seperti tepi, bentuk, dan warna. Selanjutnya, data masuk ke dalam modul *Inception*, yang merupakan inti dari arsitektur ini. Dalam setiap modul *Inception*, citra diproses secara paralel melalui beberapa jalur dengan filter berukuran berbeda misalnya  $1 \times 1$ ,  $3 \times 3$ , dan  $5 \times 5$  piksel serta jalur *pooling* seperti

max pooling. Penggunaan beberapa jalur ini memungkinkan jaringan untuk menangkap fitur dari berbagai skala secara bersamaan, baik fitur lokal maupun global. Hal ini meningkatkan kemampuan model dalam mengenali pola kompleks yang muncul pada berbagai jenis gejala penyakit. Hasil dari seluruh jalur dalam satu modul kemudian digabungkan (*concatenate*) menjadi satu keluaran fitur terpadu [8]. Proses ini berlangsung secara bertingkat dalam beberapa modul Inception, sehingga menghasilkan representasi fitur yang semakin kaya dan mendalam. Representasi akhir ini kemudian diteruskan ke lapisan fully connected yang berfungsi untuk melakukan klasifikasi akhir terhadap citra.

Salah satu permasalahan dalam penelitian klasifikasi citra adalah menentukan apakah suatu metode benar-benar sesuai dengan objek yang diteliti. Berbagai penelitian sebelumnya menunjukkan bahwa arsitektur InceptionV3 berhasil digunakan untuk mengklasifikasikan penyakit daun pada beberapa tanaman lain, seperti kentang, tomat, dan padi [9]. Namun, keberhasilan tersebut belum tentu dapat langsung diterapkan pada objek yang berbeda, karena setiap jenis tanaman memiliki karakteristik visual daun dan pola penyakit yang tidak sama. Hingga saat ini, belum terdapat penelitian yang menerapkan *InceptionV3* pada citra daun cabai jamu, sehingga belum diketahui apakah metode ini mampu mengenali dan membedakan gejala penyakit daun cabai jamu dengan baik.

Permasalahan ini menekankan pentingnya pemilihan metode klasifikasi citra yang tepat agar dapat membedakan fitur visual yang sangat mirip pada daun cabai jamu. Oleh karena itu, penelitian ini dilakukan untuk mengklasifikasikan citra daun cabai jamu berdasarkan gejala penyakitnya dengan menggunakan arsitektur *InceptionV3*. *InceptionV3* dipilih karena mendukung proses ekstraksi fitur visual secara lebih detail, sehingga model mampu menangkap karakteristik daun secara lebih optimal untuk proses klasifikasi [7]. Dengan pendekatan ini, diharapkan hasil klasifikasi menjadi lebih akurat dan konsisten, sehingga memberikan kontribusi yang signifikan dalam pengolahan citra digital.

Beberapa penelitian tentang klasifikasi penyakit daun banyak dilakukan. Pada tahun 2020, penelitian [10] mendeteksi penyakit daun kentang menggunakan *InceptionV3*. Tanaman yang digunakan adalah tanaman kentang dengan data memiliki sekitar 1000 gambar daun yang terserang penyakit hawar daun, 1000

gambar penyakit daun busuk dan 152 gambar tanaman sehat. Penelitian ini Menghasilkan *accuracy* sebesar 90% dari dataset uji dalam klasifikasi.

Pada tahun 2024 penelitian [11] menggunakan Arsitektur *InceptionV3* dengan menggunakan *optimizer* Adam, SGD, dan *RMS Prop* yang bertujuan mengklasifikasi penyakit pada daun tomat. Penelitian ini menggunakan dataset citra daun tomat sebanyak 11000 yang dibagi 10 kelas yaitu data citra daun sehat, data citra daun penyakit Bercak daun, data citra daun penyakit *target spot*, data citra daun penyakit *bacterial spot*, data citra daun penyakit *yellow leaf curl virus*, data citra daun penyakit *late blight*, data citra daun penyakit *leaf mold*, data citra daun penyakit *early blight*, data citra daun penyakit *spider mites*, dan data citra daun penyakit *septoria leaf spot*. Hasil pengujian menunjukkan *accuracy* sebesar 93.8% dengan model optimal menggunakan *optimizer* Adam.

Pada tahun 2023, penelitian [9] mengklasifikasikan penyakit daun tanaman padi menggunakan arsitektur *InceptionV3*. Penelitian ini menggunakan dataset berjumlah 1630 data yang dibagi menjadi 3 kelas yaitu penyakit Hawar Daun Bakteri, Bercak Coklat (*Browspot*), dan sehat. Hasil dari penelitian ini menunjukkan hasil yang sangat baik di angka 98%.

Berdasarkan penelitian tersebut, penelitian ini bertujuan untuk mengklasifikasi penyakit pada tanaman cabai jamu berdasarkan citra daun menggunakan *Convolutional Neural Network (CNN)* dengan arsitektur *InceptionV3*. Dan diharapkan metode ini dapat menghasilkan *accuracy* yang baik serta dapat melakukan perawatan pada tanaman cabai jamu dengan tepat[12].

## **1.2 Perumusan Masalah**

Permasalahan yang ada, solusi/metode usulan, dan pertanyaan penelitian yang harus dijawab dalam penelitian ini.

### **1.2.1 Permasalahan**

Permasalahan dalam penelitian ini adalah belum diketahuinya kecocokan arsitektur *InceptionV3* dalam mengklasifikasikan penyakit pada daun cabai jamu yang memiliki kemiripan visual antar kelas penyakit. Permasalahan tersebut semakin kompleks karena citra daun cabai jamu diperoleh langsung dari kamera dan masih berupa data mentah, sehingga diperlukan proses penyeragaman dan pemfokusan objek agar citra dapat digunakan untuk masuk ke arsitektur model

klasifikasi citra secara optimal. Oleh karena itu, perlu dilakukan pengujian untuk mengetahui apakah InceptionV3 mampu membedakan penyakit daun cabai jamu secara akurat dan konsisten.

### 1.2.2 Solusi Permasalahan

Solusi yang diusulkan adalah menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur *InceptionV3* untuk mengklasifikasikan citra penyakit pada daun cabai jamu. *InceptionV3* dipilih karena mampu mengekstraksi fitur visual secara mendalam dan mengenali pola gejala yang halus serta lokal. Dengan ukuran input citra yang lebih besar (299×299 piksel), model ini dapat menangkap detail penting seperti bintik, perubahan warna pada daun, sehingga meningkatkan *accuracy* dan konsistensi klasifikasi pada gejala pada daun cabai jamu.

### 1.2.3 Pertanyaan Penelitian

1. Bagaimana kinerja arsitektur *InceptionV3* dalam mengklasifikasikan penyakit pada daun cabai jamu berdasarkan nilai *accuracy*, *precision*, *recall*, dan *F1-score*?
2. Bagaimana pengaruh variasi *learning rate*, *batch size*, dan *epoch* terhadap kinerja *InceptionV3* dalam klasifikasi penyakit daun cabai jamu?

## 1.3 Tujuan dan Manfaat

### 1.3.1 Tujuan Penelitian

1. Mengetahui kinerja arsitektur *Convolutional Neural Network* (CNN) *InceptionV3* dalam mengklasifikasikan penyakit daun cabai jamu (*Piper retrofractum* Vahl) berdasarkan nilai *accuracy*, *precision*, *recall*, dan *F1-score*.
2. Menganalisis pengaruh variasi parameter pelatihan, yaitu *learning rate*, *batch size*, dan *epoch* terhadap kinerja klasifikasi penyakit daun cabai jamu menggunakan arsitektur *InceptionV3*.

### 1.3.2 Manfaat

Penelitian ini bermanfaat untuk mengetahui kinerja arsitektur *Convolutional Neural Network* (CNN) *InceptionV3* dalam mengklasifikasikan penyakit daun cabai jamu (*Piper retrofractum* Vahl) berdasarkan nilai *accuracy*, *precision*, *recall*, dan *F1-score*, serta mengetahui pengaruh variasi parameter pelatihan, yaitu *learning rate*, *batch size*, dan *epoch* terhadap kinerja model.

### 1.4 Batasan Masalah

Batasan masalah dalam penelitian ini adalah sebagai berikut:

1. Pelabelan data dilakukan secara manual dengan melibatkan pakar di bidang pertanian oleh Syaiful Khoiri, S.P.,M.S.i untuk memastikan keakuratan kelas penyakit daun.
2. Data citra dibagi ke dalam tiga kelas, yaitu bercak daun, daun keriting, dan daun sehat.
3. Pengambilan data

Tabel 1. 1 Perbedaan Aspek Pengambilan Data

| Aspek                           | Kamera A<br>(vivo)                                    | Kamera B<br>(Samsung)                               | Dampak                      |
|---------------------------------|-------------------------------------------------------|-----------------------------------------------------|-----------------------------|
| Brightness                      | 0                                                     | 5.64                                                | Perbedaan kontras objek[13] |
| Format                          | .jpg (3120 x 4160)                                    | .jpg (3024 x 4032)                                  | Berbeda ukuran              |
| Lokasi                          | perkebunan petani di Desa Aengbaja Kenek              | Desa Kebunagung                                     | Berbeda lingkungan          |
| Cuaca                           | Cerah                                                 | Cerah                                               | Kondisi lingkup cuaca       |
| Jumlah Gambar                   | 254                                                   | 113                                                 | Jumlah dataset              |
| Jumlah Gambar setelah pelabelan | 54(bercak daun), 100 (keriting daun), 100(daun sehat) | 53(bercak daun), 30 (daun keriting), 47(daun sehat) | Jumlah dataset              |

4. Jumlah data yang digunakan keseluruhan 384 data dan terbagi menjadi 3 kelas yaitu 147 Daun Sehat, 130 daun keriting, dan 107 bercak daun.
5. Metode yang digunakan dalam penelitian ini adalah *InceptionV3*.

### 1.5 Sistematika Laporan

Sistematika penulisan laporan tugas akhir ini adalah sebagai berikut :

#### BAB I: PENDAHULUAN

Bab ini menjelaskan tentang latar belakang penelitian, rumusan masalah, solusi permasalahan, batasan masalah, tujuan dan manfaat, dan sistematika proposal.

**BAB II: KAJIAN PUSTAKA**

Bab ini menjelaskan tentang landasan teori yang menjadi landasan dalam penyusunan penelitian ini meliputi landasan teori tanaman daun cabai jamu, Citra Digital, *Convolutional Neural Network (CNN)*, arsitektur *InceptionV3*.

**BAB III: METODOLOGI PENELITIAN**

Pada bab ini menguraikan metodologi yang diterapkan dalam penelitian ini. Bagian ini akan membahas tentang struktur penelitian, mencakup aspek seperti objek penelitian dan sumber data, serta prosedur yang terlibat dalam penelitian, termasuk pemahaman sistem, studi literatur, dan perancangan sistem.

**BAB IV: HASIL DAN PEMBAHASAN**

Bab ini menjabarkan tentang hasil implementasi dari sistem. Hasil dari implementasi terdiri dari yaitu: lingkungan uji coba, tahap-tahap pembuatan program, dan hasil analisis uji coba.

**BAB V: PENUTUP**

Bab ini memuat hasil kesimpulan dari penelitian yang telah dilakukan, disesuaikan dengan pertanyaan penelitian, dan saran terkait pengembangan model selanjutnya.