

# **BAB I**

## **PENDAHULUAN**

### **1.1. Latar Belakang**

Secara botani, rimpang (rhizome) merupakan batang yang mengalami modifikasi sehingga tumbuh mendatar di permukaan tanah dan tampak seperti tunas baru [1]. Kelompok tanaman ini sangat akrab dan banyak digunakan oleh masyarakat, baik untuk kebutuhan pangan maupun kesehatan [2]. Namun, kemiripan bentuk dan penampakan antarjenis rimpang menyebabkan proses pembedaan setiap jenis menjadi tidak mudah [3]. Kesamaan visual tersebut menimbulkan tantangan tersendiri dalam tahap identifikasi manual [4].

Proses pengenalan jenis rimpang yang dilakukan secara manual cenderung kurang konsisten dan rentan menimbulkan kekeliruan klasifikasi karena banyak spesies memiliki tampilan yang hampir sama [5]. Dalam proses klasifikasi rimpang, diperlukan metode yang mampu membedakan setiap jenis secara akurat untuk meningkatkan efisiensi pengolahan [6]. Identifikasi yang tepat sangat penting karena setiap jenis rimpang memiliki karakteristik morfologi dan kandungan senyawa yang berbeda [7]. Oleh karena itu, penelitian ini berfokus pada pengembangan metode klasifikasi yang lebih akurat untuk mengelompokkan rimpang berdasarkan ciri khasnya [8]. Pemanfaatan sistem klasifikasi berbasis citra diharapkan dapat membantu pengguna dalam membedakan jenis rimpang dengan cara yang lebih mudah dan terstandar [6].

Perkembangan deep learning, terutama arsitektur Convolutional Neural Network (CNN), telah menunjukkan kinerja yang baik dalam berbagai tugas klasifikasi citra, termasuk pengenalan rimpang. Beberapa studi terdahulu melaporkan bahwa model CNN seperti AlexNet mampu mencapai akurasi sekitar 97% untuk klasifikasi beberapa jenis rimpang. Penelitian lain yang membandingkan MobileNet dan InceptionV3 pada dataset rimpang juga menunjukkan bahwa kedua arsitektur tersebut dapat menghasilkan akurasi hingga sekitar 98%, meskipun InceptionV3 membutuhkan sumber daya komputasi yang lebih besar. Temuan-temuan ini memperlihatkan bahwa CNN berpotensi kuat digunakan untuk sistem identifikasi rimpang otomatis [9]. Selain itu, arsitektur

*MobileNet* dan *InceptionV3* berhasil mengklasifikasikan lima jenis rimpang (kunyit, jahe, laos, kencur, dan kunci) dengan *accuracy* 98%, meskipun *InceptionV3* membutuhkan waktu komputasi lebih lama [10]. Dalam penelitian ini, ekstraksi fitur tekstur menggunakan *Local Binary Pattern* (LBP) diterapkan untuk menangkap pola unik permukaan rimpang [1]. Dengan mengembangkan lebih lanjut metode *deep learning*, penelitian ini membandingkan antara arsitektur CNN *MobileNetV3-Large* dan *EfficientNetB2* dalam klasifikasi rimpang berbasis *Local Binary Pattern*. Pendekatan ini bertujuan untuk mengevaluasi keunggulan masing-masing arsitektur CNN dalam meningkatkan akurasi dan efisiensi klasifikasi.

Dalam beberapa tahun terakhir, *machine learning* khususnya *Local Binary Pattern*, telah dimanfaatkan untuk pengenalan jenis tanaman karena mampu mengekstraksi pola tekstur lokal pada permukaan daun maupun organ tanaman secara efektif [11]. Penelitian [1] menunjukkan bahwa meskipun *Local Binary Pattern* dapat terpengaruh oleh gangguan pada gambar, metode ini tetap efektif dalam mengenali perbedaan tekstur yang halus pada tanaman.

Dalam Penelitian ini menggunakan arsitektur CNN *MobileNetV3-Large* dan *EfficientNetB2*. Arsitektur CNN *MobileNetV3-Large* dirancang untuk memberikan efisiensi tinggi dalam komputasi dengan ukuran model yang lebih kecil, namun tetap menghasilkan akurasi yang baik, sehingga cocok digunakan untuk klasifikasi gambar dalam perangkat dengan sumber daya terbatas [12]. Sementara itu, *EfficientNetB2* merupakan model yang lebih efisien dalam hal penggunaan parameter dan komputasi, dengan kemampuan generalisasi yang lebih baik, sehingga dapat meningkatkan akurasi klasifikasi pada dataset yang lebih kompleks [13].

Berikut beberapa penelitian sebelumnya telah dilakukan dan memiliki keterkaitan dengan metode yang dipakai. Penelitian oleh [14] membahas klasifikasi spesies tanaman sukulen menggunakan arsitektur *MobileNetV3-Large*. Model ini diuji pada dataset 4.500 gambar dengan parameter *input shape* 224x224x3, *batch size* 64, *optimizer adam*, *learning rate* 0.0001, dan 30 *epoch*. Hasilnya, model mencapai *accuracy* 99,11%, dengan beberapa spesies seperti *agave parryi* dan *crassula ovata* memperoleh *accuracy* 100%. Meskipun terdapat ketidakakuratan *minor* pada *kalanchoe luciae* dan *sempervivum tectorum*, model ini tetap unggul

dibandingkan metode sebelumnya. Penelitian ini membuktikan potensi *MobileNetV3-Large* dalam identifikasi otomatis tanaman sukulen untuk pertanian dan konservasi.

Penelitian yang dilakukan [15] mengeksplorasi penggunaan *EfficientNetB2* dengan *transfer learning* untuk klasifikasi 8 jenis mangga. Dengan dataset 1.600 gambar yang mencakup data pelatihan, pengujian, dan validasi, model ini mencapai *accuracy* 98%. Temuan ini menunjukkan efektivitas *transfer learning* dalam meningkatkan kinerja model, terutama dalam mengenali variasi visual mangga berdasarkan ciri unik seperti ukuran dan bentuk, serta potensinya untuk mendukung konservasi varietas mangga.

Penelitian yang dilakukan [16] mengembangkan metode deteksi penyakit daun tanaman dengan mengintegrasikan arsitektur *MobileNetV2* dan teknik ekstraksi fitur *Local Binary Pattern* (LBP). Dengan memanfaatkan dataset *plantvillage* yang berisi 31.361 citra daun dari berbagai tanaman dan penyakit, pendekatan ini berhasil mencapai *accuracy* 96%, *precision* 90%, *recall* 89%, dan *f1-score* sebesar 89%. Integrasi *Local Binary Pattern* terbukti mampu meningkatkan kemampuan model dalam menangkap informasi tekstur penting dari daun, sementara visualisasi *grad-cam* memberikan interpretabilitas yang lebih baik terhadap keputusan model. Temuan ini menunjukkan potensi metode gabungan *MobileNet* dan *Local Binary Pattern* sebagai solusi yang andal dan efisien untuk deteksi penyakit tanaman secara otomatis.

Berdasarkan penelitian sebelumnya, pembaruan dari penelitian ini terletak pada penerapan teknik ekstraksi fitur *Local Binary Pattern* (LBP) yang dikombinasikan dengan dua arsitektur *Convolutional Neural Network* yaitu *MobileNetV3-Large* dan *EfficientNetB2* untuk klasifikasi jenis rimpang. Selain peningkatan pada sisi metode, penelitian ini juga memperluas cakupan objek dengan menggunakan delapan jenis rimpang yang meliputi jahe, kunyit, kencur, kunci, lengkuas, temulawak, temu hitam, dan bangle. Delapan rimpang tersebut dipilih karena merupakan komoditas biofarmaka yang umum digunakan masyarakat Indonesia serta memiliki kemiripan visual yang tinggi sehingga rentan menimbulkan kesalahan identifikasi. Jumlah kelas ini lebih banyak dibandingkan penelitian sebelumnya yang umumnya hanya mengklasifikasikan lima hingga tujuh

jenis rimpang, sehingga perluasan cakupan menjadi salah satu kontribusi penting dalam penelitian ini. Penelitian ini bertujuan untuk mengukur kecepatan dan akurasi dari kedua arsitektur *Convolutional Neural Network* yang dipadukan dengan *Local Binary Pattern* (LBP) serta mengevaluasi sejauh mana metode ekstraksi fitur tersebut berperan dalam meningkatkan performa klasifikasi. Hipotesis dari penelitian ini menyatakan bahwa penerapan *Local Binary Pattern* pada kedua arsitektur tersebut mampu meningkatkan keseimbangan antara akurasi dan efisiensi dalam sistem klasifikasi citra rimpang.

### 1.2. Rumusan Masalah

Berdasarkan latar belakang, dapat di buat rumusan masalah sebagai berikut:

1. Bagaimanakah perbandingan kinerja *MobileNetV3-Large* dan *EfficientNetB2* pada klasifikasi jenis rimpang, baik pada kondisi yang tidak menggunakan maupun menggunakan penambahan ekstraksi fitur *Local Binary Pattern* (LBP)?
2. Bagaimanakah pengaruh variasi *learning rate* (0.1, 0.01, 0.001 dan 0.0001) terhadap kinerja *MobileNetV3-Large* dan *EfficientNetB2* pada klasifikasi jenis rimpang, baik pada kondisi yang tidak menggunakan maupun menggunakan penambahan ekstraksi fitur *Local Binary Pattern* (LBP)?
3. Arsitektur manakah yang menunjukkan kinerja lebih baik untuk klasifikasi jenis rimpang antara *MobileNetV3-Large* dan *EfficientNetB2*, baik pada kondisi yang tidak menggunakan maupun menggunakan penambahan ekstraksi fitur *Local Binary Pattern* (LBP)?

### 1.3. Tujuan Penelitian

Berdasarkan penjelasan pada rumusan masalah di atas, tujuan dari penelitian ini adalah sebagai berikut:

1. Mengetahui perbandingan kinerja model *MobileNetV3-Large* dan *EfficientNetB2* dalam klasifikasi jenis rimpang pada citra asli dan citra dengan penambahan ekstraksi fitur *Local Binary Pattern* (LBP).
2. Menganalisis pengaruh variasi nilai *learning rate* (0.1; 0.01; 0.001; dan 0.0001) terhadap kinerja model *MobileNetV3-Large* dan *EfficientNetB2* dalam klasifikasi jenis rimpang pada citra asli serta citra dengan penambahan ekstraksi fitur *Local Binary Pattern* (LBP).

3. Mengidentifikasi arsitektur yang menunjukkan kinerja lebih baik dalam klasifikasi jenis rimpang antara *MobileNetV3-Large* dan *EfficientNetB2*, baik pada kondisi tanpa penambahan maupun dengan penambahan ekstraksi fitur *Local Binary Pattern* (LBP).

#### **1.4. Manfaat Penelitian**

Berdasarkan penjelasan pada tujuan penelitian di atas, manfaat dari penelitian ini adalah sebagai berikut:

1. Memberikan kontribusi terhadap pengembangan metode klasifikasi jenis rimpang melalui analisis perbandingan kinerja antara *MobileNetV3-Large* dan *EfficientNetB2*, baik pada kondisi citra asli maupun citra dengan penambahan ekstraksi fitur *Local Binary Pattern* (LBP), sehingga dapat menjadi dasar dalam peningkatan akurasi, kestabilan, serta efisiensi model klasifikasi berbasis citra.
2. Menyediakan gambaran yang jelas mengenai pengaruh variasi nilai *learning rate* (0.1; 0.01; 0.001; dan 0.0001) terhadap kinerja model *MobileNetV3-Large* dan *EfficientNetB2* pada klasifikasi jenis rimpang, baik pada kondisi citra asli maupun citra dengan penambahan ekstraksi fitur *Local Binary Pattern* (LBP), sehingga dapat dijadikan rujukan dalam penentuan parameter pelatihan yang optimal.
3. Menghasilkan informasi yang relevan untuk menentukan arsitektur yang menunjukkan kinerja lebih baik dalam klasifikasi jenis rimpang antara *MobileNetV3-Large* dan *EfficientNetB2*, baik pada kondisi tanpa penambahan maupun dengan penambahan ekstraksi fitur LBP, sehingga dapat dijadikan acuan dalam pemilihan arsitektur model yang sesuai pada penelitian maupun pengembangan aplikasi klasifikasi citra rimpang di masa mendatang.

#### **1.5. Batasan Masalah**

Batasan masalah yang ditentukan untuk melakukan penelitian ini adalah sebagai berikut:

1. Arsitektur CNN yang digunakan dalam penelitian ini adalah *MobileNetV3-Large* dan *EfficientNetB2*, yang dibandingkan performanya dalam

klasifikasi jenis rimpang pada dua kondisi input data, yaitu citra asli dan citra dengan penambahan ekstraksi fitur *Local Binary Pattern* (LBP).

2. Penelitian ini secara khusus membandingkan kinerja dan akurasi kedua arsitektur model tersebut pada klasifikasi jenis rimpang, baik menggunakan citra asli maupun citra yang dilengkapi dengan fitur tambahan hasil ekstraksi fitur LBP.
3. Fokus penelitian ini adalah pada klasifikasi jenis rimpang yang memiliki kemiripan dalam bentuk dan tekstur, dengan memperhatikan karakteristik visual yang khas dari masing-masing jenis tanaman.
4. Jenis rimpang yang diklasifikasikan meliputi 8 jenis rimpang, yaitu jahe, kunyit, kencur, kunci, lengkuas, temulawak, temu hitam, dan bangle.
5. Dataset merupakan data primer yang berjumlah 50 setiap kelasnya dengan total berjumlah 400 data primer, data diperoleh dari pembelian rimpang di Pasar Srimangunan. Setiap rimpang difoto satu per satu menggunakan kamera iPhone 11 dengan jarak 15 cm, diambil antara pukul 12.00–14.00 siang dengan latar belakang kertas HVS putih. Pengambilan gambar juga menggunakan flash dari ponsel untuk memastikan pencahayaan yang merata.
6. Penelitian ini hanya berfokus pada klasifikasi jenis rimpang dan tidak mencakup analisis atau klasifikasi kualitas, ukuran, atau kondisi lain dari rimpang.