

BAB I

PENDAHULUAN

1.1 Latar Belakang

Beras merupakan pangan utama yang sangat penting di Indonesia dan negara-negara Asia lainnya, baik sebagai sumber karbohidrat maupun kontribusinya terhadap perekonomian dan ketahanan pangan. Beragamnya jenis beras di Indonesia, seperti beras Ciherang, Basmati, Rojolele, IR 42, IR 64, Batang Lembang, Beras C4, Menthik Wangi, Beras Solok, Beras Merah, Beras Hitam, dan beras untuk kesehatan (Pusat Data dan Sistem Informasi Pertanian, 2020).

Di sisi lain, isu mengenai beras sintetis yang diduga berbahan dasar plastik sempat menggemparkan masyarakat Indonesia. Informasi yang dilansir melalui Setkab.go.id menunjukkan bahwa kasus ini bukan hanya menyangkut aspek kesehatan, tetapi juga menyentuh ranah keamanan nasional karena dianggap sebagai bentuk teror sosial yang berpotensi menciptakan keresahan publik secara luas. Kasus tersebut menyoroti pentingnya sistem deteksi dan klasifikasi beras yang mampu mengidentifikasi secara dini.

Namun, dalam praktiknya proses identifikasi dan klasifikasi jenis beras masih menghadapi berbagai tantangan. Perbedaan antar varietas beras yang cukup kompleks baik dari segi bentuk, ukuran, warna, maupun tekstur seringkali sulit dikenali secara manual (Alamadani & Indriyana, 2024).

Berdasarkan hasil wawancara dan observasi di Dinas Pertanian dan Ketahanan Pangan Kabupaten Kuningan, diketahui bahwa proses monitoring dan klasifikasi varietas beras masih dilakukan secara manual oleh petugas lapangan, petani, dan masyarakat. Penentuan jenis beras hanya berdasarkan pengamatan fisik dan visual, tanpa dukungan teknologi yang dapat memastikan keakuratan data. Kurangnya pemanfaatan teknologi ini berisiko menimbulkan kesalahan dalam klasifikasi beras, yang dapat berdampak pada kerugian bagi penjual maupun pembeli. Salah satu masalah utama adalah beras yang tidak sesuai dengan varietas aslinya dapat tersebar

di pasaran, yang berpotensi disalahgunakan dan menurunkan kepercayaan konsumen.

Dalam era digital dan perkembangan teknologi informasi, pemanfaatan teknologi berbasis kecerdasan buatan (*Artificial Intelligence*) dan pembelajaran mesin (*machine learning*) sudah mulai meningkat (Surya Adi Laksono, Basuki Rahmat, 2020).

Beberapa penelitian sebelumnya menunjukkan efektivitas berbagai metode dalam klasifikasi beras, seperti penelitian penggunaan algoritma *Support Vector Machine* (SVM) untuk klasifikasi varietas beras Mekongga menghasilkan akurasi sebesar 46,67%, namun setelah dioptimasi dengan *Particle Swarm Optimization* (PSO), akurasi meningkat menjadi 70,83% (Emilia Ayu Wijayanti et al., 2021). Penelitian Gansar Suwanto (2021) yang memperoleh akurasi rata-rata 85,2% dengan metode *Adaptive Neuro Fuzzy Inference System* (ANFIS) dan Sobel pada 140 citra beras (Gansar Suwanto et al., 2021), serta penelitian Ivan Pratama Putra yang menggunakan arsitektur ResNet-50 untuk klasifikasi penyakit daun jagung dengan akurasi tertinggi 90,4% (Putra et al., 2022). Dalam berbagai penelitian, algoritma *Faster R-CNN* ini telah menunjukkan hasil akurasi yang signifikan, seperti yang dicontohkan dalam penelitian yang mencapai akurasi hingga 82,% dalam deteksi kain tenun (Rizki et al., 2021). *Faster R-CNN* menunjukkan akurasi hingga 96,84% dalam deteksi kerusakan jalan, serta konsistensi dalam deteksi retakan jalan 98% (Fajar et al., 2022).

Pada penelitian ini, dilakukan pengujian terhadap tiga faktor utama yang memengaruhi performa sistem, yaitu intensitas cahaya, jarak pengambilan gambar, dan posisi objek. Hasil pengujian menunjukkan bahwa intensitas cahaya, jarak, dan posisi pengambilan gambar berpengaruh terhadap performa *Faster R-CNN* dalam mendeteksi dan mengklasifikasikan jenis beras, dengan akurasi terbaik mencapai 89% pada pencahayaan 250 *lux*, 87% pada jarak 5 *cm*, dan 82% pada posisi pengambilan gambar dari atas.

Berdasarkan latar belakang tersebut, penelitian ini mengambil judul **”Implementasi Algoritma *Faster R-CNN* Pada Deteksi dan Klasifikasi Jenis Beras”**. Metode ini diharapkan mampu mengatasi keterbatasan identifikasi manual

yang selama ini menjadi kendala, sekaligus meningkatkan keandalan proses klasifikasi dengan bantuan teknologi yang relevan.

1.2 Identifikasi Masalah

Berdasarkan latar belakang yang telah disampaikan sebelumnya, berikut adalah identifikasi masalah yang lebih terfokus dan terstruktur:

1. Beras memiliki banyak varietas dengan karakteristik yang berbeda, seperti bentuk, ukuran, warna, dan tekstur, yang menyulitkan proses identifikasi secara manual.
2. Belum adanya pemanfaatan teknologi kecerdasan buatan dan machine learning dalam proses klasifikasi beras secara *realtime* di dinas pertanian kabupaten kuningan.

1.3 Rumusan Masalah

Untuk menegaskan arah penelitian yang akan dilakukan, maka perlu dibuat rumusan masalah berdasarkan latar belakang yang sudah dipaparkan di atas. Rumusan masalah dalam penelitian ini yaitu:

1. Bagaimana tingkat efektivitas algoritma *Faster R-CNN* dalam mendeteksi dan mengklasifikasikan jenis beras ditinjau dari akurasi (*precision, recall, mAP*) serta kecepatan proses deteksi (*inference time*)?
2. Apa saja faktor yang mempengaruhi akurasi deteksi dan klasifikasi jenis beras menggunakan algoritma *Faster R-CNN*?

1.4 Batasan Masalah

Batasan masalah ditetapkan untuk menghindari meluasnya pembahasan maupun penyimpangan dari pokok permasalahan yang diteliti. Adapun batasan masalah dalam penelitian ini adalah sebagai berikut :

1. Penelitian akan terbatas pada sejumlah varietas beras seperti IR 64, Basmati, Rojolele, Ciherang dan Beras Merah.
2. Penelitian ini akan menggunakan citra beras yang diambil dalam kondisi pencahayaan dan resolusi yang baik serta posisi objek beras yang sesuai.
3. Dataset yang digunakan dalam penelitian ini berjumlah 10000 file

gambar terbagi ke dalam 5 kelas.

4. Fokus penelitian ini adalah pada algoritma *Faster R-CNN*.
5. Penelitian ini akan membatasi pengujian pada parameter tertentu dari model *Faster R-CNN*, yaitu jumlah *epoch*, ukuran pada *batch*, dan *learning rate*.
6. Format gambar menggunakan *JPG* dan ukuran tiap gambar 640 x 640.
7. Pengujian dilakukan dengan 3 metode, jarak, cahaya dan posisi.
8. Aplikasi ini berbasis android.

1.5 Tujuan Penelitian

Adapun penelitian ini dilakukan dengan tujuan untuk:

1. Membangun aplikasi deteksi lima varietas beras secara *realtime* dengan berbasis *android*.
2. Mengimplementasikan algoritma *Faster R-CNN* dalam *model deep learning* untuk dapat diterapkan dalam proses deteksi objek beras. Penggunaan metode ini diharapkan mampu meningkatkan akurasi dan efisiensi dalam proses identifikasi berbagai varietas beras.

1.6 Manfaat Penelitian

Berdasarkan tujuan penelitian yang telah ditetapkan, maka penelitian ini diharapkan memberikan manfaat dalam pendidikan maupun pertanian. Adapun manfaat yang diperoleh dari penelitian ini meliputi:

1. Manfaat teoritis
 - a. Memperdalam pemahaman tentang algoritma *Faster R-CNN* dan aplikasinya dalam deteksi objek.
 - b. Menyediakan wawasan baru mengenai teknik deep learning yang dapat diterapkan dalam klasifikasi citra.
 - c. Menjadi referensi ilmiah untuk pengembangan sistem serupa dalam bidang pertanian dan teknologi informasi.

2. Manfaat praktis

a. Bagi Penulis

Dapat menambah wawasan dan pengalaman langsung tentang proses deteksi dan klasifikasi suatu objek dalam hal ini yaitu varietas beras.

b. Bagi Pertanian

Sebagai bahan acuan dalam bidang pertanian khususnya untuk proses pemilihan jenis dan kualifikasi beras, serta modernisasi pertanian baik pelaku petani dan dinas terkait yang diharapkan guna membantu dalam hal identifikasi varietas beras.

c. Bagi Masyarakat Umum

Membantu masyarakat dalam mengidentifikasi varietas beras secara tepat.

1.7 Pertanyaan Penelitian

Berdasarkan identifikasi masalah yang telah dijelaskan, dapat dirumuskan pertanyaan penelitian ini sebagai berikut:

1. Apakah penerapan aplikasi deteksi lima varietas beras dapat mempermudah dinas pertanian dan masyarakat umum dalam mengidentifikasi jenis beras secara *real-time*?
2. Apakah algoritma *Faster R-CNN* dapat diimplementasikan untuk mengidentifikasi jenis beras secara *real-time*?

1.8 Hipotesis Penelitian

Dari hasil analisis yang telah dilakukan, peneliti merumuskan hipotesis penelitian yaitu dengan dibuatnya sistem deteksi dan klasifikasi beras menggunakan algoritma *Faster R-CNN* dalam aplikasi berbasis mobile untuk memberikan kemudahan bagi dinas pertanian dalam mengidentifikasi jenis beras secara *real-time*.

1.9 Metodologi Penelitian

Penelitian ini menggunakan metode eksperimen dengan pendekatan kuantitatif guna mengevaluasi efektivitas algoritma *Faster R-CNN* dalam proses deteksi dan klasifikasi jenis beras berdasarkan dataset yang tersedia..

1.9.1 Metode Pengumpulan Data

Dalam penelitian ini, teknik pengumpulan data yang digunakan meliputi:

1. Wawancara

Data dikumpulkan menggunakan metode wawancara yang dilakukan secara langsung dengan Bapak H.Uci Sanusi ,S.P., M.P selaku sekretaris dinas ketahanan pangan dan pertanian kab.kuningan, untuk mendapatkan wawasan lebih mengenai pertanian khususnya varietas beras.

2. Observasi


Melakukan pengamatan ke pasar terkait penyebaran varietas beras yang ada di kuningan.

3. Studi Pustaka

Pengumpulan informasi dilakukan melalui studi literatur dari jurnal, artikel, dan penelitian sebelumnya yang berkaitan dengan deteksi objek, klasifikasi gambar, serta algoritma *Faster R-CNN*.

1.9.2 Metode Pengembangan Sistem

Penelitian ini menggunakan metode *Rapid Application Development* (RAD) sebagai pendekatan pengembangan sistem. Metode tersebut menekankan pengembangan yang cepat dengan proses perbaikan berulang berdasarkan umpan balik yang diperoleh (Sintawati, 2022). Pemilihan metode ini didasarkan pada kemampuannya dalam mempercepat proses pengembangan sistem melalui pendekatan iteratif, sehingga evaluasi dan penyempurnaan dapat dilakukan secara berkelanjutan berdasarkan umpan balik yang diterima. Berikut tahapan dan alur metode *Rapid Application Development* (RAD) dapat dilihat pada Gambar 1.1.



Gambar 1.1 Metode RAD (Ramadhan et al., 2024)

Langkah-langkah dalam pengembangan sistem ini meliputi :

1. Rencana Kebutuhan (*Requirements planning*)

Tahap ini melibatkan pengumpulan data awal melalui studi pustaka, wawancara, dan observasi objek penelitian untuk menentukan kebutuhan yang diperlukan dalam penelitian.

2. Desain Sistem

Pada tahap ini, rancangan sistem dibuat sesuai dengan solusi untuk masalah yang ada, menggunakan metode seperti *Unified Modeling Language* (UML). Aktivitas yang dilakukan meliputi identifikasi aktor, analisis proses serta kinerja sistem, pengenalan struktur objek beserta hubungan antarobjek, pemodelan interaksi dan perilaku objek, serta perancangan antarmuka.

3. Pengembangan


Tahap ini melibatkan pembuatan sistem yang direncanakan, termasuk penyusunan kode program (*coding*) untuk mengubah desain menjadi aplikasi yang dapat digunakan.

4. Implementasi

Tahap peralihan sistem kepada pengguna, setelah dilakukan pengujian menyeluruh terhadap *User Interface* (UI) dan *User Experience* (UX) menggunakan metode SUS, serta pengujian fungsional sistem menggunakan *tools* seperti *qase.io* untuk memastikan tidak ada masalah dalam penggunaan sistem.

1.9.3 Metode Penyelesaian Masalah

Penelitian ini menggunakan metodologi yang meliputi pengumpulan dataset beras, *pre-processing*, implementasi penggunaan *Faster R-CNN*, pelatihan model dan pengujian deteksi. Berikut merupakan metodologi penelitian dapat dilihat pada gambar 1.2.




Gambar 1.2 Flowchart Tahap Penelitian (Rahman & Bambang,2021)

Untuk menyelesaikan masalah yang dihadapi dalam penelitian ini, beberapa langkah penyelesaian nya sebagai berikut:

a. Pengumpulan Dataset

Dataset pelatihan pada penelitian ini terdiri dari 10.000 gambar yang dikelompokkan ke dalam lima kelas dengan jumlah gambar 2.000 untuk beras IR 64 (sentra ramos), Basmati, Rojolele, Ciherang, dan Beras Merah. Selanjutnya dataset dibagi menjadi data training, data testing, dan data validasi per masing-masing kelas pada data set. Dataset dari 5 Varietas bisa di lihat pada gambar 1.3.



Gambar 1.3 Jenis Beras a).IR64 , b).Basmati, c).Ciherang, d).Rojolele, e).Beras Merah

b. *Pre-processing*


Data yang telah dikumpulkan selanjutnya diproses melalui tahap *pre-processing* sebagai langkah awal sebelum digunakan dalam klasifikasi. Tahap ini bertujuan untuk membersihkan data serta menghilangkan *noise*, menonjolkan fitur, dan mendeteksi pola (Azizah, 2023). Pada penelitian ini tahap *pre- processing* terdiri dari proses merubah dimensi citra. Citra tiap varietas beras pada penelitian ini dengan tipe *RGB* dengan ukuran berbeda- beda. Untuk memudahkan proses klasifikasi akan dilakukan *resize* atau dimensi citra dengan ukuran 640 x 640 piksel.

c. Perancangan Arsitektur CNN

Tahapan selanjutnya adalah perancangan arsitektur algoritma *Convolutional Neural Network* (CNN), tahap ini algoritma *Convolutional Neural Network* (CNN) dilakukan menggunakan dataset yang telah melalui tahap *preprocessing* sebelumnya (Tegar Prabowo & Hadikurniawati, 2023).

Convolutional Neural Network (CNN) merupakan salah satu algoritma *Deep Learning* yang dirancang untuk mengolah data dalam bentuk grid/data dua dimensi, misalnya gambar atau suara. CNN digunakan untuk mengklasifikasikan data yang

berlabel dengan menggunakan metode *supervised learning* (Wibowo & Allaam, 2021). CNN terdiri dari 2 lapisan arsitektur, yakni *feature learning* dan *classification layer* seperti terlihat pada gambar 1.4.



Gambar 1.4 Arsitektur CNN (Yuliany et al., 2022)

a. Komponen Ekstraksi Fitur

Pada bagian ini metode akan menjalankan operasi convolutional dan pooling untuk memproses citra masukan.

1. Lapisan Convolutional

Pada arsitektur CNN, lapisan awal yang digunakan adalah lapisan konvolusi. Fungsi dari lapisan ini adalah mengekstraksi informasi penting pada citra input dengan menerapkan operasi konvolusi menggunakan filter tertentu. Proses ini tidak merusak struktur asli dari citra masukan. Hasil dari operasi konvolusi kemudian melewati fungsi aktivasi *ReLU* (*Rectified Linear Unit*) untuk mengubah data menjadi *non-linear*, sehingga memudahkan model dalam memahami pola kompleks pada data. Seperti terlihat pada gambar 1.5.


$$\begin{array}{|c|c|c|c|c|c|} \hline 3 & 0 & 1 & 2 & 7 & 4 \\ \hline 1 & 5 & 8 & 9 & 3 & 1 \\ \hline 2 & 7 & 2 & 5 & 1 & 3 \\ \hline 0 & 1 & 3 & 1 & 7 & 8 \\ \hline 4 & 2 & 1 & 6 & 2 & 8 \\ \hline 2 & 4 & 5 & 2 & 3 & 9 \\ \hline \end{array} \quad \begin{array}{|c|c|c|} \hline 1 & 0 & -1 \\ \hline 1 & 0 & -1 \\ \hline 1 & 0 & -1 \\ \hline \end{array} \quad = \quad \begin{array}{|c|c|c|c|} \hline -5 & -4 & 0 & 8 \\ \hline -10 & -2 & -2 & 3 \\ \hline 0 & -2 & -4 & -7 \\ \hline -3 & -2 & -3 & -16 \\ \hline \end{array}$$

$6 \times 6 \qquad 3 \times 3 \qquad 4 \times 4$

Gambar 1. 5 Lapisan Konvolusi

2. Lapisan *Pooling*


Lapisan Pooling layer berfungsi untuk memperkecil dimensi data hasil lapisan konvolusi, terutama pada citra yang berukuran besar. Penggunaan lapisan ini membantu menangani citra berukuran besar dengan lebih efisien. Salah satu teknik yang umum digunakan yaitu max pooling, yang mempertahankan nilai terbesar dari setiap area data untuk dilanjutkan ke proses berikutnya. Pada proses ini, nilai selain nilai maksimum akan dieliminasi. Ilustrasi proses *max pooling* dapat dilihat pada gambar 1.6.



Gambar 1. 6 Lapisan Max Pooling (Dzaky, 2021)

b. Komponen Klasifikasi


Setelah melewati lapisan konvolusi dan pooling, komponen selanjutnya adalah klasifikasi yang terdiri dari beberapa *Fully- Connected Layer* (lapisan yang terhubung secara penuh). Lapisan ini hanya menerima data 1 dimensi. Maka perlu mengkonversi dari data 3 dimensi ke 1 dimensi, dengan menggunakan fungsi flatten. Lapisan ini memiliki node yang saling terhubung dan memiliki bobot serta fungsi aktivasi. Akhir dari layer ini merupakan keluaran berbentuk sebuah prediksi berdasarkan data yang sebelumnya kitamasukan. Gambaran struktur lapisan ini dapat dilihat pada gambar 1.7.



Gambar 1.7 Lapisan Fully Connected (Dzaky, 2021)


d. Implementasi Arsitektur Faster R-CNN

Faster R-CNN merupakan pengembangan algoritma *faster R-CNN* yang menghasilkan kecepatan dalam pelatihan data dan kecepatan dalam pengenalan objek. Dalam proses pelatihan, terdapat empat tahap: melatih *Region Proposal Network* (RPN), melatih jaringan *faster R-CNN* menggunakan RPN dari langkah pertama, melatih ulang RPN dengan berbagi bobot dengan *faster R-CNN*, dan melatih ulang *faster R-CNN* menggunakan RPN yang telah diperbarui. RPN terdiri dari dua jaringan. Yang pertama adalah CNN. Lima lapisan terakhir dari CNN digantikan dengan lapisan konvolusi 3x3 yang diikuti oleh lapisan *ReLU*, lapisan 1x1 yang diikuti oleh lapisan *reshape* untuk lapisan RPN, lapisan *softmax*, dan lapisan klasifikasi RPN. Jaringan kedua terdiri dari dua lapisan: lapisan konvolusi 1x1 untuk kotak regresi (RPN) dan Lapisan *Output Regresi* Kotak *Smooth-L1*. Proses pelatihan RPN bertujuan untuk meminimalkan fungsi kerugian total yang merupakan agregat dari fungsi kerugian data pada tahap klasifikasi dan fungsi kerugian regularisasi (Pratama et al., 2024). Struktur lapisan di ini dapat di lihat pada gambar 1.8.



Gambar 1.8 Arsitektur Faster R-CNN (G. A. Pratama et al., 2024)

Komponen utama dalam arsitektur *Faster R-CNN* untuk deteksi objek adalah *Region Proposal Network* (RPN). *Region Proposal Network* merupakan jaringan saraf konvolusi penuh yang berfungsi untuk memprediksi batas objek sekaligus menentukan skor objek pada setiap lokasi secara bersamaan. (Pratama et al., 2024). Proposal wilayah berkualitas tinggi dimanfaatkan oleh modul deteksi *Faster R-CNN* dalam proses identifikasi objek pada citra (Li dkk., 2022). Penggunaan lapisan konvolusi yang sama pada RPN dan *Faster R-CNN* dilakukan untuk meminimalkan kompleksitas perhitungan. Dengan metode sliding window, RPN memetakan jendela spasial ke dalam fitur berdimensi lebih rendah untuk menghasilkan proposal wilayah, yang kemudian diproses melalui lapisan regresi serta klasifikasi kotak seperti pada gambar 1.9.




Gambar 1.9 Cara Kerja RPN (G. A. Pratama et al., 2024)

Region Proposal Network adalah jaringan saraf konvolusi penuh yang digunakan untuk menentukan batas objek serta skor objek secara bersamaan pada setiap lokasi. Dalam proses deteksi objek, *Faster R-CNN* memanfaatkan hasil proposal wilayah dari RPN untuk mengenali objek pada citra. Penggunaan lapisan konvolusi yang sama pada RPN dan *Faster R-CNN* dilakukan untuk meningkatkan efisiensi komputasi. Melalui pemetaan jendela spasial ke fitur dengan dimensi yang lebih rendah, RPN mengirimkan informasi tersebut melalui lapisan regresi kotak dan lapisan klasifikasi kotak untuk menghasilkan prediksi. Metode sliding window digunakan untuk menghasilkan sejumlah saran wilayah yang berpusat pada anchor box dan disesuaikan dengan skala serta rasio aspek. RPN dirancang dengan arsitektur jangkar multi-skala, yang memungkinkan ketahanan terhadap perubahan posisi dan ukuran anchor serta proposal. Dalam pelatihannya, Fungsi kerugian multi-tugas pada jaringan ini digunakan untuk menggabungkan proses klasifikasi dan regresi dalam memprediksi objek yang relevan serta menentukan batas kotaknya (Pratama et al., 2024). CNN yang digunakan dalam *Faster R-CNN* ini yaitu *MobileNet*.

1. *MobileNet V2*

MobileNet V2 merupakan arsitektur yang dirancang untuk aplikasi visi pada perangkat bergerak dan *embedded system* dengan menggunakan struktur jaringan yang lebih sederhana melalui penerapan *depth-wise separable convolutions* untuk mengurangi jumlah parameter dan meningkatkan performa jaringan. *MobileNet V2* juga memiliki kinerja yang baik dan ringan digunakan pada perangkat ponsel. *MobileNet V2* menambahkan dua fitur baru yaitu *linear bottleneck* dan *shortcut connections antar layer*. Struktur dasar dari arsitektur *MobileNet V2* ada pada gambar 1.10.



Gambar 1.10 Arsitektur MobileNetV2 (Dzaky, 2021)

e. Pelatihan Model

Pada tahap ini, model yang telah dirancang akan dilatih menggunakan data training yang telah dipersiapkan. Hasil akhir dari training adalah berupa prediksi gambar sesuai dengan jenis obyek pada gambar. Hasil keluaran training akan dibandingkan kembali dengan hasil sebenarnya untuk mengukur seberapa besar tingkat akurasi fitur prediksi. Setelah model selesai dilatih, data testing digunakan untuk menguji akurasi model.

f. Pengujian Model

Setelah model dilatih, langkah selanjutnya yaitu mengevaluasi kinerjanya. Dengan menggunakan dataset pengujian yang telah disiapkan sebelumnya untuk menguji model dan menghitung metrik evaluasi seperti akurasi, presisi, *recall*, *F1-score*, dan *confusion matrix*.

1.10 Jadwal Penelitian

Tabel 1.1 Tahapan dan Jadwal Penelitian

No	Nama Kegiatan	Tahun 2025				Tahun 2026					
		Sept	Okt	Nov	Des	Jan	Feb	Mar	Apr	Mei	Juni
1	Seminar Usulan Penelitian										
2	Rencana Kebutuhan										
3	User Design										
4	Contruction										
5	Cutover										
6	Seminar Hasil Penelitian										
7	Sidang Akhir										

1.11 Sistematika Penelitian

BAB I : PENDAHULUAN

Bab ini menjelaskan latar belakang permasalahan yang diangkat dalam penelitian, rumusan masalah, tujuan penelitian, manfaat penelitian, ruang lingkup penelitian, serta sistematika penulisan skripsi secara keseluruhan. Tujuannya adalah memberikan gambaran umum mengenai penelitian yang dilakukan.

BAB II : LANDASAN TEORITIS

Bab ini berisi teori-teori yang relevan sebagai dasar atau referensi untuk mendukung penelitian. Termasuk di dalamnya ulasan terhadap penelitian terdahulu, konsep atau teknologi yang digunakan, serta kerangka berpikir.

BAB III : ANALISA DAN PERANCANGAN

Bab ini menjelaskan analisis terhadap sistem yang ada (jika ada), kebutuhan sistem yang akan dikembangkan, serta

perancangan sistem yang mencakup arsitektur, alur proses, dan rancangan antarmuka.

BAB IV : IMPLEMENTASI DAN PENGUJIAN

Bab ini menjelaskan implementasi atau realisasi sistem berdasarkan rancangan sebelumnya, serta pengujian sistem untuk memastikan bahwa sistem bekerja sesuai dengan kebutuhan.

BAB V : KESIMPULAN DAN SARAN

Bab terakhir ini menyajikan kesimpulan dari hasil penelitian dan pengembangan sistem, serta saran untuk pengembangan lebih lanjut atau perbaikan di masa mendatang.