

BAB I PENDAHULUAN

1.1 Latar Belakang

Indonesia merupakan negara agraris dengan sektor pertanian sebagai salah satu penopang utama ketahanan pangan nasional. Di antara berbagai komoditas pertanian, tanaman padi (*Oryza sativa* L.) memiliki peran yang sangat strategis karena menjadi sumber pangan pokok bagi sebagian besar masyarakat Indonesia. Data Badan Pusat Statistik (BPS) menunjukkan bahwa luas panen padi nasional pada tahun 2023 mencapai 10,21 juta hektare [1]. Skala produksi yang sangat besar tersebut menjadikan produktivitas dan kesehatan tanaman padi sebagai aspek yang sangat penting untuk dijaga. Namun, produktivitas padi sering kali mengalami penurunan akibat berbagai faktor, salah satunya adalah defisiensi unsur hara makro seperti Nitrogen (N), Fosfor (P), dan Kalium (K). Kekurangan unsur hara tersebut dapat menyebabkan gangguan fisiologis tanaman yang ditandai melalui perubahan visual pada daun, seperti klorosis, perubahan pigmentasi, hingga nekrosis tepi daun, yang pada akhirnya berdampak pada penurunan hasil panen secara signifikan [2], [3].

Dalam praktik di lapangan, proses identifikasi defisiensi nutrisi pada tanaman padi masih banyak dilakukan secara konvensional melalui pengamatan visual manual oleh petani maupun penyuluh pertanian. Pendekatan ini memiliki berbagai keterbatasan mendasar. Hasil pengamatan sangat bergantung pada pengalaman dan subjektivitas individu, sehingga tingkat konsistensi diagnosis antar pengamat sering kali berbeda [2]. Selain itu, gejala visual antara defisiensi unsur hara dan penyakit daun kerap memiliki kemiripan yang tinggi, sehingga proses identifikasi menjadi sulit bahkan bagi pengamat yang berpengalaman [3]. Pengamatan manual juga membutuhkan waktu yang relatif lama dan kurang efisien untuk diterapkan pada area persawahan yang luas. Kondisi ini menyebabkan proses deteksi dini menjadi kurang optimal, padahal identifikasi gejala pada tahap awal sangat penting untuk menentukan tindakan agronomis yang tepat dan mencegah penurunan produktivitas tanaman secara lebih besar [4].

Perkembangan teknologi pertanian presisi (*precision agriculture*) membuka peluang baru dalam meningkatkan efisiensi pemantauan kondisi tanaman melalui

pemanfaatan teknologi digital dan kecerdasan buatan. Salah satu teknologi yang berkembang pesat adalah *computer vision* berbasis *deep learning*, yang mampu melakukan analisis citra secara otomatis untuk mengenali pola visual kompleks pada daun tanaman. Dalam beberapa tahun terakhir, *deep learning* telah merevolusi bidang *computer vision* melalui kemampuan ekstraksi fitur hierarkis secara otomatis dari data citra dengan tingkat akurasi yang sangat tinggi. Arsitektur Convolutional Neural Network (CNN) menjadi fondasi utama dalam berbagai penelitian klasifikasi citra karena kemampuannya dalam mempelajari pola warna, tekstur, dan bentuk secara mendalam. Berbagai inovasi arsitektur CNN terus dikembangkan untuk meningkatkan kemampuan generalisasi model, efisiensi komputasi, dan kualitas representasi fitur pada data visual yang kompleks.

Salah satu arsitektur CNN yang memiliki performa sangat baik adalah DenseNet. DenseNet memanfaatkan konsep dense connectivity, di mana setiap lapisan terhubung langsung dengan seluruh lapisan sebelumnya sehingga memungkinkan terjadinya *feature reuse* secara optimal. Pendekatan ini membuat aliran informasi dan gradien menjadi lebih stabil, mengurangi risiko vanishing gradient, serta meningkatkan efisiensi parameter dibandingkan arsitektur CNN konvensional [5]. Penelitian terkini menunjukkan bahwa pengembangan DenseNet modern mampu menghasilkan performa yang kompetitif bahkan melampaui beberapa arsitektur populer lainnya seperti ResNet-style maupun Vision Transformer pada berbagai *benchmark computer vision* berskala besar [5]. Selain itu, DenseNet juga terbukti efektif dalam tugas klasifikasi citra yang membutuhkan representasi fitur kaya dan detail, termasuk pada domain pertanian [6].

Meskipun memiliki performa tinggi, konvolusi standar pada CNN masih memiliki keterbatasan karena bersifat spatial-agnostic, yaitu menggunakan kernel yang sama untuk seluruh lokasi spasial pada citra. Padahal, pada kasus citra daun padi, gejala defisiensi nutrisi sering muncul dalam pola lokal yang bervariasi pada area tertentu daun. Untuk mengatasi keterbatasan tersebut, operator Involution diperkenalkan sebagai alternatif konvolusi adaptif-spasial. Berbeda dengan konvolusi biasa, Involution menghasilkan kernel dinamis yang bergantung pada posisi piksel sehingga lebih sensitif terhadap variasi pola spasial lokal [7]. Pendekatan ini memungkinkan model untuk menangkap karakteristik gejala visual

secara lebih adaptif dengan jumlah parameter yang lebih efisien dibandingkan konvolusi tradisional. Integrasi Involution ke dalam arsitektur DenseNet telah terbukti mampu meningkatkan performa klasifikasi citra sekaligus menekan kompleksitas komputasi, khususnya pada domain pertanian seperti deteksi penyakit tanaman [8].

Namun demikian, peningkatan kompleksitas model *deep learning* sering kali menyebabkan model menjadi sulit dipahami atau bersifat black box, di mana proses pengambilan keputusan model tidak dapat dijelaskan secara transparan [9]. Permasalahan ini menjadi tantangan penting dalam implementasi kecerdasan buatan pada sektor pertanian, karena pengguna perlu mengetahui dasar model dalam menghasilkan suatu prediksi agar kepercayaan terhadap sistem dapat meningkat. Untuk menjawab tantangan tersebut, bidang *Explainable Artificial Intelligence* (XAI) berkembang sebagai pendekatan yang memungkinkan interpretasi terhadap keputusan model *deep learning*. Salah satu metode XAI yang populer adalah *Grad-CAM++*, yaitu teknik visualisasi berbasis gradien yang menghasilkan *heatmap* untuk menunjukkan area citra yang paling berpengaruh terhadap keputusan model [10]. Dibandingkan metode *Grad-CAM* standar, *Grad-CAM++* memanfaatkan gradien orde tinggi sehingga mampu menghasilkan lokalisasi area penting yang lebih presisi dan lebih baik dalam menangani pola visual kompleks [10]. Dalam beberapa penelitian terkini, *Grad-CAM++* telah berhasil diterapkan pada domain medis dan pertanian untuk menjelaskan fokus perhatian model terhadap gejala penyakit maupun defisiensi nutrisi pada daun tanaman [11].

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan pengembangan model klasifikasi defisiensi nutrisi daun padi menggunakan arsitektur Involution-Infused DenseNet yang dipadukan dengan pendekatan *Explainable Artificial Intelligence* melalui *Grad-CAM++*. Model yang dikembangkan bertujuan untuk mengklasifikasikan kondisi daun padi ke dalam kategori Healthy, defisiensi Nitrogen (N), defisiensi Fosfor (P), dan defisiensi Kalium (K) berdasarkan citra digital daun. Integrasi operator Involution diharapkan mampu meningkatkan kemampuan model dalam menangkap variasi pola spasial lokal secara lebih adaptif, sedangkan penerapan *Grad-CAM++* diharapkan dapat

memberikan interpretasi visual terhadap dasar pengambilan keputusan model melalui visualisasi *heatmap*. Dengan demikian, penelitian ini tidak hanya berfokus pada peningkatan performa klasifikasi, tetapi juga pada aspek transparansi dan interpretabilitas model, sehingga hasil yang diperoleh dapat lebih dipercaya dan berpotensi mendukung implementasi teknologi pertanian presisi secara nyata di Indonesia.

1.2 Rumusan Masalah

Berdasarkan uraian latar belakang yang telah dijelaskan sebelumnya, terdapat beberapa permasalahan utama yang menjadi fokus penelitian ini, yaitu:

1. Bagaimana mengimplementasikan arsitektur DenseNet121 yang dimodifikasi dengan operator Involution dan integrasi *Grad-CAM++* untuk klasifikasi defisiensi nutrisi Nitrogen (N), Fosfor (P), Kalium (K), serta kondisi sehat pada citra daun padi?
2. Bagaimana penerapan *Grad-CAM++* dapat menghasilkan visualisasi *heatmap* yang akurat dan bermakna untuk menjelaskan area citra yang paling berpengaruh terhadap keputusan klasifikasi model?
3. Bagaimana performa kuantitatif model Involution-Infused DenseNet yang diusulkan dibandingkan antar skenario *preprocessing* berdasarkan metrik akurasi, *F1-score* dan AUC-ROC?

1.3 Batasan Masalah

Batasan masalah dalam penelitian ini ditetapkan agar penelitian lebih terarah dan sesuai dengan tujuan yang telah ditentukan. Adapun batasan masalah yang digunakan adalah sebagai berikut:

1. Penelitian ini hanya berfokus pada tanaman padi (*Oryza sativa* L.), khususnya untuk deteksi defisiensi unsur hara makro Nitrogen (N), Fosfor (P), dan Kalium (K).
2. Set data yang digunakan untuk melatih model berasal dari set data publik *Nutrient-Deficiency-Symptoms-in-Rice* dan *Rice Leafs*, tanpa melakukan pengambilan data lapangan baru.

3. Model yang digunakan merupakan pengembangan dari arsitektur DenseNet121 dengan penambahan operator *Involution* untuk meningkatkan efisiensi spasial dan representasi fitur.
4. Penerapan *Explainable Artificial Intelligence (XAI)* dibatasi pada metode visualisasi berbasis *Gradient-weighted Class Activation Mapping (Grad-CAM++)* guna menginterpretasikan proses pengambilan keputusan model.
5. Penelitian ini berfokus pada klasifikasi citra daun padi berdasarkan kategori defisiensi, tanpa membahas aspek kuantitatif kadar unsur hara atau integrasi dengan sistem *Internet of Things (IoT)*.
6. Pengujian pada data nyata lapangan dibatasi pada tanaman padi berusia 5 minggu, sehingga hasil validasi lapangan tidak dapat digeneralisasikan untuk fase pertumbuhan lainnya.
7. Evaluasi kinerja model dalam penelitian ini difokuskan pada metrik akurasi, presisi, *recall*, *F1-score*, serta aspek visual *interpretability*.

1.4 Tujuan

Adapun tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut:

1. Merancang Mengembangkan model *Explainable Involution-Infused DenseNet* untuk klasifikasi defisiensi unsur hara makro (N, P, K) pada tanaman padi berbasis citra daun.
2. Meningkatkan kemampuan ekstraksi fitur spasial dan efisiensi komputasi model melalui penerapan operator *Involution* dalam arsitektur DenseNet.
3. Menerapkan metode *Explainable AI (XAI)* menggunakan *Grad-CAM++* guna menghasilkan visualisasi peta panas (*heatmap*) yang menjelaskan area daun yang menjadi dasar keputusan klasifikasi.
4. Menganalisis performa dan interpretabilitas model berdasarkan berbagai metrik evaluasi untuk memastikan keseimbangan antara akurasi dan transparansi hasil.
5. Menyediakan sistem diagnosis berbasis AI yang dapat dijadikan dasar pengembangan alat bantu digital pertanian presisi, sehingga hasil prediksi dapat digunakan untuk rekomendasi tindakan agronomis yang lebih tepat sasaran.

1.5 Manfaat

Penelitian ini diharapkan dapat memberikan manfaat baik secara akademik maupun praktis, sebagai berikut:

1. Manfaat Akademik

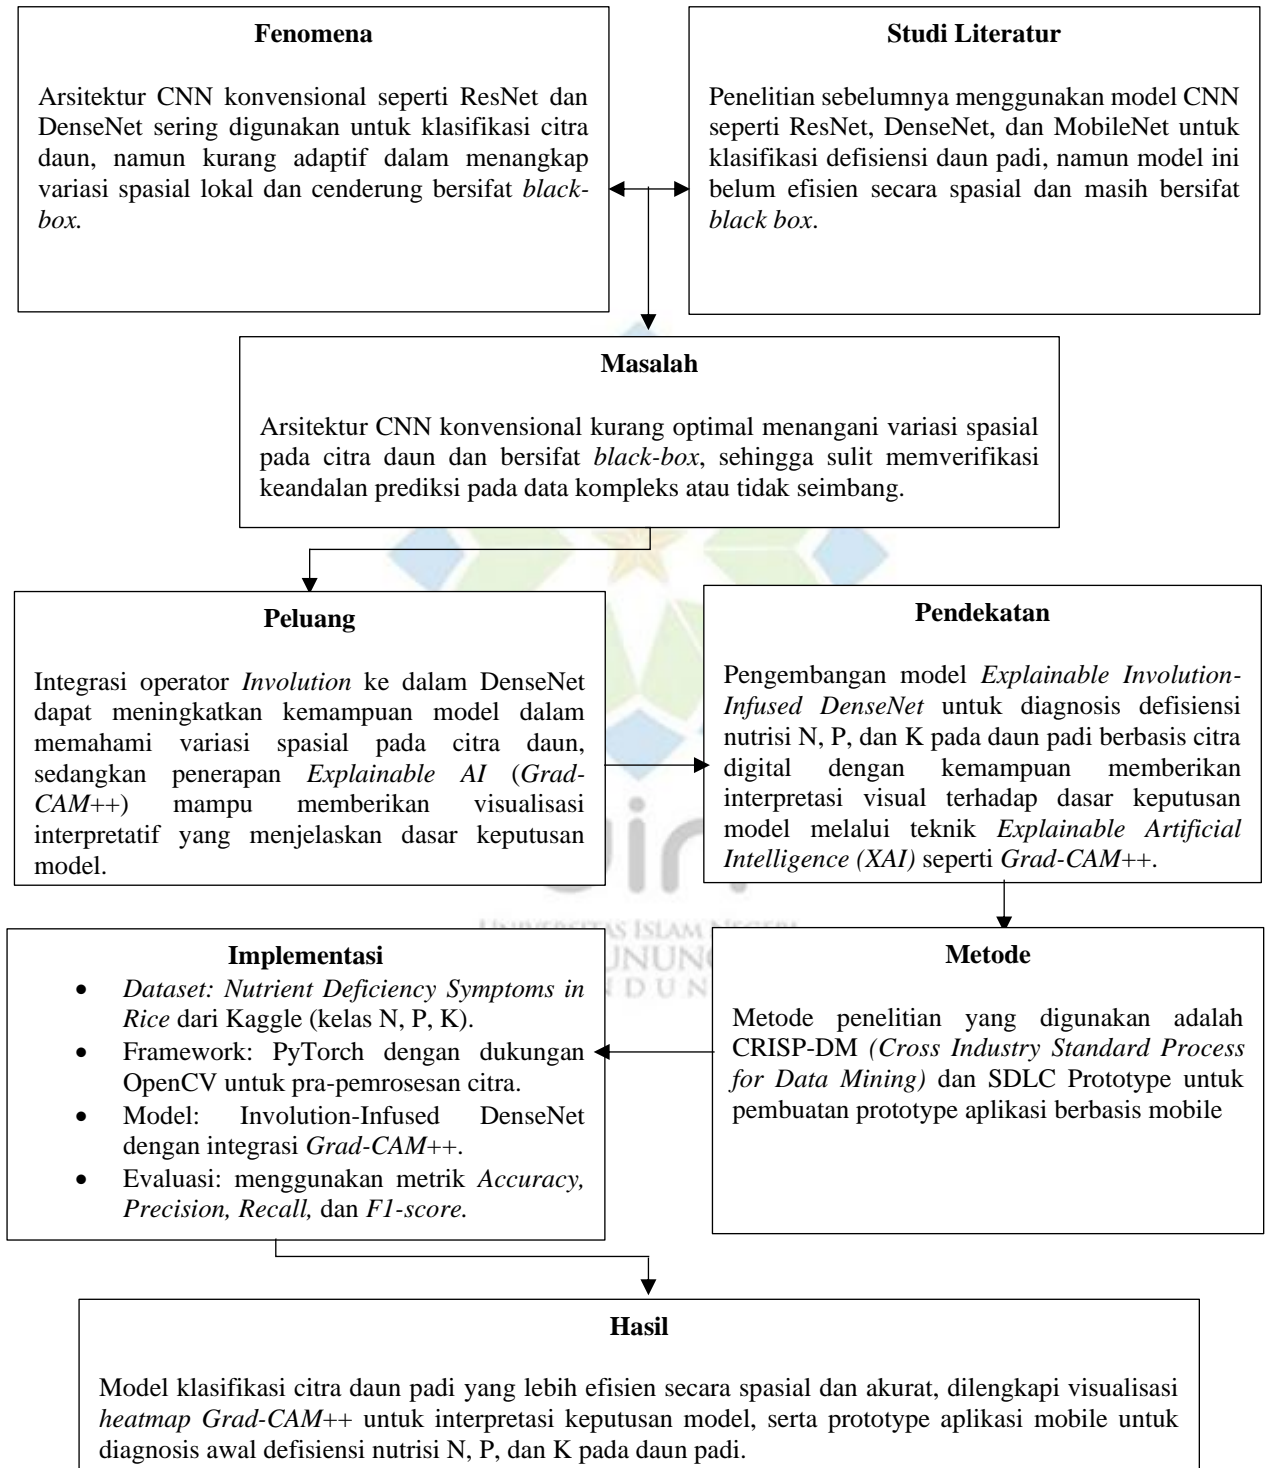
- a) Menambah kontribusi ilmiah dalam bidang *Computer vision* dan *Explainable AI* pada domain pertanian, khususnya diagnosis defisiensi unsur hara tanaman padi.
- b) Memberikan pendekatan baru dalam pengembangan arsitektur CNN yang lebih efisien melalui integrasi operator *Involution* ke dalam DenseNet.
- c) Menjadi referensi penelitian lanjutan untuk eksplorasi model hibrida antara efisiensi spasial dan interpretabilitas model dalam konteks pertanian cerdas.

2. Manfaat Praktis

- a) Menyediakan sistem diagnosis otomatis dan transparan yang dapat membantu petani atau penyuluh pertanian dalam mendeteksi defisiensi nutrisi secara cepat dan tepat.
- b) Mengurangi ketergantungan terhadap analisis manual dan subjektif, serta mempercepat proses pengambilan keputusan agronomis.
- c) Mendukung implementasi pertanian presisi (*precision agriculture*) yang efisien, adaptif, dan berkelanjutan melalui penerapan kecerdasan buatan yang dapat dijelaskan (*explainable AI*).
- d) Memberikan landasan awal untuk pengembangan aplikasi berbasis AI yang dapat diintegrasikan dengan sistem pengelolaan pertanian digital nasional di masa mendatang.

1.6 Kerangka Pemikiran

Kerangka pemikiran penelitian ini disusun untuk menggambarkan alur logis dari latar belakang hingga solusi yang diusulkan.



Gambar 1.1 Kerangka Pemikiran

Berdasarkan studi literatur, berbagai penelitian sebelumnya telah memanfaatkan model CNN seperti ResNet, DenseNet, dan MobileNet untuk mengklasifikasikan gejala defisiensi nutrisi pada daun padi. Namun, pendekatan tersebut masih memiliki keterbatasan dalam efisiensi pemodelan informasi spasial pada citra serta belum memberikan penjelasan yang memadai terkait alasan di balik prediksi yang dihasilkan oleh model.

Permasalahan utama yang diidentifikasi dalam penelitian ini adalah keterbatasan arsitektur CNN konvensional dalam menangani variasi spasial pada citra daun serta sifat model yang tidak transparan dalam menjelaskan dasar pengambilan keputusan. Hal ini menjadi penting terutama ketika model digunakan pada data yang kompleks atau tidak seimbang, sehingga diperlukan pendekatan yang mampu meningkatkan kemampuan representasi spasial sekaligus memberikan interpretasi terhadap hasil prediksi model.

Berdasarkan permasalahan tersebut, terdapat peluang untuk meningkatkan performa model melalui integrasi operator *Involution* ke dalam arsitektur DenseNet. Operator ini memiliki kemampuan untuk menangkap informasi spasial secara lebih adaptif dibandingkan konvolusi konvensional. Selain itu, penerapan pendekatan *Explainable Artificial Intelligence* (XAI) menggunakan metode *Grad-CAM++* dapat memberikan visualisasi berupa *heatmap* yang menunjukkan bagian citra yang paling berpengaruh terhadap keputusan model.

Pendekatan yang diusulkan dalam penelitian ini adalah pengembangan model *Explainable Involution-Infused DenseNet* untuk melakukan diagnosis defisiensi nutrisi Nitrogen (N), Fosfor (P), dan Kalium (K) pada daun padi berdasarkan citra digital. Model yang dikembangkan tidak hanya berfokus pada peningkatan akurasi klasifikasi, tetapi juga pada kemampuan interpretasi hasil prediksi melalui visualisasi *Grad-CAM++*.

Dalam proses penelitian, metode yang digunakan adalah CRISP-DM (*Cross Industry Standard Process for Data Mining*) untuk tahapan pengolahan data dan pengembangan model machine learning, serta metode SDLC *Prototype* untuk proses pengembangan *prototype* aplikasi berbasis mobile. Implementasi penelitian dilakukan menggunakan *dataset Nutrient Deficiency Symptoms in Rice* yang diperoleh dari Kaggle, dengan *framework* PyTorch serta dukungan OpenCV untuk

tahap pra-pemrosesan citra. Model yang dihasilkan kemudian dievaluasi menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-score*.

Hasil yang diharapkan dari penelitian ini adalah model klasifikasi citra daun padi yang lebih efisien secara spasial, akurat, serta mampu memberikan interpretasi visual terhadap keputusan model melalui visualisasi *heatmap Grad-CAM++*. Selain itu, penelitian ini juga menghasilkan *prototype* aplikasi mobile untuk diagnosis awal defisiensi nutrisi N, P, dan K pada daun padi.

1.7 Sistematika Penulisan

Sistematika penulisan laporan Tugas Akhir ini disusun untuk memberikan gambaran yang jelas mengenai kandungan setiap bab, urutan penyajian, serta keterkaitan antar bab dalam sebuah laporan yang utuh dan logis. Berikut adalah struktur penulisan laporan Tugas Akhir yang digunakan:

BAB I PENDAHULUAN

Bab ini merupakan bagian pengantar yang menjelaskan konteks dan fondasi penelitian. Bab ini terdiri dari latar belakang masalah, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, kerangka pemikiran, serta sistematika penulisan. Bab ini berfungsi sebagai dasar untuk memahami urgensi penelitian dan arah yang akan ditempuh pada bab-bab selanjutnya.

BAB II KAJIAN PUSTAKA

Bab ini membahas landasan teori dan kajian literatur yang relevan dengan penelitian. Diuraikan penelitian terdahulu, konsep-konsep dasar, teori terkait *computer vision*, arsitektur *deep learning* (termasuk DenseNet), operator *Involution*, teknik *Explainable AI (Grad-CAM++)*, serta tinjauan tentang defisiensi nutrisi pada tanaman padi dari perspektif visual. Bab ini menjadi rujukan teoritis yang mendukung pemilihan metode dan model pada bab selanjutnya.

BAB III METODOLOGI PENELITIAN

Bab ini menjelaskan secara rinci langkah-langkah penelitian yang dilakukan. Menggunakan kerangka CRISP-DM (dengan fokus pada lima fase: *Business*

Understanding, Data Understanding, Data Preparation, Modeling, dan Evaluation), diuraikan proses pengumpulan data, *preprocessing*, penggabungan dataset, augmentasi data, pembagian data, desain model *Involution-Infused DenseNet*, proses pelatihan (termasuk penanganan *imbalance* dan *scheduler*), serta metode evaluasi dan *explainability* menggunakan *Grad-CAM++*. Bab ini menjadi panduan teknis yang menghubungkan teori (Bab II) dengan hasil implementasi (Bab IV).

BAB IV HASIL DAN PEMBAHASAN

Bab ini memaparkan hasil implementasi dan analisis secara mendalam. Diuraikan hasil eksplorasi data, distribusi kelas, performa model (akurasi, presisi, *recall*, *F1-score*, *confusion matrix*), kurva *training history*, serta visualisasi interpretabilitas melalui *heatmap Grad-CAM++*. Selanjutnya dilakukan pembahasan yang mengaitkan hasil dengan rumusan masalah, membandingkan dengan pendekatan *baseline*, menganalisis kekuatan dan kelemahan model, serta implikasi teknis dari penggunaan *Involution* dan *Grad-CAM++*. Bab ini menjawab secara langsung rumusan masalah yang telah dirumuskan pada Bab I.

BAB V SIMPULAN DAN SARAN

Bab penutup ini berisi dua bagian utama. Pertama, simpulan yang merangkum hasil penelitian secara keseluruhan, mencakup pencapaian tujuan, jawaban atas rumusan masalah, serta kontribusi utama dari model yang dikembangkan. Kedua, saran untuk pengembangan penelitian selanjutnya, seperti pengujian pada *dataset* lapangan, integrasi dengan aplikasi mobile, *fine-tuning hyperparameter* lebih lanjut, atau eksplorasi arsitektur lain yang lebih ringan untuk *deployment*. Bab ini menutup laporan dengan memberikan arah masa depan berdasarkan temuan penelitian.