

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah/Penelitian

Infeksi cacing (*soil-transmitted helminths*) masih menjadi salah satu permasalahan kesehatan global, terutama di negara berkembang dengan kondisi sanitasi yang kurang baik. Menurut World Health Organization, lebih dari 1,5 miliar penduduk dunia terinfeksi cacing parasit sehingga diperlukan metode diagnosis yang cepat dan akurat. Proses identifikasi telur cacing saat ini umumnya masih dilakukan secara manual melalui pemeriksaan mikroskopis oleh analis laboratorium. Metode tersebut sangat bergantung pada pengalaman dan keahlian pengamat sehingga berpotensi menimbulkan subjektivitas, membutuhkan waktu yang relatif lama, serta meningkatkan risiko kesalahan klasifikasi. Selain itu, beberapa jenis telur cacing memiliki morfologi yang sangat mirip sehingga menimbulkan *fine-grained classification problem*, yaitu kondisi ketika perbedaan antar kelas sangat kecil dan sulit dibedakan secara visual (WHO, 2023).

Perkembangan teknologi Computer Vision dan deep learning, khususnya metode Convolutional Neural Network (CNN), memberikan peluang untuk mengembangkan sistem klasifikasi citra medis secara otomatis dengan tingkat akurasi yang tinggi (Basyal dkk., 2024). Namun demikian, penggunaan model CNN tunggal masih memiliki keterbatasan dalam hal generalisasi, stabilitas prediksi, dan rentan terhadap *overfitting*, terutama pada dataset medis dengan variasi citra yang tinggi. Di sisi lain, metode ensemble konvensional seperti *soft voting* umumnya menggunakan bobot tetap dan belum mempertimbangkan tingkat keyakinan (*confidence*) maupun ketidakpastian (*entropy*) dari setiap model. Oleh karena itu, diperlukan pendekatan ensemble adaptif yang mampu menggabungkan beberapa model CNN secara dinamis berdasarkan *confidence* dan *entropy* untuk meningkatkan akurasi, robustness, dan stabilitas klasifikasi citra telur cacing (He, W dkk., 2024).

Tantangan dalam mendeteksi infeksi parasit pada usus masih menjadi masalah kesehatan besar terutama di negara-negara berkembang dengan kondisi tropis. Diagnosis tradisional infeksi parasit sering dilakukan secara manual menggunakan mikroskop, yang bergantung pada keterampilan dan pengalaman teknisi laboratorium. Namun, metode ini rentan terhadap kesalahan karena kemiripan morfologi antara berbagai jenis telur cacing, serta adanya elemen pengganggu dalam sampel seperti kotoran atau serat. Keterbatasan ini membuat diagnosis memakan waktu dan tidak selalu akurat, sehingga dapat mempengaruhi kualitas pengobatan yang diberikan. Selain itu, di banyak daerah pedesaan atau kurang berkembang, penggunaan mikroskop berkualitas tinggi seringkali tidak dapat dilakukan karena biayanya yang tinggi. Hal ini mendorong penggunaan mikroskop USB berbiaya rendah, meskipun perangkat tersebut menghasilkan gambar berkualitas rendah dengan pembesaran yang terbatas. Tantangan ini menciptakan kebutuhan akan solusi otomatis yang mampu mendeteksi telur parasit secara akurat meskipun menggunakan gambar berkualitas rendah (Basyal dkk., 2024).

Salah satu tantangan dalam pengembangan model deteksi dan klasifikasi telur cacing adalah keragaman karakteristik citra yang digunakan pada proses pelatihan dan pengujian. Meskipun jumlah dataset yang tersedia dapat mencukupi, variasi morfologi telur cacing yang sangat beragam serta kemiripan bentuk antar spesies dapat menyulitkan model dalam membedakan kelas secara akurat. Perbedaan antar kelas seringkali bersifat halus (*fine-grained*), sehingga model perlu mampu mengenali detail visual yang sangat spesifik yang mungkin muncul pada kondisi nyata. Hal ini berpotensi mempengaruhi tingkat akurasi klasifikasi, terutama pada spesies yang memiliki karakteristik morfologi yang mirip. Selain itu, penelitian juga menghadapi tantangan dalam tahap preprocessing citra dan penerapan teknik augmentasi. Proses preprocessing yang tidak tepat dapat menurunkan kualitas informasi visual dan mempengaruhi hasil akhir model. Demikian pula, jika teknik augmentasi tidak diterapkan secara optimal, kemampuan generalisasi model terhadap data baru dapat menjadi terbatas. Tantangan ini menjadi semakin penting karena citra mikroskopis sering menunjukkan variasi yang signifikan dalam

pencahayaannya, kontras, dan resolusi, yang pada akhirnya dapat mempengaruhi kinerja algoritma yang digunakan (Palasuwan dkk., 2022).

Convolutional Neural Network (CNN) merupakan algoritma pembelajaran mendalam yang mampu mengekstraksi fitur hierarkis dari citra dan telah menjadi arsitektur utama dalam berbagai tugas pengenalan gambar. CNN mampu menangkap pola visual yang kompleks sehingga banyak digunakan pada aplikasi citra medis. Namun, peningkatan performa CNN umumnya diikuti oleh peningkatan kompleksitas model dan kebutuhan komputasi yang lebih tinggi (Tan dkk., 2019).

Berbagai penelitian sebelumnya menunjukkan bahwa CNN mampu menghasilkan kinerja yang tinggi pada berbagai tugas klasifikasi citra medis, seperti deteksi penyakit mata dan klasifikasi penyakit kulit, dengan tingkat akurasi di atas 95% (Cahya dkk., 2021; Hanin dkk., 2021). Hasil tersebut menunjukkan kemampuan CNN dalam menangkap fitur visual yang kompleks serta menghasilkan performa yang baik dibandingkan metode konvensional.

Transfer learning merupakan pendekatan yang memanfaatkan model pra-latih dari dataset skala besar untuk meningkatkan kinerja pada tugas target dengan data terbatas. Metode ini mampu mempercepat proses pelatihan, meningkatkan efisiensi penggunaan data, serta menghasilkan performa yang lebih stabil. Namun demikian, transfer learning juga memiliki keterbatasan, seperti risiko *overfitting* dan ketidaksesuaian domain antara data sumber dan target (Zhao dkk., 2024; Liu dkk., 2023).

Fine-tuning merupakan proses penyesuaian parameter model pra-latih terhadap karakteristik data target untuk meningkatkan kemampuan representasi. Pendekatan ini terbukti mampu meningkatkan akurasi dan performa model, terutama pada dataset terbatas. Namun, proses *fine-tuning* memerlukan pengaturan yang tepat untuk menghindari *overfitting* serta peningkatan kebutuhan komputasi (Talukder dkk., 2024). Meskipun penggunaan CNN dengan *transfer learning* dan *fine-tuning* telah menunjukkan kinerja yang baik pada berbagai tugas klasifikasi citra medis, pendekatan berbasis model tunggal masih memiliki keterbatasan. Setiap arsitektur CNN memiliki karakteristik ekstraksi fitur yang berbeda, sehingga performa model

dapat bervariasi tergantung pada kompleksitas data. Pada kasus klasifikasi *fine-grained*, model tunggal sering mengalami kesalahan pada sampel dengan tingkat ambiguitas visual yang tinggi (Khan dkk., 2024).

Salah satu pendekatan yang dapat digunakan untuk meningkatkan kinerja dan stabilitas prediksi adalah metode *ensemble*, yaitu dengan menggabungkan keluaran dari beberapa model yang berbeda. Pendekatan ini mampu memanfaatkan keunggulan masing-masing arsitektur sehingga menghasilkan prediksi yang lebih robust dibandingkan model tunggal. Metode *ensemble* yang umum digunakan adalah soft voting, yaitu dengan merata-ratakan probabilitas keluaran dari beberapa model (Sevim dkk., 2023).

Metode *ensemble* konvensional seperti *soft voting* menggunakan pembobotan tetap dan belum mempertimbangkan tingkat keyakinan model pada setiap sampel. Dalam konteks klasifikasi citra medis yang bersifat *fine-grained*, tingkat ketidakpastian prediksi menjadi faktor penting karena perbedaan antar kelas yang sangat halus dapat meningkatkan ambiguitas (Liu dkk., 2022). Selain itu, model *deep learning* sering menghasilkan nilai *confidence* yang tinggi meskipun prediksi tidak akurat, sehingga diperlukan pendekatan yang mempertimbangkan kalibrasi dan estimasi ketidakpastian (Guo dkk., 2017; Abdar dkk., 2021). Oleh karena itu, model dengan tingkat *confidence* tinggi dan ketidakpastian rendah seharusnya memiliki kontribusi yang lebih besar dalam proses pengambilan keputusan melalui mekanisme pembobotan adaptif (Lakshminarayanan dkk., 2020). Oleh karena itu, diperlukan suatu pendekatan *ensemble* adaptif yang mampu menyesuaikan bobot model secara dinamis berdasarkan tingkat *confidence* dan *entropy*. Pendekatan ini didasarkan pada teori *ensemble learning* yang menyatakan bahwa pembobotan statis tidak optimal ketika performa model bervariasi per sampel. Selain itu, teori *uncertainty* dan *information theory* menunjukkan bahwa kualitas prediksi dapat diukur melalui *confidence* dan *entropy*. Oleh karena itu, pembobotan adaptif berbasis kedua faktor tersebut memungkinkan model memberikan kontribusi yang lebih proporsional terhadap keputusan akhir (Khosravi dkk., 2021).

Kondisi terkini terkait *Adaptive Weighted Ensemble* menunjukkan adanya pergeseran dari metode *ensemble* konvensional yang menggunakan bobot statis,

seperti *majority voting* dan *soft voting*, menuju mekanisme pembobotan adaptif yang dapat menyesuaikan kontribusi setiap model secara dinamis. Pendekatan modern tidak hanya mempertimbangkan performa global model, tetapi juga memanfaatkan informasi pada tingkat sampel, seperti nilai *confidence*, *entropy*, dan *uncertainty*, untuk menentukan bobot yang paling sesuai pada saat inferensi. Tren ini banyak diterapkan pada klasifikasi citra medis karena terbukti mampu meningkatkan akurasi, stabilitas, dan reliabilitas prediksi, terutama pada kasus *fine-grained classification* yang memiliki tingkat kemiripan antar kelas yang tinggi dan ketidakpastian prediksi yang besar. Dengan demikian, *Adaptive Weighted Ensemble* menjadi salah satu pendekatan yang berkembang pesat untuk menghasilkan sistem klasifikasi yang lebih robust dibandingkan ensemble berbobot tetap.

Penerapan *Convolutional Neural Network* (CNN) yang dikombinasikan dengan teknik pemrosesan citra menawarkan solusi otomatisasi diagnosis yang mampu mereduksi ketergantungan pada inspeksi manual yang memakan waktu. Melalui pendekatan *transfer learning*, model CNN dapat mengadaptasi pengetahuan dari *dataset* skala besar untuk mengenali fitur kompleks pada citra telur cacing secara presisi. Penelitian ini memanfaatkan tiga arsitektur *backbone* dengan karakteristik komplementer: *EfficientNet-B0* untuk optimasi akurasi-efisiensi melalui *compound scaling* (Tan & Le, 2019); *MobileNetV3-Large* sebagai representasi model ringan yang relevan untuk perangkat berbiaya rendah seperti mikroskop USB (Howard dkk., 2019); serta *ResNet-50* yang memiliki stabilitas tinggi dalam mengekstraksi fitur morfologi medis yang mendalam (He dkk., 2016).

Kombinasi ketiga arsitektur tersebut diharapkan mampu menangkap detail *fine-grained* telur cacing secara lebih komprehensif dibandingkan model tunggal. Namun, guna mengatasi kelemahan metode *ensemble* statis, penelitian ini mengusulkan metode *Adaptive Multi-Backbone Ensemble*. Pendekatan ini secara dinamis menggabungkan keluaran model berdasarkan nilai *confidence* dan *entropy*, sehingga sistem dapat menyesuaikan diri terhadap ketidakpastian (*uncertainty*) tiap model pada setiap sampel citra tanpa memerlukan proses pelatihan ulang (*retraining*).

Integrasi mekanisme pembobotan dinamis dengan keragaman ekstraksi fitur dari tiga *backbone* ini diharapkan menghasilkan solusi diagnostik yang tidak hanya akurat dan *robust*, tetapi juga efisien secara komputasi untuk diimplementasikan pada perangkat standar di lapangan.

1.2 Identifikasi Masalah Penelitian

Masalah yang diidentifikasi dalam penelitian ini adalah proses klasifikasi telur cacing yang masih dilakukan secara manual dalam diagnosis penyakit cacing pada manusia, yang memerlukan waktu lama dan tenaga kerja yang intensif. Proses manual tersebut bergantung pada keahlian analis laboratorium serta rentan terhadap kesalahan akibat kemiripan morfologi antar spesies telur cacing dan variasi kualitas citra mikroskopis. Kondisi ini berdampak pada efisiensi dan akurasi diagnosis.

Meskipun pendekatan otomatis berbasis *Convolutional Neural Network* (CNN) telah menunjukkan kinerja yang baik dalam klasifikasi citra medis, permasalahan klasifikasi telur cacing termasuk dalam kategori *fine-grained classification*, di mana perbedaan antar kelas bersifat sangat halus. Tantangan ini menyebabkan model tunggal sering mengalami kesalahan pada sampel dengan tingkat ambiguitas visual yang tinggi.

Selain itu, setiap arsitektur CNN memiliki karakteristik ekstraksi fitur yang berbeda, sehingga performa model dapat bervariasi tergantung pada kompleksitas dan karakteristik data. Pendekatan berbasis satu model belum tentu mampu memberikan kinerja yang optimal dan stabil pada seluruh variasi data. Oleh karena itu, diperlukan suatu pendekatan yang mampu meningkatkan akurasi dan robustness sistem klasifikasi melalui pemanfaatan beberapa arsitektur CNN seperti *EfficientNetB0*, *MobileNetV3Large*, dan *ResNet50* dengan pendekatan *transfer learning* dan *fine-tuning*. Selanjutnya, diperlukan mekanisme penggabungan model yang lebih efektif dibandingkan metode konvensional, dengan mempertimbangkan tingkat keyakinan dan ketidakpastian prediksi pada setiap sampel.

Dengan mengatasi keterbatasan klasifikasi manual dan model tunggal melalui sistem otomatis berbasis CNN *multi-backbone* dan pendekatan *ensemble* adaptif,

diharapkan sistem yang dikembangkan dapat meningkatkan efisiensi dan keandalan diagnosis infeksi cacing pada manusia.

1.3 Perumusan Masalah

Berdasarkan latar belakang diatas, maka peneliti merumuskan permasalahan yang akan jadi topik pembahasan dalam penelitian ini yaitu:

- a. Bagaimana membangun model klasifikasi telur cacing berbasis *Convolutional Neural Network* (CNN) menggunakan pendekatan *transfer learning* dan *fine-tuning*?
- b. Bagaimana kinerja tiga arsitektur CNN, yaitu *EfficientNetB0*, *MobileNetV3Large*, dan *ResNet50*, dalam mengklasifikasikan jenis telur cacing berdasarkan citra digital?
- c. Apakah metode *ensemble* dengan teknik *soft voting* dapat meningkatkan akurasi dan stabilitas prediksi dibandingkan model tunggal?
- d. Bagaimana pengaruh pendekatan *ensemble* adaptif berbasis *confidence* dan *entropy* terhadap peningkatan kinerja sistem klasifikasi telur cacing?
- e. Seberapa efisien beban komputasi dan latensi inferensi dari penggabungan tiga arsitektur model tersebut untuk diimplementasikan pada perangkat komputasi standar?

1.4 Maksud dan Tujuan Penelitian

Tujuan dari penelitian ini adalah:

1. Membangun model CNN berbasis transfer learning dan fine-tuning untuk mengklasifikasikan jenis telur cacing parasit berdasarkan citra digital.
2. Melakukan perbandingan kinerja tiga arsitektur CNN, yaitu *EfficientNetB0*, *MobileNetV3Large*, dan *ResNet50*, dalam proses klasifikasi telur cacing.
3. Mengembangkan metode *ensemble* menggunakan teknik soft voting untuk meningkatkan akurasi dan stabilitas hasil klasifikasi.
4. Menerapkan pendekatan *ensemble* adaptif berbasis nilai *confidence* dan *entropy* untuk meningkatkan performa dan *robustness* sistem klasifikasi telur cacing.

5. Menganalisis biaya komputasi (*computational cost*) dan waktu inferensi dari sistem *ensemble* untuk memastikan kelayakan implementasi pada perangkat keras laboratorium.

1.5 Kebaruan dan Orisinalitas (*Novelty and Originality*)

Penelitian ini memiliki kebaruan dan orisinalitas yang terletak pada pendekatan metodologis dalam menyelesaikan permasalahan klasifikasi *fine-grained* telur cacing berbasis citra mikroskopis. Berbeda dengan penelitian sebelumnya yang umumnya berfokus pada peningkatan performa melalui pemilihan arsitektur *Convolutional Neural Network* (CNN) atau penambahan jumlah data pelatihan, penelitian ini mengkaji keterbatasan pendekatan tersebut serta mengusulkan strategi peningkatan kinerja yang lebih efektif dan efisien.

Kebaruan pertama sekaligus kontribusi utama penelitian ini adalah pengembangan *framework Adaptive Multi-Backbone Ensemble* berbasis *confidence* dan *entropy*. *Framework* ini menggabungkan beberapa model CNN pra-latih, yaitu *EfficientNetB0*, *MobileNetV3Large*, dan *ResNet50*, dengan mekanisme pembobotan adaptif pada tingkat sampel. Berbeda dengan *ensemble* konvensional yang menggunakan bobot statis atau *soft voting* sederhana, pendekatan yang diusulkan menyesuaikan kontribusi setiap model berdasarkan tingkat keyakinan prediksi dan ketidakpastian, sehingga menghasilkan keputusan yang lebih andal.

Kebaruan kedua terletak pada efisiensi implementasi metode yang diusulkan, karena proses *ensemble* adaptif dilakukan tanpa memerlukan pelatihan ulang model. Pendekatan ini memungkinkan integrasi model pada tahap inferensi secara langsung, sehingga lebih efisien secara komputasi dan lebih praktis untuk diterapkan pada sistem diagnosis otomatis dengan sumber daya terbatas.

Secara keseluruhan, orisinalitas penelitian ini terletak pada pergeseran pendekatan dari peningkatan performa berbasis penambahan data menuju pengelolaan ketidakpastian model, yang terbukti lebih efektif untuk permasalahan *fine-grained classification* pada domain medis.

Hipotesis kebaruan dalam penelitian ini terletak pada pengembangan metode *Adaptive Confidence–Entropy Weighted Ensemble CNN* berbasis *transfer learning*

untuk klasifikasi citra telur cacing pada citra mikroskopis. Penelitian ini mengasumsikan bahwa penggunaan mekanisme pembobotan adaptif berdasarkan nilai *confidence* dan *entropy* mampu menghasilkan performa klasifikasi yang lebih baik dibandingkan metode *ensemble* konvensional yang menggunakan bobot statis seperti *soft voting*. Dalam metode yang diusulkan, setiap model CNN tidak memberikan kontribusi yang sama, melainkan ditentukan secara dinamis berdasarkan tingkat keyakinan prediksi dan tingkat ketidakpastian yang dihasilkan pada setiap sampel citra. Model dengan nilai *confidence* yang tinggi dan *entropy* yang rendah akan memiliki bobot kontribusi yang lebih besar dalam proses pengambilan keputusan akhir. Selain itu, penelitian ini juga menghipotesiskan bahwa integrasi beberapa model CNN pra-terlatih, yaitu *EfficientNetB0*, *MobileNetV3Large*, dan *ResNet50*, dalam satu *framework ensemble* adaptif mampu meningkatkan kemampuan sistem dalam membedakan jenis telur cacing yang memiliki kemiripan morfologi (*fine-grained classification problem*). Pendekatan ini diharapkan dapat meningkatkan akurasi, stabilitas, dan robustness sistem klasifikasi, terutama pada citra mikroskopis dengan kualitas rendah atau variasi visual yang tinggi. Kebaruan lainnya adalah metode *ensemble* yang diusulkan tidak memerlukan proses pelatihan ulang (*retraining*) pada tahap *ensemble*, sehingga lebih efisien secara komputasi namun tetap mampu menghasilkan peningkatan performa yang signifikan dibandingkan model CNN tunggal maupun ensemble konvensional.

Kontribusi yang diharapkan dari penelitian ini adalah menghasilkan metode Adaptive Confidence–Entropy Weighted Ensemble yang mampu meningkatkan akurasi dan reliabilitas klasifikasi fine-grained telur cacing melalui pembobotan dinamis berbasis *confidence* dan *entropy*. Secara akademik, penelitian ini memperkaya pengembangan ensemble learning pada citra medis, sedangkan secara praktis dapat mendukung pengembangan sistem diagnosis parasit otomatis yang lebih akurat, cepat, dan konsisten.

1.6 Manfaat Penelitian

Adapun manfaat dari penelitian ini adalah:

1. Mengembangkan pemahaman dan keterampilan dalam penerapan computer vision untuk klasifikasi telur cacing parasit berbasis pemrosesan citra digital menggunakan *Convolutional Neural Network*.
2. Memberikan pendekatan yang lebih *robust* dalam klasifikasi citra medis melalui penerapan metode multi-model *ensemble* berbasis *confidence* dan *entropy*.
3. Meningkatkan kemampuan sistem dalam mengidentifikasi jenis telur cacing dengan tingkat akurasi, stabilitas, dan kemampuan generalisasi yang lebih baik.

1.7 Pembatasan Masalah

Ada beberapa batasan masalah dalam penelitian ini, yaitu :

1. Penelitian ini berfokus pada penggunaan tiga arsitektur *Convolutional Neural Network* (CNN) sebagai *backbone*, yaitu *MobileNetV3Large*, *EfficientNet-B0*, dan *ResNet50*, yang dipilih berdasarkan variasi karakteristik efisiensi dan performanya.
2. Pengembangan utama dibatasi pada desain *framework Adaptive Multi-Backbone Ensemble* yang menggabungkan keluaran model secara dinamis berdasarkan nilai *confidence* dan *entropy*.
3. Pengembangan dan eksperimen dilakukan menggunakan bahasa pemrograman *Python* di lingkungan lokal (*Anaconda/Jupyter Notebook*) untuk menjamin kompatibilitas versi *library* pendukung terhadap model yang telah dilatih.
4. Penelitian menggunakan dataset *Chula-Parasite-II* yang merupakan *gold standard* yang divalidasi oleh ahli parasitologi, sehingga validasi pada data lapangan di luar *dataset* tersebut tidak menjadi cakupan utama penelitian ini.

5. Penelitian hanya berpusat pada klasifikasi citra mikroskopis telur cacing yang terbagi ke dalam 11 kelas spesifik (seperti *Ascaris lumbricoides*, *Hookworm*, *Taenia spp*, dll).
6. Metode penggabungan model dilakukan pasca-pelatihan (*post-training*) tanpa melakukan pelatihan ulang model (*retraining*) atau modifikasi pada arsitektur internal masing-masing model *backbone*.
7. Evaluasi performa komputasi dibatasi pada pengukuran jumlah parameter, ukuran file model, dan latensi inferensi per citra.

1.8 Sistematika Penulisan

BAB I PENDAHULUAN

Bab ini berisi tentang latar belakang masalah atau penelitian, identifikasi masalah penelitian, perumusan masalah, maksud dan tujuan penelitian, kebaruan dan orisinalitas (*novelty and originality*), manfaat penelitian, pembatasan masalah, serta sistematika penulisan disertasi.

BAB II KAJIAN PUSTAKA

Bab ini membahas tinjauan pustaka yang mendeskripsikan perkembangan penelitian dan ilmu pengetahuan terbaru yang relevan dengan topik penelitian dan dikaji secara komprehensif. Selain itu, bab ini juga memuat keaslian penelitian untuk menjelaskan orisinalitas gagasan yang dikembangkan. Landasan teori yang dibahas meliputi pengolahan citra digital, *Convolutional Neural Network* (CNN), *transfer learning*, *fine-tuning*, metode *ensemble*, serta konsep *confidence* dan *uncertainty* pada model klasifikasi.

BAB III METODOLOGI PENELITIAN

Bab ini menjelaskan keseluruhan proses penelitian yang dilakukan agar hasil yang diperoleh bersifat objektif dan dapat dipertanggungjawabkan secara ilmiah. Uraian meliputi dataset yang digunakan, tahap preprocessing, proses pelatihan model CNN dengan *transfer learning* dan *fine-tuning*, serta perancangan metode *multi-backbone ensemble* yang terdiri dari *soft voting* dan *adaptive weighting* berbasis *confidence* dan *entropy*.

BAB IV HASIL PENELITIAN DAN PEMBAHASAN

Bab ini menyajikan hasil eksperimen dan analisis secara ilmiah terhadap model yang dikembangkan. Pembahasan meliputi:

- a. Hasil pelatihan model tunggal (*EfficientNetB0*, *MobileNetV3Large*, dan *ResNet50*).
- b. Perbandingan performa model tunggal.
- c. Implementasi dan evaluasi metode *ensemble* menggunakan *soft voting*.
- d. Analisis kinerja *Adaptive Multi-Backbone Ensemble*.
- e. Evaluasi statistik dan analisis kesalahan pada kelas dengan kemiripan morfologi tinggi.
- f. Perbandingan hasil dengan penelitian sebelumnya.

BAB V PENUTUP

Bab ini berisi kesimpulan sebagai jawaban atas tujuan dan rumusan masalah penelitian, serta saran yang memuat rekomendasi untuk pengembangan penelitian selanjutnya maupun implementasi praktis sistem klasifikasi telur cacing berbasis citra mikroskopis.

SEKOLAH PASCASARJANA