

BAB V

SIMPULAN DAN SARAN

5.1 Simpulan

Penelitian ini mengevaluasi performa model *Deep Learning* untuk segmentasi semantik citra *drone* dalam mendata objek-objek yang berkaitan dengan populasi hama lalat buah kawasan perkebunan salak dengan kondisi ketersediaan data berlabel yang terbatas. Berbeda dengan pendekatan sebelumnya yang bersifat biner (*Salak* dan *Background*), penelitian ini memperluas cakupan segmentasi menjadi tujuh kelas ekologis spesifik (*Pohon Salak*, *Pohon Inang Alternatif*, *Bangunan*, *Jalan dan Halaman*, *Badan Air*, *Tanah Terbuka dan Semak*, dan *Background*) untuk mengakomodasi *stakeholder* MySalak dalam menyediakan model segmentasi untuk kebutuhan lebih lanjut seperti analisis risiko hama (PRA) atau proyek lainnya yang berkaitan dengan manajemen hama pada kawasan kebun salak. Berhubung kebutuhan waktu yang banyak dalam anotasi data multikelas pada citra, pendekatan *semi-supervised learning* diterapkan sebagai solusi untuk memaksimalkan pemanfaatan data berlabel dan tidak berlabel untuk proses pelatihan model.

Secara metodologis, penelitian ini dijalankan melalui dua fase eksperimen utama dalam kerangka kerja DiverseNet. Fase pertama berfokus pada pemilihan arsitektur terbaik dengan membandingkan *baseline* DeepLabV3+ ResNet-50 melawan UNet++ MobileNetV2, di mana UNet++ terbukti lebih efektif dalam menangani karakteristik visual tajuk salak. Fase kedua merupakan tahap optimasi yang membandingkan performa model terpilih (UNet++ MobileNetV2) dengan DeepLabV3+ Xception menggunakan strategi pelatihan *Baseline V2*. Pendekatan *Baseline V2* ini secara spesifik menerapkan integrasi *Sqrt-Damped Class-Balanced Loss* dan *Class Specific Confidence Thresholds* untuk memitigasi dampak ketidakseimbangan kelas yang ekstrem serta memperbaiki kualitas *pseudo-label* pada kelas minoritas.

Berdasarkan hasil evaluasi menyeluruh, konfigurasi UNet++ MobileNetV2 dengan strategi *Baseline* V2 mencapai performa puncak pada skenario ketersediaan data berlabel 5% (50 citra). Pada titik ini, model mencatatkan mIoU sebesar $0,4956 \pm 0,0262$ dan F1-Score $0,6091 \pm 0,0370$, serta berhasil memenuhi syarat utama *stakeholder* dengan mempertahankan performa deteksi kelas Salak yang mencapai IoU sebesar $0,8534 \pm 0,0275$. Nilai ini secara konsisten melampaui ambang batas 0,80 tanpa mengalami degradasi. Keunggulan pada skenario data minim ini, yang justru mengungguli skenario data lebih besar (10% dan 20%), mengindikasikan bahwa fitur pembobotan adaptif pada *Baseline* V2 sangat efisien dalam mengekstraksi informasi, sementara penambahan data berlabel yang lebih besar justru memicu saturasi performa akibat potensi *noise* pada kualitas label.

Secara keseluruhan, penelitian ini menyimpulkan bahwa model yang diusulkan didukung dengan hasil inferensi visual pada ketiga skenario data uji, telah berhasil menjawab pertanyaan penelitian dengan menyediakan peta segmentasi multikelas yang kompetitif dan stabil, bahkan dalam kondisi keterbatasan data yang ekstrem. Meskipun tujuan utama untuk mendeteksi salak tanpa degradasi telah tercapai dengan baik, evaluasi menunjukkan bahwa peningkatan performa lebih lanjut pada kelas minoritas masih dimungkinkan. Hal ini dapat dicapai melalui perbaikan mekanisme kurasi kualitas label sebelum meningkatkan jumlah data latih, menjadikan model ini fondasi yang kuat namun tetap terbuka untuk pengembangan lanjutan dalam ekosistem MySalak.

5.2 Saran

Berdasarkan pengalaman dan hasil evaluasi selama pelaksanaan penelitian ini, beberapa saran yang diharapkan dapat bermanfaat bagi pengembangan penelitian selanjutnya:

1. Melakukan eksplorasi lanjutan terhadap konfigurasi *hyperparameter* pelatihan, khususnya *learning rate*, strategi pembobotan kelas, serta mekanisme *confidence thresholding* pada skema *semi-supervised learning*. Hasil penelitian ini menunjukkan

bahwa peningkatan proporsi data berlabel dapat mengubah dinamika pembelajaran model, sehingga penyetelan yang lebih tepat berpotensi diperlukan untuk menjaga stabilitas performa, terutama pada kelas minoritas.

2. Menambah data latih berlabel pada dengan memperhatikan kelas-kelas minoritas dari wilayah yang berbeda atau kondisi lingkungan yang bervariasi. Data latih berlabel juga harus dipastikan memiliki kualitas anotasi dan citra yang baik.
3. Pemilihan arsitektur model dan backbone perlu dipertimbangkan lagi terhadap ketersediaan dan karakteristik data. Hasil penelitian ini menunjukkan bahwa arsitektur yang lebih ringan memberikan performa yang lebih stabil pada kondisi data berlabel terbatas, sehingga eksplorasi konfigurasi model dan *backbone* yang sesuai tetap menjadi aspek penting dalam pengembangan lanjutan.

