

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang Masalah

Salak pondoh (*Salacca zalacca* var. pondoh) merupakan komoditas hortikultura unggulan Indonesia yang memiliki nilai ekonomi strategis dengan potensi ekspor tinggi berkat cita rasa manis-asam dan tekstur daging buah yang renyah. Komoditas ini diminati pasar domestik maupun internasional, dengan tujuan ekspor meliputi negara-negara Asia, Timur Tengah, hingga Eropa [1], [2], [3]. Berdasarkan Outlook Komoditas Hortikultura Salak Tahun 2020, produksi nasional tahun 2019 tumbuh 37,71% mencapai lebih dari 1.680 ton, dengan Kecamatan Turi, Sleman, sebagai sentra utama yang didukung kemitraan Paguyuban Mitra Turindo [3], [4]. Meskipun begitu, stabilitas ekspor komoditas ini menghadapi tantangan nyata akibat serangan hama lalat buah (*Bactrocera spp.*). Insiden penanggulangan impor oleh otoritas Tiongkok pada Maret 2024 akibat temuan infestasi [5] mengindikasikan bahwa pengendalian organisme pengganggu tumbuhan (OPT) merupakan faktor penting dalam keberlanjutan akses pasar global, terutama kepada negara mitra dagang yang mewajibkan jaminan keamanan pangan tinggi.

Untuk membuka peluang pasar global yang lebih besar lagi, prasyarat mutlak yang harus dipenuhi adalah kepemilikan *Phytosanitary Certificate* (PC) sebagai jaminan legal bahwa komoditas bebas dari hama karantina sesuai standar *International Standards for Phytosanitary Measures* (ISPM) No. 26 [21], [40]. Proses penerbitan sertifikat ini melibatkan inspeksi fisik yang sangat ketat oleh otoritas karantina (Barantin). Sebagaimana disampaikan dalam wawancara pakar entomologi UGM dengan Dr. Suputa, S.P., M.P., mekanisme pemeriksaan untuk tujuan ekspor risiko tinggi menerapkan pengambilan sampel acak yang representatif (dapat mencapai 10% dari total volume), dengan prinsip '*Zero Tolerance*'. Artinya, temuan satu ekor larva atau

alat buah hidup saja dalam sampel tersebut akan memicu penolakan terhadap keseluruhan kontainer ekspor dari lahan kelompok tani terkait, bukan hanya sampel yang terinfeksi. Risiko kerugian ekonomi ini menunjukkan urgensi untuk mengoptimalkan strategi pertanian agar sesuai dengan kaidah teknis yang dikembangkan oleh FAO (*Food and Agriculture Organization*) dan IAEA (*International Atomic Energy Agency*), lembaga rujukan internasional yang menetapkan standar global untuk program pengendalian hama alat buah berbasis area luas [40]. Optimalisasi ini berorientasi pada pencapaian dan pemeliharaan indeks populasi atau *Fruit Fly per Trap per Day* (FTD) yang konsisten rendah. Stabilitas nilai FTD di level minimum (0) ini menjadi indikator bagi otoritas karantina, jika dapat dibuktikan secara ilmiah, hal ini menjadi landasan kuat untuk menegosiasikan penurunan persentase pengambilan sampel, sehingga probabilitas keberhasilan ekspor dapat ditingkatkan secara signifikan [6].

Sebagai respons terhadap standar ketat tersebut, penerapan strategi *Area-Wide Integrated Pest Management* (AW-IPM) menjadi pilihan terbaik. Secara fundamental, AW-IPM adalah pendekatan menyeluruh yang mengintegrasikan berbagai teknik pengendalian untuk menekan populasi hama di seluruh kesatuan wilayah geografis yang luas, melampaui batas-batas kepemilikan lahan individu. Dalam ekosistem strategi ini, manajemen perangkap memegang peranan sentral sebagai instrumen *monitoring* keberadaan OPT, yang salah satunya adalah hama alat buah. Sehubungan dengan hal tersebut, maka ditentukanlah fondasi utama keberhasilan manajemen *trap monitoring* dalam AW-IPM adalah berdasarkan *Pest Risk Analysis* (PRA), yaitu metode asesmen risiko hama secara ilmiah yang menjadi dasar pengambilan keputusan untuk menentukan kepadatan perangkap (*trap density*) serta sebaran spasialnya melalui pemetaan mosaik area risiko [6]. Namun, realitas di lapangan menunjukkan adanya kesenjangan teknis dalam implementasi strategi manajemen perangkap, di mana penempatan perangkap belum didasarkan pada standar PRA maupun AW-IPM. Hingga saat ini, belum

ada acuan resmi maupun rekaman data mengenai zona risiko penyebaran lalat buah di Turi, sehingga basis data yang diperlukan untuk mitigasi hama masih belum tersedia secara lengkap. Ditambah lagi, pemetaan mosaik area dalam kawasan kebun salak tersebut juga belum dilakukan secara menyeluruh ke semua lahan para petani. Padahal, pakar menyampaikan bahwa justifikasi ilmiah mengenai 'berapa', 'mengapa', dan 'di mana' perangkat diletakkan merupakan syarat *monitoring* hama dalam diplomasi ekspor. Namun, perhitungan risiko hama secara ilmiah baru bisa dilakukan setelah semua faktor di lapangan seperti lahan salak, zona penyangga, dan kondisi iklim terpetakan dengan jelas [6], [41].

Dengan adanya realitas di lapangan yang menunjukkan bahwa pengelolaan monitoring hama di Turi saat ini masih berjalan secara konvensional tanpa dukungan data spasial yang terstandarisasi, maka selama ini, penentuan lokasi pengamatan maupun identifikasi area risiko sering kali hanya mengandalkan intuisi atau estimasi visual semata, yang sangat rentan terhadap bias subjektif, terutama di tengah karakteristik lanskap yang rumit dan terfragmentasi. Ketiadaan dokumentasi wilayah yang memadai menyebabkan sulitnya melakukan evaluasi maupun penelusuran kembali terhadap efektivitas strategi yang diterapkan, di mana area-area kritis di zona penyangga seringkali luput dari perhatian karena tidak tercatat dalam peta kerja. Oleh karena itu, sesuai dengan anjuran FAO/IAEA pada dokumennya, ketersediaan peta digital hingga pendataan objek-objek dalam peta tersebut, menjadi kebutuhan mendesak untuk menggeser paradigma pengelolaan tersebut menuju manajemen berbasis data ilmiah [6]. Peta digital ini diproyeksikan bukan sekadar sebagai visualisasi semata, melainkan sebagai fondasi basis data spasial *Geographic Information System* (GIS) yang mampu mendokumentasikan kondisi lahan secara transparan. Hal ini penting untuk memvalidasi bahwa setiap keputusan penempatan perangkat *monitoring* benar-benar merepresentasikan zonasi risiko yang ada di lapangan, bukan sekadar penempatan acak tanpa dasar ilmiah yang dapat dipertanggungjawabkan [40].

Kebutuhan akan pemetaan yang selaras dengan pedoman teknis FAO/IAEA ini menekankan bahwa analisis risiko dalam sebuah kawasan kebun tidak cukup hanya mempertimbangkan faktor makro seperti iklim atau jarak saja, melainkan harus berbasis pada pendataan elemen fisik pembawa risiko secara detail yang berada di kebun dan sekitarnya juga [6]. Kebutuhan ini menjadi semakin kompleks di wilayah studi Kecamatan Turi, Sleman, yang memiliki karakteristik *mixed landscape* atau lanskap pertanian campuran. Berbeda dengan perkebunan monokultur berskala industri, kebun salak di wilayah ini terfragmentasi dan bercampur secara heterogen dengan vegetasi liar, pemukiman, infrastruktur publik, maupun *buffer zones* lainnya. Maka dari itu, variabel yang wajib terpetakan untuk pendataan berdasarkan pedoman teknis FAO/IAEA dan informasi dari pakar meliputi distribusi tanaman inang utama (*Salak*), keberadaan inang alternatif (*secondary hosts*) seperti kebun cabai, serta pemukiman (*human settlements*) yang berperan sebagai jalur introduksi hama. Selain itu, fitur lingkungan lain seperti jalan raya sebagai koridor pergerakan, tanah terbuka sebagai tempat bersembunyi atau merupakan *shelter* dan berpotensi tempat pembuangan sampah, serta badan air, yang memiliki peran ganda sebagai sumber kelembaban maupun habitat predator alami, semuanya perlu didata dengan baik. Menurut observasi lapangan dan pendapat pakar, area-area semacam ini sering menjadi sumber perkebangbiakan tersembunyi yang luput dari pengawasan rutin maupun *monitoring* lewat perangkat yang ada, sehingga ketiadaan data spasial mengenai objek-objek pada kawasan kebun salak tersebut akan menyebabkan analisis risiko menjadi bias dan dapat berdampak pada strategi *monitoring* yang tidak tepat sasaran [6], [20], [41].

Upaya konkret untuk mewujudkan modernisasi pertanian berbasis data tersebut kini diakselerasi oleh MySalak, sebuah tim riset dan pengembangan yang berfokus pada implementasi teknologi *Artificial Intelligence of Things* (AIoT) untuk Paguyuban Mitra Turindo. Didukung oleh pendanaan hibah EPICS in IEEE, MySalak mengintegrasikan tim pengembang perangkat keras

(*hardware*) dan perangkat lunak (*software*) untuk turut aktif berkomunikasi dengan para *stakeholders* agar membantu membangun ekosistem AW-IPM pada Paguyuban Mitra Turindo. Dalam *roadmap* pengembangan sistem cerdas ini, fondasi digitalisasi pemetaan lahan sebenarnya telah diletakkan oleh kontributor tim MySalak tahun sebelumnya dengan cara melakukan foto wilayah pertanian menggunakan *drone*, yaitu oleh Zaini dan Tjandra [7], [10]. Hal ini dilakukan berdasarkan diskusi dengan pakar, bahwa metode survei terestris atau pemetaan manual dengan menyusuri lahan dinilai tidak layak untuk diterapkan pada skala kawasan yang luas. Kompleksitas vegetasi yang rapat dan aksesibilitas lahan yang sulit membuat pendataan setiap objek risiko, seperti letak spesifik inang alternatif di dalam perkebunan atau pekarangan warga, membutuhkan alokasi sumber daya manusia dan durasi waktu yang sangat banyak dan panjang. Oleh sebab itu, kontribusi mereka menjadi langkah awal dalam transisi petani Turi dari manajemen lahan konvensional menuju penerapan sistem AW-IPM yang menyeluruh. Selanjutnya, melalui peta mosaik berkat gabungan citra *drone* ini akan menjadi landasan untuk pendataan objek-objek dalam wilayah, hingga pengembangan fitur rekomendasi penempatan *trap monitoring* dan dikelola melalui GIS. Hal-hal ini merupakan target pengembangan berkelanjutan dari *roadmap* MySalak.

Sebagai tindak lanjut dari penyediaan peta mosaik wilayah, pendekatan *Deep Learning* dipilih sebagai solusi untuk mengatasi limitasi skalabilitas dan konsistensi yang melekat pada metode pendataan atau anotasi objek-objek pada peta secara manual. Secara operasional, anotasi pemetaan visual pada lanskap Turi yang heterogen menghadapi kendala efisiensi karena satu wilayah kebun bisa mencapai hampir ratusan hektar luasnya. Ditambah, proses anotasi manual untuk satu porsi kecil dari peta mosaik keseluruhan yang diambil melalui citra *drone* beresolusi tinggi saja dapat memakan waktu yang relatif lama akibat kompleksitas membedakan pohon salak dengan vegetasi lainnya, maupun anotasi objek-objek lainnya. Dengan luasnya area para kelompok tani yang harus dipetakan, metode ini menjadi tidak layak untuk diterapkan secara

luas. Lebih jauh, pakar juga menyoroti bahwa ketergantungan pada pengamatan manusia rentan terhadap faktor kelelahan yang memicu subjektivitas dan inkonsistensi data.

Maka dari itu, dalam implementasinya, Zaini berhasil mengimplementasikan arsitektur UNet++ dengan *backbone* MobileNetV2 untuk mensegmentasi hanya pada zona lahan salak dengan penyangga, mencatatkan IoU impresif sebesar 0,7747 pada kelas salak, sementara Tjandra mengeksplorasi ketangguhan DeepLabV3+ dengan *backbone* Xception untuk tujuan yang sama dengan hasil IoU 0,8196 [7], [10]. Mengingat karakteristik lanskap perkebunan Turi yang sangat luas, terfragmentasi, dan heterogen, serta berkaitan dengan *roadmap* MySalak, pendekatan segmentasi biner (*Salak & Background*) yang sudah diterapkan, menyisakan celah dalam label *Background*, alias zona penyangga. Label ini menggabungkan semua objek yang ada selain salak menjadi satu kelas, sehingga objek spesifik lain yang relevan menurut pedoman dan wawancara tidak dapat diidentifikasi.

Untuk mengatasi keterbatasan segmentasi biner ini, tim *Software* MySalak merencanakan pengembangan model baru berupa *multiclass semantic segmentation* yang mampu membedakan tujuh kelas objek lingkungan, di antaranya adalah kelas *Pohon Salak, Pohon Inang Alternatif, Bangunan, Jalan dan Halaman, Badan Air, Tanah Terbuka dan Semak*, dan *Background*. Penambahan kelas dari biner ke *multiclass* ini tidak hanya memungkinkan pemetaan kelas tambahan yang berdampak ke pendataan PRA, yang dokumen forumalisanya saat ini sedang dilakukan secara paralel dalam kerangka kerja yang terpisah pada kawasan kebun salak, tetapi juga beririsan dengan *roadmap* proyek MySalak berikutnya, yaitu sistem manajemen dan otomasi rekomendasi titik perangkat *monitoring* hama lalat buah. Tanpa data objek yang memadai dari hasil segmentasi, sistem tidak dapat menentukan lokasi perangkat pada lingkungan eksternal kebun salak secara valid, berisiko



menghasilkan rekomendasi yang sembarang, tidak terkontrol, dan gagal mendeteksi migrasi lalat buah dari lingkungan sekitar.

Pada pengembangan model multiclass ini, performa model menjadi perhatian utama dan diamati langsung oleh *stakeholder*, yaitu tim MySalak, dengan prioritas menjaga performa kelas *Salak* berupa nilai  $IoU\ IoU > \pm 0,8$  agar tetap dipertahankan seperti pada model biner yang sudah ada. Metrik lain yang berada dalam domain *confusion matrix* seperti *precision*, *recall*, dan sebagainya akan dijelaskan di bawah, digunakan sebagai metrik pendukung untuk menilai kualitas keseluruhan model secara kuantitatif maupun kualitatif berupa visual hasil inferensi. Tercapainya performa model yang sesuai dengan kriteria tersebut menjadi prasyarat utama bagi *stakeholder* (MySalak) untuk memastikan bahwa perluasan dari segmentasi biner ke multiclass tidak menurunkan keandalan deteksi kelas *Salak* yang sudah ada pada model sebelumnya, sekaligus menghasilkan informasi lingkungan tambahan pada tugas segmentasi ini. Dengan demikian, model yang dikembangkan harus mampu menyesuaikan dengan kebutuhan *stakeholder* untuk dapat digunakan lebih lanjut dalam ekosistem MySalak.

Dalam ranah pembelajaran mesin dan segmentasi citra, paradigma pelatihan model umumnya dikategorikan menjadi tiga pendekatan utama, yaitu *fully-supervised learning*, *unsupervised learning*, dan *semi-supervised learning*. Pembelajaran *supervised* memerlukan data yang berlabel lengkap untuk setiap piksel, yang dalam kasus ini menjadi penghambat utama akibat tingginya biaya waktu anotasi. Di sisi lain, metode *unsupervised* beroperasi tanpa label sama sekali (seperti *clustering*), namun seringkali kurang akurat untuk klasifikasi objek spesifik. Mengingat kondisi spesifik pada citra drone kebun salak, di mana proses anotasi piksel sangat memakan waktu namun data mentah (citra tanpa label) tersedia dalam jumlah banyak, pendekatan *Semi-Supervised Learning* (SSL) menjadi pilihan yang paling pragmatis dan ideal. Metode ini bekerja dengan memanfaatkan sebagian kecil data berlabel

dan sebagian besar data tidak berlabel untuk melatih model. Sebuah survei terbaru mengkaji banyak metode *semi-supervised semantic segmentation* dan menyimpulkan bahwa kombinasi teknik seperti *pseudo-labeling*, *adversarial learning*, dan regularisasi konsistensi menjadi tren utama dalam meningkatkan performa model dengan data terbatas [9].

Sebagai solusi terhadap permasalahan keterbatasan data label akibat kebutuhan sumber daya manusia (SDM) untuk melakukan proses pelabelan (*labeling*) data yang masif. Lalu, berdasarkan estimasi menggunakan platform anotasi Darwin V7 Labs, proses anotasi manual untuk satu citra *drone* beresolusi tinggi ditambah dengan penambahan kelas ini, membutuhkan waktu antara 25 hingga 45 menit per citra [8]. Oleh karena itu, penelitian ini mengusulkan penerapan *framework semi-supervised learning semantic segmentation* berbasis perturbasi keputusan yang dinamakan DiverseNet yang secara spesifik menggunakan arsitektur DiverseHead [11].

Pemilihan DiverseNet sebagai landasan metode dalam penelitian ini didasarkan pada efektivitasnya yang telah teruji pada domain segmentasi citra penginderaan jauh (*remote sensing*). Dalam publikasi aslinya, *framework* ini divalidasi menggunakan dataset standar industri seperti ISPRS Potsdam (*multi-band*) dan DFC2020, menunjukkan kemampuan adaptasi terhadap variasi fitur lingkungan. Secara spesifik, konfigurasi yang diadopsi dalam penelitian ini menggunakan arsitektur DeepLabv3+ sebagai model dasar segmentasi dengan ResNet-50 sebagai *backbone* yang telah dilatih sebelumnya (*pre-trained*) pada ImageNet. Keunggulan utama arsitektur ini terletak pada desain DiverseHead yang ringan. Alih-alih menggunakan beberapa jaringan penuh yang berat, metode ini hanya memodifikasi bagian akhir jaringan dengan menambahkan beberapa *decision heads* yang masing-masing hanya terdiri dari dua lapisan konvolusi. Evaluasi performa menunjukkan bahwa konfigurasi ini mampu melampaui metode *state-of-the-art* lainnya seperti MT, CCT, dan CPS dalam metrik akurasi dan



*mIoU*, dengan keunggulan berupa ukuran parameter model yang jauh lebih kecil dan waktu pelatihan yang lebih singkat. Selain itu, ketersediaan implementasi kode *open source* di repositori resmi untuk menjamin reproduktifitas penelitian dan memfasilitasi integrasi ke dalam ekosistem pengembangan MySalak [11], [23].

*Framework semi-supervised learning* DiverseNet juga bersifat fleksibel terhadap pergantian model dasar. Meskipun konfigurasi awal DiverseNet pada publikasi aslinya menggunakan DeepLabV3+ dengan backbone ResNet-50, penelitian ini tidak secara langsung menggunakan konfigurasi tersebut. Pemilihan arsitektur dasar dilakukan dengan mempertimbangkan temuan pada penelitian terdahulu, khususnya penggunaan UNet++ dengan backbone MobileNetV2 oleh Zaini serta DeepLabV3+ dengan backbone Xception oleh Tjandra, yang masing-masing menunjukkan performa yang sudah cukup baik pada segmentasi citra perkebunan salak. Berdasarkan dari referensi tersebut, penelitian ini melakukan pengujian terlebih dulu terhadap beberapa arsitektur segmentasi dalam framework DiverseNet, termasuk DeepLabV3+ dengan *backbone* ResNet-50, DeepLabV3+ dengan *backbone* Xception, serta UNet++ dengan *backbone* MobileNetV2.

Selain pemilihan arsitektur, permasalahan lain dalam transisi dari segmentasi biner ke multikelas adalah munculnya ketidakseimbangan distribusi kelas, di mana representasi piksel kelas *Salak* jauh mendominasi dibandingkan kelas minoritas seperti *Badan Air* atau *Jalan dan Halaman*. Penggunaan fungsi kerugian standar pada kondisi ini berisiko menyebabkan model mengabaikan kelas minoritas. Oleh karena itu, penelitian ini akan mengimplementasikan mekanisme *Sqrt-Damped Class-Balanced Loss*, sebuah strategi pembobotan yang mengikuti metode *Inverse Frequency Weighting* untuk memberikan penalti gradien lebih besar pada kelas jarang, namun dengan peredaman akar kuadrat guna mencegah instabilitas pelatihan akibat bobot yang terlalu tinggi [35]. Lebih lanjut, untuk memaksimalkan

pemanfaatan data tidak berlabel pada kelas-kelas sulit, diterapkan strategi *Class Specific Confidence Thresholds*. Berbeda dengan *Fixed Threshold* pada DiverseNet standar, metode ini menyesuaikan ambang batas *pseudo-label* secara fleksibel berdasarkan tingkat kesulitan pembelajaran tiap kelas, mengacu pada prinsip *Curriculum Learning* [36], sehingga fitur pada kelas minoritas tetap dapat dipelajari secara bertahap.

Untuk menguji batas efektivitas model dalam menangani peningkatan semantik dari dua kelas menjadi tujuh kelas melalui kerangka *semi-supervised learning*, penelitian ini merancang skema eksperimen menggunakan dataset 1.000 citra drone MySalak dengan variasi proporsi data berlabel bertingkat (2%, 5%, 10%, hingga 20%). Variasi proporsi ini disusun untuk mensimulasikan berbagai tingkat keterbatasan sumber daya pelabelan, dengan tujuan melakukan analisis untuk menemukan titik efisiensi data yang optimal. Fokus utama evaluasi adalah kemampuan model mempertahankan konsistensi performa segmentasi bahkan pada kondisi data minimal, tanpa degradasi metrik IoU pada kelas *Salak* dibanding model terdahulu ( $\text{IoU} > \pm 0,8$ ). Sebagai penunjang, serangkaian metrik pendukung yang mencakup *mean Intersection over Union* (mIoU), IoU per kelas non-*Salak*, *Overall Accuracy* (OA), *Producer's Accuracy* (PA), *User's Accuracy* (UA), dan F1-Score digunakan untuk mengukur keseimbangan dan kualitas generalisasi model pada kelas-kelas baru. Melalui pengujian menggunakan metrik evaluasi ini, penelitian bertujuan membuktikan bahwa pendekatan yang diusulkan mampu menghasilkan segmentasi pada ketujuh kelas dengan kebutuhan data label yang minimal, memberikan solusi bagi tim MySalak tanpa mengorbankan performa deteksi pada kelas *Salak* sebagai *primary host*.

Secara keseluruhan, implementasi metode *semi-supervised learning* melalui *framework* DiverseNet memberikan solusi konkrit terhadap kendala keterbatasan data label, pada ekosistem MySalak saat ini. Transisi kemampuan segmentasi peta dari biner ke *multiclass* yang dihasilkan penelitian ini menjadi

aset fundamental bagi *stakeholder* tim MySalak, menyediakan pemetaan elemen lahan yang jauh lebih rinci. Maka, kontribusi ini dapat difungsikan sebagai solusi teknologi yang bermanfaat bagi pengembangan fitur lanjutan seperti otomasi rekomendasi manajemen perangkat, kesediaan data untuk PRA, serta inisiasi basis data spasial berupa GIS yang lengkap bagi kemitraan Paguyuban Mitra Turindo.

## 1.2 Pertanyaan Penelitian

Berdasarkan latar belakang yang sudah penulis paparkan, identifikasi masalah yang didapat terdiri dari beberapa poin yaitu:

- 1.2.1 Bagaimana performa model dalam melakukan segmentasi multi kelas citra drone kebun salak pada kondisi data berlabel terbatas dan tak berimbang, khususnya dalam mempertahankan IoU kelas *Salak*  $> \pm 0,8$  serta stabilitas performa pada kelas lainnya?

## 1.3 Batasan Penelitian

Untuk menjaga fokus penelitian agar lebih terarah, batasan ditetapkan sebagai berikut:

- 1.3.1 Penelitian ini memanfaatkan dataset primer yang terdiri dari 1.020 citra udara (*drone*) RGB. Dataset tersebut diakuisisi oleh tim MySalak pada bulan Juli 2024, mencakup area perkebunan milik Kelompok Tani Sedyo Makmur dan Muda Jaya yang tergabung dalam Paguyuban Mitra Turindo.
- 1.3.2 Segmentasi difokuskan pada tujuh kelas semantik yang dipilih berdasarkan signifikansi bobot risikonya terhadap dinamika populasi lalat buah, mengacu pada pedoman FAO/IAEA dan validasi pakar [6], [41]:
  1. Pohon Salak (*Primary Host*): Area produksi utama.
  2. Inang Alternatif (*Secondary Host*): Vegetasi yang berfungsi sebagai inang lalat buah selain *Primary Host*.Dalam penelitian ini, pelabelan kelas ini dibatasi secara

spesifik pada komoditas tanaman cabai. Tanaman inang berjenis pohon (seperti belimbing, mangga, dan jambu) tidak dimasukkan ke dalam kelas ini karena adanya kendala ambiguitas visual pada citra yang menyebabkan annotator sulit membedakan morfologi tajuk pohon inang tersebut dengan pohon non-inang (vegetasi liar) lainnya.

3. Tanah Terbuka dan Semak (*Open Land*): Area dengan risiko sanitasi buruk yang sering menjadi lokasi pembuangan limbah buah busuk dan juga semak-semak belukar yang menjadi *shelter* inang.
4. Bangunan (*Human Settlements*): Area berisiko tinggi sebagai titik masuk (*entry point*) akibat aktivitas manusia dan pergerakan komoditas.
5. Badan Air (*Natural Barrier*): Sumber kelembapan, batas alami, atau berpotensi sebagai habitat predator dengan bobot risiko rendah atau negatif, serta berfungsi sebagai batas bagi penempatan perangkat.
6. Jalan dan Halaman: Jalur distribusi atau pergerakan manusia yang dapat memfasilitasi pergerakan inang antar-lokasi.
7. Lain-lain (*Background*): Objek yang tidak berkontribusi signifikan pada perhitungan risiko, dapat dikategorikan sebagai *buffer zones*.

1.3.3 Evaluasi difokuskan pada ketangguhan model menggunakan metrik mean *Intersection over Union* (mIoU), IoU per *Class*, F1-Score, *Overall Accuracy* (OA), *Producer's Accuracy* (PA), dan *User's Accuracy* (UA) di mana IoU pada kelas salak harus tetap dipertahankan ( $\text{IoU} > \pm 0,8$ ).

- 1.3.4 Penelitian ini berfokus pada pengembangan model segmentasi citra multikelas. Perhitungan matematis skor risiko (*risk calculation*) untuk PRA, rekomendasi penentuan titik koordinat perangkat (*trap placement*), dan GIS merupakan tahap lanjutan yang berada di luar lingkup skripsi ini.

#### 1.4 Tujuan Penelitian

Penelitian ini bertujuan untuk mengembangkan model *Deep Learning* berbasis arsitektur *DiverseNet* yang mampu melakukan segmentasi semantik multikelas pada citra *drone* kawasan kebun salak untuk mengidentifikasi tujuh kelas atau variabel lingkungan berbeda. Secara spesifik, penelitian ini berupaya membuktikan efektivitas pendekatan *semi-supervised learning* dalam mempertahankan performa deteksi yang tangguh meskipun hanya dilatih menggunakan data berlabel yang sangat terbatas, sehingga mampu menghasilkan segmentasi peta mosaik berdasarkan pada citra *drone* yang berfungsi sebagai infrastruktur data spasial untuk dapat mendukung otomasi penempatan perangkat *monitoring*, implementasi PRA, dan GIS dalam strategi AW-IPM.

#### 1.5 Manfaat Penelitian

Penelitian ini diharapkan memberikan manfaat sebagai berikut:

- 1.5.1 Menyediakan model segmentasi multikelas berbasis *semi-supervised learning* untuk kawasan perkebunan salak Paguyuban Mitra Turindo menggunakan citra drone, sebagai pengembangan dari pendekatan segmentasi biner yang telah ada.
- 1.5.2 Membantu pengembangan sistem rekomendasi penempatan perangkat monitoring serta penyusunan peta dan analisis risiko hama (PRA) dalam ekosistem MySalak.
- 1.5.3 Menjadi referensi penelitian selanjutnya dalam penerapan kerangka *semi-supervised learning* untuk segmentasi citra perkebunan dengan keterbatasan data label dan ketidakseimbangan kelas.

## **1.6 Sistematika Penulisan**

Sistematika penulisan skripsi ini adalah sebagai berikut:

### **1.6.1 BAB I PENDAHULUAN**

Bab ini memaparkan latar belakang, pertanyaan penelitian, batasan penelitian, tujuan penelitian, manfaat penelitian, dan sistematika penulisan.

### **1.6.2 BAB II TINJAUAN PUSTAKA**

Membahas teori-teori terkait Computer Vision, Deep Learning, dan teknologi aksesibilitas untuk penyandang disabilitas, serta penelitian terkait sebelumnya.

### **1.6.3 BAB III METODOLOGI PENELITIAN**

Menjelaskan metode penelitian, rancangan eksperimen, data yang digunakan, serta langkah-langkah pengembangan fitur deteksi bahasa isyarat.

### **1.6.4 BAB IV HASIL DAN PEMBAHASAN**

Memaparkan hasil pengembangan fitur dan evaluasi performa fitur deteksi bahasa isyarat berdasarkan kriteria akurasi, kecepatan, dan stabilitas.

### **1.6.5 BAB V KESIMPULAN DAN SARAN**

Menyajikan kesimpulan dari hasil penelitian serta saran untuk pengembangan lebih lanjut.