BAB I
PENDAHULUAN

1.1 Latar Belakang

Sampah merupakan berbagai macam barang yang dibuang oleh manusia secara cuma-cuma tanpa adanya pemilahan dan pengolahan sehingga mengakibatkan kerusakan lingkungan dan masalah kesehatan yang serius [1]. Sistem Informasi Pengelolaan Sampah Nasional milik Kementerian Lingkungan Hidup dan Kehutanan (KLHK) melaporkan bahwa hasil dari penginputan data yang dilakukan oleh 514 Kabupaten/Kota se-Indonesia pada tahun 2025 terdapat 144,839 ton sampah per hari dari 38 provinsi. Sampah yang terkelola hanya 35.747 ton sampah per hari atau 25 %, dan sampah yang tidak terkelola mencapai 109,092 ton sampah per hari atau 75%.

Berdasarkan kondisi tersebut, diperlukaan teknik pengelolaan sampah yang tepat untuk mengurangi timbulan volume, jenis, karakteristik sampah yang beragam. Tata kelola sampah telah tercantum pada UU No. 18 Tahun 2008 tentang Pengelolaan Sampah. Agar pengelolaan sampah pada ketentuan Pasal 11 ayat (2) , Pasal 16, Pasal 20 ayat (5), Pasal 22 ayat (2), Pasal 24 ayat (3), Pasal 25 ayat (3) dan ayat (4), dan Pasal 28 ayat (3) UU Nomor 18 Tahun 2008 tentang Pengelolaan Sampah dapat terlaksana, Pemerintah Republik Indonesia telah menetapkan PP No. 81 Tahun 2012 tentang Pengelolaan Sampah Rumah Tangga Dan Sampah Sejenis Rumah Tangga.

Penanganan sampah yang tercantum dalam Pasal 16 PP No. 81 Tahun 2012 terdiri atas empat kegiatan, yakni (a) pemilahan, (b) pengumpulan, (c) pengangkutan, (d) pemrosesan akhir sampah. Sesuai dengan PP No. 18 Tahun 2008 Pasal 22 ayat 1 huruf (a) menegaskan bahwa kegiatan pemilahan sampah dilakukan

dengan mengelompokkan dan memisahkan sampah berdasarkan jenis, jumlah, dan/atau karakteristik sampah itu sendiri. Namun, sangat disayangkan upaya dalam mengurangi timbulan volume sampah masih belum dapat diselesaikan, khususnya sampah rumah tangga. Masyarakat biasanya hanya mengumpulkan sampah rumah tangga tanpa dilakukan pemilahan sampah terlebih dahulu. Mereka cenderung mengumpulkan semua jenis sampah menjadi satu ke dalam kantong plastik sebelum dibuang ke tempat sampah. Hal ini dapat menghambat pengelolaan sampah, karena terlalu banyak sampah yang menumpuk dan berbagai jenis sampah tidak dikelompokkan, sehingga pengelompokkan sampah menjadi lebih sulit, karena setiap jenis sampah memerlukan cara pengolahan yang berbeda [2].

Kemajuan pesat teknologi saat ini memungkinkan penerapan *Artificial Intelligence* (AI), *Machine Learning* (ML), dan *Deep Learning* (DL) sebagai solusi dari efisiensi pemilahan sampah [3]. *Artificial Intelligence* (AI) merupakan cabang ilmu komputer yang semakin penting dalam beberapa tahun terakhir. Kemampuan komputasinya bertujuan untuk meniru penalaran manusia dan mengembangkan solusi pemecahan masalah yang logis. *Machine Learning* (ML), salah satu subbidang AI, menggunakan algoritma dan model statistik untuk memungkinkan sistem komputer belajar dari pengalaman dan selalu memperbaiki kinerjanya tanpa memerlukan instruksi pemrograman yang eksplisit [4]. Dalam *Machine Learning* (ML), klasifikasi gambar merupakan pengambilan informasi visual dari gambar *input* lalu melakukan pembelajaran terhadap nilai tersebut untuk melatih model dalam memahami karakteristik visualnya, sehingga dapat diklasifikasikan [5]. *Deep Learning* (DL) menyederhanakan keseluruhan analisis algoritma dan proses pembelajaran berdasarkan *Machine Learning* (ML), serta dapat mencapai akurasi di area tertentu yang tidak dapat dicapai oleh pembelajaran mesin tradisional [6].

Computer Vision (CV) merupakan cabang penting dari *deep learning* yang mempelajari pola penglihatan manusia atau hewan sebagai sebuah usaha dalam mengestraksi data menggunakan model yang dibangun dengan metode statistik berdasarkan geometri, fisika, dan teori pembelajaran [7]. Sebagai manusia, kita

memiliki kecerdasan yang luar biasa dalam memahami setiap pola yang ada, misalnya kita bisa melihat dan membedakan jenis hewan berdasarkan karakteristiknya seperti warna kulit, bentuk, jenis kulit, habitat, cara berkembang biak, dan sebagainya. Namun, hal tersebut sangat berbanding terbalik dengan komputer. Komputer perlu menganalisis pola yang dilihatnya secara statistikal berdasarkan informasi visual yang diperolehnya. Kemampuan *Computer Vision* (CV) dalam mengolah informasi visual yang diperolehnya menjadikannya sebuah terobosan dalam ilmu pengetahuan yang dapat digunakan dalam kehidupan sehari-hari, misalnya dalam mengenali nomor kendaraan secara otomatis, pencitraan medis, dan sebagainya [8]. Tidak hanya itu, kemampuan manusia dalam menemukan bagian yang penting pada suatu pemandangan menginspirasi pengembangan mekanisme *attention* pada bidang *computer vision*. Mekanisme ini dirancang untuk meniru sistem visual manusia melalui penyesuaian bobot fitur secara adaptif sesuai informasi yang terdapat pada gambar *input* [9].

Kemampuan CV tidak terbatas hanya dengan mengolah informasi visual dari sebuah citra ataupun video, namun juga mampu menemukan dan menentukan posisi akurat dari sebuah objek, proses tersebut dikenal sebagai *Object Detection* (OD) [10]. *Object Detection* berbasis *Deep Learning* mampu mempelajari pola yang lebih kompleks menggunakan *Convolutional Neural Netwoks* (CNNs), hal ini menjadikannya lebih unggul daripada metode deteksi objek konvesional [10] yang hanya berfokus pada penentuan fitur citra spesifik secara manual, sehingga kurang generalitas dan portabilitas [11]. Namun, karena faktor-faktor seperti latar belakang yang kompleks, pencahayaan, skala, oklusi, dan deformasi objek, deteksi objek menjadi sangat menantang dan sulit [12].

Object Detection berbasis *Deep Learning* berdasarkan model CNN terbagi atas dua *framework*, yakni *two-stage object detection* dan *one-stage object detection*. *Two-stage object detection* menghasilkan *bounding box* menggunakan *regions of interest* (ROIs), dan mengekstrak fitur dari wilayah tersebut dalam mendeteksi objek, sementara *one-stage object detection* menggabungkan kedua tahap menjadi

satu [10]. Beberapa algoritma *two-stage object detection* adalah *RCNN* [13], *SPPNet* [14], *Fast RCNN* [15], *Faster RCNN* [16], *Feature Pyramid Network* (FPN) [17], dan sebagainya, sedangkan *one-stage object detection* di antaranya YOLO [18], SSD [19], *RetinaNet* [20], *RTMDet* [21], dan sebagainya.

RCNN menggabungkan *region proposal* dengan CNN dan memiliki performa deteksi objek yang lebih unggul dibanding dengan hanya menggunakan HOG *feature* [13]. *SPPNet* lebih unggul komputasinya dibandingkan dengan *RCNN,* karena kemampuannya dalam mengelompokkan fitur yang diektraksi pada berbagai skala [14]. *Fast RCNN* hadir dengan kemampuannya yang akurat dan efisien yang mengungguli *RCNN* dan *SPPNet* dalam mengklasifikasikan proposal objek menggunakan *deep convolutional networks* [15]. *Region Proposal Network* (RPN) diperkenalkan dalam *Faster RCNN* untuk menghasilkan proposal wilayah pada *Fast RCNN*. Fitur konvolusi RPN dan *Fast RCNN* diintegrasikan ke dalam satu jaringan dalam terminologi *neural networks* dengan *attention mechanism,* bertujuan agar RPN mampu menginstruksikan jaringan di mana harus mencari, sehingga meningkatkan akurasi deteksi objek [16]. *Feature Pyramid Network* (FPN) mengembangkan arsitektur *top-down* dengan koneksi lateral untuk membangun peta fitur semantik tingkat tinggi pada berbagai skala, menunjukkan peningkatan signifikan sebagai ekstraktor fitur dalam berbagai aplikasi [17].

Berdasarkan perkembangan tersebut, metode deteksi objek mengalami evolusi yang signifikan dari sisi akurasi maupun efisiensi komputasi. *RCNN* menjadi awal penggunaan CNN dalam deteksi objek, kemudian dikembangkan oleh *SPPNet* dan *Fast RCNN* untuk meningkatkan kecepatan serta efisiensi proses ekstraksi fitur mulltiskala dan klasifikasi objek. Selanjutnya, *Faster RCNN* memperkenalkan *Region Proposal Network* (RPN) yang mampu menghasilkan proposal wilayah secara otomatis dan terintegrasi dalam satu jaringan, sehingga meningkatkan performa deteksi. Pengembangan lebih lanjut dilakukan melalui *Feature Pyramid Network* (FPN) yang mampu membangun representasi fitur multi-skala, sehingga deteksi objek menjadi lebih optimal pada berbagai ukuran objek. Akan tetapi,

terdapat kelemahan dari model CNN konvesional yakni membutuhkan kompleksitas komputasi yang tinggi, ditandai dengan banyaknya parameter dan operasi FLOPs dalam menghasilkan akurasi yang optimal [22].

YOLO sebagai *framework one-stage object detection* mendefinisikan deteksi objek sebagai masalah regresi tunggal yang secara langsung memprediksi koordinat *bounding box* dan probabilitas kelas dari piksel gambar. Dengan demikian, YOLO mampu mempelajari representasi objek secara umum, cepat, melakukan generalisasi dari gambar alami ke domain lain, serta mengungguli metode lain termasuk RCNN [18]. SSD mengembangkan metode berbasis *Deep Neural Networks* (DNN) dengan membagi ruang *output bounding box* menjadi beberapa *frame* standar yang memiliki beragam skala dan rasio aspek pada setiap posisi *feature map*. Dalam proses prediksi, jaringan menentukan skor keberadaan objek pada tiap kategori serta melakukan penyesuaian *frame* agar lebih sesuai dengan karakteristik objek. Pendekatan ini menghasilkan performa deteksi yang lebih cepat dibandingkan YOLO dan akurasi yang lebih baik daripada Faster RCNN [19]. Keunggulan RetinaNet dibandingkan Faster RCNN, SSD, dan YOLO terletak pada penerapan *focal loss* yang mampu menekan pengaruh loss dari data yang mudah diklasifikasikan. Dengan mekanisme tersebut, masalah ketidakseimbangan antara kelas *foreground* dan *background* pada proses pelatihan deteksi objek dapat diminimalkan [20]. *RTMDet* merupakan penyempurnaan dari YOLOX [23] untuk meningkatkan efisiensi dan tingkat keakuratannya dalam mendeteksi objek, yakni memodifikasi arsitektur ResNet-50 sebagai *backbone*-nya menggunakan teknik *deep convolutional* dengan *large kernel* dan pelabelan dinamis. Keseimbangan antara tingkat akurasi dan kecepatan yang dimiliki oleh *RTMDet* sangat baik sehingga dapat digunakan berbagai industri [21].

Dataset merupakan komponen penting dalam *computer vision* untuk meningkatkan performa algoritma *object detection,* dan mengatasi batasan pemahaman visual yang bermakna seiring dengan perkembangan keragaman dan cakupan gambar target [24]. Dengan demikian diperlukan keseimbangan dalam

distribusi *dataset.* Apabila *dataset* bersifat tidak seimbang, maka akan menyebabkan beberapa kendala seperti menurunkan performa algoritma *object detection,* ruang fitur yang terbatas pada kelas minoritas [25], bias pada model, keterkendalaan generalisasi terhadap model, dan kurang efisien dalam pengumpulan lebih banyak data untuk kelas minoritas [26]. Adapun permasalahan *imbalanced dataset* dalam tugas *object detection* adalah *class imbalance, scale imbalance, spatial imbalance,* dan *objective imbalance* [27]. *Class imbalance* terjadi ketika jumlah *instances* dari setiap kelas terdapat perbedaan yang signifikan. *Scale imbalance* merupakan kondisi ketika *instances* pada setiap kelas memiliki berbagai skala yang berbeda. *Spatial imbalance* mengacu pada berbagai aspek seperti geometris *bounding boxes* seperti penalti regresi, lokasi, dan IoU. *Objective imbalances* mengacu pada pengoptimalan *loss function* [27]. Inovasi model sebagai upaya untuk meningkatkan kemampuan fitur kelas minoritas telah banyak dikembangkan dengan memperkenalkan metode *attention mechanism, multi-scale feature extraction,* dan pemodelan hubungan kontekstual jangka panjang dan jangka pendek [28]. Selain itu juga terdapat teknik *resampling* dengan pengambilan *sample* berlebih pada kelas minoritas *(oversampling),* atau mengurangi *sample* berlebih pada kelas mayoritas *(undersampling)*, menetapkan biaya kesalahan klasifikasi yang berbeda untuk setiap kelas atau *cost sensitive learning,* menerapkan *transfer learning* dengan menggunakan fitur model yang telah dilatih sebelumnya, membuat *sample* buatan pada kelas minoritas [26]. *Repeat Factor Sampling* (RFS) merupakan teknik *resampling* yang bekerja dengan meningkatkan frekuensi kemunculan kelas minoritas melalui proses *oversampling* pada gambar yang mengandung kelas tersebut [29]. RFS efektif dalam dalam menangani ketidakseimbangan distribusi data pada deteksi objek dan meningkatkan performa model terhadap kelas dengan jumlah sampel terbatas [30]. Teknologi dari *Deep Learning* dapat dimanfaatkan dalam lakukan pemilahan sampah dengan berdasarkan kategori sampah dari citra sampah tersebut [31]. Meskipun banyak algoritma *Deep Learning* telah dikembangkan untuk mengkategorikan sampah,

algoritma-algoritma tersebut sering kali mengalami kesulitan dalam mendeteksi berbagai kategori sampah dari satu gambar *input* [32], bentuk dan ukuran sampah yang tidak terstuktur juga menjadi salah satu penyebab algoritma *Deep Learning* sulit mendeteksinya. Deteksi terhadap objek kecil juga memiliki kendala seperti kurangnya ketajaman terhadap informasi visual dan kerentanan terhadap kesalahan interpretasi [33], berbanding terbalik dengan objek yang berukuran *medium* dan *large* cenderung lebih mudah dideteksi. RTMDet menggunakan kombinasi FPN dan PANet sebagai *neck*-nya untuk memperoleh informasi citra tambahan. Namun, terdapat kekurangan yang dimiliki FPN, seperti adanya penggabungan *feature maps* berdimensi tinggi dan rendah yang tidak cukup menggabungkan fitur multiskala dan dapat menghasilkan data yang tidak relevan [34]. Salah satu hal yang dapat dilakukan untuk mengatasi hal tersebut adalah dengan memperbaiki teknik *upsampling* yang digunakan oleh FPN. *Feature upsample* merupakan komponen penting untuk memulihkan resolusi fitur secara bertahap [35]. CARAFE, FADA, dan SAPA merupakan teknik *dynamic upsampler* berbasis *kernel* yang memerlukan biaya besar dalam inferensinya, struktur yang kompleks, dan memerlukan CUDA dalam pengimplementasiannya, berbanding terbalik dengan teknik *Dysample* yang lebih cepat dan efektif [35]. CNN secara bertahap belajar memusatkan perhatian pada fitur atau area gambar yang paling penting untuk memahami isi gambar, dengan mengambil informasi penting dari gambar sedikit demi sedikit melalui *layer* konvolusi [36]. Sebagai pendekatan alternatif, *attention mechanism* memiliki struktur yang fleksibel sehingga mampu meningkatkan pembelajaran representasi fitur yang lebih diskriminatif serta mudah diintegrasikan ke dalam *backbone* arsitektur CNN.

Secara umum, mekanisme *attention* terbagi menjadi tiga jenis utama, yaitu *channel attention, spatial attention*, dan kombinasi dari keduanya [37]. *Channel attention* bertugas untuk menentukan informasi fitur yang paling relevan pada citra input, sementara *spatial attention* berfokus pada identifikasi lokasi bagian yang penting dalam gambar. Kedua jenis attention tersebut bersifat saling melengkapi

[38]. Mekanisme *channel attention* dan *spatial attention* efektif dalam meningkatkan representasi fitur, tetapi proses reduksi dimensi *channel* pada pemodelan hubungan antar *channel* dapat menyebabkan hilangnya informasi penting. Oleh karena itu, *Efficient Multi-Scale Attention* (EMA) hadir sebagai modul *attention* yang mampu mempertahankan informasi tiap *channel* dengan memanfaatkan hubungan antara fitur global dan lokal dengan penggunaan *convolution* 1×1 dan 3×3 secara paralel [37]. EMA memanfaatkan fitur global dan lokal agar *attention* dapat menangkap informasi pada berbagai ukuran dan jangkauan spasial objek.

Meskipun deteksi objek sampah telah banyak dilakukan, namun model masih mengalami kendala dalam permasalahan *imbalanced dataset, scaled imbalanced,* dan *small object detection* pada *background* yang kompleks. Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk membangun model *deep learning* dalam mendeteksi objek sampah *outdoor* pada *dataset* yang bersifat tidak seimbang. Adapun teknik yang digunakan untuk mengatasi permasalahan ketidakseimbangan *dataset* adalah *repeat factor sampling*. Algoritma *object detection* yang digunakan adalah RTMDet karena memiliki *trade-off* yang baik antara akurasi dan kecepatan [21]. Untuk meningkatkan performa dalam mendeteksi *small object,* penelitian ini juga menggunakan teknik *DySample* sebagai teknik *upsampling*-nya, yakni mengganti teknik *nearest neighbor* yang digunakan di *Feature Pyramid Network. DySample* lebih fokus pada wilayah target dan melakukan reduksi *noise* pada *background* dibanding teknik *interpolasi,* karena kemampuannya yang secara adaptif menyesesuaikan bobot *upsampling* berdasarkan fitur *input* [39]. Penelitian ini juga menerapkan EMA untuk menangani permasalahan *scale imbalance* pada objek antar kelas, dan menerapkan *Ghost Conv module* yang memanfaatkan redundansi antar *feature map* untuk menghasilkan representasi fitur yang efisien dengan jumlah parameter dan komputasi yang lebih rendah. Dengan demikian, penelitian ini dapat menghasilkan model yang mampu mendeteksi objek sampah *outdoor* secara akurat dan efisien.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dijabarkan, diperoleh rumusan masalah bahwa deteksi objek pada sampah *outdoor* masih menjadi tantangan dalam bidang *computer vision*, khususnya terkait permasalahan *imbalanced dataset*, di antaranya distribusi data yang tidak seimbang, keterbatasan jumlah sampel pada kategori tertentu, serta keberadaan objek dengan ukuran, dan karakteristik yang beragam. Kondisi tersebut menyebabkan model cenderung memiliki performa yang lebih baik pada kategori dengan jumlah sampel yang banyak dibandingkan kategori dengan jumlah sampel terbatas. Selain itu, proses ekstraksi dan representasi fitur yang kurang optimal juga dapat memengaruhi kemampuan model dalam mendeteksi objek pada berbagai skala. Kemudian, proses *upsampling* pada FPN berpotensi menyebabkan hilangnya informasi spasial, sehingga representasi objek khususnya *small* objek selama proses fusi fitur belum optimal. Tidak hanya itu, kompleksitas model juga masih cukup tinggi akibat proses konvolusi pada seluruh *channel* sehingga diperlukan metode yang mampu meningkatkan efisiensi model melalui pengurangan jumlah parameter tanpa menurunkan performa model secara signifikan. Berbagai pendekatan telah dikembangkan untuk mengatasi permasalahan tersebut, seperti strategi *resampling,* mekanisme *attention,* metode *upsampling,* maupun modifikasi operasi konvolusi. Namun, masih diperlukan kajian mengenai bagaimana kontribusi masing-masing pendekatan serta pengaruh integrasinya terhadap performa deteksi objek pada *dataset* dengan karakteristik tidak seimbang.

Berdasarkan permasalahan tersebut, penelitian ini mengembangkan model RTMDet dengan mengintegrasikan *Repeat Factor Sampling* (RFS), *Efficient Multiscale Attention* (EMA), dan GCSPNeXt untuk meningkatkan performa deteksi objek sampah *outdoor.* Selain mengevaluasi peningkatan performa secara keseluruhan, penelitian ini juga menganalisis kontribusi masing-masing modul

terhadap kemampuan deteksi berdasarkan distribusi kategroi (*rare, common, frequent*), ukuran objek (*small, medium,* dan *large*), serta efisiensi model.

1.3 Pertanyaan Penelitian

Berdasarkan rumusan masalah di atas, penelitian ini bertujuan untuk menjawab pertanyaan-pertanyaan berikut:

1. Bagaimana pengaruh integrasi *Repeat Factor Sampling* (RFS), *DySample, Efficient Multi-Scale Attention* (EMA), dan GCSPNeXt pada model RTMDet terhadap performa deteksi objek sampah *outdoor* pada *dataset* dengan kelas yang tidak seimbang ?
2. Bagaimana kontribusi masing-masing modul, yaitu *Repeat Factor Sampling* (RFS), *DySample,* dan *Efficient Multi-Scale Attention* (EMA), dan GCSPNeXt pada RTMDet terhadap peningkatan performa deteksi objek sampah *outdoor* berdasarkan distribusi kategori (*rare, common, frequent*), ukuran objek (*small, medium, large*), serta efisiensi model ?

1.4 Tujuan Penelitian

Tujuan dari dilaksanakannya penelitian ini adalah sebagai berikut:

1. Mengevaluasi pengaruh integrasi *Repeat Factor Sampling* (RFS) pada model RTMDet terhadap performa deteksi objek sampah *outdoor* pada *dataset* dengan kelas yang tidak seimbang.
2. Mengevaluasi kontribusi masing-masing modul, yaitu *Repeat Factor Sampling* (RFS), *DySample,* dan *Efficient Multi-Scale Attention* (EMA), dan GCSPNeXt pada RTMDet terhadap peningkatan performa deteksi objek sampah *outdoor* berdasarkan distribusi kategori (*rare, common, frequent*), ukuran objek (*small, medium, large*), serta efisiensi model.

1.5 Batasan Masalah

Terdapat komponen yang menjadi batasan permasalahan dalam penelitian ini adalah sebagai berikut:

1. *Dataset* sampah yang digunakan adalah *TACO Dataset.*
2. Kategori jenis sampah hanya terdiri dari 27 kategori.
3. Jenis *dataset* yang digunakan adalah *multiple object.*
4. Latar belakang *dataset* sampah hanya untuk lingkungan *outdoor.*
5. Penelitian ini hanya mengggunakan *framework one stage detection,* yakni RTMDet sebagai *baseline*-nya dengan *backbone* CSPNeXt, dan *neck* CSPNeXt-PAFPN, tanpa mengubah arsitektur dasar model selain penambahan modul yang diusulkan.
6. Penelitian hanya mengevaluasi performa model pada proses deteksi objek, dan tidak membahas implementasi *real-time* pada perangkat keras, robot, maupun *embedded system.*

1.6 Manfaat Penelitian

Manfaat teoritis dan praktis yang dihasilkan dari penelitian ini adalah sebagai berikut:

1.6.1 Manfaat Teoritis

1. Memberikan kontribusi pada penelitian deteksi objek sampah *outdoor* dengan distribusi tidak seimbang.
2. Memperkaya kajian terkait integrasi teknik *resampling* RFS, *Efficient Multi-Scale Attention* (EMA), *DySample*, dan *Ghost Conv* pada arsitektur RTMDet dalam meningkatkan representasi fitur multi-skala dan performa deteksi objek.
3. Menjadi referensi bagi penelitian selanjutnya dalam pengembangan metode deteksi objek yang berfokus pada peningkatan representasi fitur multi-skala, penanganan *small object detection*, serta integrasi teknik *resampling* pada *computer vision.*

1.6.2 Manfaat Praktis

1. Meningkatkan performa deteksi objek sampah *outdoor* pada kondisi *background* yang kompleks dan variasi ukuran objek yang beragam.
2. Memberikan alternatif model deteksi yang memiliki performa lebih baik dengan kompleksitas model yang lebih rendah.
3. Mendukung pengembangan teknologi yang dapat membantu proses identifikasi dan pemantauan sampah secara otomatis yang dapat berpotensi meningkatkan efektivitas pengelolaan kebersihan lingkungan.

1.7 Sistematika Penulisan

Bagian ini memberikan gambaran singkat terkait isi dari setiap bab yang diuraikan dalam tesis ini, dengan tujuan untuk membantu pembaca dalam memahami alur dan tujuan dari penelitian yang dilakukan.

Sistematika penulisan disusun secara sistematis dan terstruktur sebagai berikut:

BAB I: Pendahuluan

Bab ini menjelaskan hal yang menjadi latar belakang penelitian, rumusan masalah, pertanyaan penelitian, tujuan penelitian, batasan masalah, manfaat penelitian, dan sistematika penelitian. Latar belakang menguraikan permasalahan sampah di Indonesia yang masih belum terkelola dengan baik, tata kelola sampah yang telah ditentukan berdasarkan UU No. 18 Tahun 2008 tentang Pengelolaan Sampah, dan peran teknologi dalam memudahkan pengelolaan sampah dengan teknik *computer vision*-nya. Rumusan masalah merinci masalah yang akan diselesaikan, sedangkan pertanyaan penelitian merinci pertanyaan yang ingin dijawab dalam penelitian yang dilakukan. Tujuan penelitian untuk menjawab pertanyaan penelitian, sementara batasan masalah mengacu pada ruang lingkup penelitian agar penelitian yang dilakukan lebih fokus, jelas, dan terarah. Manfaat penelitian menyoroti kontribusi yang diberikan dari penelitian yang dilakukan baik secara teoritis dan praktis. Terakhir, sistematika penelitian mengacu pada urutan

yang sistematis dan terstruktur dalam penulisan tesis agar penelitian lebih terarah dan dipahami oleh pembaca.

BAB II: Tinjauan Pustaka

Bab ini membahas penelitian yang telah dilakukan terlebih dahulu yang relevan dengan penelitian ini, menyajikannya dalam sebuah tabel perbandingan penelitian, dan keterbaruan dari penelitian yang dilakukan. Penelitian terdahulu yang ditinjau adalah penelitian yang menggunakan algoritma *deep learning* ataupun *machine learning* dalam menyelesaikan permasalahan sampah, mengatasi permasalahan *imbalanced dataset, scaled imbalanced,* dan mengatasi permasalahan deteksi *small object* yang sulit untuk dideteksi pada lingkungan nyata. Tabel perbandingan penelitian berisi rangkuman hasil tinjauan dari penelitian terdahulu berdasarkan fokus penelitian, metode, hasil penelitian, dan keterbatasannya. Kebaruan penelitian menguraikan hal yang menjadi kebaruan ataupun perbedaan dari penelitian terdahulu yang relevan.

BAB III: Landasan Teori

Bab ini menjelaskan teori-teori yang digunakan sebagai dasar dalam melakukan penelitian ini. Bab ini membahas definisi sampah, pengelolaan sampah terkait penanganan sampah di Indonesia yang telah tertuang dalam PP Nomor 81 tahun 2012 pasal 22, terkait pemilahan, pengumpulan, pengangkutan, pengolahan sampah, hingga pemrosesan akhir. Selain itu, bab ini juga menjelaskan bagaiamana konsep *biological neural, artificial neural, feedforward neural,* dan *convolutional neural.* Konsep *convolutional neural* juga dijelaskan secara mendalam terkait dengan pemahaman *convolutional layer,* fungsi aktivasi, *pooling layer, fully-connected layer,* dan *loss funtion.* Teori *features, recognition, localization,* dan *detection* sebagai bagian dari *object detection* juga dijelaskan pada bab ini. Konsep RTMDet, GhostNet, DySample, *Efficient Multiscale Attention, imbalanced dataset*, *Repeat Factor Sampling* (RFS), dan *Meam Average* juga menjadi bagian yang dijelaskan pada bab ini.

BAB IV: Metode Penelitian

Bab ini membahas metode yang digunakan dalam penelitian, diawali dengan diagaram garis besar tahapan penelitian, dan detail dari tahapan penelitian. Detail tahapan penelitian mencakup identifikasi, studi literatur, pengumpulan dataset, perancangan model, pelatihan model, evaluasi model, analisis hasil, dan penulisan laporan.

BAB V: Hasil dan Pembahasan

Bab ini membahas hasil pelatihan model, evaluasi model, analisis visual, dan implikasi penelitian. Evaluasi dilakukan untuk mengukur efektivitas integrasi teknik resampling RFS, DySample, EMA, dan GCSPNeXt pada arsitektur RTMDet dalam mengatasi permasalahan ketidakseimbangan class imbalance, dan variasi ukuran objek pada dataset TACO outdoor. Analisis dilakukan melalui pengamatan proses pelatihan berdasarkan nilai loss yang diperoleh, perbandingan kinerja model, performa berdasarkan ukuran objek (small, medium, large), performa berdasarkan kelompok frekuensi kelas (*rare, common, frequent*), serta analisis efisiensi model berdasarkan jumlah parameter, *latency*, dan *frame per second* (FPS). Selain evaluasi kuantitatif, dilakukan pula analisis kualitatif melalui visualisasi *overlay feature map, confusion matrix*, dan hasil deteksi untuk memperoleh pemahaman yang lebih mendalam mengenai perilaku model dalam mendeteksi model. Selanjutnya, bab ini juga menyajikan implikasi dari penelitian terkait berdasarkan implikasi teoritis, dan praktis nya.

BAB VI: Kesimpulan dan Saran

Bab ini menjelaskan kesimpulan yang diperoleh sebagai jawaban atas tujuan dan pertanyaan penelitian berdasarkan hasil analisis yang telah dilakukan. Selain itu, bab ini juga menyajikan saran untuk pengembangan metode maupun penelitian selanjutnya.