

BAB II

TINJAUAN LITERATUR

2.1 Tinjauan Pustaka

Penelitian oleh (Visen & Charibaldi, 2025) dengan judul “Penerapan Object Detection Menggunakan Deep Learning YOLOv8 Untuk Mengidentifikasi Sampah Anorganik” menggunakan metode YOLOv8 nano dengan dataset sebanyak 2.459 citra. Masalah penelitian ini adalah tingginya volume sampah anorganik yang membutuhkan sistem deteksi otomatis untuk mendukung proses pengelolaan sampah. Hasil penelitian menunjukkan bahwa model YOLOv8 mampu mencapai nilai mAP50 sebesar 87,1% dan dapat mendeteksi hingga 10 objek dalam satu citra. Namun, performa model cenderung menurun pada objek kecil dan kondisi citra yang kompleks.

Penelitian oleh (Sari et al., n.d.) dengan judul “Otomatisasi Klasifikasi Sampah Menggunakan Convolutional Neural Network (CNN)” menggunakan metode Convolutional Neural Network dengan dataset sebanyak 1.200 citra. Masalah utama dalam penelitian ini adalah kompleksitas pemilahan sampah yang membutuhkan sistem klasifikasi otomatis berbasis citra. Hasil penelitian menunjukkan bahwa model CNN mampu mencapai akurasi sebesar 93,9%, yang menunjukkan performa tinggi dalam klasifikasi citra. Namun, metode ini tidak mampu melakukan deteksi lokasi objek secara spesifik.

Penelitian oleh (Fahmitra et al., 2026) dengan judul “Klasifikasi Sampah Plastik di Laut Menggunakan Algoritma Faster R-CNN” menggunakan metode Faster R-

CNN dengan backbone ResNet-50 FPN. Masalah yang dikaji adalah perlunya sistem otomatis untuk mendeteksi sampah plastik di lingkungan perairan yang memiliki kondisi kompleks. Hasil penelitian menunjukkan bahwa metode Faster R-CNN menghasilkan nilai mAP50 sebesar 82,64% dan mAP0.50:0.95 sebesar 59,55%. Hal ini menunjukkan bahwa metode tersebut cukup efektif dalam mendeteksi objek pada lingkungan yang kompleks.

Penelitian oleh (Lisana Sidka Alia, 2023) dengan judul “Klasifikasi Jenis Sampah Menggunakan Image Classification Convolutional Neural Network” menggunakan metode CNN dengan arsitektur MobileNetV2. Permasalahan penelitian ini adalah rendahnya efektivitas pemilahan sampah karena masih dilakukan secara manual. Hasil penelitian menunjukkan bahwa model CNN mampu mencapai akurasi hingga 92,74%, sehingga terbukti efektif dalam klasifikasi jenis sampah. Namun, keterbatasannya adalah tidak dapat melakukan deteksi lokasi objek secara langsung.

2.2 *Faster R-CNN*

Faster Region-Based Convolutional Neural Network (Faster R-CNN) merupakan salah satu metode deteksi objek berbasis deep learning yang dikembangkan sebagai penyempurnaan dari metode Region-based Convolutional Neural Network (R-CNN) dan Fast R-CNN. Metode ini diperkenalkan untuk meningkatkan efisiensi proses deteksi objek dengan mengintegrasikan proses pembangkitan region proposal ke dalam jaringan saraf melalui komponen yang disebut Region Proposal Network (RPN). Integrasi tersebut memungkinkan proses pencarian wilayah yang berpotensi mengandung objek dilakukan secara lebih efisien

dibandingkan metode sebelumnya (Ren et al., 2015).

Berbeda dengan metode deteksi objek satu tahap, Faster R-CNN menggunakan pendekatan deteksi dua tahap (two-stage object detector). Tahap pertama bertugas menghasilkan wilayah kandidat objek (region proposals) menggunakan RPN, sedangkan tahap kedua melakukan klasifikasi objek dan regresi bounding box terhadap wilayah kandidat tersebut. Arsitektur ini memungkinkan model memperoleh informasi lokasi dan kategori objek secara lebih akurat, terutama ketika objek memiliki ukuran kecil atau berada pada latar belakang yang kompleks.

Pada penelitian ini, Faster R-CNN digunakan untuk mendeteksi sampah plastik berukuran kecil pada citra digital. Pemilihan metode ini didasarkan pada kemampuannya dalam menghasilkan region proposal yang relevan dan melakukan ekstraksi fitur secara mendalam sehingga dapat membantu mengenali objek yang memiliki ukuran relatif kecil, bentuk yang beragam, serta kondisi latar belakang yang tidak seragam.

2.2.1 Arsitektur Faster R-CNN

Arsitektur Faster R-CNN terdiri atas beberapa komponen utama, yaitu backbone network, Region Proposal Network (RPN), RoI Pooling atau RoI Align, classification head, dan bounding box regression. Secara umum, proses deteksi objek pada Faster R-CNN dapat digambarkan sebagai berikut:

Citra Input → *Backbone CNN* → *Feature Map* → *Region Proposal Network (RPN)* → *Region Proposal* → *RoI Pooling/RoI Align* → *Classification* → *Bounding Box Regression* → *Hasil Deteksi*

1. Input Citra

Tahap pertama adalah memasukkan citra digital ke dalam model. Citra dapat direpresentasikan sebagai:

$$I \in R^{H \times W \times C}$$

Keterangan:

H = tinggi citra (height)

W = lebar citra (width)

C = jumlah kanal warna (channel)

Pada citra RGB, nilai C = 3. Sebelum diproses, citra dapat melalui tahap preprocessing, seperti resize, normalisasi nilai piksel, dan data augmentation apabila diperlukan.

2. Backbone Convolutional Neural Network

Citra input selanjutnya diproses menggunakan jaringan Convolutional Neural Network (CNN) sebagai backbone. Backbone bertugas mengekstraksi karakteristik atau fitur dari citra, seperti tepi, tekstur, bentuk, dan pola objek.

Operasi konvolusi secara matematis dapat dituliskan sebagai:

$$F_{i,j,k} = \sigma \left(\sum_m \sum_n \sum_c W_{m,n,c,k} I_{i+m,j+n,c} + b_k \right)$$

Keterangan:

I = citra atau feature map masukan

W = bobot kernel konvolusi

b = bias

F = feature map

i, j = posisi spasial

m, n = posisi kernel

c = kanal input

k = indeks filter

σ = fungsi aktivasi

Salah satu fungsi aktivasi yang umum digunakan adalah ReLU (Rectified Linear Unit):

$$ReLU(x) = \max(0, x)$$

Fungsi ReLU mengubah nilai negatif menjadi nol dan mempertahankan nilai positif sehingga membantu jaringan mempelajari pola nonlinier.

3. Region Proposal Network (RPN)

Komponen utama yang membedakan Faster R-CNN dari metode sebelumnya adalah Region Proposal Network (RPN). RPN merupakan jaringan yang bekerja pada feature map untuk menghasilkan kandidat wilayah yang kemungkinan mengandung objek.

Pada setiap lokasi feature map, RPN menggunakan beberapa anchor box dengan ukuran dan rasio aspek yang berbeda. RPN menghasilkan dua keluaran utama, yaitu:

1. Objectness score, yaitu probabilitas bahwa suatu anchor mengandung objek.
2. Bounding box regression, yaitu koordinat koreksi untuk menyesuaikan posisi dan ukuran anchor terhadap objek sebenarnya.

4. Anchor Box

Anchor box merupakan kotak referensi yang ditempatkan pada setiap lokasi feature map. Setiap anchor dapat memiliki ukuran (scale) dan rasio aspek (aspect ratio) yang berbeda.

Apabila anchor direpresentasikan sebagai:

$$A = (x_a, y_a, w_a, h_a)$$

dan ground truth bounding box direpresentasikan sebagai:

$$G = (x^*, y^*, w^*, h^*)$$

maka target regresi bounding box dapat dihitung menggunakan persamaan:

$$t_x^* = \frac{x^* - x_a}{w_a}, t_y^* = \frac{y^* - y_a}{h_a}$$

$$t_w^* = \log\left(\frac{w^*}{w_a}\right), t_h^* = \log\left(\frac{h^*}{h_a}\right)$$

Persamaan tersebut digunakan agar model dapat mempelajari transformasi dari anchor box menuju ground truth bounding box.

5. Objectness Classification

RPN menentukan apakah sebuah anchor merupakan kandidat objek atau bukan. Keluaran ini berupa skor objectness yang menunjukkan kemungkinan anchor mengandung objek.

Probabilitas kelas dapat dihitung menggunakan fungsi softmax:

$$P_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$$

Keterangan:

P_i = probabilitas kelas ke-i

z_i = skor logit kelas ke-i

K = jumlah kelas

Pada RPN, klasifikasi umumnya bersifat biner, yaitu object dan background.

6. Intersection over Union (IoU)

Intersection over Union (IoU) digunakan untuk mengukur tingkat tumpang tindih antara bounding box prediksi dan ground truth.

$$IoU = \frac{Area(B_p \cap B_{gt})}{Area(B_p \cup B_{gt})}$$

Keterangan:

B_p = predicted bounding box

B_{gt} = ground truth bounding box

Nilai IoU berada pada rentang:

$$0 \leq IoU \leq 1$$

Semakin mendekati nilai 1, semakin tinggi tingkat kesesuaian antara bounding box prediksi dan ground truth.

7. Bounding Box Regression pada RPN

RPN melakukan regresi koordinat untuk memperbaiki posisi anchor.

Transformasi dari anchor menuju kotak prediksi dapat dinyatakan sebagai:

$$x = x_a + t_x w_a, y = y_a + t_y h_a \\ w = w_a e^{t_w}, h = h_a e^{t_h}$$

Keterangan:

x, y = koordinat pusat kotak prediksi

w, h = lebar dan tinggi kotak prediksi

x_a, y_a, w_a, h_a = parameter anchor box

t_x, t_y, t_w, t_h = parameter regresi yang diprediksi model

8. Region Proposal

Setelah RPN menghasilkan objectness score dan regresi bounding box, kandidat wilayah objek diseleksi berdasarkan skor dan kualitas kotaknya. Karena jumlah kandidat yang dihasilkan cukup banyak, diperlukan proses Non-Maximum Suppression (NMS) untuk menghilangkan kandidat yang terlalu tumpang tindih.

9. Non-Maximum Suppression (NMS)

NMS bertujuan mempertahankan bounding box dengan skor tertinggi dan menghilangkan kotak lain yang memiliki tingkat tumpang tindih tinggi dengan kotak tersebut.

Proses NMS dilakukan dengan tahapan:

1. Mengurutkan bounding box berdasarkan skor dari yang tertinggi.
2. Memilih bounding box dengan skor tertinggi.
3. Menghitung IoU antara kotak yang dipilih dengan kotak lainnya.
4. Menghapus kotak yang memiliki nilai IoU melebihi threshold.
5. Mengulangi proses hingga seluruh kandidat diproses.

Dengan proses tersebut, prediksi ganda terhadap objek yang sama dapat dikurangi.

10. RoI Pooling atau RoI Align

Region of Interest (RoI) yang dihasilkan RPN kemudian diproses agar memiliki ukuran fitur yang seragam sebelum diteruskan ke detection head.

Pada Faster R-CNN klasik digunakan RoI Pooling. RoI Pooling membagi wilayah kandidat menjadi beberapa bagian dan mengambil nilai maksimum pada setiap bagian.

Operasi max pooling secara sederhana dapat dituliskan sebagai:

$$y = \max_{x \in R} x$$

Keterangan:

R = wilayah fitur yang sedang diproses

y = nilai maksimum dari wilayah tersebut

Pada implementasi modern, RoI Align juga dapat digunakan untuk mengurangi kesalahan kuantisasi koordinat dan mempertahankan informasi spasial dengan lebih baik.

11. Classification Head

Fitur hasil RoI kemudian diteruskan ke classification head untuk menentukan kategori objek.

$$P(c | x) = \frac{e^{z_c}}{\sum_{j=1}^K e^{z_j}}$$

Keterangan:

$P(c|x)$ = probabilitas objek termasuk kelas c

z_c = skor kelas c

K = jumlah kelas

Kelas dengan probabilitas terbesar dapat dipilih sebagai kelas hasil deteksi.

12. Bounding Box Regression

Selain melakukan klasifikasi, Faster R-CNN melakukan regresi bounding box untuk memperoleh lokasi objek yang lebih tepat.

Parameter regresi direpresentasikan sebagai:

$$t = (t_x, t_y, t_w, t_h)$$

Parameter tersebut digunakan untuk menghitung koordinat kotak prediksi:

$$x = x_p + t_x w_p, y = y_p + t_y h_p$$

$$w = w_p e^{t_w}, h = h_p e^{t_h}$$

Keterangan: x_p, y_p, w_p, h_p = parameter proposal box; t_x, t_y, t_w, t_h = parameter regresi.

2.2.2 Loss Function pada Faster R-CNN

Proses pelatihan Faster R-CNN menggunakan loss function untuk mengukur kesalahan prediksi model. Secara umum, loss terdiri atas classification loss dan bounding box regression loss pada RPN serta classification loss dan bounding box regression loss pada detection head.

Secara keseluruhan dapat dituliskan:

$$L = L_{RPN} + L_{det}$$

atau secara rinci:

$$L = L_{cls}^{RPN} + \lambda L_{reg}^{RPN} + L_{cls}^{det} + \lambda L_{reg}^{det}$$

Keterangan:

L_{cls} -RPN = classification loss pada RPN

L_{reg} -RPN = bounding box regression loss pada RPN

L_{cls} -det = classification loss pada detection head

L_{reg} -det = bounding box regression loss pada detection head

λ = faktor pembobot loss

1. Classification Loss

Classification loss digunakan untuk mengukur kesalahan model dalam menentukan kelas objek. Salah satu fungsi yang digunakan adalah cross-entropy loss:

$$L_{cls} = - \sum_{c=1}^K y_c \log(p_c)$$

Keterangan:

y_c = label sebenarnya untuk kelas c

p_c = probabilitas prediksi kelas c

K = jumlah kelas

Untuk klasifikasi biner, binary cross-entropy dapat dituliskan sebagai:

$$L_{cls} = -[y \log(p) + (1 - y) \log(1 - p)]$$

2. Bounding Box Regression Loss

Bounding box regression loss digunakan untuk mengukur kesalahan antara koordinat bounding box prediksi dan ground truth.

Fungsi Smooth L1 Loss dapat dituliskan sebagai:

$$SmoothL_1(x) = \begin{cases} \frac{1}{2}x^2, & |x| < 1 \\ |x| - \frac{1}{2}, & |x| \geq 1 \end{cases}$$

Dengan demikian, regression loss dapat dituliskan:

$$L_{reg} = \sum_i SmoothL_1(t_i - t_i^*)$$

Keterangan:

t_i = parameter bounding box hasil prediksi

t_i^* = parameter bounding box ground truth

2.2.3 Proses Pelatihan Faster R-CNN

Proses pelatihan Faster R-CNN dilakukan melalui beberapa tahapan berikut:

1. Pengumpulan Dataset — Dataset citra dikumpulkan sesuai objek yang akan dideteksi, yaitu sampah plastik.
2. Anotasi Dataset — Setiap objek sampah plastik pada citra diberi label dan bounding box menggunakan perangkat anotasi seperti LabelImg.
3. Pembagian Dataset — Dataset dibagi menjadi data pelatihan (training), validasi (validation), dan pengujian (testing) sesuai rancangan penelitian.
4. Preprocessing — Citra diproses melalui resize, normalisasi, dan data augmentation apabila diperlukan.
5. Ekstraksi Fitur — Citra dimasukkan ke dalam backbone CNN untuk menghasilkan feature map.

6. Pembentukan Anchor — Pada setiap lokasi feature map, RPN membentuk sejumlah anchor box berdasarkan skala dan rasio aspek tertentu.
7. Proses RPN — RPN menghitung objectness score dan melakukan regresi bounding box untuk menghasilkan kandidat wilayah objek.
8. Penentuan Label Anchor — Setiap anchor dibandingkan dengan ground truth menggunakan IoU untuk menentukan label positif atau negatif.
9. NMS — Kandidat yang memiliki tingkat tumpang tindih berlebihan disaring menggunakan NMS sehingga diperoleh region proposal yang lebih relevan.
10. RoI Pooling/RoI Align — Setiap region proposal dipetakan ke feature map dan diubah menjadi representasi fitur dengan ukuran yang seragam.
11. Klasifikasi Objek — Fitur RoI diteruskan ke classification head untuk menentukan kelas objek.
12. Regresi Bounding Box — Model melakukan penyempurnaan koordinat bounding box agar lokasi objek menjadi lebih akurat.
13. Perhitungan Loss — Kesalahan klasifikasi dan lokasi objek dihitung menggunakan classification loss dan bounding box regression loss.
14. Backpropagation — Nilai loss digunakan untuk menghitung gradien terhadap parameter jaringan.
15. Optimasi Bobot — Bobot model diperbarui menggunakan algoritma optimasi, seperti Stochastic Gradient Descent (SGD).

Pembaruan parameter menggunakan SGD dapat dituliskan sebagai:

$$\theta_{t+1} = \theta_t - \eta \nabla_{\theta} L(\theta_t)$$

Keterangan:

θ_t = parameter model pada iterasi ke- t

η = learning rate

$\nabla_{\theta} L$ = gradien loss terhadap parameter model

Proses tersebut dilakukan secara berulang selama beberapa epoch hingga

model memperoleh parameter yang mampu menghasilkan prediksi yang baik.

2.2.4 Proses Inferensi Faster R-CNN

Setelah proses pelatihan selesai, model digunakan untuk mendeteksi objek pada citra baru. Tahapan inferensi meliputi:

1. Citra masukan diberikan kepada model.
2. Backbone menghasilkan feature map.
3. RPN menghasilkan region proposal.
4. Proposal disaring menggunakan NMS.
5. Fitur setiap proposal diekstraksi melalui RoI Pooling atau RoI Align.
6. Detection head menentukan kelas objek.
7. Model melakukan regresi bounding box.
8. Prediksi dengan skor rendah dihilangkan berdasarkan confidence threshold.
9. Hasil akhir berupa kelas objek, confidence score, dan koordinat bounding box.

Hasil deteksi dapat direpresentasikan sebagai:

$$D = \{(B_i, C_i, S_i)\}_{i=1}^N$$

Keterangan:

B_i = bounding box objek ke- i

C_i = kelas objek ke- i

S_i = skor kepercayaan objek ke- i

N = jumlah objek yang terdeteksi

2.2.5 Evaluasi Kinerja Faster R-CNN

Evaluasi dilakukan untuk mengetahui kemampuan model dalam mendeteksi objek sampah plastik. Metrik yang digunakan meliputi confusion matrix, precision, recall, F1-score, IoU, Average Precision (AP), dan mean

Average Precision (mAP).

1. Confusion Matrix

Tabel 2. 1 Confusion Matrix

	<i>Prediksi Positif</i>	<i>Prediksi Negatif</i>
<i>Aktual Positif</i>	<i>True Positive (TP)</i>	<i>False Negative (FN)</i>
<i>Aktual Negatif</i>	<i>False Positive (FP)</i>	<i>True Negative (TN)</i>

Keterangan:

- 1) *TP*: data positif terdeteksi benar
- 2) *TN*: data negatif terdeteksi benar
- 3) *FP*: data negatif salah dianggap positif
- 4) *FN*: data positif tidak terdeteksi

1. *Precision*

Precision digunakan untuk mengukur tingkat ketepatan model dalam mendeteksi objek. Nilai *precision* menunjukkan proporsi objek yang diprediksi sebagai sampah plastik dan benar-benar merupakan sampah plastik. Semakin tinggi nilai *precision*, semakin kecil jumlah *false positive* (FP) yang dihasilkan model

$$Precision = \frac{TP}{TP + Fp}$$

2. Recall

Recall digunakan untuk mengukur kemampuan model dalam menemukan seluruh objek sampah plastik yang terdapat pada data uji. Nilai recall menunjukkan proporsi objek yang berhasil dideteksi dibandingkan dengan seluruh objek yang sebenarnya ada. Semakin tinggi nilai recall, semakin sedikit objek yang tidak terdeteksi (*false negative*).

$$Recall = \frac{TP}{TP + FN}$$

3. F1-Score

Pada metode Faster R-CNN, fungsi *loss* digunakan untuk mengukur tingkat kesalahan model selama proses pelatihan. Total *loss* terdiri atas dua komponen utama, yaitu *classification loss* yang mengukur kesalahan dalam proses klasifikasi objek dan *bounding box regression loss* yang mengukur kesalahan prediksi posisi serta ukuran *bounding box*. Kedua komponen tersebut digabungkan sehingga menghasilkan *loss* total yang digunakan sebagai acuan dalam proses optimasi model.

$$F1 - Score = \frac{2 \times Precision + Recall}{Precision \times Recall}$$

5. Intersection over Union (IoU)

$$IoU = \frac{Area(B_p \cap B_{gt})}{Area(B_p \cup B_{gt})}$$

Semakin tinggi nilai IoU, semakin sesuai lokasi bounding box prediksi dengan ground truth.

6. Average Precision (AP)

$$AP = \int_0^1 p(r)dr$$

Keterangan:

$p(r)$ = precision pada tingkat recall tertentu

r = recall

7. Mean Average Precision (mAP)

$$mAP = \frac{1}{K} \sum_{k=1}^K AP_k$$

Keterangan:

K = jumlah kelas

AP_k = Average Precision kelas ke- k

Dalam evaluasi deteksi objek, mAP dapat dihitung pada ambang IoU tertentu, misalnya mAP@0.5. Notasi mAP@0.5 menunjukkan bahwa deteksi dianggap benar apabila nilai IoU mencapai atau melebihi 0.5.

2.3 Perbedaan dan Keunikan Karya Cipta yang Ditawarkan

Berdasarkan hasil *Systematic Literature Review* (SLR), penelitian-penelitian sebelumnya menunjukkan bahwa metode deep learning telah banyak digunakan dalam deteksi dan klasifikasi sampah plastik dengan berbagai pendekatan, seperti *Convolutional Neural Network* (CNN), YOLO, dan *Faster R-CNN*.

Penelitian oleh (Sari et al., 2025b) dengan judul “Otomatisasi Klasifikasi Sampah Menggunakan *Convolutional Neural Network* (CNN)” menggunakan metode CNN dengan dataset 1.200 citra dan menghasilkan akurasi sebesar 93,9%.

Penelitian oleh Lisana Sidka Alia (2023) juga menunjukkan bahwa CNN berbasis MobileNetV2 mampu mencapai akurasi hingga 92,74%. Namun, kedua penelitian tersebut hanya berfokus pada proses klasifikasi citra dan tidak dapat menentukan lokasi objek secara spesifik dalam gambar.

Sementara itu, penelitian oleh (Charibaldi, 2025b) dengan judul “Penerapan *Object Detection* Menggunakan *Deep Learning YOLOv8*” menunjukkan bahwa metode YOLOv8 mampu mencapai mAP50 sebesar 87,1% dan dapat mendeteksi hingga 10 objek dalam satu citra. Namun, berdasarkan hasil penelitian tersebut, performa YOLO cenderung menurun pada objek berukuran kecil dan kondisi citra yang kompleks.

Di sisi lain, penelitian oleh (Fahmitra et al., 2026) serta (Faizal, 2023a) menunjukkan bahwa metode *Faster R-CNN* memiliki performa yang baik dalam deteksi objek sampah plastik dengan nilai *mAP* hingga 82,64% serta akurasi tinggi pada beberapa kelas objek. Hal ini menunjukkan bahwa *Faster R-CNN* memiliki kemampuan yang stabil dalam mendeteksi objek dengan karakteristik yang lebih kompleks.

Berdasarkan hasil analisis tersebut, keunikan penelitian ini terletak pada fokus kajian yang secara khusus meneliti performa metode *Faster R-CNN* dalam mendeteksi sampah plastik berukuran kecil. Objek berukuran kecil memiliki karakteristik berupa jumlah piksel yang terbatas dan detail fitur yang rendah, sehingga lebih sulit dideteksi dibandingkan objek berukuran normal. Kondisi ini menjadi tantangan dalam proses deteksi, terutama pada citra dengan latar belakang yang kompleks dan tidak homogen.

Selain itu, penelitian ini tidak berfokus pada pengembangan sistem, tetapi pada analisis kinerja metode *Faster R-CNN* berdasarkan hasil pengujian model menggunakan dataset citra sampah plastik. Evaluasi dilakukan menggunakan metrik *precision*, dan *recall* untuk memperoleh gambaran performa model secara lebih komprehensif.

Dengan demikian, perbedaan utama penelitian ini dibandingkan penelitian sebelumnya terletak pada fokus objek (sampah plastik berukuran kecil), pendekatan yang digunakan (analisis kinerja model *Faster R-CNN*), serta evaluasi performa yang lebih menekankan pada kondisi citra yang kompleks.

2.4 Kerangka Berpikir

Permasalahan sampah plastik saat ini semakin meningkat seiring dengan tingginya penggunaan plastik dalam kehidupan sehari-hari. Plastik banyak digunakan karena praktis, ringan, dan mudah ditemukan, namun plastik sangat sulit terurai secara alami. Akibatnya, sampah plastik menumpuk dan mencemari lingkungan, baik di darat maupun di perairan. Salah satu jenis sampah yang cukup sulit ditangani adalah sampah plastik berukuran kecil, seperti serpihan plastik, potongan kemasan, tutup botol, dan pecahan plastik lainnya.

Sampah plastik berukuran kecil sering kali sulit dikenali secara langsung karena ukurannya yang kecil dan bentuknya yang tidak beraturan. Selain itu, objek tersebut biasanya bercampur dengan latar belakang yang kompleks, seperti tanah, rumput, pasir, atau sampah lainnya. Kondisi ini menyebabkan proses identifikasi dan pemilahan sampah secara manual menjadi kurang efektif dan membutuhkan waktu yang lama.

Perkembangan teknologi saat ini, khususnya di bidang *Artificial Intelligence (AI)* dan *deep learning*, dapat dimanfaatkan untuk membantu proses deteksi sampah secara otomatis melalui citra digital. Salah satu metode yang sering digunakan dalam deteksi objek adalah *Faster R-CNN*. Metode ini dipilih karena memiliki kemampuan yang baik dalam mendeteksi objek kecil dan mampu menentukan lokasi objek pada gambar dengan lebih akurat.

Pada penelitian ini, tahap pertama dimulai dengan pengumpulan data citra sampah plastik berukuran kecil. Data diperoleh dari hasil pengambilan gambar menggunakan kamera atau smartphone serta dataset publik dari internet. Setelah data terkumpul, dilakukan proses anotasi atau pelabelan objek.

Tahap selanjutnya adalah preprocessing data, yaitu proses penyesuaian ukuran gambar, normalisasi, dan pengecekan kualitas citra agar data siap digunakan dalam proses training model. Setelah preprocessing selesai, data akan digunakan untuk melatih model *Faster R-CNN* agar model dapat mempelajari ciri-ciri sampah plastik berukuran kecil.

Setelah proses training selesai, model akan diuji menggunakan data testing untuk mengetahui kemampuan model dalam mendeteksi objek. Hasil deteksi model berupa label objek akan dibandingkan dengan data asli (*ground truth*). Dari hasil tersebut akan diperoleh nilai *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*.