

Waste Detection Based on Dilated Faster R-CNN and Similarity Analysis Using Feature Fusion

SiUng Kim*, JunHyeok Go*, JeongHyeon Park*, Namme Moon**

*Student, Dept. of Computer Science and Engineering, Hoseo University, Asan, Korea

**Professor, Dept. of Computer Science and Engineering, Hoseo University, Asan, Korea

[Abstract]

With the increasing volume of waste generation, an effective system for efficient waste management has become essential. Waste generators must be able to attach stickers corresponding to large waste items, and collectors need to verify that the disposed waste matches the stickers before proceeding with collection. If this process is not executed smoothly, additional labor and costs may be incurred for further handling. To address this, this paper proposes a system that utilizes Dilated Faster R-CNN for accurate waste classification and detection, along with a fusion-based similarity analysis to evaluate the similarity of disposed large waste items. This system enables waste generators to classify large waste items accurately and allows collectors to verify whether the disposed waste matches the intended waste for collection, thereby enhancing the efficiency of waste disposal and collection processes. The proposed Dilated Faster R-CNN achieves a 4.01% improvement in accuracy compared to the conventional Faster R-CNN. Additionally, the fusion-based similarity analysis improves processing speed by approximately 59% compared to SIFT-based feature extraction and achieves a 3.79% improvement in accuracy over ORB-based feature extraction.

▶ **Key words:** Object Detection, Similarity Analysis, Waste Management, Dilated Convolution, Fusion based Feature extraction

[요 약]

폐기물 발생량의 증가에 따라 이를 효과적으로 처리하는 시스템이 필요하다. 폐기물을 배출하는 배출자는 대형 폐기물에 해당하는 스티커를 부착하여야 하며, 수거자는 배출된 폐기물과 스티커가 일치하는지 확인 후, 수거가 이루어져야 한다. 이러한 과정이 원활하게 이루어지지 않을 경우, 추가적인 처리에 따른 인력과 비용이 발생하게 된다. 이에 따라 본 논문에서는 Dilated Faster R CNN을 통해 폐기물에 대한 정확한 분류 및 탐지를 진행하고, 퓨전 기반 유사도 분석을 통해 배출된 대형 폐기물의 유사도를 분석하는 시스템을 제안한다. 이를 통해 배출자는 대형 폐기물을 정확하게 분류할 수 있도록 하며, 수거자는 배출된 폐기물과 수거할 폐기물이 서로 일치하는지 확인하여 폐기물 배출 및 수거 작업의 효율성을 향상시킨다. Dilated Faster R CNN을 통해 기존의 Faster R CNN보다 정확도가 4.01% 향상되었으며, 퓨전 기반 유사도 분석을 통해 기존의 SIFT기반 특징 추출보다 처리 속도가 약 59% 향상되었으며, 정확도는 ORB기반 특징 추출보다 3.79% 향상되었다.

▶ **주제어:** 객체 탐지, 유사도 분석, 폐기물 관리, 확장 컨볼루션, 퓨전 기반 특징 추출

- First Author: SiUng Kim, Corresponding Author: Namme Moon
- *SiUng Kim (kimsiung990811@gmail.com), Dept. of Computer Science and Engineering, Hoseo University
- *JunHyeok Go (junhyeok970306@gmail.com), Dept. of Computer Science and Engineering, Hoseo University
- *JeongHyeon Park (jh.park970609@gmail.com), Dept. of Computer Science and Engineering, Hoseo University
- **Namme Moon (namme.moon@gmail.com), Dept. of Computer Science and Engineering, Hoseo University
- Received: 2025. 02. 06, Revised: 2025. 04. 22, Accepted: 2025. 04. 22.

I. Introduction

경제 및 기술의 발전에 따라 가구와 같은 대형 폐기물의 발생량도 증가하였다[1]. 대형 폐기물은 매립, 소각, 재활용 등의 처리가 이루어진다. 그러나 폐기물의 잘못된 처리로 인해 사회적, 환경적인 문제 또한 증가하고 있다[2]. 이를 해결하기 위해서는 폐기물의 종류와 특성에 따라 다양하고 체계적인 운반 및 처리, 재활용 과정이 요구된다[3,4].

그중 대형 폐기물을 처리 과정은 다음과 같다. 배출자는 대형 폐기물에 해당하는 스티커를 구매 및 부착하고 지정된 배출 장소에 배출하고, 수거자는 지정된 배출 장소에 배출된 폐기물을 수거한다. 하지만 이 과정에서 배출자가 잘못된 스티커 부착 또는 지정되지 않은 위치에 배출하는 상황이 발생할 경우, 이를 처리하는 것에 대한 추가적인 처리 비용이 발생하게 된다. 또한 잘못된 배출자의 추적 및 피드백이 어려운 구조로 인해 악순환이 반복될 가능성이 높다.

본 연구에서는 위와 같은 문제를 해결하기 위해 Dilated Faster R CNN 모델을 통해 객체를 분류 및 탐지를 진행하고, SIFT와 ORB 특징 추출 방법을 혼합한 퓨전 기반 유사도 분석을 통해 대형 폐기물 관리 시스템을 제안한다.

II. Preliminaries

1. Related works

1.1 Object Detection

인공지능을 활용하여 폐기물을 탐지 및 분류하는 연구는 활발히 진행되고 있으며, ResNet 기반의 Faster R-CNN 모델을 활용하여 F1-score 63%~77%의 성능을 달성한 바 있다[5]. 생활 폐기물 감지와 분류 분야에서는 CNN과 그래프 신경망을 결합한 CNN-GLSTM 구조로 정확도 97.55%, mAP 95.92%의 높은 성능을 보였다[6]. 또한 Sanghyun Kim et al.[7]은 IoT 및 AI를 활용하여 수거 차량의 효율적인 운영을 제안하였다.

그러나 기존 연구들은 모두 '폐기물 탐지 또는 분류'에만 초점을 맞추고 있으며, 동일 객체 여부를 판단하는 연구는 거의 이루어지지 않고 있다. 실제 수거 과정에서는 중복 수거, 오인 수거 등으로 인해 불필요한 인력 낭비가 발생할 수 있으나, 이를 방지할 수 있는 '동일 폐기물 여부 판별 시스템'은 현재 전무하다.

이에 본 연구는 단순 탐지를 넘어, 대형 폐기물이 이전에 등록되었던 객체와 동일한 객체인지를 판단하는 과정을 포함하여 실제 수거 효율성을 높이고자 하였다. 이를 위해 사전 학습된 ResNet-18의 Convolution Layer를 Dilated Convolution으로 변경하여 더 풍부한 특성 정보를 추출하여 분류를 진행한다. 또한, SIFT, ORB, AKZE와 같은 전통적 특징 추출 방법과 각 특징을 융합한 Fusion 기반 유사도 분석 기법을 제안하였다.

1.2 Similarity Analysis

이미지의 유사도를 분석하기 위해서는 이미지의 특징에 해당하는 키 포인트를 통해 주변의 픽셀값을 분석하여 디스크립터를 검출한다. 검출된 디스크립터는 벡터값을 가지며, 두 이미지 간의 디스크립터를 비교 및 계산하여 이미지의 유사도를 판별한다[7]. 이미지의 특징 추출하는 방법은 SIFT(Scale Invariant Feature Transform), ORB(Oriented FAST and Rotated BRIEF) 등 다양하게 존재하며 본 연구에서는 SIFT와 ORB 두 가지 특징 추출 방법을 통해 특징을 추출 및 각 방법을 혼합하여 특징을 추출한다. 이렇게 추출된 특징들을 딥러닝 방법을 사용하여 학습하고 유사도 분석을 진행하여 객체 탐지 시, 같은 객체임에도 불구하고 각도나 조도 차이에 의해 학습된 모델이 다른 객체와 혼동하는 경우를 최소화하고자 한다.

1.2.1 SIFT based feature extraction

SIFT 기반 특징 추출 방법은 이미지를 단계적으로 축소시키는 가우시안 피라미드(Gaussian Pyramid)를 사용한 대[6]. 이때, 축소시킬 때 마다 가우시안 블러(Gaussian Blur)를 적용하여 이미지를 부드럽게 만든다. 이후 DoG(Difference of Gaussian) 피라미드를 사용하여 각 단계별 이미지들의 차이를 계산하여 특징을 추출한다. 이를 통해 회전, 조명 변화 등에 대해 강건한 키 포인트와 디스크립터를 검출하여 특징을 추출하는 방식이다. 이는 복잡한 객체도 정확하게 특징을 추출할 수 있다는 장점이 존재하지만, 특징을 추출하기 위해서 많은 연산을 요구하기 때문에 실시간 환경에서 적용하기 어렵다는 단점이 있다.

1.2.2 ORB based feature extraction

ORB 기반 특징 추출 방법은 FAST (Features from Accelerated Segment Test)와 BRIEF(Binary Robust Independent Elementary Features) 기반의 특징 추출의 강점을 결합한 방식이다. 특징점 추출은 FAST 알고리즘의 방식과 같이 어떤 점 p 를 중심으로 원형 픽셀 범위

안에 존재하는 주변 픽셀 간의 밝기 차이를 이용하여 키 포인트를 검출한다. 이후 키 포인트 주변의 고정된 패치 내의 기울기를 계산하여 주 방향을 할당한다. 이후 BRIEF 알고리즘과 같이 임의의 이미지 패치의 특징을 이진 문자열로 인코딩하여 디스크립터를 추출한다. 여기에 추가로 주 방향에 맞춰 BRIEF 패턴을 회전시켜 회전 불변성을 확보한 디스크립터를 검출하여 특징을 추출하는 방식이다 [8]. 이는 빠른 특징 추출이 가능하지만 복잡한 객체나 조명의 변화에 약하기 때문에 정확한 특징 추출이 어렵다는 단점이 있다.

1.2.3 AKAZE based feature extraction

AKAZE 기반 특징 추출은 기존의 KAZE 특징 추출 방식의 비선형 확산 필터를 사용해 스케일 공간을 생성해 계산량이 큰 단점을 해결하기 위해 FED(Fast Explicit Diffusion) 방식을 통해 여러 개의 확산 단계를 조합하여 빠르고 안정적으로 스케일 공간을 구성하여 특징 추출이 가능한 방법으로, 각 스케일에서 이미지의 Hessian 행렬의 행렬식을 계산하여 특징점을 검출한다. 이후 M-LDB(Modified-Local Difference Binary)라는 이진 디스크립터를 사용한다. 이를 통해 영역간 평균 값을 비교하여 더 강건한 디스크립터를 검출한다[9]. 이를 통해 기존의 KAZE 특징 추출 방식보다 빠르면서, 비슷한 정확도를 달성한다.

III. The Proposed Scheme

1. Large Waste Management System

1.1 Large Waste detection dataset

폐기물 분류 및 탐지를 위해 실험에 사용한 데이터 셋은 크롤링, 촬영 등의 클라우드 소싱으로 수집되었으며, 42개의 클래스로 이루어진 대형 폐기물 데이터 44,554장으로 구성되어 있다. 폐기물 데이터는 실제 현장에서 폐기되는 환경으로 촬영된 데이터와 실제 가정환경에 배치되어 있는 전자제품, 가구 등으로 촬영된 데이터가 혼합되어 있다. 폐기물 데이터 중 일부는 아래 Fig 1. 과 같으며, 실험은 Train, Val, Test의 비율을 7:2:1 로 구성하였다.



Fig. 1. Waste Detection dataset

1.2 Large Waste Similarity Analysis dataset

유사도 분석을 위해 실험에 사용한 데이터는 AI HUB의 생활 폐기물 이미지 데이터 셋에서 가구에 해당하는 데이터, 그 중 대형 폐기물 탐지 데이터셋과 매치되어 있는 의자, 수납장, 책상 데이터를 사용하였다. 서로 같은 객체이지만 각도와 조도가 다르게 촬영된 이미지 2902쌍, 서로 다른 객체로 촬영된 이미지 2093쌍으로 총 5805쌍으로 구성된 폐기물 데이터 셋으로 구성되어 있으며, 그 중 일부는 아래의 Fig 2. 와 같다. 유사도 분석 실험은 Train, Val, Test의 비율을 6:2:2로 구성하였다. 대형 폐기물 탐지는 충분한 양의 데이터가 확보 되어있기 때문에 7:2:1의 비율을 산정하였지만, 유사도 분석에 사용되는 데이터 셋은 데이터의 양이 상대적으로 적으며, 같음과 다름의 관계를 구분하는 이진 분류가 목적이므로, val과 test의 비중을 높은 6:2:2 비율로 실험을 구성하게 되었다.



Fig. 2. Waste Similarity Analysis dataset

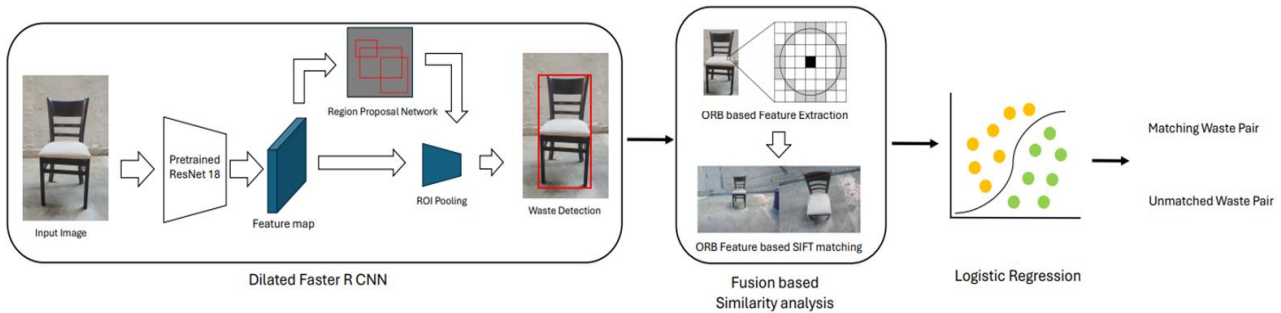


Fig. 3. Large Waste Detection and Management System Process

1.3 Large Waste Management System

대형 폐기물의 효율적인 폐기 및 재활용을 위해서는 체계적이고 전략적인 접근이 필요하다. 이를 위한 폐기물 관리 시스템은 대형 폐기물 탐지와 유사도 분석으로 구성되어 있으며, Fig 3과 같다. 먼저 대형 폐기물을 탐지하기 위해 확장 컨볼루션이 적용된 Faster R CNN 모델을 사용하여 대형 폐기물의 이미지를 학습시킨다. 이를 통해 대형 폐기물을 인공지능이 인식하여 분류할 수 있도록 한다. 이후 ORB 특징 추출과 SIFT 매칭을 활용하여 폐기물의 이미지 유사도를 판단하기 위한 특징을 추출하고 이를 Logistic Regression을 통해 유사도를 분석하여 배출된 폐기물 데이터를 식별한다. 이를 통해 수거자는 추가적인 자원 소모 없이 대형 폐기물에 대해 정확히 분류 및 식별할 수 있게 한다.

이 시스템을 전체적인 폐기물 관리의 효율성을 향상시킬 수 있다. 배출자는 폐기물을 신속하게 분류하여 작업속도의 향상을 기대할 수 있으며, 수거자는 배출자가 배출한 종류와 동일한 폐기물인지 판단하는데 걸리는 시간을 단축시킬 수 있다. 이러한 기술을 기반으로 한 폐기물 관리 시스템은 스마트 도시 환경에서 폐기물 관리를 효율적으로 진행하여 도시 발전에 기여할 수 있다.

1.4 Dilate based Faster R CNN

Faster R CNN은 이미지 분류 분야에서 훌륭한 성능을 보여주는 모델이다. 이 모델은 백본 네트워크 모델에 이미지를 입력하여 이미지의 Feature map을 추출한다. 이후 Feature map으로 잠재적인 객체의 위치인 RPN(Region Proposal Network)을 제안한다. PRN은 여러개의 앵커박스로 이미지에 존재하는 객체의 위치인 ROI(Region of Interest)를 제안한다. PRN이 제안하는 각 ROI를 고정된 크기로 변환하는 ROI Pooling 작업을 진행한다. 마지막으로 Fully Connected Layer를 통과하여 객체 분류 및 탐지 작업이 이루어진다[10].

본 연구에서는 기존 Faster R CNN의 백본 네트워크에서 적용된 Convolution Layer를 확장 컨볼루션(Dilated

Convolution)으로 변경하여 성능을 향상시키고자 한다. 확장 컨볼루션은 Convolution을 진행할 때, 커널이 이미지의 픽셀을 건너뛰어 수용하는 영역을 확장 시켜 더 넓은 영역의 정보를 학습할 수 있도록 한다[11]. 하지만 수용 영역을 확장 시킴으로써 이미지의 세부적인 정보를 파악하기 어려운 단점이 존재하기 때문에, 본 연구에서는 물체의 크기가 크며 단일 객체로 구성되어있는 대형 폐기물 데이터셋에 학습을 진행할 것이다. 사전 학습된 ResNet-18 모델의 컨볼루션의 일부를 확장 컨볼루션으로 변경하여 학습을 진행하고자 한다. 확장 컨볼루션의 구조는 Fig 4. 와 같다.




Fig. 4. Structure of Dilated Convolution

1.5 Fusion-Based Feature Extraction and Logistic Regression Analysis

첫 번째 알고리즘을 활용하여 두 이미지 간의 주요 키포인트와 디스크립터를 추출하고, 설정된 임계값에 따라 매칭을 수행한다. 이 과정을 통해 신뢰도 높은 초기 매칭 결과를 확보한 후, 해당 매칭에 포함된 키 포인트를 기반으로 두 번째 알고리즘을 적용하여 보다 정밀한 특징 추출을 진행한다. 이후 새롭게 생성된 고차원 특징 벡터를 다시 매칭하고, 동일한 거리 조건을 적용하여 우수한 매칭 결과를 선별한다. 이렇게 서로 다른 알고리즘에서 추출된 특징 정보를 순차적으로 융합함으로써, 두 이미지 간의 유사도를 보다 정교하게 평가할 수 있다. 최종적으로, 통합된 매칭 개수를 기반으로 로지스틱 회귀 분석을 수행하여 이미지 간의 클래스 일치 여부를 예측하고, 이를 통해 이미지

간 관계를 효과적으로 분석한다.

2. Experimental

2.1 Experiment environment & evaluation methods

실험은 다음 Table 1과 같은 환경에서 진행하였다.

Table 1. Experimental Environment

CPU	Intel(R) Core(TM) i7-8700K
GPU	NVIDIA GeForce RTX 4090
RAM	64GB
CUDA	12.1
OpenCV	4.5
Python	3.10.14

성능평가는 Accuracy, F1-score, mAP(mean Average Precision)를 사용하였다. Accuracy는 모델이 얼마나 정확하게 맞추었는지를 의미하며, 다음 식(1)과 같이 계산된다.

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \quad (1)$$

F1-score는 모델이 양성으로 예측한 값 중 실제 양성인 비율을 의미하는 정밀도(Precision)와 실제 양성인 데이터 중 모델이 맞게 예측한 비율을 나타내는 재현율(Recall)의 조화 평균으로, Accuracy 보다 정밀한 성능평가를 위해 사용하였다. F1-score는 다음 식(2)와 같이 계산된다.

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2)$$

mAP는 모델의 객체 탐지 성능을 평가하는 지표로 Precision과 Recall의 곡선 그래프의 면적을 클래스별로 계산한 다음, 클래스별 평균을 계산한 값이다. mAP는 다음 식(3)과 같이 계산된다.

$$mAP = \frac{1}{C} \sum_{i=1}^C AP_i \quad (3)$$

이와 같은 성능평가 지표들을 활용하여 모델의 성능을 평가하고자 한다.

2.2 Dilated Faster R CNN Experimental Result

학습 결과는 아래 Table 2와 같이 정확도 89%, F1-score 90%, mAP 85%이고, 확장 컨볼루션을 적용한 Dilated Faster R CNN의 결과는 정확도 93.14%, F1-score 90%, mAP 90%의 결과로 확장 컨볼루션이 적용된 모델의 성능이 기존의 모델보다 성능이 향상되었다

는 것을 확인할 수 있었다.

또한, Dilated Faster R CNN의 학습 그래프는 아래 Fig 5. 와 같으며, 학습을 진행하였을 때, 안정적으로 수렴하고 있다는 것을 확인할 수 있다.

Table 2. Large Waste Detection Experiment results

Method	Acc(%)	F1-score(%)	mAP(%)
Faster R CNN	89.13	90.01	88.13
Dilated Faster R CNN	93.14	93.4	91.24




Fig. 5. Dilated Faster R CNN Evaluation Loss Graph

2.3 Experimental Results for Feature Extraction in Similarity Analysis

다양한 조건과 상황에서도 잘 판별할 수 있는지 실험하기 위해 아래의 Table 3과 같이 실험을 진행하였다. 이때, 손상된 폐기물은 데이터가 존재하지 않음으로, 이미지의 일부를 마스킹 처리하여 폐기되었다고 가정하고 실험을 진행하였다.

Table 3. Similarity Analysis Based on Logistic Regression results

Feature extraction	Method	Train_Acc (%)	Test_Acc (%)	FPS
SIFT	X	90.98	89.75	3.78
	brightness			
	brightup	76.66	79.41	
	Remove Background			
Masked	89.98	89		
ORB	X	80.75	81.05	16.39
	brightness	79.67	81.74	
	brightup	74.69	74.68	
	Remove Background	77.32	78.04	
	Masked	86.02	87.17	
AKAZE	X	80.31	80.52	7.14
	brightness	84.21	85.53	
	brightup	85.91	86.56	
	Remove Background	80.7	80.71	
	Masked	91.6	90.35	

조도 변화, 배경 제거, 마스킹 등 다양한 환경에서 실험을 진행하였다. 그 결과 SIFT 기반 특징 추출은 기울기 기반 특징을 표현을 진행하기 때문에 조명변화에 특징 추출 값이 변하지 않았다. ORB와 AKAZE는 일부 마스킹 처리된 이미지의 특징을 더욱 잘 포착했는데, 이는 마스킹된 부분 때문에 보다 덜 복잡한 특징점만 남게 되어 매칭이 기존 이미지보다 더 쉬운 것으로 판단된다. 또한, 배경을 지우자 모든 알고리즘에서 정확도가 비슷하거나 떨어진 결과를 확인할 수 있는데, 이는 배경 또한 객체를 판단할 때, 인지되는 주요 요소라는 것을 암시한다. 종합적으로 ORB를 제외한 다른 알고리즘은 다양한 변수에도 높은 기존의 성능 또는 그 이상의 결과를 도출할 수 있는 것을 확인하였다. 속도 측면에서는 SIFT 기반의 특징 추출 방법에서 도출된 FPS의 결과는 실시간 시스템에 적용하는데 한계가 있다. ORB 기반의 특징 추출 방법은 실시간 시스템에 적용 가능할 정도로 속도가 빠르지만, 정확도가 낮다는 단점이 존재한다. 이러한 SIFT의 느린 속도와 ORB의 낮은 정확도를 해결하기 위해서 특징 추출기법을 융합하여 새로운 특징 추출을 진행하였다. 특징 추출기법을 융합한 실험 결과는 Table 4와 같다.

Table 4. Similarity Analysis Based on Fusion Feature Extraction

Fusion Method	Train_Acc (%)	Test_Acc (%)	FPS
AKAZE -> SIFT	88.54	88.72	4.29
AKAZE -> ORB	73.25	71.58	5.29
SIFT -> ORB	65.03	65.20	3.58
ORB -> SIFT	84.84	86.03	9.28

실험 결과 AKAZE 기반의 특징 추출기법과 SIFT 기반 특징 추출의 장점을 혼합한 결과가 정확도가 가장 높게 도출되었다. 그러나 FPS 4.29로 실시간 환경에서 처리하기에는 낮은 처리 속도를 보여 주었다. ORB 기반 특징 추출기법과 SIFT 기반 특징 추출의 장점을 혼합한 결과의 프레임이 가장 높은 처리 속도를 보여 주었다. 이는 ORB 기반 특징 추출을 통해 빠르게 적은 수의 특징점 매칭을 진행하고, 이를 바탕으로 SIFT에 ORB 매칭 결과로 필터링된 중요 특징점만 SIFT에 전달하여 불필요한 특징 추출 시간을 단축하여 SIFT 매칭을 진행하였기 때문이다. 최종적으로 기존의 SIFT 기반 특징 추출 기법보다 처리 속도가 약 59% 향상되었으며, ORB 기반 특징 추출 기법보다 정확도가 3.79% 향상되었다. 아래 그림은 Fusion 기반 특징 추출 후, 로지스틱 회귀 분석을 한 결과를 Fig 6.과 같이 혼동행렬로 나타낸 것이다.




Fig. 6. Confusion Matrix for Fusion-Based Feature Extraction

유사도 기반 분류 정확도는 대체적으로 높은 것으로 확인되었으나, 같은 쌍의 폐기물 데이터를 서로 다른 쌍으로 분류하는 비율이 높게 나타나고 있는 것으로 확인된다. 이를 세부적으로 분석하기 위해 잘못 예측된 데이터만을 분석하였으며 결과는 Fig 7.과 같다.

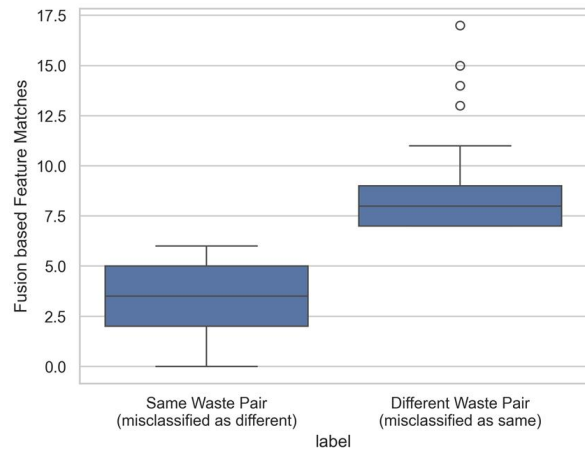


Fig. 7. Boxplot of Fusion based Feature Matches for Misclassified Waste Image Pairs

그림 7에서 같은 폐기물을 서로 다른 폐기물로 오분류한 왼쪽 박스플롯은 특징의 개수가 적으며, 다른 폐기물을 서로 같은 폐기물로 오분류한 오른쪽 박스플롯은 상대적으로 특징의 개수가 더 많다. 이는 다른 각도에서 촬영된 동일한 폐기물의 데이터의 특징이 충분히 매칭이 되지 않았기 때문이다. 이러한 결과는 각도에 따른 데이터의 다양성이 부족하기 때문에 발생하는 것으로 보인다. 이를 해결하기 위해서 증강을 통해 다양한 패턴을 반영하여 학습하여 동일 폐기물에 대한 유사도를 높이거나, Hard Negative Mining을 통해 다른 폐기물임에도 유사한 특징을 가지는 이미지 쌍을 집중적으로 학습하여 다른 클래스 간 유사도를 낮추도록 유도해야 한다.

IV. Conclusions

본 연구의 첫 번째 실험에서는 42종의 대형 폐기물을 Dilated Faster R CNN으로 분류 및 탐지를 진행하였다. 실험에서는 필터가 수용 가능한 영역을 확장시켜 폐기물을 보다 높은 정확도로 탐지가 가능하였다. 두 번째 실험에서는 서로 같은 이미지 쌍과 다른 이미지 쌍의 폐기물을 퓨전 특징 추출 기반 유사도 분석을 진행하였다. 실험에서는 SIFT 기반 특징 추출, ORB 기반 특징 추출, 두 특징 추출의 장점을 융합시킨 퓨전 특징 추출을 진행하였고, 각 특징을 로지스틱 회귀 분석을 진행하였다. 그 결과 퓨전 기반 특징 추출이 SIFT 특징 추출 기법보다 처리 속도가 향상되었으며, ORB 특징 추출 기법보다 정확도가 향상되었다는 것을 보여 주었다. 이를 통해 폐기물의 배출 과정에서 배출자는 잘못된 배출을 줄일 수 있으며, 수거자는 배출된 폐기물에 대한 유사도 분석을 기반으로 실제 신고된 항목과 일치하는지 빠르게 검증하여, 정확한 수거 작업을 진행할 수 있다. 이러한 시스템은 대형 폐기물의 관리 과정에서 효율성을 크게 향상시키고, 불필요한 처리 비용을 감소시켜 환경에 미치는 영향을 최소화 하는데 기여할 것으로 기대된다. 추후 연구에서는 조도, 각도, 배경과 같은 요소들이 더욱 다양한 데이터 셋을 학습하여 일반화 성능을 향상시키고, 실시간 분석 기능을 추가하여 실제 운영 환경에서도 효과적으로 작동할 수 있도록 시스템을 개선할 예정이다.

and real-time detection using deep learning methods. *Urban Climate*, 49, 101462.

- [7] Lowe, D. G. (2004). Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, 60, 91-110.
- [8] Rublee, E., Rabaud, V., Konolige, K., & Bradski, G. (2011, November). ORB: An efficient alternative to SIFT or SURF. In *2011 International conference on computer vision* (pp. 2564-2571). Ieee.
- [9] Alcantarilla, P. F., & Solutions, T. (2011). Fast explicit diffusion for accelerated features in nonlinear scale spaces. *IEEE Trans. Patt. Anal. Mach. Intell* , 34 (7), 1281-1298.
- [10] Ren, S., He, K., Girshick, R., & Sun, J. (2016). Faster R-CNN: Towards real-time object detection with region proposal networks. *IEEE transactions on pattern analysis and machine intelligence*, 39(6), 1137-1149.
- [11] Yu, F., & Koltun, V. (2015). Multi-scale context aggregation by dilated convolutions. *arXiv preprint arXiv:1511.07122*.

REFERENCES


- [1] Haseli, G., Torkayesh, A. E., Hajiaghaci-Keshteli, M., & Venghaus, S. (2023). Sustainable resilient recycling partner selection for urban waste management: Consolidating perspectives of decision-makers and experts. *Applied Soft Computing*, 137, 110120.
- [2] Kim, Y., & Cho, J. (2022). AIDM-Strat: augmented illegal dumping monitoring strategy through deep neural network-based spatial separation attention of garbage. *Sensors*, 22(22), 8819.
- [3] Artificial intelligence based Smart Waste Management—a systematic review(2022)Morgan Kaufmann Pub., ch. 2, pp.66-153, 2007.
- [4] Nanda, S., & Berruti, F. (2021). Municipal solid waste management and landfilling technologies: a review. *Environmental chemistry letters*, 19(2), 1433-1456.
- [5] Ma'rifah, P. N., Sarosa, M., & Rohadi, E. Comparison of Faster R-CNN ResNet-50 and ResNet-101 Methods for Recycling Waste Detection.
- [6] Li, N., & Chen, Y. (2023). Municipal solid waste classification

Authors



SiUng Kim received the B.S. degrees in Computer Science and Engineering from Hoseo University, in 2023. B.S Kim joined the Department of computer science at Hoseo University, asan, korea in 2023.

He is currently a Master in the Department of Computer Science, Hoseo University He is interested in Computer Vision, Object Detection, Image Generation.



JunHyeok Go received the B.S. degrees in Computer Science and Engineering from Hoseo University, in 2023. B.S Go joined the Department of computer science at Hoseo University, asan, korea in 2023.

He is currently a Master in the Department of Computer Science, Hoseo University He is interested in Computer Vision, Object Detection, Image Generation.



JeongHyeon Park received the B.S. degrees in Computer Engineering from Hoseo University, Korea, in 2023. Park joined the Department of computer science at Hoseo University, asan, korea in 2023.

He is currently a Master in the Department of Computer Science, Hoseo Graduate School Asan, Korea, in 2023. He is interested in Data analysis and BigData



Nammee Moon received B.S, M.S., and ph.D. degrees in School of Computer Science and Engineering from Ewha Womans University in 1985, 1987 and 1998, respectively. She served as an assistant professor at Ewha

Womans University from 1999 to 2003. From 2003 to 2008, she is a professor of Department Digital Media, Graduate School of Seoul Venture Information. Since 2008, she is currently a professor in the Department of Computer Science and Engineering, Hoseo University. She is current research interests include Social Learning, HCI and User Centric Data, Big-data Processing and Analysis.