

박사학위논문

음식물쓰레기에서 이물질 구별을
위한 딥러닝 적용에 관한 연구

2023년

한 성 대 학 교 대 학 원

스마트융합건설팅학과

스마트융합제품전공

김 용 일

박 사 학 위 논 문
지도교수 김승천

음식물쓰레기에서 이물질 구별을 위한 딥러닝 적용에 관한 연구

A Study on the Application of Deep Learning for
Foreign Object Classification in Food Waste

2022년 12월 일

한 성 대 학 교 대 학 원

스마트융합컨설팅학과

스마트융합제품전공

김 용 일

박 사 학 위 논 문
지도교수 김승천

음식물쓰레기에서 이물질 구별을 위한 딥러닝 적용에 관한 연구

A Study on the Application of Deep Learning for
Foreign Object Classification in Food Waste

위 논문을 공학 박사학위 논문으로 제출함

2022년 12월 일

한 성 대 학 교 대 학 원

스마트융합컨설팅학과

스마트융합제품전공

김 용 일

김용일의 공학 박사학위 논문을 인준함

2022년 12월 일

심사위원장 노 광 현 (인)

심 사 위 원 홍 정 완 (인)

심 사 위 원 임 진 호 (인)

심 사 위 원 임 황 용 (인)

심 사 위 원 김 승 천 (인)

국 문 초 록

음식물쓰레기에서 이물질 구별을 위한 딥러닝 적용에 관한 연구

한 성 대 학 교 대 학 원
스 마 트 융 합 컨 설 팅 학 과
스 마 트 융 합 제 품 전 공
김 용 일

현대 사회가 급속하게 산업화로 발전하면서 함께 증가하는 것이 있다. 다름 아닌 우리 주변의 각종 생활폐기물과 음식물쓰레기일 것이다. 더욱이 지난 2019년 말부터 시작된 코로나19로 인해서 근 2년 반 동안 사회적 거리두기로 야외 활동보다는 실내에서 활동하는 시간이 많아졌다. 그러다 보니 배달 음식문화가 발달하였고 배달 음식을 통해 일회용품 용기들과 버려지는 음식물쓰레기들이 증가하고 있다.

버려지는 음식물에는 우리가 무심코 버리는 생활폐기물과 함께 포함되어 버려져 사회적으로 이슈화되고 있다. 이렇게 혼입되어 버려진 음식물쓰레기 이물질은 재활용 과정에서 누군가 선별하여야 한다. 이를 위해서 음식물쓰레기를 처리하기 위한 자원화 처리시설을 설치하여 음식물쓰레기를 활용한 퇴비 및 사료화로 이용하고 있다. 우리가 음식물쓰레기를 줄여서 비용 절감과 환경보호를 하는 것이 목적인데 오히려, 음식물쓰레기 이물질 선별 작업과 선

별과정에서 이물질로 인한 설비파손으로 유지보수비용 등이 증가하고 있다. 사실 이러한 문제를 요즘 TV 광고에서 많이 나오고 있는 가정에서 사용할 수 있는 음식물처리기로 하면 쉽게 해결할 수 있다고 한다. 하지만, 현실적인 문제가 있다. 분쇄형 음식물처리기는 싱크대 설치형이 대부분인데 이는 1차로 음식물을 분쇄하고 2차로 처리한 음식물을 배출하는 방식이다. 하지만, 우리나라 하수도법에 따르면 분쇄된 음식물을 20% 이상 하수도로 배출하는 것을 금지하기 때문에 불법 논란이 있다. 그 외 제품들은 필터 비용부담, 전기료, 악취 문제 등으로 논란의 여지가 있기에 사용에 제한이 있다.

따라서, 본 연구에서는 이러한 문제점을 인식하고 음식물쓰레기 이물질 구분을 위하여 딥러닝 모델을 활용하여 해결하고자 한다. 음식물쓰레기 이물질 구분을 위한 데이터를 위한 실험을 위해서 공개데이터 사이트인 AI 허브를 통해서 공공데이터 수집하였다. 딥러닝의 여러 모델에 적용하여 비교 분석을 통해서 최적의 모델을 찾고자 하였다. 수집된 데이터를 바탕으로 딥러닝의 이미지 기반 분류 알고리즘 VGG, ResNet, EfficientNet 3가지 모델을 선택하였다.

실험방법은 일차적으로는 생활폐기물 이미지에 대한 학습 및 검증을 한 뒤 테스트하고, 2차는 생활폐기물 이미지로 분류한 데이터가 실제 음식물쓰레기 이물질은 부패하고 또한 음식물쓰레기와 섞여 있는 이물질이 대부분인데 이에 대한 신뢰성 문제가 제기될 수 있어 이에 대한 비교 측정으로 음식물쓰레기 이물질 이미지와 데이터 증식, 전이 학습을 통해서 얻은 유사한 이미지로 학습 및 검증, 테스트하여서 두 실험을 통해 우수한 알고리즘 모델을 선택하여 최종적으로 실제 집하장 이미지로 테스트하고자 하였다. 각 알고리즘별 6개의 분류 모델을 만들어 각 데이터셋의 테스트 데이터의 분류 정확도를 측정하였다. 두 실험 측정을 통해서 EfficientNet 모델이 가장 정확도가 높았고, 이를 바탕으로 집하장 이미지로 최종 측정을 한 결과 전체 이미지보다는 높지 않았지만, 부분 이미지보다는 월등히 높은 정밀도, 재현율, F1 스코어를 나타냈지만, 정확도는 부분 이미지와 별반 차이가 없음을 나타냈다.

본 연구에서 위 결과를 근거로 집하장 및 민간시설에서 음식물쓰레기 이물질 구분에 활용할 것을 제안하며, 이를 통해서 집하장에서 근무하는 작업자

들이 보다 나은 근무환경과 안전하게 근무하고 안정화된 설비로 재활용 자원에 있어 높은 생산성과 자동화시스템이 빠르게 도입될 것으로 기대된다. 또한, 이산화탄소를 배출하는 음식물쓰레기를 우리가 분리배출을 잘하고 이를 체계적으로 운용하여 자원 재활용을 할 수 있다면 탄소 중립화에 크게 기여할 수 있다고 기대된다.

【주제어】 딥러닝, 이물질 구분, 인공지능, 탄소중립, EfficientNet

목 차

제 1 장 서 론	1
제 1 절 연구의 배경	1
1) 음식물쓰레기로 인한 사회/경제적 낭비 요소	1
2) 음식물쓰레기 줄이기 정부 시책	3
3) 2050 탄소중립 체계 출범	4
제 2 절 연구의 필요성	5
1) 탄소 자원화의 중요성	5
2) 이물질로 인한 처리비용 증가	6
제 3 절 연구의 목적 및 방법	10
1) 연구의 목적	10
2) 연구의 방법	11
3) 연구의 범위	11
제 2 장 이론적 배경 및 선행 연구	12
제 1 절 음식물쓰레기 종량제 적용에 관한 연구	14
1) RFID	14
2) 음식물쓰레기 종량제	19
제 2 절 이물질 구분을 위한 이미지 학습에 관한 인공지능 연구	32
1) 이미지 기반 알고리즘 모델	35
2) 인공지능에 관한 선행 연구	44
제 3 장 음식물쓰레기 이물질 구분을 위한 모델 설계	50

제 1 절 이미지 기반 딥러닝 모델 개요	50
1) 실험데이터 개요	50
2) 데이터셋 구성	52
3) 데이터의 분포	53
4) 데이터의 포맷	54
제 2 절 이물질 구분을 위한 알고리즘 설계	56
1) 실험 정의	56
2) 데이터의 전처리	58
3) 실험 환경	62
 제 4 장 딥러닝 적용 이물질 구분 시스템 구현 및 테스트	67
제 1 절 모델별 이물질 구분 시스템 구현	67
1) 구현 범위	67
2) 성능평가	68
제 2 절 모델별 이물질 구분시스템 테스트 평가	72
1) 전체 이미지에 적용된 모델별 분류 결과	72
2) 부분 이미지에 적용된 모델별 분류 결과	76
3) 전체 이미지와 부분 이미지에 적용된 모델별 분류 결과 비교	80
4) EfficientNet 모델 적용한 집하장 이미지 분류 결과	98
제 3 절 연구의 성과	104
1) 이물질 구분시스템의 기대 효과	104
2) 이물질 구분시스템의 시사점	105
 제 5 장 결 론	107
 참 고 문 헌	109

ABSTRACT	115
----------------	-----

표 목 차

[표 1-1] 음식물쓰레기 중 이물질 종류와 장애 현상	8
[표 2-1] 정부 기관별 RFID 기술의 정의	14
[표 2-2] RFID와 바코드 기술 특성 비교	16
[표 2-3] 경제성분석 지표	17
[표 2-4] 음식물쓰레기 종량제 수거기의 호퍼승하강장치	26
[표 2-5] 적용 기술	26
[표 2-6] 응답자 특성	30
[표 2-7] 만족도	31
[표 3-1] 폐기물 종류별 세부 분류	52
[표 3-2] 데이터셋 구성	52
[표 3-3] 선별 데이터 상세정의	54
[표 3-4] VGG-16 Model	66
[표 4-1] VGG 분류 모델의 전체 이미지 분류 결과	72
[표 4-2] ResNet 분류 모델의 전체 이미지 분류 결과	73
[표 4-3] EfficientNet 분류 모델의 전체 이미지 분류 결과	74
[표 4-4] VGG 분류 모델의 부분 이미지 분류 결과	76
[표 4-5] ResNet 분류 모델의 부분 이미지 분류 결과	77
[표 4-6] EfficientNet 분류 모델의 분류 결과	78
[표 4-7] 집하장 이미지 EfficientNet 분류 모델 분류 결과	100

그 립 목 차

[그림 1-1] 버려진 음식물이 끼치는 영향(출처:강남구 보건소)	2
[그림 1-2] 음식물쓰레기 20% 감소 시 효과(출처:강남구 보건소)	2
[그림 1-3] 음식물쓰레기 줄이기 정부 시책	3
[그림 1-4] 음식물쓰레기 종량제 수수료 부과방식	4
[그림 1-5] 쓰레기 처리 과정(출처:구미시 환경 자원화 시설 처리 공정)	6
[그림 1-6] 음식물쓰레기 처리 과정	7
[그림 1-7] 서울시 공공 처리시설 5곳 음식물쓰레기 처리현황	9
[그림 2-1] 음식물쓰레기 배출과 처리 과정	12
[그림 2-2] 종량제 유형 및 적용방식(출처:한국환경공단)	20
[그림 2-3] 권장 우선순위(출처:한국환경공단)	21
[그림 2-4] 선불방식	22
[그림 2-5] 후불방식	22
[그림 2-6] 호퍼승하강장치가 적용된 내부 모습	27
[그림 2-7] 중량 한계시험	28
[그림 2-8] 분동을 이용한 편심 시험	28
[그림 2-9] 서울시 마포구 아파트 배출량	29
[그림 2-10] 대전시 유성구 아파트 배출량	29
[그림 2-11] 인천시 강화군 아파트 배출량	30
[그림 2-12] 음식물쓰레기 종량기 만족도	31
[그림 2-13] 인공지능(AI) 변천사	32
[그림 2-14] 이미지 인식을 대표하는 태스크	35
[그림 2-15] CNN 구조	36
[그림 2-16] VGG-16 기본 아키텍처	37
[그림 2-17] ResNet 구조	38
[그림 2-18] EfficientNet Model Scaling	41
[그림 2-19] ImageNet 모델 간 정확도 순위	41
[그림 3-1] 생활폐기물 데이터 AI 서비스 흐름도	51

[그림 3-2] 데이터 포맷	55
[그림 3-3] 음식물쓰레기 처리 흐름도	57
[그림 3-4] 음식물쓰레기 이물질 구분시스템 흐름도	57
[그림 3-5] 이물질 구분시스템 흐름도(2)	58
[그림 3-6] 데이터 증식 방법	60
[그림 3-7] 전통적인 기계학습과 전이 학습 비교	61
[그림 3-8] 케라스와 텐서플로	63
[그림 4-1] 테스트 데이터셋 이미지	67
[그림 4-2] 예측 클래스(Predicted Class)	69
[그림 4-3] 전체 이미지에 대한 모델별 F1 스코어 및 정확도 비교	75
[그림 4-4] 부분 이미지에 대한 모델별 F1 스코어 및 정확도 비교	79
[그림 4-5] # 0(고철류)에 대한 모델별 정밀도 비교	80
[그림 4-6] # 0(고철류)에 대한 모델별 재현율 비교	81
[그림 4-7] # 0(고철류)에 대한 모델별 F1 스코어 비교	82
[그림 4-8] # 1(비닐류)에 대한 모델별 정밀도 비교	83
[그림 4-9] # 1(비닐류)에 대한 모델별 재현율 비교	84
[그림 4-10] # 1(비닐류)에 대한 모델별 F1 스코어 비교	85
[그림 4-11] # 2(캔류)에 대한 모델별 정밀도 비교	86
[그림 4-12] # 2(캔류)에 대한 모델별 재현율 비교	87
[그림 4-13] # 2(캔류)에 대한 모델별 F1 스코어 비교	88
[그림 4-14] # 3(나무류)에 대한 모델별 정밀도 비교	89
[그림 4-15] # 3(나무류)에 대한 모델별 재현율 비교	90
[그림 4-16] # 3(나무류)에 대한 모델별 F1 스코어 비교	91
[그림 4-17] # 4(도기류)에 대한 모델별 정밀도 비교	92
[그림 4-18] # 4(도기류)에 대한 모델별 재현율 비교	93
[그림 4-19] # 4(도기류)에 대한 모델별 F1 스코어 비교	94
[그림 4-20] # 5(플라스틱류)에 대한 모델별 정밀도 비교	95
[그림 4-21] # 5(플라스틱류)에 대한 모델별 재현율 비교	96
[그림 4-22] # 5(플라스틱류)에 대한 모델별 F1 스코어 비교	97

[그림 4-23] 집하장 음식물쓰레기 이물질 선별 작업대	99
[그림 4-24] 집하장 음식물쓰레기 이물질 이미지	99
[그림 4-25] EfficientNet 모델의 카테고리별 정밀도 비교	101
[그림 4-26] EfficientNet 모델의 F1 스코어와 정확도 비교	102
[그림 4-27] EfficientNet 모델의 정밀도와 재현율 비교	103
[그림 4-28] 이물질 제거 시스템	105

제 1 장 서 론

제 1 절 연구의 배경

현대 사회는 급속하게 산업화로 발전하면서 함께 증가하는 것이 있다. 다름 아닌 우리 주변의 각종 생활폐기물과 음식물쓰레기일 것이다. 더욱이 지난 2019년 말부터 시작된 코로나19로 인해서 근 2년 반 동안 사회적 거리두기로 야외 활동보다는 실내에서 활동하는 시간이 많아졌다. 그러다 보니 배달 음식문화가 발달하였고 배달 음식을 통해 일회용품 용기들과 버려지는 음식물들이 증가하고 있다. 이로 인한 사회적, 경제적 비용 또한 늘어가고 있다. 더욱 심각한 것은 수도권 매립지 및 지방 매립지 또한, 고갈되어 가거나 면적이 축소되는 실정이다.

1) 음식물쓰레기로 인한 사회/경제적 낭비 요소


[그림 1-1]과 [그림 1-2]¹⁾는 음식물쓰레기 배출로 인한 4인 가족을 기준으로 연간 온실가스 배출량과 에너지 소모량을 각종 환경에 비교 분석하여 나타내고 있다. 예시를 보면 4인 가족 기준으로 배출한 음식물쓰레기의 양이 724kg이라고 가정할 때 발생한 온실가스 배출량은 승용차로 서울에서 부산을 4.8회 왕복하는 것과 20~30년생 소나무 149그루가 1년간 흡수한 이산화탄소량과 같다는 것이다.

1) 강남구 보건소(<https://health.gangnam.go.kr>)



[그림 1-1] 버려진 음식물이 끼치는 영향(출처:강남구 보건소)

이를 2011년도 기준일 통계에 의하면 연간 배출량이 약 13,537톤에 이르고 있으며, 이를 기준으로 20% 감량 시 1,600억 원의 음식물쓰레기 처리비용이 줄이고 온실가스 177만 톤 CO2e 감소와 연간 에너지 18억 kwh를 절약할 수 있다는 것이다.




[그림 1-2] 음식물쓰레기 20% 감소 시 효과(출처:강남구 보건소)

음식물쓰레기는 일반적으로 공장에서 식품이 생산되는 과정, 원산지에서 도매를 거쳐 소매로 유통되는 과정에서 발생하는 부산물, 식물을 손질하는 과정 발생하는 부산물, 음식을 조리과정에서 발생하는 농·수·축산물 쓰레기이다. 이외에도 가정에서 유통기한이 지났거나 상한 음식, 음식점 등에서의 뷔페 음식이나 단체급식에서 먹지 않고 남은 음식 또는 먹다 남은 음식물 등이 있다.

2) 음식물쓰레기 줄이기 정부 시책

음식물쓰레기의 심각성은 국내뿐만 아니라 해외에서도 마찬가지이다. [그림1-3]을 보면 1996년 런던국제협약에서 2013년부터 음폐수 해양투기를 금지하였고 해양투기가 금지됨에 따라 국내에도 음식물쓰레기 줄이기 위한 정부의 시책을 발표하였다. 1995년 쓰레기 종량제 실시, 2005년 음식물쓰레기 분리배출 전면 실시, 2012년 음식물쓰레기 배출량에 따른 종량제 전면 시행을 의무화하여 현재에 이르고 있다.

음식물 쓰레기 줄이기 정부시책



>> 국제협약(런던협약)

협약내용 : 런던협약 '96의정서 "발효로" 2012년부터 음폐수 해양투기 금지(연도별 배출허용량(전국))

[그림 1-3] 음식물쓰레기 줄이기 정부 시책

[그림 1-4]는 종량제 실시 전과 후를 비교한 것이다. 즉, 종량제 실시 전에는 음식물쓰레기의 양에 상관없이 누구나 똑같이 1,000원의 수수료를 부과하는 방식이고 종량제 실시 후에는 음식물쓰레기를 버린 무게를 계급하여 수수료를 차등(500원과 2,000원) 부과하는 방식이다.



[그림 1-4] 음식물쓰레기 종량제 수수료 부과방식

국내외 환경에 대한 정책은 빠르게 추진되고 있지만 현실과 대치되는 상황도 발생하고 있다.

3) 2050 탄소중립 체계 출범

파리 기후변화협약 이후 온실가스 감축에 대한 관심이 증대되었다. 2030년 국가 온실 감축 목표와 2050년 장기 저탄소 발전전략을 2022년 말까지 제출하였다. 개발도상국 중심으로 신기후 체제에 따른 감축 수요 증가가 예상된다.

제 2 절 연구의 필요성

1) 탄소 자원화의 중요성

최근 전 세계적으로 지구 온난화에 대한 심각성을 상기시키고 있다. 산업화의 가속화와 화석연료 사용으로 온실가스의 주범인 이산화탄소 배출이다. 지구 온난화 문제를 해결하기 위해서는 이산화탄소의 배출량을 줄여야 한다. 지구의 평균온도가 1℃만 상승하면 북극의 빙하가 녹는 속도가 빨라져 북극곰이 멸종 위기에 놓이게 된다. 2℃ 상승하면 그린란드 전체가 녹아 마이애미, 맨해튼이 바다에 잠기고, 수십만 명이 열사병으로 사망하게 되고 6℃ 상승하면 생물의 95%가 멸종하게 된다고 한다. 이러한 사실은 TV 다큐멘터리에 종종 나오곤 한다. 북극곰이 빙하가 해마다 녹으면서 먹이를 찾으러 수백에서 수천 Km을 이동하고 있다. 따라서, 최근 들어 화두가 되는 이슈로는 단연 탄소중립(Carbon Neutrality), 탄소 제로(Zero Carbon Emission)라 할 수 있다. 탄소중립은 대기 중 이산화탄소 농도 증가를 막기 위해 인간 활동에 의한 배출량은 최대한 감소시키고, 흡수량을 증대시켜 순 배출량을 '0'이 되도록 하는 상태를 말한다. 즉, 인간 활동으로 배출하는 온실가스는 최대한 줄이고, 배출되는 온실가스는 산림 흡수 등으로 제거하여 실질적인 배출량을 '0' 수준으로 낮추는 것이다. 이처럼, 지구 온난화를 막기 위해 온실가스의 제거가 가장 큰 목적이며 여기에는 이산화탄소와 메테인 등 탄소 관련 물질이 대부분 차지하기 때문이다. 이를 위해 2019년 유엔기후변화협약 당사국총회에서 77개국들이 2050년까지 탄소중립 달성을 위한 서약을 하였다. 이러한 심각성을 인지하고 기온상승을 산업화 이전 대비 2℃ 이하로 지키자는 파리협정('15.12)의 목적을 달성하더라도 막대한 피해는 불가피하다.²⁾³⁾

이러한 위기를 극복하고자 EU·미국은 탄소 국경조정제도 도입계획 발표, 글로벌기업의 RE100⁴⁾ 선언, ESG⁵⁾ 투자 확산 등 선제적으로 대응을 추진하고

2) 환경오염에 대한 경각심(<https://blog.naver.com/mynameisatolee/222364158589>)


3) 워뉴스(<https://www.wip-news.com/news/articleView.html?idxno=13422>)

4) 나무위키(<https://namu.wiki/w/RE100>)

있다.

2) 이물질로 인한 처리비용 증가

[그림 1-5]는 우리가 환경을 위해서 각종 쓰레기를 처리하는 과정을 보여주고 있다. 처리 과정을 보면 소각하거나 매립되는 생활 쓰레기와 사업장 생활 폐기물이 있고 재활용할 수 있는 재활용품이나 대형폐기물, 음식물쓰레기로 구분되어 있다. 생활 쓰레기는 배출된 후 선별시설에서 가연물과 불연물로 선별하여 가연물은 소각시설에서 소각하고 불연물은 매립시설에 매립을 한다. 재활용품은 종류별로 분리된 재활용품을 선별시설에서 선별하여 품목별로 매각하거나 잔재물은 소각 또는 매립을 한다. 사업장 생활폐기물은 파쇄하여 생활 쓰레기와 마찬가지로 소각 또는 매립하고 대형폐기물 또한 재활용품과 마찬가지로 처리한다. 끝으로 음식물쓰레기는 음식물 사료화시설이나 재활용시설에서 처리하여 축산농가 등에 무상 공급한다는 것이다.



[그림 1-5] 쓰레기 처리 과정(출처:구미시 환경 자원화 시설 처리 공정)

- 5) 기업의 비재무적 요소인 환경, 사회, 지배구조를 뜻하는 것으로 장기적인 관점에서 친환경 및 사회적 책임경영과 투명경영을 통해 지속 가능한 발전을 추구하는 것이다.

음식물쓰레기의 처리 과정은 [그림 1-6]과 같다. 먼저, 가정이나 음식점에서 음식을 조리하고 섭취한 후 먹다 남은 음식이나 유통기한이 지난 상한 음식 등을 개별적으로 음식물쓰레기 봉투나 별도의 통에 담아서 RFID 기반 음식물쓰레기 종량기나 음식물쓰레기통에 배출한다. 이렇게 배출된 음식물쓰레기가 만수가 되면 각 지자체에서 위탁한 수거업체에서 음식물쓰레기 수거 차량을 통해 집하장으로 이동한다. 집하장에서는 음식물쓰레기 처리 자동화 설비를 통해 퇴비 또는 가스 등으로 자원화를 한다. 음식물쓰레기는 수분이 많고 부패와 악취가 수반되기 때문에 매립, 소각할 경우, 주변 환경을 오염시킬 우려가 있으며, 민원 야기, 매립지 확보 논란 등과 같은 발생하기 때문에 이러한 문제를 해결하기 위해 음식물쓰레기 자원화를 위한 시설을 설치하여 음식물쓰레기를 이용한 퇴비화 및 사료화로 이용하고 있다.



[그림 1-6] 음식물쓰레기 처리 과정

음식물쓰레기 처리 과정에서 [표 1-1]⁶⁾과같이 집하장에서는 수거된 음식물쓰레기로 인한 여러 문제점이 발생하고 있다. 그중에서 가장 큰 문제가 이물질로 인한 설비파손과 이물질 구별을 위한 인력들의 위험 요소들이 존재하고 있다.

[표 1-1] 음식물쓰레기 중 이물질 종류와 장애 현상

쇠붙이 류	파쇄 날을 망가뜨리고 철 수세미 조각은 가축이 섭취 시 위벽 손상
비닐 및 섬유류	스크루 회전 부위에 감겨 설비를 망가뜨리고 선별기 구멍이 막힘
플라스틱 및 고무류	파쇄 날과 이송 스크루를 망가뜨림
동물 뼈	단단하여 파쇄 날을 망가뜨리고 과부하로 모터 고장의 원인이 됨
조개껍데기 류	이송관을 약하게 하고 저장탱크의 바닥에 침적되어 용량을 감소시킴
나무류	단단하여 처리되지 않고 이주시개는 가축의 위벽 손상


이를 [그림 1-7]과 같이 서울시 5곳의 공공 처리시설 음식물처리현황을 통해서도 알 수 있다. 즉, 서울시의 주요 5곳의 지자체도 [표 1-1]과 대동소이하게 이물질로 가장 많이 차지하고 있는 비닐봉투를 포함하여 소, 돼지, 닭과 같은 동물 뼈, 깨진 그릇조각과 숟가락, 조개껍질 등이 전체 음식물쓰레기 처리량의 약 2~4% 정도 차지함을 알 수 있다.⁷⁾ 음식물쓰레기에 혼입된 이물질 처리 과정은 우리가 생각한 것처럼 단조롭지 않다. 일단 1단계로 자동 선별 파쇄기에서 비닐봉투 등 이물질을 부순 다음 자력선별기에서 작은 철 핀이나 밥뚜껑이나 숟가락 같은 금속류를 선별한다. 그리고 난 후 2단계로 진동

6) 대전광역시 생활정보(<https://www.daejeon.go.kr>)

7) <https://m.kmib.co.kr/view.asp?arcid=0922697553>

선별기에서 플라스틱이나 비닐 등 비금속 이물질을 걸러내는 단계를 거친다.

이처럼 우리가 무심코 버리는 음식물쓰레기에 혼입된 일반쓰레기와 음식물쓰레기 수거 차량에 남아있는 일반쓰레기 잔해가 음식물쓰레기와 혼입되면서 집하장에서 재활용하는 과정에 엄청난 비용과 인력 낭비 등 폐해를 주는 것이다.



[그림 1-7] 서울시 공공 처리시설 5곳 음식물쓰레기 처리현황
(자료 : 서울시)

위의 선례를 보더라도 집하장의 집하처리 공정에서의 문제는 단순한 설비를 적용한 재활용 목적을 위하여 많은 인력이 투입되고 인력마다의 숙련도와 컨디션에 따라 효율성이 높지 않다. 이를 해소하기 위해 다양한 이미지 기반 딥러닝 알고리즘을 이용한 이미지 분류 모델을 사용하여 효율을 개선하고자 한다.

제 3 절 연구의 목적 및 방법

1) 연구의 목적

본 연구에서는 기후변화에 따른 각국의 정책과 정부 시책에 맞춰 우리가 주변에서 할 수 있는 탄소중립을 위한 실천 방안을 모색하였다. 우리가 쉽게 실천할 수 있는 것으로 현재 실생활에서 시행되고 있고 음식물쓰레기 분리 배출과정을 살펴보고 집하장에 적재된 음식물쓰레기 이물질로 인한 선별과정의 문제점을 찾고 해결하고자 한다. 음식물쓰레기에 포함된 이물질로 인한 사회적·경제적 비용도 만만치 않다. 따라서, 이러한 문제를 인식하고 이를 해결하기 위해서 음식물쓰레기에 혼입된 이물질 구분에 인공지능을 활용하여 이미지를 분류하고자 하는 이유는 다음과 같은 목적을 위해서 제안하고자 한다.

첫 번째는 설비의 구조적인 문제 해결을 위한 대안 제시이다. 현재 집하지에 설치된 설비의 구조적인 문제개선을 위해서 이미지 분류에 대한 데이터를 제공함으로써, 각각의 특성에 맞게 설비 변경 및 구조 개선을 통해 검출 시스템을 재정비하는데 도움을 주기 위해서이다. 예를 들어, 이미지 분류의 정확도가 높은 알고리즘 모델을 택해 물류시스템처럼 각각의 이물질 특성에 맞게 고철은 설비에 자석을 활용하고, 가벼운 것은 위로 지나가고 무거운 이물질은 아래로 떨어지게 하는 등 자동 분류시스템을 위한 이미지 분류데이터 제공을 통해 설비 개선이나 구조변경을 할 수 있다.

두 번째는 1차 수거지에 음성안내 서비스 제공이다. 집하지에서의 문제점은 근본적으로 가정이나 상가에서 배출하는 과정에 혼입되기 때문이다. 특히, 상가에서 혼입되는 사례가 많다. 따라서, 이미지 분류시스템을 1차 수거지에 카메라를 설치하여 배출하는 과정의 영상을 획득하여 어떤 이물질이 혼입되었음을 알려주는 것이다. 음식물쓰레기 배출은 불특정 다수가 함으로써 이물질 혼입이 발생하는데, 배출시 본인에게 귀중한 이물질이 포함될 수 있는데 이러한 안내를 통해 분실을 사전 예방할 수 있다.

세 번째는 시간적·경제적 비용 절감 효과이다. 이물질로 인해 설비파손으

로 인한 시간과 비용 절감과 위험에 노출되어있는 인력들이 안전하게 근무할 수 있는 환경 개선으로 설비가 가동 중단으로 인한 음식물쓰레기 처리 지연으로 인한 2차, 3차에 대한 음식물쓰레기 대란이 발생하는데 이를 사전 예방할 수 있다.

끝으로, 탄소중립 실천에 대한 기여도이다. 탄소중립의 실천은 어렵고 복잡한 것이 아니라, 우리가 직접 실천하는 있는 음식물쓰레기 종량제 실천이야말로 탄소중립에 앞장서고 동참을 하게 되는 것이다.

2) 연구의 방법

연구의 방법은 딥러닝의 CNN 기반으로 한 ImageNet 관련 모델 3가지를 선정하여 생성한다. 딥러닝에 대한 다양한 모델들이 있지만 그중 VGG-16, 신경망 깊이가 깊어질수록 딥러닝 성능이 좋아진다는 ResNet, 이전 모델보다 훨씬 작고 빠른 이미지 분류 모델인 EfficientNet 3개의 딥러닝 알고리즘을 음식물쓰레기 이물질 구분을 위한 모델로 활용하고자 한다.


3) 연구의 범위

본 연구의 범위는 기후변화에 따른 각국의 정책과 정부 시책에 맞춰 우리가 주변에서 할 수 있는 탄소중립을 위한 방안으로 우리가 실생활에서 시행되고 있고 음식물쓰레기 분리배출과 집하장에서의 음식물쓰레기 이물질 선별과정을 대상으로 하였다. 물론, 재활용품과 일회용품 플라스틱 용기도 문제가 되고 있다. 하지만 재활용품은 아직도 헛갈리는 부분이 있지만 시행도 오래되고 홍보도 많이 했기 때문에 분리수거가 잘 이루어지고 있고 일회용품 플라스틱 용기 또한 자원순환 보증금 관리센터(COSMO)⁸⁾가 대안을 마련하고 있어 이번 연구에서 제외하기로 하였다.

8) <https://www.cosmo.or.kr/home/main.do>

제 2 장 이론적 배경 및 선행 연구

음식물 배출로 인한 낭비와 피해를 없애고자 음식물쓰레기종량제가 2012년부터 시행되었다. 하지만, 음식물쓰레기 종량제를 시행하면서 기존 배출량 대비 20~30%의 감량 효과가 있었다. 반면에 여러 문제점이 발생하고 있다. 그중에서도 [그림 2-1] 음식물쓰레기 처리 과정에서 가정이나 상가에서 음식물쓰레기와 함께 배출한 쇠붙이, 동물 뼈, 비닐류 등의 이물질이 가장 큰 문제가 되고 있다. 배출된 음식물쓰레기는 통상적으로 1차 수거지에서 2차 집하장으로 이동하거나 직접 감량기를 통해 자원화한다.



[그림 2-1] 음식물쓰레기 배출과 처리 과정

가정이나 상가의 음식물쓰레기 배출과정에서 이물질 구분을 하는 방법과 집하장에서 이물질 구분하는 방법을 모색하였다. 하지만, 음식물쓰레기 배출 방식이 RFID 기반 방식, 칩(스티커) 방식, 봉투 방식이 있는데, RFID 기반 방식 외에는 개인별로 구매하여 배출하는 칩(스티커) 방식, 봉투 방식은 사실상 이물질 판단이 어려운 부분이 없지 않아 있다. 따라서 본 연구에서는 1차

수거지에서 최종 목적지로 이동된 음식물쓰레기 이물질로 문제가 시급한 음식물 집하장에서의 이물질 분류를 목적으로 하였다.

집하장으로 운반된 음식물쓰레기를 재활용 및 퇴비화 과정에서 혼입된 이물질을 분류하는 과정에서 시간적·경제적 비용이 많이 든다는 것이다. 물론, 감량기를 통한 퇴비화 과정에서 이물질로 인한 설비파손으로 수리 비용이 증가하고 있다. 이러한 문제를 해결하기 방안으로 1차 수거지인 RFID 기반 음식물쓰레기 종량기에서 수거 시 사전에 구분하는 방안과 집하된 수거지에서 이물질을 구분하는 장치를 도입하여 해결하는 방안을 모색하게 되었다. 그 방안으로 RFID 기반 음식물쓰레기 종량기 또는 집하장에 사전 학습된 데이터를 통해 카메라로 이물질을 분리 작업하는 것이다.

이와 관련하여 본 연구에서는 이러한 문제점을 해결하기에 앞서 2012년부터 시행된 RFID 기반 음식물쓰레기 종량제 시행과 관련하여 무선 통신기술인 RFID와 음식물쓰레기 종량제에 대한 기본적인 지식과 이론적 배경이 되는 각각의 선행 연구와 적용된 사례를 살펴보고 이물질로 인해 집하장 또는 감량기에서 설비파손 및 이를 구분하기 위해 투입된 인원들에 대한 안전을 위한 방안으로 집하처리 과정에서 설치된 카메라를 통해 이물질을 구분하고자 인공지능에 대한 이론적 배경이 되는 선행 연구를 하였다.

제 1 절 음식물쓰레기 종량제 적용에 관한 연구

음식물쓰레기 종량제 방식은 봉투 방식, 칩 방식, 개별계량방식 있는데, 현재 대다수 공동주택이 개별계량방식인 RFID 기반 음식물쓰레기 종량제를 채택하고 있다. 초반에는 지그비(Zigbee)나 비콘(Beacon)을 사용하였으나 RFID 기술의 발달과 대중화로 인해 현재는 RFID 방식을 채택하여 사용하고 있다. 10여 년 동안 시행되어온 음식물쓰레기 종량제가 그간 여러 시행착오와 보완을 통해 개선되어 음식물쓰레기 배출량이 많은 감량 효과를 보고 있다. 따라서 이러한 많은 개선 효과가 있는 RFID 기반 음식물쓰레기 종량제에 대해 알아보려고 한다. 먼저 RFID 기반으로 운영이 된다고 하니 이에 RFID 방식이 무엇인지에 대해서 먼저 알아보고 음식물쓰레기 종량제에 대한 전반적인 개요와 선행 연구를 하고자 한다.

1) RFID

가) 개요 및 특징

RFID는 RF(Radio Frequency) + ID(Identification)의 합성어로 무선 주파수(RF)를 이용해 대상(물건, 사람 등)을 식별하는 기술이다. 안테나와 칩으로 구성된 전자태그(Tag)를 사용 목적에 알맞은 정보를 저장하여 적용 대상에 부착된 RFID 판독기(Reader)를 통해 개체의 정보를 인식하는 방법으로 활용된다. 우리나라 각 관련기관에서는 서로의 이해관계에 따라 RFID 관련 시스템을 [표 2-1]과 같이 각각 정의하고 있다. 정의하는 기술이 정부 기관별로 다를 수 있다.⁹⁾

9) 최종희, 김수엽, & 이호춘. (2007). 향만물류 선진화를 위한 RFID 기술 도입 방안. 연구보고서, 1-182.

[표 2-1] 정부 기관별 RFID 기술의 정의

정부 기관	기술 정의
지식경제부 (과거 정보통신부)	· U-센서 네트워크 서비스 · 사물에 전자태그를 부착하고 각 사물의 정보를 수집/가공함으로써 개체 간 정보교환, 측위, 원격처리, 관리 등의 서비스를 제공하는 것
산업통상자원부 (과거 산업자원부)	· 제품에 부착된 칩의 정보를 주파수를 이용해 읽고 쓸 수 있는 무선 주파수 인식으로 사람, 상품, 차량 등 비접촉 인식 기술
전자통신연구원 (ETRI)	· 무선 주파수를 사용하는 소형 IC칩을 사용하여 비접촉으로 사물을 인식하는 기술로서, 사물의 위치 파악 및 경로추적을 통해 기업에 실시간으로 제품의 상황에 관한 정보를 전달할 수 있는 기술
정보통신산업진흥원 (IITA)	· 마이크로칩을 내장한 태그, 레이블, 카드 등에 저장된 데이터를 무선 주파수를 이용해 판독기에서 자동 인식하는 기술

나) RFID의 논리적 구성

RFID는 4가지 계층으로 디바이스 계층, 센서 네트워크 계층, 미들웨어 계층, 애플리케이션 계층으로 구성되어 있다. 첫 번째 디바이스 계층은 태그 데이터 수집 기능을 하며 고유의 코드 정보를 저장하는 태그와 무선을 통하여 태그의 정보를 판독 및 해독 기능을 하는 리더로 구성된다. 여기에 사용되는 통신 규격은 125kHz, 135kHz, 13.56MHz, 433MHz, 860~930MHz, 2.45GHz 등으로 국제표준화를 예상한 바 있다. 현재는 ISO 18000-2, 3, 4, 5, 6, 7로써 표준화가 되었다. 두 번째 센서 네트워크 계층은 태그, 센서, 리더, 서버들 간의 효율적인 통신을 제공하는 네트워크 기술이다. 세 번째 미들웨어 계층은 디바이스 계층으로부터 수집된 객체 코드 정보를 애플리케이션 계층에서 효과적으로 사용할 수 있도록 데이터의 전송 처리, 실시간 데이터 환경에서의 데이터 지원 등과 같은 서비스를 제공한다. 끝으로 애플리케이션

계층은 물류, 공급망 관리, 의료 국방, 제조 등과 같은 다양한 응용 솔루션을 제공하는 기술로 구성된다.¹⁰⁾

다) RFID와 바코드

RFID 태그는 스마트 라벨(Smart Label)이라고 불리며, 카드 타입, 태그 타입, 라벨 타입, 동전 타입 등의 다양한 형태로 존재한다.

[표 2-2]에서 바코드는 한 번에 하나씩 인식하는 반면 RFID는 동시에 여러 개를 인식할 수 있다. 그 외 정보량, 인식 거리, 인식 속도 면에서도 월등함을 알 수 있다. 단지, 가격이 비싸다는 단점이 있지만, 시간이 지날수록 가격은 낮춰지는 추세이다.

[표 2-2] RFID와 바코드 기술 특성 비교

구 분	바코드	RFID
인식 방법	광학식(Read only)	무선(Read / Write)
다중 인식	한 번에 한 개씩	동시에 여러 개 인식 가능
정 보 량	수십 단어(최대 100 bytes)	수천 단어(최대 128 kbytes)
인식 거리	최대 수십 cm	최대 100m
인식 속도	개별 스캐닝	최대 수백 개
관리 레벨	상품 그룹 표시	개별 제품 인식(고유 일련번호)
가 격	라벨 인쇄 10원 미만	태그 수백 원(50원 이하 목표)

라) RFID 적용 기술에 관한 선행 연구

지난 수십 년 동안 기업에서는 여러 기술에 RFID에 많은 투자를 아끼지 않았다. 이로 인해 기존의 바코드 시스템에 비해 RFID가 가지고 있는 압도적인 이점을 생각하면 RFID 기술의 활용 분야 중 특히 물류 부문에 미치는 파급효과는 매우 클 것으로 기대하였다. 하지만 우리가 생각했던 만큼 빠르게

10) 박차길, 이선규. (2008). RFID 응용 기술의 도입에 미치는 영향 요인에 관한 연구. 『한국산학기술학회』, 9(4), 1018-1029.

진행되고 있지 않다. 그 이유는 기술적인 문제와 정보보호 문제, 비용 문제, 국제표준화 등을 들 수 있다.¹¹⁾

RFID를 도입할 때 중요한 문제는 비용이나 위험보다는 RFID를 구현하고 체화할 수 있는 조직 내 정보기술 역량이 더욱 중요한 이유가 되고 있다.¹²⁾ 즉, 정보기술 역량이 충분치 않은 기업에서 RFID를 도입했을 때 이를 활용할 수 있는 조직 내 역량이 충분치 않기 때문에 RFID가 제공하는 다양한 이점을 충분히 활용하지 못할 가능성이 있다.¹³⁾

RFID 도입과 같은 신기술 도입을 위한 경제성분석의 주된 목적은 경제적 타당성 분석을 통해서 면밀한 비용과 효과 분석을 통해 직관적이면서 설득력 있는 숫자를 제시함으로써 사업 기획 초기의 분석에서 투자 결정의 의사결정을 지원할 수 있는 도구로 활용될 수 있다고 본다. [표 2-3]과 같이 경제성 분석은 비용 및 편익 추정치, 순현재가치(Net Present Value), 내부수익률(Internal Return Rate), 회수 기간(Payback Period) 등의 계산과정을 통하여 사업의 경제성, 채산성을 파악하게 되며, 비용 및 편익 추정치의 오차를 보완하기 위하여 내부수익률에 기반을 둔 할인율(Discount Rate), 연차별 기대성취율 등을 추가하여 도출하기도 한다. 즉, ROI 분석을 통하여 투자 타당성을 도출하고 시간에 따른 경제적 파급효과를 산정한다.¹⁴⁾¹⁵⁾

11) 방희석, 강동준, 나정호. (2009). RFID 시스템의 도입요인과 효과에 관한 연구. 『전자무역연구』, 7(1), 65-89.

12) Angeles, R. (2009), Anticipated IT infrastructure and supply chain integration capabilities for RFID and their associated deployment outcomes, *International Journal of Information Management*, 29(3), 219-231.

13) 임세헌, 정남호. (2010). 성공적인 RFID 도입에 있어서 정보기술 역량의 영향 : 기대 효익, 신뢰 그리고 위험의 역할. 『대한경영학회지』, 23(5), 2543-2563.

14) 구훈영. (2010). RFID 도입을 위한 경제성분석 방안에 관한 연구 : 택배 물류 산업을 중심으로. 『한국전자거래학회지』, 15(1), 11-137.

15) 정해준, 한대희, 장태우, 김현수. (2010). 제조업 중심의 RFID 시스템 ROI 분석 프레임워크. 『한국로지스틱스학회』, 18(1), 103-120.

[표 2-3] 경제성분석 지표

지표	계산식	한계	의미
투자수익률 (ROI : Return On Investment)	총 프로젝트 비용 대비 순효과의 비율(총이익/ 총비용)	투자에 따른 순 이익에 필요한 소요 시간을 알 수 없음	투자 타당성 여 부
투자수익률 (ROI : Return On Investment)	화폐의 할인율을 고려 해서 현재 화폐가치로 나타낸 프로젝트 비용 과 효과 사이의 순 차 이	회수 기간에 따 른 리스크를 별 도 고려	정확한 미래 순 이익 규모, 시간 에 따른 화폐의 가치를 반영
투자수익률 (ROI : Return On Investment)	예정 프로젝트의 현금 흐름에 대비하여, 투자 에 따라 발생 되어야 할 수익. 장애율과 직 접 비교할 수 있는 투 자이익을 이자율로 예 측함	투자의 규모와 투자금액 회수 기간을 고려하 지 못함	리스크 감수 여 부를 판단하기 위한 연 단위 기 대수익 규모
투자수익률 (ROI : Return On Investment)	누적효과가 누적 비용 을 초과하여 프로젝트 가 손익분기점에 도달 할 때까지의 시간(누적 비용 대비 누적효과의 교차 그래프 활용)	수익의 가치가 아닌 수익 발생 시점만 보여줌	흑자전환 시점 또는 가시적 성 공 전환 시점

무선 위치 추적 시스템은 모바일, 로봇추적시스템 및 인터넷 위치 기반 서비스(LBS) 애플리케이션과 같은 응용 분야에서 사용할 수 있다. GPS 시스템은 가장 잘 알려진 위치 추적 시스템이지만 실내에서의 사용이 원활하지 않다. 실내 위치 추적 시스템에 대한 효율적인 측면에서 무선 주파수 식별(RFID) 위치 추적 방법으로 사용하고 있다. 기기나 태그의 형태로 휴대 전화나 컴퓨터와 함께 기능해야 한다. RFID 태그는 몇 미터에서 수십 미터까지 읽을 수 있으며 이러한 장점으로 인해 RFID 활용을 위한 많은 연구가 이루어지고 있다. 이 선행 연구에서는 패시브 RFID 태그를 활용하여 와이파이를 사용하는 시스템보다 저렴한 실내 위치 추적 시스템을 개발하였고 실내 위치 추적 시스템의 유효성을 실험을 통해 입증하였다.¹⁶⁾

RFID와 NFC 태그를 이용한 수도시설 자산관리는 자산관리시설 설치 위

치에 따라 자산을 관리하기 위하여 자산관리 식별코드 관리 방법을 제안하였다. 지상 및 지하 시설물에 설치된 RFID 및 NFC 태그를 관리하는 방법은 전용 리더기 또는 태그의 종류에 따라 스마트폰을 사용하고 스마트폰 단독 사용 시에는 블루투스용 RFID 리더기를 이용하도록 하였다. 시설물 자산관리를 위해 근거리 판독이 가능한 시설물에 NFC 태그를 설치하였다. 또한, RFID 태그는 수십 센티미터의 거리에서 판독 가능하고 근접 판독이 불가능한 시설물에서도 자산관리가 가능하기 때문이다.¹⁷⁾

한편 높은 전자기 결합, 열악한 임피던스 정합 문제를 해결하기 위한 새로운 방식을 제시한 연구도 있다. 두 개의 RFID 태그 안테나가 매우 짧은 거리에 위치할 때 방사 특성이 저하된다. 주기적인 EBG 형 구조와 Notch-Making Stub 등 다양한 시도함으로써 전자파 커플링을 낮추고 두 태그 안테나의 입력 임피던스를 정합시키는 최적의 장치를 얻을 수 있다. UHF 대역의 장치는 두껍거나 다층으로 된 다른 격리 강화 장치와 달리 1mm 미만으로 매우 얇습니다. S11 및 S21-곡선의 급강하가 목표 주파수에서 생성되는데, 이것은 RFID에서 더 높은 처리량에 도움이 된다.¹⁸⁾

2) 음식물쓰레기 종량제¹⁹⁾

가) 개요

(1) 추진 배경

16) 조재형. (2019). RFID 태그를 이용한 실내 위치 추적 시스템에 관한 연구. 『디지털융복합연구』, 17(12), 211-217.

17) 강병모, 홍인식. (2017). RFID와 NFC 태그를 이용한 상수도 시설물 자산관리 시스템에 관한 연구. 『Journal of The Korea Knowledge Information Technology Society(JKITS)』, 12(3), 447-456.

18) 박희준, 압둘 레만, 이창형, 진성훈, 강승택. (2019). 『RFID 태그 안테나들의 초근접 시의 격리도 및 전기적 특성을 향상시키는 설계』. 대한전기학회, 68(2), 334-341.

19) 한국환경공단, (2013). 『RFID 음식물쓰레기 관리체계 사업 및 운영관리 매뉴얼(수정본)』, 환경부

환경부 「음식물류폐기물 수수료 종량제 시행지침」에 따라 전국 지자체 144개 시군구에서는 2012년부터 음식물쓰레기 종량제 전면 실시를 하였다. 시행을 위해 [그림 2-2]와 [그림 2-3]과 같이 RFID 기반 방식, 칩(스티커) 방식, 봉투 방식 등 병행 적용하되 농어촌형을 제외하고 RFID 기반 방식을 우선할 것을 권장하였다. RFID 방식 종량제를 추진하는 지자체의 사업관리 편의성과 효율성을 제고하고 전국 환산을 도모함으로써 음식물쓰레기 감량 목표 달성을 하고자 한 것이다.

(가) 구성 체계

■ 종량제 유형

① RFID기반 방식	② 칩(스티커) 방식	③ 봉투 방식
• 개별계량방식 • 차량수거방식 • 휴대형리더기 방식	• 칩 방식 • 스티커 방식 • 납부칩(거점수거) 방식	• 봉투 방식

※ 납부칩(거점수거) 방식은 칩 방식을 준용한 거점수거 방식

■ 종량제 적용방식

RFID	• 장비에 RFID태그를 인식, 배출 후 배출자 정보 및 무게정보가 중앙 시스템에 자동 전송되어 수수료를 부과하는 방식(선·후불제) - 개별·차량·휴대형리더기 방식이 있으며, 중앙시스템은 환경부(공단)에서 통합적으로 운영(수수료정보 등 포털서비스 제공)
칩 (스티커)	• 칩방식: 주민이 개별용기에 칩을 부착하여 배출하고 배출횟수에 비례하여 수수료를 부과하는 방식(선불제) • 스티커방식: 주민이 개별용기에 스티커를 부착하여 배출하고 배출횟수에 비례하여 수수료를 부과하는 방식(선불제)
봉 투	• 주민이 종량제 봉투를 구입하여 봉투를 직접 배출하거나 거점수거 용기에 배출하는 방식(선불제)

[그림 2-2] 종량제 유형 및 적용방식(출처:한국환경공단)

[그림 2-3]은 환경부의 「음식물류폐기물 종량제 수수료 시행지침」에 의해 배출자부담 원칙에 의거 배출량에 비례하여 수수료를 부과하는 종량제 취지를 고려할 때 농어촌형을 제외하고는 RFID 기반의 무게 측정방식을 우선 권장하였다.

우선 순위	도시형			도농형			농어촌형		
	단독주택	공동주택	음식점	단독주택	공동주택	음식점	단독주택	공동주택	음식점
①	RFID 휴대형	RFID 개별	RFID 차량	RFID 휴대형	RFID 차량	RFID 차량	칩 (스티커)	칩 (스티커)	칩 (스티커)
②	칩 (스티커)	RFID 차량	칩 (스티커)	칩 (스티커)	RFID 개별	칩 (스티커)	봉투 방식	RFID 차량	봉투 방식
③	-	칩 (스티커)		-	칩 (스티커)	-	-	-	-

[그림 2-3] 권장 우선순위(출처:한국환경공단)

나) RFID 방식 종량제

RFID 기반 음식물쓰레기 관리체계는 관계부처 합동 “음식물쓰레기 줄이기 종합대책(‘10.2)”²⁰⁾의 핵심과제로써 음식물쓰레기 종량제 시행 및 감량 정책 선진화를 위해 도입이 필요하였다.

배출 세대원의 배출량에 비례하여 수수료를 차등 부과하기 위해서는 정확한 중량측정 및 정보수집·활용·공개가 필수적이며 정보시스템을 구축하여 실시간으로 세대원의 배출정보 수집하고 수수료 정보, 배출 통계관리 등 음식물쓰레기에 대한 전반적인 통합관리 추진이 필요하기 때문이다.

2년간의 시범운영을 통해 RFID 기반 종량제 운영프로세스를 확립하여 RFID 사업추진체계 정립에 따라 효과적 현장 적용과 확산 기반을 마련하고자 하였다.

(1) RFID 기반 종량제 방식별 특성


개별계량, 차량 수거, 휴대용 리더기 방식 등 3가지 방식이 있다.

(가) 개별계량 방식


개별계량 방식은 각 세대원이 배출하는 음식물쓰레기를 직접 무게를 측정

20) 녹색성장위원회, (2010). 『음식물쓰레기 줄이기 종합대책』, 환경부

하여 부과하는 방식이며, 여기에는 선불방식과 후불방식이 있다. [그림 2-4]와 같이 선불방식은 선불카드나 교통카드 등을 기기에 있는 RFID에 직접 태그를 하여 무게를 재고 바로 결제되는 방식이다. 반면, 후불방식은 [그림 2-5]처럼 각 세대원이 배출한 음식물쓰레기를 아파트 관리사무소에서 세대별로 집계하여 월 단위로 관리비 고지서에 부과하는 방식이다.



[그림 2-4] 선불방식



[그림 2-5] 후불방식

(나) 차량 수거 방식

두 번째, 차량 수거 방식은 주로 음식점이 많은 상가에서 사용하는 방식이다. 음식점에 비치된 수거 용기별 배출량 측정 및 수수료 부과가 수월하기 때문에 음식점 등 사업장에 적용하고 있다. 차량 장비와 수거자가 동시에 이동하므로 유지관리가 편리하다.

(다) 휴대용 리더기 방식

휴대용 리더기 방식은 대형상가나 식당가 위주로 수거하는 방식이고, 휴대용 리더기는 RFID 태그를 부착된 음식물 수거통에 음식물을 버리면 수거해가는 방식으로 주로 밀집된 주택가나 소형음식점이 많은 상가 등에서 사용하고 있다. 단점으로는 수거 차량이 진입이 힘들고 수거통 분실의 염려가 있다.

(2) 운영체계

전국 144개 지자체가 현장장비를 장비업체로부터 입찰을 통해 설치·운영을 전담하고, 시스템 구축과 운영은 한국환경공단에 통합 설치된 중앙시스템을 활용하고 데이터베이스 또한 관리를 직접 한다. 공단 중앙시스템을 공동 활용하므로 지자체, 장비업체, 관리사무소는 별도의 시스템 구축이 필요하지 않다. 단, 장비업체는 세대원과 배출량을 지자체와 정산을 위해서 별도의 프로그램과 시스템을 구축하여 데이터를 장비에서 전송할 수 있도록 하여야 한다.

다) 음식물쓰레기 종량제에 관한 선행 연구

RFID 방식의 도입과 활용이 원활하게 이루어지지 않는 이유를 분석하기 위해 연구목적으로 세 가지를 제시하였다. 즉, 회귀분석(Logistic Analysis)을 통해 RFID 개별계량 도입을 좌우하는 요인과 특정 자치구에서 수집한 데이

터를 바탕으로 PSM-DID²¹⁾ 분석을 통해 '세대별 종량제'의 쓰레기 감량 효과가 있음을 시계열 분석을 통해서도 배출 수수료 인상이 음식물쓰레기 감량에 미치는 효과가 미미함을 증명하고자 하였다.²²⁾

국내에서는 기계적 선별 공정으로만 구성된 약 20여 개소의 생활 폐기물 고형연료화 시설에서 폐기물 투입량 대비 25~40%의 고형연료화가 생산되고 있으나, 30~50%에 달하는 선별 잔재물이 배출되는 것으로 있음을 조사하였다. 그리고 투입 물질의 혼합비, 초기 수분 함량, 초기 유기물 함량, 팽화제, 공기공급, 온도, 교반, 식중, 체류시간 등에 영향에 대한 연구가 꾸준히 진행되고 있음을 조사하였고 연구 결과로써 공기공급량 자동 제어시스템에 의해 공기 공급량이 변화됨에 따라 배출가스 온도가 설정된 제어범위 내에서 안정적으로 유지될 수 있음을 확인하였다. 이외에도 제시된 순서대로 연구를 진행하여 7가지의 결론을 도출하였다.²³⁾

음식물쓰레기를 하나의 자원이라는 인식하고 적극적으로 활용하기 위한 연구의 필요성을 가지고 최근 공유가치 창출(Creating Shared Value : CSV) 전략이 대두되고 있고 제품·시장에 대한 재인식과 가치사슬의 재인식, 클러스터의 재인식을 통해 음식물쓰레기 자원화 사업과 공유가치사슬을 연결하여 음식물쓰레기 자원화 사업의 중요성을 인식하고자 E사를 중심으로 음식물쓰레기의 솔루션을 제공하고 환경을 이롭게 할 수 있는 경제적·사회적 가치의 공유가치 창출 개념을 반영한 모델을 제시하였다.²⁴⁾

음식물쓰레기 자원화는 사전구매계획이 미비할수록 쓰레기 발생이 높았으며, 따라서 쓰레기 종량제 실시에도 불구하고 식생활 문화와 생활 수준이 향상됨에 따른 음식의 과소비는 변하지 않으므로, 발생된 음식물쓰레기의 자원화 기술개발과 제도적 지원을 보다 적극적으로 추진해야 한다고 제시하였

21) 각 아파트 단지의 경향 점수 매칭(P propensity Score Matching)을 구하여 세대별 종량제 효과 도출을 위한 이중 차감법(Difference-In-Difference)을 활용하여 분석하는 방법.

22) 이사빈. (2017). 음식물 쓰레기 종량제 RFID 도입요인과 효과성 분석. 서울대학교 대학원 박사학위논문.

23) 박재람. (2021). 생활폐기물 고형연료화 시설에서 배출되는 선별 잔재물의 Bio-drying 공정 적용에 관한 연구. 서울시립대학교 대학원 박사학위논문.

24) 이기성. (2015). 음식물쓰레기 자원화 산업에서의 공유가치창출(CSV) 모델에 관한 연구:E사를 중심으로. 한양대학교 기업경영대학원 석사학위논문.

다.²⁵⁾

라) RFID 기반 음식물쓰레기 종량제 적용 사례

(1) 호퍼승하강장치를 장착한 음식물쓰레기 종량기

해당 장비는 3개의 기술을 적용하였다. 첫 번째는 결제 시 발생하던 중간에 카드를 강제 인출로 인한 미결제 문제를 ‘카드홀딩장치’를 장착하여 해결하고자 하였다. 두 번째는 음식물쓰레기 배출자가 폐물 투입 시 만에 하나 발생할지 모를 미연의 사고를 방지하기 위하여 ‘손 끼임 3중 안전장치를 채택하였다. 마지막으로 음식물쓰레기 배출자가 음식물쓰레기 투입 시 음식물쓰레기가 장비 내부로 튀는 것을 방지하기 위하여 ‘호퍼승하강장치’를 장착하여 호퍼를 음식물쓰레기 수거통에 삽입시켜서 음식물쓰레기로 인한 내부오염 문제를 해결하고 측정의 안정성과 정확성을 증가시킨 장점을 취하면서 동시에 장비의 내구성, 내식성의 장점을 취하였다.

[표 2-4]는 호퍼승하강장치에 대한 특허출원 내용을 간략히 표로 나타낸 것이다. 제품구조와 특허에 적용된 내용을 기술하였다. [표 2-5]는 적용 사례 제품에 대한 특허 적용 기술을 표로 나타냈으며 자세한 사항은 표의 내용을 통해 알 수 있다. 그 중 호퍼승하강장치가 적용된 내부 모습을 [그림 2-6]으로 보여주고 있다. 즉, 왼쪽 사진은 수거통이 닫혀 있을 때 호퍼가 내려온 상태이고, 오른쪽 사진은 만수가 된 음식물쓰레기통을 수거하기 위하여 장비를 열었을 때 호퍼가 올라간 모습을 보여주고 있다.


25) 오정익, 이현정, 석희진. (2010). 음식물쓰레기 자원화를 위한 공동주택 거주자의 음식물쓰레기 배출량 및 자원화 의향에 관한 분석. 『대한환경공학회지』, 32(10), 905-915.

[표 2-4] 음식물쓰레기 종량제 수거기의 호퍼승하강장치

제품구조	명칭
	A - 음식물쓰레기 수거통 10 - 음식물쓰레기 종량제 수거기 11 - 케이스 12 - 도어 13 - 개폐 도어 14 - 호퍼 20 - 제어부 100 - 음식물쓰레기 종량제 수거기의 호퍼 승하강 장치 110 - 작동부 130 - 상해 방지부 150 - 개폐 수단 170 - 호퍼 승하강 수단
적용 특허 : 음식물쓰레기 종량제 수거기의 호퍼 승하강 장치 (특허 등록번호 10-1331915) - 본 규격의 음식물쓰레기 종량제 수거기의 호퍼승하강장치는 음식물쓰레기 수거통(A)을 교체하기 위해 음식물쓰레기 종량제 수거기(10)의 케이스(11) 전면에 개폐 가능하게 구비된 도어(12)를 개방시킴에 따른 도어 개방 감지용 센서로부터 인가된 신호에 의해 제어부(20)의 제어에 의해 작동 가능하게 케이스(11)로 구성됨 - 또한, 제품 작동 시에 음식물쓰레기 배출자의 손등 또는 손가락 등이 투입구 개폐 도어(13)에 끼임을 방지하기 위해 투입구 개폐 도어(13)가 닫히는 것을 저지하여 끼임을 방지하는 상해 방지부(130)로 구성됨 - 그리고, 투입구 개폐 도어용 개폐 수단(150)과 동시에 구동하여 투입구 개폐 도어(13)가 개방된 후, 호퍼(14)를 음식물쓰레기 투입구(도면부호 생략)에 대하여 수직 방향으로 승·하강시킬 수 있도록 구비되는 호퍼 승·하강 수단(170)을 포함함	

[표 2-5] 적용 기술

적용기술	등록번호	기술명(발명, 고안명칭)	발행기관
특허	제10-1236540호	음식물쓰레기 배출량 비례 수거장치	특허청
특허	제10-1331914호	음식물쓰레기 종량제 수거장치용 결제카드 홀딩장치	특허청
특허	제10-1331915호	음식물쓰레기 종량제 수거기의 호퍼승하강장치	특허청
성능인증	제15-1144호	호퍼승하강장치를 장착한 음식물쓰레기 종량기	중소기업청



[그림 2-6] 호퍼승하강장치가 적용된 내부 모습

[그림 2-7]은 음식물쓰레기 종량기를 한국기계전기전자시험연구원(KTC)에 형식승인을 받기 위해 자체적으로 기기의 중량을 초과했을 때를 가정하여 한계시험을 하는 모습입니다. 허용 최대 중량을 설정하였어도 혹시나 배출자들이 배출하는 과정에 전체 중량이 초과하여 계측할 수 없는 난감한 상황이 발생하기 때문에 그에 대한 예방을 위한 차원이다. [그림 2-8]은 무게를 측정하는 기기이다 보니 저울에 관련된 법을 적용받는다. 따라서 그 기준에 의하면 저울은 어느 한쪽으로 무게 쏠림이 없어야 한다는 것이다. 이에 대한 편심을 실험하는 모습이다.

지시 값의 한계 시험




150.45 kg(최대용량 150kg + 9눈금 45g) 범위 표시



최대무게설정



최대무게 150.00 kg 표시







최대무게에 지시 값의 한계 표시

[그림 2-7] 중량 한계시험

분동을 통한 편심 시험

하중받침대를 5구간 또는 9구간으로 나누어서 시험하중에 대하여 연속되는 위치를 표시하여 시험을 한다.



[그림 2-8] 분동을 이용한 편심 시험

(2) 주요 결과

(가) RFID 기반 개별계량 종량제 방식 도입 후 감량 비율

아래의 [그림 2-9], [그림 2-10], [그림 2-11]은 서울시 마포구, 대전시 유성구, 인천시 강화군의 RFID 기반 도입 전과 도입 후를 1년 단위 월별로 배출량을 4개년을 비교 분석한 결과 단지 총량, 단지 평균, 세대 평균을 보면 서울시 마포구는 29~30%, 대전시 유성구는 29%, 인천시 강화군은 30~36%의 감소량을 보이고 그 실효성을 나타내고 있다.

지역	지자체 명	공동주택명	소재지	세대수	RFID종량제 및 수	RFID종량제 적용 년도
서울특별시	마포구	신수현대	마포구 토정로 242번지	210	5	2015년
		신촌금호	마포구 황전동 439번지	239	5	2015년

공동		배출량[kg]															
신수 현대	구 분	1월	2월	3월	4월	5월	6월	7월	8월	9월	10월	11월	12월	단지 총량 [년]	단지 평균 [월]	세대평균 [월]	
	2013년	4,178	4,329	4,185	4,333	4,271	4,398	4,988	5,015	4,525	4,215	4,089	4,176	52,712	4,393	20.9	
	2014년	4,221	4,398	4,349	4,421	4,149	4,443	4,872	5,114	4,332	4,234	4,229	4,222	52,994	4,415	21.0	
	2015년	2,799	2,939	2,878	2,445	3,042	3,277	3,544	3,370	3,309	2,986	3,364	3,189	37,142	3,095	14.7	
	2016년	2,848	2,955	2,813	2,528	2,982	3,547	3,567	3,182	3,221	2,844	3,210	2,893	36,590	3,049	14.5	

공동		세대별 평균 배출량[kg]															
신촌 금호	구 분	1월	2월	3월	4월	5월	6월	7월	8월	9월	10월	11월	12월	단지 평균 [년]	세대평균 [년]	세대 평균 [월]	
	2013년	4,125	4,075	4,048	4,288	3,850	4,147	4,369	4,287	4,147	4,047	4,009	4,158	49,550	4,129	17.3	
	2014년	4,087	4,196	3,902	3,748	3,998	4,225	4,345	4,528	4,221	4,119	4,008	4,039	49,416	4,118	17.2	
	2015년	2,424	2,407	2,575	2,482	2,952	3,203	3,449	3,366	3,030	3,039	3,230	2,996	35,153	2,929	12.3	
	2016년	2,050	2,699	2,733	2,623	3,041	3,244	3,629	3,335	3,099	2,997	2,907	2,782	35,139	2,928	12.3	

[그림 2-9] 서울시 마포구 아파트 배출량

지역	지자체 명	공동주택명	소재지	세대 수	RFID종량제 갯수	RFID적용 년도
대전광역시	유성구	열매마을 5단지	유성구 문구로 31	500	10	2015년

공동		단지별 평균 배출량[kg]															
열매마을 5단지	구 분	1월	2월	3월	4월	5월	6월	7월	8월	9월	10월	11월	12월	단지 총량 [년]	단지 평균 [월]	세대평균 [월]	
	2013년	11,986	12,712	10,925	10,519	13,621	14,216	15,968	14,851	13,914	11,931	13,412	11,023	155,078	12,923	61.5	
	2014년	10,984	11,797	10,287	9,157	12,658	14,264	15,268	15,451	14,706	11,953	13,998	11,521	152,044	12,670	60.3	
	2015년	8,475	8,485	8,152	7,345	8,513	9,532	10,280	10,107	9,658	8,951	10,030	8,946	106,474	9,040	43.0	
	2016년	6,085	6,094	7,738	7,235	8,671	8,985	9,922	9,621	9,317	8,438	9,397	7,962	103,465	8,622	41.1	

[그림 2-10] 대전시 유성구 아파트 배출량

지역	지자체 명	공동주택명	소재지	세대 수	RFID종량기 갯수	RFID적용 년도
인천광역시	강화군	강화 현대	강화대로 191-14	219	4	2015년
		세광 1차	선형면 합리 663	577	11	
		세광 1차	선형면 합리 619	497	8	2015년

단위명 평균 배출량(kg)													
공중		1월	2월	3월	4월	5월	6월	7월	8월	9월	10월	11월	12월
강화 현대	2019년	3,511	4,385	3,672	3,670	3,902	4,429	4,518	4,417	4,321	4,285	4,406	3,753
	2021년	3,559	4,262	3,325	3,789	3,871	4,382	4,796	4,468	4,475	4,199	4,395	3,678
	2019년	2,371	2,372	2,366	2,348	2,787	3,172	3,511	3,399	3,193	2,948	3,764	2,827
	2021년	2,428	2,887	2,613	2,329	2,728	3,055	3,454	3,134	3,173	2,896	3,221	2,439
공중		1월	2월	3월	4월	5월	6월	7월	8월	9월	10월	11월	12월
세광 1차	2019년	12,915	12,681	11,359	8,157	12,658	15,284	16,968	15,951	15,506	12,953	17,564	11,521
	2021년	11,984	12,797	10,287	8,157	12,658	15,284	16,968	15,951	15,506	12,953	17,564	11,521
	2019년	8,438	8,634	7,998	7,627	8,499	10,010	10,980	10,555	10,383	9,467	11,867	8,979
	2021년	8,916	8,913	8,491	8,254	8,578	9,841	11,759	10,774	10,683	10,029	10,716	8,821
공중		1월	2월	3월	4월	5월	6월	7월	8월	9월	10월	11월	12월
세광 2차	2019년	9,984	11,201	8,289	11,108	13,262	14,845	15,926	14,982	15,359	10,529	12,518	13,958
	2021년	10,984	11,797	10,287	8,157	12,658	14,284	15,288	15,451	14,706	11,953	13,988	11,521
	2019년	7,227	7,123	7,237	6,825	7,810	8,818	9,259	9,008	8,408	7,714	10,260	7,603
	2021년	7,672	7,348	7,077	7,000	7,899	8,376	9,708	9,080	8,871	7,891	8,583	7,226

[그림 2-11] 인천시 강화군 아파트 배출량


(나) RFID 기반 개별계량 종량제 방식의 이용 만족도²⁶⁾

음식물류폐기물 종량제가 점진적으로 정착이 되어가는 가심에 한 리서치사인 ‘엠브레인’을 통해 RFID 기반 음식물류폐기물 종량제 만족도 조사(2022.01.18.~2022.01.21.)를 하였다. 조사 대상은 서울에 거주하는 기혼 여성이며, RFID 방식을 사용하여 음식물쓰레기 배출 경험자를 대상으로 하였다. 조사 방법은 구조화된 설문지를 온라인 조사(PC, 모바일)를 하였으며, 표본 규모는 200명이다. [표 2-6]은 응답의 특성을 권역별로 나타낸 것이다.

[표 2-6] 응답자 특성

		사례 수	비율
■ 전체 ■		(200)	100.0
권역별	서북권 ²⁷⁾	(35)	17.5
	서남권 ²⁸⁾	(62)	31.0
	동북권 ²⁹⁾	(61)	31.5
	동남권 ³⁰⁾	(42)	21.0

26) 김용일, 김승천. (2022). 투입구 기능 개선을 통한 음식물쓰레기종량제 활성화 방안에 관한 연구, 『한국인터넷방송통신학회』, 22(3), 75-81.



[그림 2-12] 음식물쓰레기 종량기 만족도

[표 2-7] 만족도


		사례 수	만족한다	보통이다	불만족한다
■ 전체 ■		(200)	82.5	15.5	2.0
권역별	서북권	(35)	80.0	17.1	2.9
	서남권	(62)	90.3	6.5	3.2
	동북권	(61)	80.3	19.7	0.0
	동남권	(42)	76.2	21.4	2.4

[그림 2-12], [표 2-7]은 본 리서치를 통해 RFID 기반 음식물류폐기물 종량기 사용자의 만족도를 권역별로 나타냈으며, 전체의 82.5%가 대략 기기에 대한 만족을 하고 있다는 것을 확인할 수 있다.

-
- 27) 서북권 : 은평구, 서대문구, 마포구, 종로구, 중구, 용산구
 28) 서남권 : 강서구, 양천구, 구로구, 영등포구, 동작구, 관악구, 금천구
 29) 동북권 : 도봉구, 강북구, 성북구, 노원구, 동대문구, 중랑구, 성동구, 광진구
 30) 동남권 : 서초구, 강남구, 송파구, 강동구

제 2 절 이물질 구분을 위한 이미지 학습에 관한 인공지능 연구

최근 들어 이미지 학습에 관한 인공지능 연구가 다양한 분야에서 진행되고 있다. 특히, 딥러닝 연구가 더 활발히 진행되고 있으며 각종 산업 전반에 영향을 끼칠 만큼 활용범위가 광범위하다. 딥러닝은 인공지능의 범주 안에 머신러닝이 있고 머신러닝 안에 일부분으로 딥러닝이 속해 있다고 보면 된다. 인공지능 또는 딥러닝에 대해서는 한번은 들어봤을 것이다. 그만큼 우리 실생활에 성큼 다가왔음을 느낄 수 있다. 따라서 본 연구에서도 이러한 흐름에 맞춰 딥러닝과 관련된 선행 연구에 대한 연구자료들을 정리하고자 한다.



[그림 2-13] 인공지능(AI) 변천사

인공지능은 사람처럼 학습하고 추론할 수 있는 지능을 가진 컴퓨터 시스템을 만드는 기술이다. 인공지능의 역사는 약 80년 남짓 되었지만, 인류는 훨씬 더 오래전부터 지능적인 시스템을 생각했다.³¹⁾

[그림 2-13]의 인공지능 변천사를 보면 1943년 워런 매컬리와 윌터 피츠

31) 박해선. (2020). 『혼자 공부하는 머신러닝+딥러닝』, 서울: 한빛미디어

는 최초로 뇌의 뉴런 개념을 발표했다. 1950년에는 앨런 튜링이 인공지능이 사람과 같은 지능을 가졌는지 테스트할 수 있는 유명한 튜링 테스트를 발표하였다.

인공지능의 개념은 1956년 다트머스 컨퍼런스에서 처음 사용되었으며 이 시기를 인공지능 태동기라 한다. 그 이후 인공지능 황금기가 도래하였고, 1957년 프랑크 로젠블라트가 퍼셉트론(Perceptron)을 발표하였다. 1959년에는 데이비드 허블과 토르스텐 비셀이 고양이를 사용해 시각 피질에 있는 뉴런 기능을 연구했다. 하지만 컴퓨터 성능의 한계로 인해 첫 번째 AI 겨울이 도래하였고, 이 기간에는 인공지능에 대한 연구와 투자가 크게 감소하였다.

그다음 전문가 시스템이 등장했고 두 번째 AI 봄이 불었지만 역시 한계를 드러내고 두 번째 AI 겨울을 맞이한다. 1980년대에서 1990년 초까지 인공지능 경망의 한계를 뛰어넘을 수 있는 얇은 레이어에 대한 연구가 활발하게 진행되었다. 1990년대 무렵부터 레이어를 활용한 깊고 복잡한 구조를 구성함으로써 다양한 딥러닝 모델들이 연구되었고 고성능 GPU, 병렬처리 가능 등 하드웨어의 성능향상으로 딥러닝의 정확성 및 고도화 향상이 향상되었다.³²⁾³³⁾³⁴⁾

머신러닝은 규칙을 일일이 프로그래밍하지 않아도 자동으로 데이터에서 규칙을 학습하는 알고리즘을 연구하는 분야이다. 인공지능의 하위 분야 중에서 지능을 구현하기 위한 소프트웨어를 담당하는 핵심 분야이다. 하지만, 최근 머신러닝의 발전은 통계나 수학 이론보다 경험을 바탕으로 발전하는 경우도 많다. 컴퓨터 과학 분야가 이런 발전을 주도하고 있다. 컴퓨터 과학 분야의 대표적인 머신러닝 라이브러리는 사이킷런(Scikit-Learn)이다.

사이킷런이 있기 전까지 머신러닝 기술은 대부분 폐쇄적인 코드와 라이브

32) 박해선. (2020). 『혼자 공부하는 머신러닝+딥러닝』, 서울: 한빛미디어

33) 고광은, 심귀보. (2017). 딥러닝을 이용한 객체 인식 및 검출 기술 동향. 『제어로봇시스템학회지』, 23(3), 18.

34) 김진성, 송재열, 김하얀, 이진국. (2017). 딥러닝 기반 이미지 자동인식 기술을 활용한 사무집기 자동인식과 정보관리 시스템과의 연동방안. 『한국퍼실리티매니지먼트학회논문집』, 12(2), 73-80.

러리로 통용되었지만, 사이킷런과 같은 오픈소스 라이브러리의 발전 덕분에 머신러닝 분야는 크게 성장을 하였다.

딥러닝은 많은 머신러닝 알고리즘 중에 인공신경망(Artificial Neural Network)을 기반으로 한 방법들을 통칭하여 부른다. 종종 사람들은 인공신경망과 딥러닝을 크게 구분하지 않고 사용한다.


1998년 얀 르쿤(Yann Lecun)이 신경망 모델을 만들어 손글씨 숫자를 인식하는데 성공했다. 이 신경망의 이름을 LeNet-5라고 하며 최초의 합성곱 신경망이다.³⁵⁾

인공지능 이미지 인식은 기계가 마치 사람처럼 사진이나 동영상으로부터 사물을 인식하거나 장면을 이해하는 것으로 정의할 수 있다. 이러한 이미지 인식은 컴퓨터 비전 기술 중 하나에 해당한다. 대표적으로 [그림 2-14]와 같이 세 가지 태스크가 존재한다. 첫 번째가 이미지 내 특정 사물을 분류(Classification)하는 태스크이고, 두 번째는 여러 사물을 동시에 검출(Detection)하는 태스크, 마지막으로 사물들을 픽셀 단위로 식별하여 분할(Segmentation)하는 태스크이다.³⁶⁾ 이미지 인식 기술은 이미지넷을 통한 대량의 이미지 인식용 데이터 배포와 딥러닝 기술의 발전으로 최근 몇 년 전부터 엄청난 성능의 향상을 보여주고 있다. 엄청난 양의 이미지넷 데이터는 이미지를 인식하는 비전 분야의 머신러닝 기술 발전에 커다란 영향을 끼쳤고, 특히 기존의 신경망 기술을 발전시킨 딥러닝 기술은 급격한 성능향상을 보여주고 있고 비전과 자연어처리 등 인공지능이 필요한 거의 모든 부분에서 접목되어 현재도 활발히 연구가 되고 있다.³⁷⁾ 본 연구에서는 음식물쓰레기 이물질을 구분하고자 함으로 분류(Classification)에 관련된 학습을 정리하고자 한다.

35) 박해선. (2020). 『혼자 공부하는 머신러닝+딥러닝』, 서울: 한빛미디어

36) 이주열. (2020). 인공지능 이미지 인식 기술 동향. 『한국정보통신기술협회』, TTA Journal, 187, 44-51.

37) 윤여찬, 상종희, 박수영. (2018). 이미지 기반의 식물 인식 기술 동향. 『한국전자통신연구원』, 전자통신동향분석, 33(4), 54-60.



[그림 2-14] 이미지 인식을 대표하는 태스크
(출처: <http://cs231n.stanford.edu/>)

1) 이미지 기반 알고리즘 모델


가) CNN(합성곱 신경망 : Convolution Neural Network)

CNN은 데이터의 특징을 추출하여 특징들의 패턴을 파악하는 구조이다. 이 알고리즘은 컨볼루션(Convolution)³⁸⁾ 과정과 풀링(Pooling)³⁹⁾ 과정을 통해 진행된다.

[그림 2-15]을 보면 입력 데이터에서 특성을 추출하는 역할 수행하는 합성곱층과 풀링층을 거치면서 입력 이미지의 주요 특성 벡터를 추출하고 완전연결층을 거치면서 1차원 벡터로 변환한다. 마지막으로 출력층에서 활성화 함수인 소프트맥스 함수를 사용하여 최종 결과가 출력되게 된다.

38) 입력 데이터에서 특성을 추출하는 역할을 수행

39) Convolution 과정을 거친 레이어의 사이즈를 줄여주는 과정



[그림 2-15] CNN 구조

CNN은 다른 모델들과 비교할 때 기준이 되는 모델이며 이미지 공간정보를 유지한 채 학습이 가능하다. 영상, 사진 같은 이미지 데이터에서 객체를 탐색하거나 위치를 찾아내는데 유용한 신경망이다.⁴⁰⁾⁴¹⁾⁴²⁾

나) VGG

VGG는 합성곱층과 풀링층으로 구성되는 기본적인 CNN이다. 다만, 비중에 있는 층(합성곱층, 완전연결층)을 모두 16층(혹은 19층)으로 심화한 것이 특징이다. 층의 깊이 따라 VGG 16, VGG 19로 구분된다. 이전 모델 AlexNet 보다 학습 깊이가 2배 이상 효과적으로 개선되어 정확도가 오차율 절반 가까이 줄었다.

VGG-16의 구조는 [그림 2-16]와 같다. VGG-16에는 파라미터가 총 1억 3,300만 개 있다. 여기에서 상기할 점은 모든 합성곱 커널의 크기는 3x3, 최대 풀링 커널의 크기는 2x2이며, 스트라이드는 2이다. [그림 2-16]에서 알 수 있듯이 conv1 레이어는 224x224 크기의 이미지를 입력으로 받는다. 이어서 입력 이미지는 3x3의 수용 필드를 갖는 일련의 conv 레이어를 통해 전파


40) J. Kim, A. -D. Nguyen and S. Lee. (2019). Deep CNN-Based Blind Image Quality Predictor, in IEEE Transactions on Neural Networks and Learning Systems, 30(1), 11-24.

41) C. S. Won. (2020). Multi-Scale CNN for Fine-Grained Image Recognition, in IEEE Access, 8, 116663-116674.

42) Roy, S. K., Krishna, G., Dubey, S. R., & Chaudhuri, B. B. (2019). HybridSN: Exploring 3-D-2-D CNN feature hierarchy for hyperspectral image classification. IEEE Geoscience and Remote Sensing Letters, 17(2), 277-281.

된다. 컨볼루션 보폭은 1픽셀로 간주되고 2인 5개의 최대 풀링 레이어가 공간 풀링을 위해 사용된다.

1000이라는 크기는 ILSVRC(ImageNet Large-Scale Visual Recognition Challenge)에 존재하는 범주의 수를 나타낸다. 소프트맥스 레이어는 마지막 레이어이다. 렐루 비선형 레이어는 모든 숨겨진 레이어를 갖추고 있다. VGG-16 아키텍처를 사용하는 가장 큰 장점은 다른 데이터 세트에 잘 일반화된다는 것이다.⁴³⁾⁴⁴⁾



[그림 2-16] VGG-16 기본 아키텍처


VGG에서 주목할 점은 3X3의 작은 필터를 사용한 합성곱층을 연속적으로 거친다. [그림 2-16]에서 보듯 합성곱층을 2~4회 연속적으로 풀링층을 두어 크기를 절반으로 줄이는 처리를 반복한다. 마지막으로 완전연결층을 통과시켜 결과를 출력한다.

43) K. Simonyan and A. Zisserman. (2014). Very deep convolutional networks for large-scale image recognition, arXiv Prepr.arXiv1409.1556, 1-14.

44) Kaur, T., & Gandhi, T. K. (2019). Automated brain image classification based on VGG-16 and transfer learning. In 2019 International Conference on Information Technology (ICIT), 94-98.

다) ResNet

ResNet은 마이크로소프트에서 개발한 알고리즘으로 “Deep Residual Learning for Image Recognition”이라는 논문에 발표되었다. ResNet 핵심은 깊어진 신경망을 효과적인 학습을 하기 위한 방법으로 레지듀얼 개념을 고안한 것이다. 개발팀은 VGG 팀이 진행한 연구(19층)에서 더 나아가 100층 이상까지 모델을 만들어 성능 실험을 진행하였다. 그 결과 층이 깊어질수록 학습에서 더 높은 에러율을 보였다. 개발팀은 이런 결과를 얻으면서 깊이에 따라 학습 효율을 증가시킬 수 있는 방법을 고민하였다. 이들이 고안해낸 대표적인 방법은 레지듀얼 학습(Residual Learning)이다.⁴⁵⁾⁴⁶⁾⁴⁷⁾



[그림 2-17] ResNet 구조

기존의 신경망은 i 번째 층과 $(i+1)$ 번째 층의 연결로 구성되어 있지만, ResNet은 i 번째 층과 $(i+r)$ 층의 연결로 구성되어 있다. [그림 2-16]을 보면 알 수 있듯이, Residual Learning에서는 정보 전달이 한 층을 건너뛰게 된다.

45) 서지영. (2021). 『딥러닝 텐서플로 교과서』, 서울: 길벗

46) B. Li and Y. He. (2018). An Improved ResNet Based on the Adjustable Shortcut Connections, in IEEE Access, 6, pp. 18967-18974.

47) Song, S., Lam, J.C., Han, Y., & Li, V.O. (2020). ResNet-LSTM for Real-Time PM2.5 and PM₁₀ Estimation Using Sequential Smartphone Images. IEEE Access, 8, 220069-220082.

즉, 지름길을 사용한다고 이해할 수 있는데, 이러한 연결 방식을 Shortcut Connection이라고 합니다. 이 방식을 사용하면 떨어진 두 개의 층을 연결함으로써 오차 역전파시 기울기가 쉽게 전파된다는 장점이 있다.

기존 방식은 이웃한 층과의 연결만 있고, 입력값(x)을 받아 $H(x)$ 를 출력한다. CNN은 학습 과정에서 가중치를 변경해가며 최적의 값을 찾아낸다. 이를 통해 최적의 $H(x)$ 를 찾는 것을 목표로 한다. 레지듀얼 학습은 여기서 조금 다른 방식을 사용한다. [그림 2-17] 중 오른쪽과 같이 목표치를 $H(x)$ 가 아닌 $F(x)+x$ 로 세운다. 그 방식은 아래와 같다.

첫째, 출력 결과를 $H(x)$ 가 아닌, $H(x)$ 와 입력값(x)의 차이로 설정한다. 즉, $H(x) - x$ 를 목표로 설정한다. 이를 $F(x)$ 라고 가정한다.

둘째, 따라서 $H(x) = F(x) + x$ 이다. 즉, Residual Learning 방식에서 얻고자 하는 출력값은 $\{ F(x) + x \}$ 가 된다.

이 방식은 지름길을 통해 i 층의 입력값 x 를 $(i+r)$ 층의 출력값 $F(x)$ 에 더하는 연산만 추가되기 때문에 파라미터가 따로 필요 없어진다. ResNet에서는 이 과정을 Identity Mapping이라고 정의했다.

(1) ResNet의 구조

ResNet은 애초부터 VGG의 구조에 대한 의문에서부터 시작되었기 때문에 VGG의 구조와 유사하다. 예를 들어, VGG-19 구조에 합성곱 층을 추가하여 깊이를 늘리고, shortcut connection을 추가하면 ResNet의 가장 간단한 구조가 된다. 이 구조는 점점 발전하여 19층에서 256층까지 늘어났다.

VGG와 마찬가지로 더 깊은 레이어에서 성능이 오히려 떨어지는 문제를 해결하기 위해서 구현한 모델이다. 즉, 기울기 소멸 문제(Vanishing Gradient Problem)를 해결하고자 고안되었다. 잔차를 사용하는 모델로 우리말로 잔차 신경망이라고 한다.

(가) 기울기 소멸(Gradient Vanishing)

CNN에서 파라미터를 업데이트할 때 기울기 값이 너무 작거나 크면 학습이 제대로 이루어지지 않을 수도 있고 학습 속도가 매우 느려질 수 있다. 이런 문제를 해결하기 위해 여러 개선 방법들이 고안되었지만, 망의 깊이가 일정 수준 이상 깊어지면 여전히 기울기 값에 대한 문제가 발생한다.

(나) 오버피팅(Overfitting)

망이 깊어질수록 파라미터의 수가 늘어나게 되어 오버피팅의 문제가 생긴다.

라) EfficientNet

EfficientNet은 2019년에 등장했다. 네트워크 차원을 확장하는 기존의 모델들과 다르게 고정된 확장 계수 셋을 사용하여 각 차원을 균일하게 확장한다. CNN의 정확도를 높이기 위해 모델 크기를 키웠고, 그 방법으로는 [그림 2-18]처럼 깊이를 깊게 하고 채널의 넓이를 넓히고 미세한 정보가 담기도록 하고 해상도를 올리는 방법이다. 즉, 한정된 자원을 가지고 있는 상황에서 깊이, 넓이, 해상도를 어떻게 적절히 조절하느냐에 따라서 모델의 크기와 연산량을 줄이면서도 성능은 높일 수 있는지에 대한 방법이다.

ImageNet에서 기존 [그림 2-19]를 보는 바와 같이 ConvNet보다 8.4배 작으면서 6.1배 빠르고 더 높은 정확도를 보였다.

ConvNet의 크기를 키우는 것은 널리 쓰이는 방법이다. 그러나 제대로 된 이해를 바탕으로 이루어지지 않는 것 같다. 그래서 제안한 방법이 compound scaling method이다.





Figure 2. **Model Scaling.** (a) is a baseline network example; (b)-(d) are conventional scaling that only increases one dimension of network width, depth, or resolution. (e) is our proposed compound scaling method that uniformly scales all three dimensions with a fixed ratio.

[그림 2-18] EfficientNet Model Scaling



[그림 2-19] ImageNet 모델 간 정확도 순위

마) 앙상블(Ensemble)

앙상블은 여러 개의 약한 학습자(Weak Learner)들이 모여 투표를 통해 더욱더 강력한 Strong Learner를 구성한다. 많은 모델이 있기 때문에 한 모델에서 예측을 벗어나게 하더라도 어느 정도 보정이 된다. 즉, 보다 일반화된 모델이 완성되는 것이다. 앙상블의 목표는 여러 분류기를 하나의 메타 분류기로 연결하여 개별 분류기보다 더 좋은 일반화 성능을 달성하는 것이다. 예를 들어 8명의 전문가로부터 예측을 얻을 수 있다고 하면 앙상블 방법은 전문가 8명의 예측을 묶어 전문가 1명보다 더 정확하고 안정된 예측을 만들 수 있다. 가장 인기가 있는 앙상블 방법은 과반수 투표 방식이다. 과반수 투표는 분류기의 과반수가 예측한 클래스 레이블을 선택하는 단순한 방법이다. 즉, 50% 이상 투표를 받은 클래스 레이블을 선택한다. 이를 다수결 투표라 하며, 이때는 가장 많은 투표를 받은 클래스 레이블을 선택하면 된다.⁴⁸⁾⁴⁹⁾

여러 모델을 사용하여 결과를 도출하는 모델로 결과를 도출하는 대표적인 방식으로는 Voting, Bagging, Boosting이 있다.

(1) 보팅(Voting)

최종 모델의 예측값을 결정짓는 보팅은 크게 하드 보팅과 소프트 보팅으로 나뉜다.

(가) 하드 보팅(Hard Voting)

하드 보팅은 각 약한 학습자들의 예측 결과값을 바탕으로 다수결 투표하는 방식이다. 빨간 공인지 파란 공인지 예측하는 이진 분류 문제에서 동일한

48) M. A. Dede, E. Aptoula and Y. Genc. (2019). Deep Network Ensembles for Aerial Scene Classification, in IEEE Geoscience and Remote Sensing Letters, 16(5), 732–735.

49) Lim, P., Goh, C. K., & Tan, K. C. (2016). Evolutionary cluster-based synthetic oversampling ensemble (eco-ensemble) for imbalance learning. IEEE transactions on cybernetics, 47(9), 2850–2861.

데이터에 대해 각 분류기는 클래스별 예측 확률을 제시한다. 이 확률값에 따라 최종 예측값이 계산되는데, 하드 보팅은 이 예측값의 다수결 투표로 최종 예측값을 결정한다. 따라서 다섯 개 분류기 중 빨간 공으로 예측한 분류기가 3개이니, 이 샘플에 대한 최종 예측값은 빨간 공이 된다.

(나) 소프트 보팅 (Soft voting)

반면 소프트 보팅은 약한 학습자들의 예측 확률값의 평균 또는 가중치 합을 사용한다. 약한 학습자 개별의 예측값은 중요하지 않다. 예측 확률값을 단순 평균 내어 확률이 더 높은 클래스를 최종 예측값으로 결정한다.

동일한 예시에서 빨간 공으로 예측한 세 개 분류기 (1, 2, 4)의 클래스별 예측 확률은 크게 차이 나지 않는다. 반면, 파란 공으로 예측한 두 개 분류기 (3, 5)는 높은 확률로 파란 공으로 예측했다. 그 결과, 최종 예측값은 파란 공이 된다. 만약, 어떠한 이유(단일 모델에 사용되는 Feature Engineering 방법 등)로 약한 학습자들에 대한 신뢰도가 다를 경우, 가중치를 부여하여 확률값의 평균이 아닌 가중치 합을 사용할 수도 있다.

동일한 예시에서 각 분류기의 예측 확률값에 상이 한 가중치를 부여하였기에, 최종 예측값이 빨간 공이 되는 것을 확인할 수 있다.

(2) 배깅(Bagging)

배깅은 Bootstrap Aggregating의 약자이다. 이름에서 알 수 있듯이 부트스트랩(Bootstrap)을 이용한다. 부트스트랩이란 주어진 데이터셋에서 랜덤 샘플링(Random sampling)하여 새로운 데이터셋을 만들어내는 것을 의미한다. 부트스트랩을 통해 만들어진 여러 데이터셋을 바탕으로 약한 학습자를 훈련시킨 뒤, 결과를 투표한다.

(3) 부스팅(Boosting)

부스팅은 반복적으로 모델을 업데이트해 나간다. 이때 이전 반복(Iteration)의 결과에 따라 데이터셋 샘플에 대한 가중치를 부여한다. 결과적으로, 반복할 때마다 각 샘플의 중요도에 따라 다른 분류기가 만들어지게 됩니다. 최종적으로는 모든 반복에서 생성된 모델의 결과를 투표한다.

(4) 스택킹(Stacking)

스택킹은 약한 학습자들의 예측 결과를 바탕으로 메타 학습자(Meta Learner)로 학습시켜 최종 예측값을 결정하는 것을 말한다. Meta Learner 또한 학습이 필요하며, 이때 사용되는 데이터는 Training Data에 대한 각 약한 학습자들의 예측 확률값의 모음이다. 과적합 방지를 위해 주로 k-Fold Cross Validation을 이용한다.⁵⁰⁾⁵¹⁾⁵²⁾⁵³⁾

2) 인공지능에 관한 선행 연구

가) CNN(합성곱 신경망 : Convolution Neural Network)

자동차 부품인 볼트에 코팅 처리를 하는데 있어 여러 요인으로 불량 발생되어 비전 또는 수동으로 불량을 선별 작업을 한다. 이러한 문제를 보완하고자 합성곱 신경망(CNN)으로 코팅 불량을 학습하고 향상된 볼트 불량 판별을 위해 시각화 기법을 사용한다. 시각화 기법을 적용해 풀림 방지 코팅 이외에 조명, 볼트 지그 등 주변 다른 요인의 영향 또는 포함함을 확인했고 이를

50) 서지영. (2021). 『딥러닝 텐서플로 교과서』, 서울: 길벗

51) 세바스찬 라스카, 바히드 미자리리, 박해선. (2021). 『머신러닝 교과서 with 파이썬, 사이킷런, 텐서플로(개정 3판)』, 서울: 길벗

52) <https://tyami.github.io/machine%20learning/ensemble-1-basics/>

53) X. Liu, Z. Liu, G. Wang, Z. Cai and H. Zhang. (2018). Ensemble Transfer Learning Algorithm, in IEEE Access, 6, 2389-2396

개선하기 위해 이미지 전처리를 사용해 볼트 영역만을 표현하여 CNN 시각화 기법을 통해 기존에 할 수 없었던 불량 판단 기준과 위치를 정량적으로 판단할 수 있게 하였다.⁵⁴⁾

산업 현장에서 사용되는 기계 설비 고장의 상당 부분을 베어링의 고장이 차지하고 있는 상황에서 베어링 고장으로 인해 발생하는 경제적/시간적 손실을 최소화하기 위해서 CNN 기반 딥러닝을 적용하여 베어링의 상태를 정확하게 판단할 수 있는 베어링 고장 진단 기법을 사용과 복잡도를 분석하였다. 결과는 기존 방식보다 100%에 가까운 진단 정확도를 보였다.⁵⁵⁾

한국에서 발생한 교통사고가 많은데 그 중에서도 차선과 관련된 사고가 많다. 이에 차선 이탈 방지 시스템을 개발하여 졸음운전, 음주운전, 부주의 운전일 때 사고 예방을 위한 시스템을 개발하였다. 여기에는 모자 모양의 커널을 사용하는 이미지에서 CNN을 사용하여 차선을 감지하는 시스템으로 노이즈 라인과 같은 다른 공식 라인 감지 알고리즘보다 성능이 우수한 것으로 나타났다.⁵⁶⁾

외래어종 퇴치를 위한 시스템 개발에 앞서 물 안의 어류 이미지를 CNN으로 학습하여 어종을 분류하는 알고리즘을 제안하였다. CNN 학습을 위한 각 어종에 대해 직접 촬영한 영상을 사용하였으며, 어종 분류성능을 높이기 위해 영상 이미지의 개수를 늘린 데이터셋 1과 최대한 자연환경과 가까운 영상 이미지를 구현한 데이터셋 2를 구성하여 학습 및 테스트 데이터로 사용하여 데이터셋 1에 대해 99.97%, 데이터셋 2에 대해서 99.5% 이상의 정확도가 나왔다.⁵⁷⁾

54) 노은솔, 이사랑, 김민수, 홍석무. (2020). CNN 및 모델 시각화 기법을 사용한 코팅 볼트 불량 판별, 대한기계학회, 44(11), 835-842.

55) 박재현, 김철홍. (2022). CNN 기반 딥러닝을 이용한 베어링 고장 진단의 정확도 및 계산 복잡도 분석, 한국차세대컴퓨팅학회, 18(1), 7-18.

56) 김지훈, 이대식, 이민호. (2016). CNN을 사용한 차선검출 시스템, 대한임베디드공학학회논문지, 11(3), 163-171.

57) 박진현, 황광복, 박희문, 최영규. (2019). 어종 분류를 위한 CNN의 적용, 한국정보통신학회논문지, 23(1), 39-46.

나) VGG

얼굴 인식에 대한 관심이 높아지고 있다. 응용범위가 넓기 때문에 생체 데이터 특성의 큰 변화에 직면할 때 여전히 어렵다. 렌즈넷 라이트 필드 카메라가 최근에 두각을 나타내고 있다. 풍부한 시공간 정보를 캡처하여 고급 생체 인식 시스템에 대한 새로운 가능성을 제공한다. 이 선행 연구는 이중 심층 학습 프레임워크를 제안하였다. 이 프레임워크는 두 개의 심층 네트워크를 순차적으로 사용하여 인트라 뷰/공간정보와 인터뷰/각 정보를 모두 모델링할 수 있다.

이것은 얼굴 인식이나 다른 시각적 인식 작업을 위해 문헌에서 제안된 적이 없는 새로운 인식 프레임워크이다. 제안된 이중 심층 학습 프레임워크 입력이 VGG-16 컨볼루션 신경망(CNN)을 사용하여 계산된 VGG-Face 설명인 장단기 메모리(LSTM) 순환 네트워크를 포함한다. VGG-Face 공간 설명은 서로 다른 관찰 각도에 해당하는 라이트 필드 이미지에서 렌더링하여 선택된 2D 서브 어퍼처(SA) 이미지 세트에서 추출된다. 그런 다음 VGG-Face 공간 설명의 시퀀스는 LSTM 네트워크에 의해 분석된다. 결과는 제안된 프레임워크가 최신기술과 비교할 때 우수한 얼굴 인식 성능을 달성한다는 것을 보여준다.⁵⁸⁾⁵⁹⁾

지난 수십 년 동안 고전적인 것부터 컨볼루션 심층 신경망(CNN)과 같은 딥러닝 접근 방식에 이르기까지 병리학적 뇌 이미지 분류 영역에서 활발히 연구가 진행되었다. 고전적인 기계학습 방법은 분류를 수행하기 위해 손으로 만든 기능이 필요하다. 반면에 CNN은 원시 이미지에서 직접 이미지 특징을 추출하여 분류를 수행한다. CNN에서 추출한 기능이 훈련 데이터 세트 크기에서 크게 의존하고 크기가 작으면 CNN이 과대 적합되는 경향이 있다. 그래서 전이 학습에 적용된 딥 CNN(DCNN)이 진화했다. 이 선행 연구의 주요

58) A. Sepas-Moghaddam, & F. Pereira. (2019). A Double-Deep Spatio-Angular Learning Framework for Light Field-Based Face Recognition, in IEEE Transactions on Circuits and Systems for Video Technology, 30(12), 4496-4512.

59) Haque, M. F., Lim, H. Y., & Kang, D. S. (2019). Object detection based on VGG with ResNet network. In 2019 International Conference on Electronics, Information, and Communication (ICEIC), 1-3.

목표는 병리학적 뇌 이미지 분류를 위한 전이 학습을 통해 사전 훈련된 DCNN VGG-16 모델의 기능을 탐색하는 것이다. VGG-16 모델의 마지막 몇 개의 레이어만 현재 애플리케이션에서 새로운 이미지 범주를 수용하기 위해 교체되었다. 전이 학습이 포함된 사전 훈련된 모델은 다음으로 구성된 Harvard Medical School 저장소에서 가져온 데이터 세트에서 검증되었다.

본 선행 연구에 제안된 모델은 민감도, 특이도 및 정확도를 사용하여 테스트 세트에 대한 유효성 검사를 통해 전이 학습을 적용한 사전 훈련된 VGG-16 모델이 기존의 다른 상태의 VGG-16 모델과 비교하여 최고의 성능을 나타낼 수 있다.⁶⁰⁾

멜라닌 세포의 악성 변화로 발병하는 흑색종은 림프절, 주변 피부, 뼈, 중추신경계 등 전이가 쉽지만 단순 점 등으로 오인하는 경우가 있어 치료하기가 가장 어려운 피부암이다. 따라서 흑색종 병변 부위 크기로 식별을 위한 모델로 U-Net 기반 Transfer Learning을 이용하여 식별하고자 하였다. U-Net을 VGG-16을 적용한 Transfer Learning 기법을 활용하였고 기존 모델보다 흑색종 크기 판별에 우수한 성능을 나타냈다.⁶¹⁾

딥러닝 기술과 결합된 구강 내 카메라 이미지는 충식을 진단하는데 유용한 도구가 된다. 구강 내 카메라 이미지에서 치과용 충식을 감지하는 데 VGG-16 컨볼루션 신경망(CNN) 모델의 정확도를 평가하였으며, 그 결과 무작위 샘플링을 통해 4개 데이터셋에 대한 VGG-16 딥러닝 모델의 정확도는 0.77%에서 0.81% 사이였으며, 0.81%가 가장 높았다. 이를 통해 VGG-16 모델은 구강 내 카메라 이미지에서 치과용 충식을 감지하는데 우수한 성능을 보였다.⁶²⁾

60) Taranjit Kaur, Tapan Kumar Gandhi. (2019). Automated brain image classification based on VGG-16 and transfer learning, 2019 International Conference on Information Technology (ICIT), 94-98.

61) 박혜빈. (2022). 전이 학습을 이용한 흑색종 병변 부위 크기 식별 연구, 경북대학교 대학원 석사학위논문.

62) 변민지, 전은주, 김지수, 황재준, 정승화. (2021). VGG-16 딥러닝 알고리즘을 활용한 우식 치아와 건전 치아 분류, Journal of Korean Academy of Oral Health, 45(4), 227-232.

다) ResNet

스마트폰 카메라 모듈의 머신비전 검사장비는 전통적인 룰 기반 알고리즘인 주변 밝기 차이와 정상 제품과의 비교를 통해 불량을 판정하고 있어 과검(Overkill)을 발생시킨다. 룰 판정의 정확도는 불필요한 직접적 또는 간접적 제조 비용이 발생하고 있어 VGG-19 모델의 깊은 망을 만들고 잔차(Residual)를 통해 연산량을 감소시킨 ResNet 모델을 선정하여 학습 진행하였으며 사전 학습 모델 가중치와 영상 데이터 세트를 모두 학습하는 방법의 학습 시간으로 99.8%의 높은 정확도를 보였다.⁶³⁾

일반쓰레기와 음식물쓰레기를 포함하는 쓰레기 분류 데이터셋으로 CNN을 이용하여 쓰레기를 분류하는 방법을 제안하고 얇은 계층을 가진 딥러닝 모델인 AlexNet과 이를 개선한 VGG-16을 비교하였다. 이와 더불어 깊은 계층을 가진 딥러닝 모델인 ResNet을 층의 깊이에 따라 비교하였다.⁶⁴⁾

라) EfficientNet

철강 가공 산업에서 제품의 품질을 높이고 그 생산량을 늘리는 것이 중요해지고 있다. 생산 속도가 빨라짐에 따라 제품의 결함을 빠르고 정확하게 식별하여 경쟁력을 확보하는 것이 아주 중요하다. 따라서 생산된 강철에 존재할 수 있는 다양한 결함을 감지하고 식별하기 위한 EfficientNet을 사용하였다. EfficientNet는 기본적으로 SSD(The Single Shot Detector) 구조를 취하고 있어서 이 기법을 사용하였다. 결과는 실제 제조 스크립트에서 강철 결함 감지에 대한 성능향상을 가져옴으로써 새로운 가능성을 보였다.⁶⁵⁾

폐렴 환자의 흉부 X-ray 이미지 데이터를 분류하는 최적의 모델을 선정

63) 김병근. (2022). ResNet을 이용한 카메라 모듈 얼룩불량 검출, 충북대학교 대학원 석사학위논문.

64) 김범석. (2018). 컨볼루션 신경망을 이용한 쓰레기 분류 연구, 울산대학교 대학원 석사학위논문.

65) 라우포조니벡. (2021). Steel Surface Defect Detecting Using EfficientNet Neural NetWork, 전남대학교 일반대학원 석사학위논문.

하고 이 모델을 사용하여 COVID-19 확진 여부를 판별한다. 모델 생성에 VGGNet, ResNet, XceptionNet, MobileNet, EfficientNet 모델을 고려하였고, 이중 정확도가 가장 높은 EfficientNet 모델을 선정하여 적용하였다. 페럼 테스트 데이터와 COVID-19 데이터셋에서 높은 정확도를 보였고 낮은 손실 값을 보였다. 더 많은 데이터를 구한다면 EfficientNet 모델을 통해 더 높은 분류성능을 가질 것으로 판단한다.⁶⁶⁾

악성코드 파일을 이미지화하고 EfficientNet 모델을 이용하여 악성코드 이미지 유형 분류를 할 수 있는 방안을 제안하고자 한다. 기존의 다양한 악성코드 파일을 분류하기 위해 분류 알고리즘의 성능을 높이는 방법에 의존하거나 동적 분석으로 가상환경에서 악성코드를 실행하여 행위 패턴을 분석하는 방법 등이다. 기계학습 모델을 접목하여 악성코드 파일을 Grayscale 이미지로 표현하여 시각화된 이미지 데이터 활용으로 학습 및 분석을 통해 특정 패턴을 찾는 것을 EfficientNet 모델을 통한 악성코드 분류방안을 검증하려고 한다.⁶⁷⁾

66) 김동건. (2022). 합성곱 신경망을 이용한 COVID-19 예측=Prediction of COVID-19 Using Convolutional Neural Network, 계명대학교 대학원 석사학위논문.

67) 김은수. (2021). EfficientNet을 이용한 악성코드 이미지 유형 분류 = Classification of malware image types using EfficientNet, 아주대학교 대학원 석사학위논문.

제 3 장 음식물쓰레기 이물질 구분을 위한 모델 설계

제 1 절 이미지 기반 딥러닝 모델 개요

1) 실험데이터 개요

음식물쓰레기 이물질을 위한 알고리즘을 설계는 음식물쓰레기 이물질은 음식물의 부패로 인한 고농축의 액체와 이물질이 혼탁하여 데이터를 확보하는데 많은 애로사항과 한계가 있다. 실제 상황에서 이진 분류데이터보다 다중 클래스 분류데이터가 더 많다. 음식물쓰레기 이물질은 사진을 찍거나 검출 결과값을 수집하는 등 데이터를 추가하거나 데이터에 라벨링을 하는 것은 시간과 비용이 많이 소모된다. 사용할 수 있는 데이터 대부분은 라벨링되지 않는 데이터인 경우가 더 많고 실제 데이터는 이물질을 분류하기 위해 데이터 수집하는 경우 정작 필요한 데이터는 음식물쓰레기와 섞인 이물질 데이터인데 대부분이 정상적인 이물질인 비닐, 수저, 그릇 등이 주류이기 때문이다.

본 연구는 집하 공정상에서 분류된 생활폐기물을 근거로 다양한 딥러닝 알고리즘 모델을 활용하여 이물질 이미지 분류하는 것을 연구 목표로 하고 있으며, 필요 데이터는 집하 공정상의 음식물쓰레기 속 이물질 이미지 데이터이다. 하지만 실제 집하장에서 수집하는 혼입된 이물질 데이터는 한계가 있다. 이에 대한 대안으로 음식물쓰레기에 혼입될 만한 생활 폐기물 이미지 데이터를 대체하여 모델을 제작하고 학습을 진행하고자 한다.

사용하고자 하는 생활폐기물 이미지 데이터는 AI-허브를 통해 공개된 생활폐기물 이미지 데이터를 활용하였다. AI-허브는 AI 기술 및 제품, 서비스 개발에 필요한 AI 인프라를 지원함으로써 누구나 활용하고 참여하는 AI 통합 플랫폼이다. 본 연구에서 활용할 생활폐기물의 이미지는 생활폐기물의 이미지

데이터를 활용하여 모델을 구축하고 이 데이터를 인공지능 모델이 학습한 이후 일상적으로 발생하는 생활폐기물의 촬영 이미지를 자동으로 인식하고 폐기물의 종류를 분류하는 알고리즘이다. 상기 알고리즘 개발을 위하여 일상생활에서 배출되는 많은 생활폐기물의 이미지를 되도록 다양하게 분류하여 학습용 데이터로 활용이 가능하도록 구축되었다. 기존의 생활폐기물 인공지능 학습용 데이터는 임의의 설정을 통해 만들어진 데이터로 공공기관, 지방자치단체, 폐기물 처리업체에서 기계학습 모델링의 현실을 잘 반영하고 있지 못하고 있다. 또한, 현실적으로 데이터 확보가 쉽지 않고, 데이터 가공에도 비용이 많이 소요된다. 따라서, 근본적인 데이터의 오류를 없애고 정확도를 높이고자 정부 주도의 데이터가 구축된 AI-허브의 공개데이터를 활용하였다.⁶⁸⁾



[그림 3-1] 생활폐기물 데이터 AI 서비스 흐름도

생활폐기물은 사업장 폐기물 외의 폐기물을 말하며, 주로 일반 주택이나 공동주택에서 배출하는 생활폐기물 중에서 연탄재, 재활용 가능 폐기물이다. 이외에도 가정에서 일련의 개보수 공사, 작업 등으로 인하여 발생하는 5톤 미만 폐기물을 의미하며, 폐기물 종류별 세부 분류는 [표 3-1]⁶⁹⁾과 같다.

68) <https://www.aihub.or.kr/>

69) 폐기물관리법시행규칙 별표 4(제4조의2제1항 관련)(<https://www.law.go.kr>)

[표 3-1] 폐기물 종류별 세부 분류

세부 분류 코드	세부 분류명
91-05-00	고철 및 금속캔류
91-07-01	유리병
91-09-00	폐유리
91-08-00	폐의류
91-10	폐목재 및 폐가구류
91-12-00	폐타일 및 도자기류
91-13-00	폐형광등
91-99-00	그 밖의 생활 폐기물

2) 데이터셋 구성

데이터셋의 구성은 아래 [표 3-2]와 같은 체계로 하였다.

[표 3-2] 데이터셋 구성

구분	순번	품목
이물질 (생활 폐기물)	# 0	고철류
	# 1	나무류
	# 2	도기류
	# 3	비닐류
	# 4	캔류
	# 5	플라스틱류

3) 데이터의 분포

공개된 생활폐기물은 탐지 및 분류를 위한 인공지능 서비스 모형을 개발하고 이를 지원하는 학습 데이터를 구축하여 폐기물 자원관리 효율화에 기여하고 생활폐기물 15종(가구, 고철류, 나무류, 도기류, 비닐류, 스티로폼, 유리병류, 의류, 자전거, 전자제품, 캔류, 페트병류, 플라스틱류, 형광등)으로 분류하고 가공된 데이터셋을 학습하여 생활 폐기물 분류 모델을 구축하였다. 다양한 이미지와 영상에 대응하기 위해서 속도와 정확도를 고려하여 AI 학습은 YOLOv4 학습 모델을 사용하였고, 이를 활용 서비스로 “생활폐기물 자동 감지 분류시스템”을 제공하고 있다. 공개데이터의 자료는 크게 생활폐기물로 분류하고 이를 중분류로 종이류, 플라스틱류, 유리류, 캔류, 고철류, 의류, 전자제품, 스티로폼, 도기류 등 15개로 분류했으며 각각 10,000건의 데이터를 제공하고 있다.

본 연구에서는 음식물쓰레기 이물질을 구분하는 것이 목적이므로 제공된 데이터셋에서 생활폐기물이 음식물쓰레기에 혼입될만한 카테고리 이미지로 크게 고철류, 나무류, 도기류, 비닐류, 캔류, 플라스틱류 등 6개의 카테고리를 선별하였다. 선별된 카테고리에서 카테고리별로 50건씩 데이터셋으로 구성하였다. 선별된 데이터의 종류와 정의, 세부 내용은 [표 3-3]과 같다. 본 연구에서 실험에 사용할 카테고리를 종류별로 코드를 부여하고 식별 기준을 위해 품목에 대한 정의를 내렸다. 그리고 세부 분류에는 어떠한 제품들이 포함되는지 등 상세 설명과 수량과 데이터 타입이 무엇인지도 표시하였다.

[표 3-3] 선별 데이터 상세정의

코드	종류	정의	세부내용	수량 (건)	데이터 타입
12	플라스틱 류	열이나 압력으로 소 성 변형을 시켜 성 형할 수 있는 고분 자 화합물을 통틀어 이르는 말. 보통 합 성수지를 이른다.	밀 폐 용 기 (주 방 용 기, 배달 용 기 등)와 욕실 용품, 바구니, 장난감 에 대한 페트병류를 제외한 생활 폐기물	50	이미지
14	캔류	양철 따위로 만든 통	철캔, 알루미늄 캔, 통 조림, 부탄가스, 살충 제 용기 등	50	이미지
15	고철류	아주 낡고 오래된 쇠, 또는 그 조각	고철(공기구, 철사, 못 등), 비철금속(알루미 늄, 스테인리스스틸류 등), 철옷걸이, 전자제 품 조각은 제외	50	이미지
19	도기류	붉은 진흙으로 만들 어 별에 말리거나 약간 구운 다음에 오릿물을 입혀 다시 구운 질그릇	그릇류, 화병류	50	이미지
20	비닐류	비닐 수지나 비닐 섬유를 이용하여 만 든 제품을 통틀어 이르는 말	비닐봉지, 김장비닐, 과자봉지 등과 같이 비닐 수지나 비닐 섬 유를 이용하여 만든 제품	50	이미지
25	나무류	집을 짓거나 가구, 그릇 따위를 만들 때 재료로 사용하는 재목	도마, 나무 행거, 가구 조각 등 나무를 원료 로 만들어진 생활 폐 기물	50	이미지

4) 데이터의 포맷

공개된 생활폐기물 이미지에 데이터 포맷은 [그림 3-2]와 분류된 각각의 품
목에 대한 코드와 사진을 표시하고 데이터에 대한 촬영 기본정보, 대상 폐기
물 정보, 데이터 형식에 대한 설명을 표 형식으로 나타내고 있다.

생활폐기물 - 22.캔류	데이터 항목	JSON 형식
	촬영기본정보 대상 폐기물 정보 바운딩박스 정보	<pre>{ "FILE NAME": "22_X004_C016_1110_4.jpg", "COLLECTION METHOD": "제작자료", "FORM": "이미지", "DATE": "2020-11-10 13:16:30", "GPS": "37.518033/126.738403", "ID CODE": "C016", "RESOLUTION": "1920*1440", "focus distance": "4.23mm", "exposure time": "40/10000sec", "Aperture values": "1.16", "Sensitivity iso": "50", "exposure method": "normal program", "DAY/NIGHT": "주간", "PLACE": "실외", "PROJECT SORTING": "생활폐기물", "BoundingCount": "1", "Bounding": [{ "CLASS": "캔류", "DETAILS": "음료수캔", "DAMAGE": "원형", "TRANSPARENCY": "불투명", "Drawing": "BOX", "x1": "915", "y1": "582", "x2": "1070", "y2": "663" }] }</pre>

[그림 3-2] 데이터 포맷

본 연구에서는 기존 공개된 데이터가 수집하는 과정에서 나름의 규칙을 가지고 체계적으로 정제되었으므로, 이미지만 활용하고자 한다.

머신러닝 애플리케이션은 데이터의 가공 및 변환 과정의 전처리 작업, 데이터를 학습 데이터와 테스트 데이터로 분리하는 데이터 세트 분리 작업을 거친 후에 학습 데이터를 기반으로 머신러닝 알고리즘을 적용해 모델을 학습시킨다. 그리고 학습된 모델을 기반으로 테스트 데이터에 대한 예측을 수행하고, 이렇게 예측된 결과값을 실제 결과값과 비교해 머신러닝 모델에 대한 평가를 수행하는 방식으로 구성된다.

제 2 절 이물질 구분을 위한 알고리즘 설계

1) 실험 정의

[그림 3-3]을 보면 1차 수거지에서 집하장으로 이동된 음식물쓰레기는 음식물 호퍼에 투입이 되고 1차 선별과정을 거쳐 이물질을 분리하고 분리된 이물질은 반출을 한다. 음식물쓰레기는 퇴비 또는 사료 등으로 재활용되기 위해 전처리 과정을 거친다. 즉, 작업자가 수작업을 통해 음식물쓰레기가 담겨진 비닐봉투를 하나하나 풀어헤쳐서 분리 및 선별 작업을 한다. 분리된 음식물쓰레기는 탈수하여 나온 폐수는 발효시켜 메탄가스를 생산하고 남은 음식물쓰레기 찌꺼기는 1~2차 발효를 통해 퇴비화하는 공정을 거친다. 이러한 공정에서 문제는 1차 선별과정에서 발생한다. 음식물쓰레기에 불특정의 이물질이 혼입되어 있어서 이를 선별하는 시간이 많이 소요되고 이물질 등이 설비에 끼여 설비파손으로 이어진다는 것이다. 설비는 대형화되어 있어서 유지보수하는 소요 시간도 하루에서 길게는 일주일 이상이 걸리기도 한다. 본 연구에서는 이러한 문제를 해결하고자 [그림 3-4]와 같이 제안하고 실험하고자 한다.


가) 딥러닝 모델 학습

사전에 준비한 음식물쓰레기 이물질 유형들의 이미지를 딥러닝 모델을 통한 강화학습을 한다. 학습에는 3가지 모델을 사용하여 가장 높은 학습은 학습 데이터 이미지와 검증 데이터 이미지를 거친 후 마지막으로 테스트 데이터 이미지로 한다. 이러한 데이터를 별도의 서버에 저장한다.


나) 카메라 설치

[그림 3-4]와 같이 1차 선별하는 공정 설비에 카메라를 설치하고 음식물

쓰레기 이물질을 스캔하여 서버에 저장된 학습된 데이터셋을 이용하여 음식물쓰레기를 구분하는 시스템이다. 카메라 위치는 설비 상단에 위치를 한다. 카메라가 가까이 있으면 이물질 구분하는 과정에서 이물질과 부딪혀 파손의 우려가 있고 너무 높이 설치되어 있으면 이미지 인식하는데 정확도가 떨어질 수 있기 때문이다. 2차 선별 공정에도 1차 선별 공정에서 걸러지지 못한 이물질을 대비하여 카메라를 설치한다.



[그림 3-3] 음식물쓰레기 처리 흐름도



[그림 3-4] 음식물쓰레기 이물질 구분시스템 흐름도



[그림 3-5] 이물질 구분시스템 흐름도(2)

최종적인 이물질 구분시스템의 흐름도는 [그림 3-5]와 같다.

다) 모델에 대한 성능평가

실제 이미지를 학습된 데이터를 근거로 한 3가지 모델에 대한 정확도, 정밀도, 재현율, F1 스코어 등에 대한 성능평가를 하여 가장 우수한 모델을 선정한다.

2) 데이터의 전처리

데이터의 전처리 작업은 오류 데이터의 보정이나 결손값(Null) 처리 등의 다양한 데이터 클렌징 작업, 레이블 인코딩이나 원-핫 인코딩과 같은 인코딩

작업, 그리고 데이터의 스케일링/정규화 작업 등으로 딥러닝 알고리즘이 최적으로 수행될 수 있게 데이터를 사전 처리하는 것이다.

딥러닝 모델은 학습 데이터셋을 학습한 뒤 별도의 테스트 데이터셋으로 평가하고자 한다. 테스트 데이터의 건수 부족이나 고정된 테스트 데이터 세트를 이용한 반복적인 모델의 학습과 평가는 해당 테스트 데이터 세트에만 치우친 빈약한 딥러닝 모델을 만들 가능성이 높다.⁷⁰⁾ 이를 해결하기 위해 학습 데이터 세트를 학습 데이터와 검증 데이터로 구성된 여러 개의 폴드 세트로 분리해 교차 검증을 수행하고자 사이킷런을 사용하였다. 사이킷런이 이러한 교차 검증을 지원하기 위해 KFold, StratifiedKFold, cross_val_score() 등의 다양한 클래스와 함수를 제공하기 때문이다.

본 연구에서는 데이터 전처리를 두 가지 방식으로 한다. 첫 번째는 레이블 인코딩으로 카테고리 피처를 코드형 숫자 값으로 변환한다. 생활 폐기물 데이터의 구분이 고철류, 비닐류, 캔류, 나무류, 도기류, 플라스틱류 값으로 되어 있는 부분을 고철류:0, 비닐류:1, 캔류:2, 나무류:3, 도기류:4, 플라스틱류:5의 숫자형 값으로 변환하였다. 다음은 원-핫 인코딩(One-Hot Encoding)으로 피처 값의 유형에 따라 새로운 피처를 추가해 고깃값에 해당하는 칼럼에만 1을 표시하고 나머지 칼럼에는 0을 표시하는 방식이다. 즉, 행 행태로 돼 있는 피처의 고깃값을 열 행태로 차원을 변환한 뒤, 고깃값에 해당하는 칼럼에만 1을 표시하고 나머지 칼럼에는 0을 표시하였다. 이렇게 함으로써 우리가 실험을 통해 구현한 데이터를 정확도, 재현율과 F1 스코어에 대한 데이터를 평가할 수 있다.

가) 데이터 증식

모델의 구조가 복잡하고 깊어질수록 성능평가를 위해서 많은 양의 데이터셋이 필요하다. 수집된 데이터를 통해 학습 및 평가하기에는 데이터 수량이 부족하다. 수량적 문제를 해결하기 위해 데이터 증식 알고리즘을 활용하여 다양한 데이터를 확보하고자 하였다. 데이터 증식(Data Augmentation)은 갖고

70) 권철민. (2022). 『파이썬 머신러닝 완벽 가이드』, 서울: 위키북스

있는 데이터셋을 여러 가지 방법으로 증식하여 실질적인 학습 데이터셋의 규모를 키울 수 있는 방법이다. 즉, 학습 데이터 수가 적어서 오버피팅이 발생할 가능성을 줄이기 위해 기존 훈련 데이터로부터 그럴듯하게 이미지를 랜덤하게 생성하여 데이터의 수를 늘리는 것이다. 오버피팅은 학습할 샘플이 너무 적어 새로운 데이터에 일반화할 수 있는 모델을 훈련시킬 수 없기 때문에 발생한다. 무한히 많은 데이터가 주어지면 데이터 분포의 모든 가능한 측면을 모델이 학습할 수 있을 것이다. 그러나, 데이터 증식 또한, 기존의 데이터의 정보량을 보존한 상태로 노이즈를 주는 방식이기에, 정보량 자체는 변하지 않고 변화만 주는 방식이다.

데이터 증식은 기본적으로 Mirroring, Rotation, Shearing, shifting 등이 있다. 여기서는 좌, 우, 상, 하 각도를 적용하였다.



[그림 3-6] 데이터 증식 방법


나) 전이 학습⁷¹⁾

전이 학습(Transfer Learning)은 기존 머신러닝 모델의 한계를 극복하기 위해 전이 학습을 도입하였다.⁷²⁾ 학습 데이터가 부족한 분야의 모델 구축을 위해 데이터가 풍부한 분야에 훈련된 모델을 재사용하는 기법이다. 전이 학습

71) <https://www.v7labs.com/blog/transfer-learning-guide>

72) Y. Jiang, Y. Li and H. Zhang. (2019). Hyperspectral Image Classification Based on 3-D Separable ResNet and Transfer Learning, in IEEE Geoscience and Remote Sensing Letters, 16(12), 1949-1953.

을 사용하는 이유는 이미 학습된 모델을 사용해 문제 해결이 가능하고 이미 학습된 모델은 적용하는 데이터가 학습할 때의 데이터와 같은 분포를 가진다고 가정할 때 효율적이다. 새로운 문제를 해결하려 할 때, 데이터의 분포가 바뀌면 기존 통계적 모델을 새로운 데이터로 만들 때 효율적이다. 복잡한 모델일 경우, 학습 시간과 과정이 비효율적이기 때문에 사용한다.



[그림 3-7] 전통적인 기계학습과 전이 학습 비교
(출처 : <https://www.v7labs.com>)

[그림 3-7]을 보면 두 학습의 차이점은 첫 번째는 기존 머신러닝 모델은 처음부터 훈련해야 하므로 계산 비용이 많이 들고 고성능을 달성하기 위해 많은 양의 데이터가 필요하다. 반면에 전이 학습은 계산적으로 효율적이며 작은 데이터셋을 사용하여 더 나은 결과를 얻는데 도움이 된다.

두 번째로는 전통적인 머신러닝에는 과거 지식에 의존하지 않고 각 모델이 특정 목적을 위해 독립적으로 훈련되는 격리된 훈련 접근 방식이고 전이 학습은 사전 학습된 모델에서 얻은 지식을 사용하여 작업은 진행한다.

마지막으로 전이 학습 모델은 기존 머신러닝 모델보다 빠르게 최적의 성능을 달성한다. 이전에 훈련된 모델의 지식(특성, 가중치 등)을 활용하는 모델은 이

미 특성을 이해하고 있기 때문에 신경망을 처음부터 훈련하는 것보다 더 빠르다.

3) 실험 환경

본 연구에서는 파이썬 3.8버전과 케라스 2.4버전, 텐서플로 2.4버전, 사이킷런 환경에서 VGG, ResNet, EfficientNet 3개의 알고리즘 모델을 적용하여 실험하였다.

실험은 일차적으로 전부 이미지 데이터셋 별로 50개씩 선별하고 2차에서는 부분 이미지는 아무래도 전체 이미지와는 달리 음식물쓰레기와 혼입된 상태이므로 부분 이미지에서는 임곗값 형식으로 1차와 마찬가지로 50개씩하고 240개씩, 300개씩 구분하여 테스트하여 정확도를 판별하고자 한다.

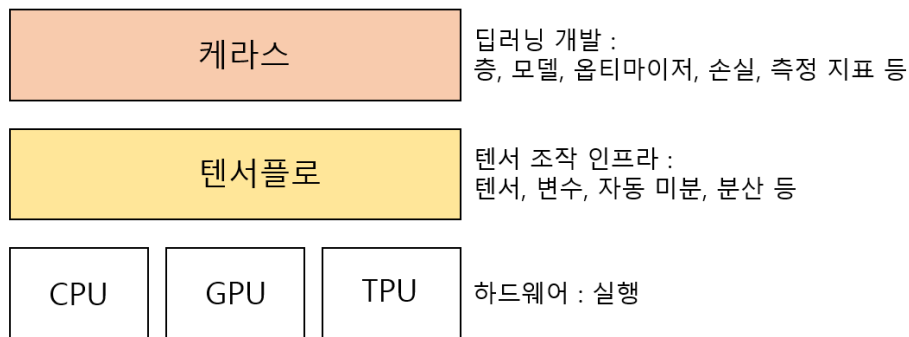
가) 텐서플로

텐서플로(TensorFlow)는 구글에서 만든 파이썬 기반의 무료 오픈소스 머신러닝 플랫폼이다. 넘파이와 매우 비슷하게 텐서플로의 핵심 목적은 엔지니어와 연구자가 수치 텐서에 대한 수학적 표현을 적용할 수 있도록 하는 것이다. 그리고 텐서플로는 다음과 같은 기능이 있다.

- (1) 미분이 가능한 어떤 표현식에 대해서도 자동으로 그레이디언트를 계산할 수 있어 머신러닝에 매우 적합
- (2) CPU뿐만 아니라 고도로 병렬화된 하드웨어 가속기인 GPU와 TPU에서도 실행 가능
- (3) 텐서플로에서 정의한 계산은 여러 머신에 쉽게 분산시킬 수 있다.
- (4) 텐서플로 프로그램은 C++, 자바스크립트, 텐서플로 라이트 등과 같은 다른 런타임에 맞게 변환

나) 케라스

케라스는 텐서플로 위에 구축된 파이썬용 딥러닝 API로 어떤 종류의 딥러닝 모델도 쉽게 만들고 훈련할 수 있는 방법을 제공한다. [그림 3-8]과 같이 텐서플로를 통해 케라스는 다양한 하드웨어(GPU, TPU 그리고 평범한 CPU) 위에서 실행하고 수천 대의 머신으로 매끄럽게 확장할 수 있다. 케라스는 개발자 경험을 중요하게 생각한다.



[그림 3-8] 케라스와 텐서플로

케라스가 텐서플로보다 8개월 앞서 나왔다. 케라스는 2015년 3월에 릴리스되었고 텐서플로는 2015년 11월에 릴리스되었다. 케라스가 텐서플로 위에 구축된 것이다. 케라스는 원래 씨아노(Theano)를 위한 라이브러리였다. 씨아노는 딥러닝 라이브러리 최초로 자동 미분과 GPU 지원을 제공하는 또 다른 텐서 조작 라이브러리이다. 씨아노는 몬트리올 대학교에서 MILA(Montreal Institute for Learning Algorithms)에서 개발되었고 여러 가지 면에서 텐서플로의 선구자 격인 라이브러리였다. 자동 미분과 CPU 및 GPU를 위한 코드를 컴파일하는 데 정적 계산 그래프를 사용하는 아이디어를 처음으로 고안했다.

텐서플로가 릴리스된 후 2015년 말에 케라스는 멀티백엔드(Multibackend)

구조로 리팩터링되었다. 즉, 케라스를 써아노나 텐서플로와 함께 사용할 수 있고, 환경 변수를 바꾸어 두 라이브러리 사이를 쉽게 전환할 수 있게 되었다. 2016년 9월에 텐서플로는 기술적으로 성숙한 수준에 도달했고 케라스의 기본 백엔드가 되었다. 2017년에 카라스에 2개의 새로운 백엔드 옵션이 추가되었다. 마이크로소프트가 개발한 CNTK와 아마존이 개발한 MXNet이다. 지금은 써아노와 CNTK 개발은 중지되었다. MXNet은 아마존 밖에 널리 사용되지 않는다. 다시 케라스는 텐서플로를 사용하는 단일 백엔드 API가 되었다.

케라스와 텐서플로는 수년간 공생관계에 있었다. 2016년과 2017년을 지나면서 케라스는 텐서플로 애플리케이션을 만드는 사용자 친화적인 방법으로 유명해졌고 텐서플로 생태계로 새로운 사용자를 유입시켰다. 2017년 말 대부분의 텐서플로 사용자는 케라스를 사용하거나 케라스와 텐서플로를 조합하여 사용했다. 2018년 텐서플로는 케라스를 텐서플로의 공식 고수준 API로 채택하였고, 케라스 API는 2019년 9월에 릴리스 된 텐서플로 2.0의 핵심이자 맨션두에 서게 되었다. 텐서플로 2.0은 4년간의 사용자 피드백과 기술 발전을 반영하여 텐서플로와 케라스를 전면적으로 재설계한 것이다.⁷³⁾

다) 케라스 라이브러리를 사용한 VGG-16 모델 요약

처음부터 모델을 적합 시키는 대신 사전 적합 이전의 최첨단 이미지 분류 모델을 사용할 수 있다. 케라스는 ImageNet Large Scale Visual Recognition Challenge(ILSVRC)를 위해 다양한 연구 그룹이 개발한 잘 수행되는 이미지 분류 모델의 많은 예를 제공한다. 2014년 대회에서 최고 성적을 거둔 VGG-16 모델이 대표적이다.

이것은 연속적으로 정렬된 컨볼루션 및 풀링 레이어의 단순한 균일한 구조를 가지고 있고, 학습된 16개 레이어로 깊이가 있으며, 성능이 매우 우수

73) 프랑소와 솔레, 박해선. (2022). 『케라스 창시자에게 배우는 딥러닝 개정 2판, 서울:길벗

하여 필터와 결과 피쳐 맵이 유용한 기능을 캡처할 수 있기 때문에 시각화에 사용하기 좋은 모델이다. 다음과 같은 몇 줄의 코드로 [표 3-4]와 같이 VGG16 모델을 로드하고 요약할 수 있다.⁷⁴⁾

[표 3-4]는 ImageNet 모델을 케라스 라이브러리를 사용하여 로드하였고, 우리는 ImageNet의 모델 중에서 VGG-16을 사용하였다. CNN 모델을 떠올리게 하는 구조라는 것을 알 수 있다. 입력값의 요구조건이 (num_of_images, 244, 244, 3) 라는 것을 알 수 있다. 이것은 이미지가 244*244 RGB의 3개 칼라 채널을 갖고 있다는 것을 의미한다. 모델을 사용하여 추론을 할 때, 우리가 모델에 넘겨주는 이미지도 이와 같은 요구조건을 갖도록 재형성을 해줘야 한다.

출력값은 1,000개의 카테고리를 갖는 것을 확인할 수 있다. 사실 ImageNet을 사용하면 20,000개가 넘는 카테고리를 분류할 수 있지만 우리가 사용하는 모델은 그것의 Subset인 1,000개의 카테고리 분류를 제공한다. 해당 모델의 Category와 Index Mapping에 대한 정보는 다음 링크에 있다.⁷⁵⁾

74) Karen simonyan, Andrew Zisserman. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition, Published as a conference paper at ICLR 2015, 1-14.

75) <https://gist.github.com/yrevar/942d3a0ac09ec9e5eb3a>

[표 3-4] VGG-16 Model

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	(None, 224, 224, 3)	0
block1_conv1 (Conv2D)	(None, 224, 224, 64)	1792
block1_conv2 (Conv2D)	(None, 224, 224, 64)	36928
block1_pool (MaxPooling2D)	(None, 112, 112, 64)	0
block2_conv1 (Conv2D)	(None, 112, 112, 128)	73856
block2_conv2 (Conv2D)	(None, 112, 112, 128)	147584
block2_pool (MaxPooling2D)	(None, 56, 56, 128)	0
block3_conv1 (Conv2D)	(None, 56, 56, 256)	295168
block3_conv2 (Conv2D)	(None, 56, 56, 256)	590080
block3_conv3 (Conv2D)	(None, 56, 56, 256)	590080
block3_pool (MaxPooling2D)	(None, 28, 28, 256)	0
block4_conv1 (Conv2D)	(None, 28, 28, 512)	1180160
block4_conv2 (Conv2D)	(None, 28, 28, 512)	2359808
block4_conv3 (Conv2D)	(None, 28, 28, 512)	2359808
block4_pool (MaxPooling2D)	(None, 14, 14, 512)	0
block5_conv1 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv2 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv3 (Conv2D)	(None, 14, 14, 512)	2359808
block5_pool (MaxPooling2D)	(None, 7, 7, 512)	0
flatten (Flatten)	(None, 25088)	0
fc1 (Dense)	(None, 4096)	102764544
fc2 (Dense)	(None, 4096)	16781312
predictions (Dense)	(None, 1000)	4097000
Total params: 138,357,544		
Trainable params: 138,357,544		
Non-trainable params: 0		


제 4 장 딥러닝 적용 이물질 구분 시스템 구현 및 테스트

제 1 절 모델별 이물질 구분 시스템 구현

1) 구현 범위

본 연구에서는 제안하는 음식물쓰레기 이물질 구분시스템은 음식물쓰레기 이물질로 자주 언급이 되는 생활폐기물 이미지로 대체하여 구현한다.

데이터셋은 크게 [그림 4-1]과 같이 두 가지로 나뉜다. 생활폐기물 이미지 원본 그대로 테스트하는 전체 이미지이고 다른 하나는 전체 이미지를 부분적으로 처리하여 실제 음식물에 섞인 형상으로 이미지화한 부분 이미지, 데이터 증식, 전이 학습된 자료를 토대로 한 이미지이다. 부분 이미지는 실제로 음식물쓰레기가 시간이 지나면서 부패하거나 산패되면서 곱썩한 모습, 파손된 형태의 이물질이 혼입되면서 섞여 있는 형태 등 다양한 형상을 하고 있는 것을 가정한 이미지이다. 위 두 가지 실험 후 높은 정확도를 나타낸 알고리즘 모델을 선정 후 집하장 현장 이미지로 최종 측정을 하고자 한다.



[그림 4-1] 테스트 데이터셋 이미지

가) 전체 이미지

전체 이미지는 카테고리별로 각각 훈련데이터 50개, 검증용 데이터는 20개 중 10개 선정하여 80:20 비율로 선택하였다. 이러한 데이터셋을 가지고 모델별 알고리즘을 가지고 각각의 데이터를 활용하여 훈련과 검증에 사용하고 나서 분류된 모델의 성능을 측정하기 위해 테스트 데이터를 사용한다.

나) 부분 이미지

부분 이미지도 카테고리별로 각각 훈련데이터 300개, 검증용 데이터는 100개 중 80개 선정하여 80:20 비율로 선택하였다.

2) 성능평가

3개의 알고리즘 모델을 통해 최고의 분류성능을 가진 분류 모델을 찾고자 하는 것으로 일반적으로 검증을 하면 EfficientNet이 타 알고리즘에 비해 높은 정확도를 나타내고 있다. 아직 최적화 작업을 수행하지 않았고, 데이터도 충분하지 않기 때문에 어떤 알고리즘이 가장 성능이 좋다고 평가할 수 없다. 분류의 성능평가지표는 정확도(Accuracy), 오차 행렬(Confusion Matrix), 정밀도(Precision), 재현율(Recall), F1 스코어, ROC AUC 있다.

먼저, 정확도는 실제 데이터에서 예측 데이터가 얼마나 같은지를 판단하는 지표이다.

$$\text{정확도 (Accuracy)} = \frac{\text{예측 결과가 동일한 데이터 건수}}{\text{전체 예측 데이터 건수}}$$

정확도는 직관적으로 모델 예측 성능을 나타내는 평가 지표이다. 하지만 이진 분류의 경우 데이터의 구성에 따라 모델의 성능을 왜곡할 수 있기 때문에 정확도 수치 하나만 가지고 성능을 평가하지 않는다.

이진 분류에서 성능 지표로 잘 활용되는 오차 행렬(confusion matrix)은 학습된 분류 모델이 예측을 수행하면서 얼마나 헷갈리고(confused) 있는지도 함께 보여주는 지표이다.

오차 행렬은 다음과 같은 4분 면 실제 레이블 클래스값과 예측 레이블 클래스값이 어떠한 유형을 가지고 매핑되는지를 나타낸다. 4분 면의 왼쪽, 오른쪽을 예측된 클래스 값 기준으로 Negative와 Positive로 분류하면 예측 클래스와 실제 클래스의 값 유형에 따라 결정되는 TN, FP, FN, TP 형태로 오차 행렬의 4분 면을 채울 수 있다. TN, FP, FN, TP 값을 다양하게 결합해 분류 예측 성능의 오류가 어떠한 모습으로 발생하는지 알 수 있는 것이다.

	Negative(0)	Positive(0)
Negative(0)	TN True Negative	FP False Positive
실제 클래스 (Actual Class)		
Positive(1)	FN False Negative	TP True Positive

[그림 4-2] 예측 클래스(Predicted Class)

TN, FP, FN, TP는 예측 클래스와 실제 클래스의 Positive 결정 값(값1)과 Negative 결정 값(값 0)의 결합에 따라 결정된다. 예를 들어 TN은 True Negative의 의미이며 앞 True는 예측 클래스값과 실제 클래스값이 같다는 의미고 뒤의 Negative는 예측값이 Negative 값이라는 의미이다. 즉, TN은 예측을 Negative 값 0으로 예측했는데, 실제 값도 Negative 값 0이라는 의미이다. TN, FP, FN, TP 기호가 의미하는 것은, 앞 문자 True, False는 예측값과 실제값이 '같은가/틀린가'를 의미한다. 뒤 문자 Negative/Positive는 예측 결과가 부정(0)/긍정(1)을 의미한다.

- *TN*는 예측값을 *Negative* 값 0으로 예측했고 실제 값 역시 *Negative* 값 0
- *FP*는 예측값을 *Positive* 값 1로 예측했고 실제 값 역시 *Negative* 값 0
- *FN*는 예측값을 *Negative* 값 0으로 예측했고 실제 값 역시 *Positive* 값 1
- *TP*는 예측값을 *Positive* 값 1로 예측했는데 실제 값 역시 *Positive* 값 1

TN, *FP*, *FN*, *TP* 값은 Classifier 성능의 여러 면모를 판단할 수 있는 기반 정보를 제공한다. 이 값을 조합해 Classifier의 성능을 측정할 수 있는 주요 지표인 정확도(Accuracy), 정밀도(Precision), 재현율(Recall)값을 알 수 있다.

정확도는 예측값과 실제값이 얼마나 동일한가에 대한 비율만으로 결정된다. 즉, 오차 행렬에서 True에 해당하는 값인 *TN*과 *TP*에 좌우된다. 정확도는 오차 행렬 상에서 다음과 같이 재정의될 수 있다.

$$\text{정확도} = \frac{\text{예측 결과와 실제 값이 동일한 건수}}{\text{전체 데이터 수}} = \frac{TN + TP}{TN + FP + FN + TP}$$

정확도는 분류(Classification) 모델의 성능을 측정할 수 있는 한 가지 요소일 뿐이다. 불균형한 데이터 세트에서 정확도만으로는 모델 신뢰도가 떨어질 수 있다. 다음으로 불균형한 데이터 세트에서 정확도보다 더 선호되는 평가 지표인 정밀도(Precision)와 재현율(Recall)이다.

정밀도와 재현율은 Positive 데이터셋의 예측 성능에 좀 더 초점을 맞춘 평가 지표이다. 정밀도와 재현율에 대한 공식은 다음과 같다.

$$\text{정밀도} = TP / (FP + TP)$$

$$\text{재현율} = TP / (FN + TP)$$

다음으로 F1 스코어(Score)는 정밀도와 재현율을 결합한 지표이다. F1 스코어는 정밀도와 재현율이 어느 한쪽으로 치우치지 않는 수치를 나타낼 때 상대적으로 높은 값을 가진다. F1 스코어의 공식은 다음과 같다.

$$F1 \text{ 스코어} = \frac{2}{\frac{1}{recall} + \frac{1}{precision}} = 2 * \frac{precision * recall}{precision + recall}$$

만일 A 예측 모델의 경우 정밀도가 90%, 재현율이 10%로 극단적인 차이가 나고, B 예측 모델은 정밀도가 50%, 재현율이 50%로 정밀도와 재현율이 큰 차이가 없다면 A 예측 모델의 F1 스코어는 18%이고, B 예측 모델의 F1 스코어는 50%로 B 모델에 비해 매우 우수한 F1 스코어를 가지게 된다.⁷⁶⁾

본 연구에서도 모델별 이물질 구분시스템에 의해 분류된 데이터셋에 대한 성능평가를 하였다. 성능평가지표로는 정확도, 정밀도, 재현율, F1 스코어 등 4가지 지표로 하였다.

76) 권철민. (2022). 『파이썬 머신러닝 완벽 가이드』, 서울: 위키북스

제 2 절 모델별 이물질 구분시스템 테스트 평가

1) 전체 이미지에 적용된 모델별 분류 결과

전체 이미지에 대한 데이터셋의 테스트 데이터 분류체계는 6개의 카테고리로 분류하였다. 50건에 대한 각각의 항목별 분류 결과는 정밀도(Precision), 재현율(Recall), F1 스코어를 측정하였고, 전체 데이터에 대한 정확도, 정밀도, 재현율, F1 스코어를 측정하였다.

[표 4-1] VGG 분류 모델의 전체 이미지 분류 결과

	Precision	Recall	F1-Score	Support
# 0	0.7761	0.7647	0.7704	50
# 1	0.8028	0.9344	0.8636	50
# 2	0.8261	0.9194	0.8703	50
# 3	0.8154	0.8548	0.8346	50
# 4	0.8028	0.9194	0.8572	50
# 5	0.8358	0.9032	0.8682	50
accuracy			0.8284	300
macro avg	0.8098	0.8827	0.8440	300
weighted avg	0.8098	0.8827	0.8440	300

전체적인 정확도는 82.84%이고 정밀도 평균은 80.98%이고 이중에서는 #5 (플라스틱류)가 83.58% 높게 나타나고 # 0(고철류)가 77.61%로 낮게 나타났다. 재현율 평균은 88.27%이고 #1 (비닐류)가 93.44% 높게 나타나고 이 역시 # 0(고철류)가 76.47%로 낮게 나타났다. F1 스코어 평균은 84.40%이고 #2 (캔류)가 87.03% 높게 나타나고 이 역시 # 0(고철류)가 77.03%로 낮게 나타났다.

[표 4-2] ResNet 분류 모델의 전체 이미지 분류 결과


	Precision	Recall	F1-Score	Support
# 0	0.7361	0.7465	0.7413	50
# 1	0.7397	0.8438	0.7883	50
# 2	0.7895	0.8955	0.8392	50
# 3	0.7500	0.8226	0.7846	50
# 4	0.7857	0.8871	0.8333	50
# 5	0.7808	0.93.44	0.8507	50
accuracy			0.7838	300
macro avg	0.7636	0.8550	0.8062	300
weighted avg	0.7636	0.8550	0.8062	300

전체적인 정확도는 78.38%이고 정밀도 평균은 76.36%이고 이중에서는 #2 (캔류)가 78.95% 높게 나타나고 # 0(고철류)가 73.61%로 낮게 나타났다. 재현율 평균은 85.50%이고 #5 (플라스틱류)가 93.44% 높게 나타나고 이 역시 # 0(고철류)가 76.47%로 낮게 나타났다. F1 스코어 평균은 80.62%이고 #5 (플라스틱류)가 85.07% 높게 나타나고 이 역시 # 0(고철류)가 74.13%로 낮게 나타났다.

[표 4-3] EfficientNet 분류 모델의 전체 이미지 분류 결과

	Precision	Recall	F1-Score	Support
# 0	0.8286	0.8923	0.8593	50
# 1	0.8143	0.9500	0.8769	50
# 2	0.8219	0.9524	0.8824	50
# 3	0.8000	0.9333	0.8615	50
# 4	0.8028	0.9661	0.8769	50
# 5	0.8406	0.9508	0.8923	50
accuracy			0.8284	300
macro avg	0.8180	0.9408	0.8749	300
weighted avg	0.8180	0.9408	0.8749	300

전체적인 정확도는 82.84%이고 정밀도 평균은 81.80%이고 이중에서는 #5 (플라스틱류)가 84.06% 높게 나타나고 # 3(나무류)가 80.00%로 낮게 나타났다. 재현율 평균은 94.08%이고 #4 (도기류)가 96.61% 높게 나타나고 # 0(고철류)가 89.23%로 낮게 나타났다. F1 스코어 평균은 87.49%이고 #5 (플라스틱류)가 89.23% 높게 나타나고 이 역시 # 0(고철류)가 85.93%로 낮게 나타났다.



[그림 4-3] 전체 이미지에 대한 모델별 F1 스코어 및 정확도 비교

전체 이미지에 대한 F1 스코어와 정확도를 보면 EfficientNet 모델이 87.49%, VGG 모델 84.40%, ResNet 모델이 80.62%로 나와 EfficientNet > VGG > ResNet 모델 순으로 각각 3.09%, 6.87%의 F1 스코어가 높게 나타났다. 정확도도 EfficientNet 모델이 85.69%, VGG 모델 82.44%, ResNet 모델이 78.38%로 나와 EfficientNet > VGG > ResNet 모델 순으로 각각 2.85%, 7.31% 정확도가 높게 나타났다.

결과적으로 비닐류가 통상적으로 이물질 비율이 높아서 비닐류가 통상적으로 높게 나타날 것으로 예상하지만, 전체 이미지는 원형 이미지 그대로 측정하기 때문에 비닐류가 높다고 독단할 수 없다. 전반적으로 각각의 성능평가에서 높은 성능을 나타낸 EfficientNet 모델을 분석하면 플라스틱류가 우수한 평가를 받고 있다. 플라스틱류는 사실 그 종류가 다양하고 각각의 특성이 뚜렷하여 높은 성능을 보였다고 본다.

2) 부분 이미지에 적용된 모델별 분류 결과

부분 이미지에 대한 데이터셋의 테스트 데이터 분류체계는 6개의 카테고리로 분류하였다. 300건에 대한 각 항목별 분류 결과는 정밀도(Precision), 재현율(Recall), F1 스코어를 측정하였고, 전체 데이터에 대한 정확도(Accuracy), 정밀도, 재현율, F1 스코어를 측정하였다.

[표 4-4] VGG 분류 모델의 부분 이미지 분류 결과

	Precision	Recall	F1-Score	Support
# 0	0.5132	0.6760	0.5835	300
# 1	0.5940	0.6791	0.6337	300
# 2	0.5543	0.7317	0.6308	300
# 3	0.5076	0.7186	0.5949	300
# 4	0.5015	0.5714	0.5342	300
# 5	0.5483	0.6725	0.6041	300
accuracy			0.7197	1,800
macro avg	0.5365	0.6749	0.5969	1,800
weighted avg	0.5365	0.6749	0.5969	1,800

전체적인 정확도는 71.97%이고 정밀도 평균은 53.65%이고 이중에서는 # 1 (비닐류)가 59.40% 높게 나타나고 # 3(나무류)가 50.15%로 낮게 나타났다. 재현율 평균은 67.49%이고 #2 (캔류)가 73.17% 높게 나타나고 # 4(도기류)가 57.14%로 낮게 나타났다. F1 스코어 평균은 59.69%이고 #1 (비닐류)가 63.37% 높게 나타나고 이 역시 # 4(도기류)가 53.42%로 낮게 나타났다.

[표 4-5] ResNet 분류 모델의 부분 이미지 분류 결과


	Precision	Recall	F1-Score	Support
# 0	0.4464	0.6858	0.5408	300
# 1	0.5650	0.6557	0.6070	300
# 2	0.5473	0.7333	0.6268	300
# 3	0.5079	0.6389	0.5659	300
# 4	0.5194	0.6569	0.5801	300
# 5	0.5755	0.7295	0.6434	300
accuracy			0.7172	1,800
macro avg	0.5269	0.6834	0.5940	1,800
weighted avg	0.5269	0.6834	0.5940	1,800

전체적인 정확도는 71.72%이고 정밀도 평균은 52.69%이고 이중에서는 #5 (플라스틱류)가 57.55% 높게 나타나고 # 0(고철류)가 44.64%로 낮게 나타났다. 재현율 평균은 68.34%이고 #2 (캔류)가 73.33% 높게 나타나고 # 3 (나무류)가 63.89%로 낮게 나타났다. F1 스코어 평균은 59.40%이고 #5 (플라스틱류)가 64.34% 높게 나타나고 # 0 (고철류)가 54.08%로 낮게 나타났다.

[표 4-6] EfficientNet 분류 모델의 분류 결과

	Precision	Recall	F1-Score	Support
# 0	0.5217	0.7215	0.6055	300
# 1	0.6025	0.6979	0.6467	300
# 2	0.5543	0.7453	0.6358	300
# 3	0.5278	0.6376	0.5775	300
# 4	0.5182	0.7810	0.6230	300
# 5	0.5926	0.7080	0.6452	300
accuracy			0.7489	1,800
macro avg	0.5529	0.7152	0.6223	1,800
weighted avg	0.5529	0.7152	0.6223	1,800

전체적인 정확도는 74.89%이고 정밀도 평균은 55.29%이고 이중에서는 #1 (비닐류)가 60.25% 높게 나타나고 # 4 (도기류)가 51.82%로 낮게 나타났다. 재현율 평균은 71.52%이고 #4 (도기류)가 78.10% 높게 나타나고 # 3 (나무류)가 63.76%로 낮게 나타났다. F1 스코어 평균은 62.23%이고 #1 (비닐류)가 64.67% 높게 나타나고 이 역시 # 3(나무류)가 57.75%로 낮게 나타났다.



[그림 4-4] 부분 이미지에 대한 모델별 F1 스코어 및 정확도 비교


부분 이미지에 대한 F1 스코어와 정확도를 보면 EfficientNet 모델이 62.23%, VGG 모델 59.69%, ResNet 모델이 59.40%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 2.54%, 2.83% F1 스코어가 높게 나타났다. 정확도도 EfficientNet 모델이 74.89%, VGG 모델 71.97%, ResNet 모델이 71.72%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 2.92%, 3.17% 정확도가 높게 나타났다.

결과적으로 비닐류가 통상적으로 이물질 비율이 높아서 비닐류가 통상적으로 높게 나타날 것으로 예상하였으나, 전반적으로 각각의 성능평가에서 높은 성능을 나타난 EfficientNet 모델을 분석하면 앞서 언급한 이물질 비율이 높은 비닐류가 단연 우수한 평가를 받고 있다.

3) 전체 이미지와 부분 이미지에 적용된 모델별 분류 결과 비교

전체 이미지와 부분 이미지에 대한 딥러닝 알고리즘 모델별 실험한 결과를 토대로 각 데이터셋의 분류체계별 정밀도와 재현율, 그리고 F1 스코어에 대해 각각 분석하였다.

(가) 데이터 # 0 (고철류)




[그림 4-5] # 0(고철류)에 대한 모델별 정밀도 비교

데이터셋 # 0(고철류)의 정밀도를 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 82.86%, VGG 모델 77.61%, ResNet 모델이 73.61%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 5.25%, 9.25% 정밀도가 높게 나타났다. EfficientNet 모델이 VGG 모델보다 ResNet 모델에서 큰 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과도 EfficientNet 모델이 52.17%, VGG 모델 51.32%, ResNet 모델이 44.64%로 나와 EfficientNet > VGG > ResNet

모델 순으로 EfficientNet 모델이 각각 0.85%, 7.53% 정밀도가 높게 나타났다. EfficientNet 모델이 VGG 모델보다 근소한 차이로 높고 ResNet 모델에서 큰 차이를 나타내고 있다.

위 [그림 4-5] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활 폐기물 이미지보다 정밀도가 크게 낮음을 알 수 있다.




[그림 4-6] # 0(고철류)에 대한 모델별 재현을 비교

데이터셋 # 0(고철류)의 재현율을 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 89.23%, VGG 모델 76.47%, ResNet 모델이 74.65%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 12.76%, 14.58% 재현율이 높게 나타났다. EfficientNet 모델이 VGG 모델과 ResNet 모델에서 큰 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과도 EfficientNet 모델이 72.15%, VGG 모델 67.60%, ResNet 모델이 68.58%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 4.55%, 3.57% 재현율이 높게 나타났다. EfficientNet 모델이 VGG 모델, ResNet 모델보다 5% 범위에서 근소한

차이를 나타내고 있다.

위 [그림 4-6] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활폐기물 이미지보다 EfficientNet 모델의 재현율이 타 모델보다 큰 차이를 나타내고 있다.




[그림 4-7] # 0(고철류)에 대한 모델별 F1 스코어 비교

데이터셋 # 0(고철류)의 F1 스코어를 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 85.93%, VGG 모델 77.04%, ResNet 모델이 74.13%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 8.89%, 11.80% F1 스코어가 높게 나타났다. EfficientNet 모델이 VGG 모델보다 ResNet 모델에서 조금 더 큰 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과도 EfficientNet 모델이 60.55%, VGG 모델 58.35%, ResNet 모델이 54.08%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 2.20%, 6.47% F1 스코어가 높게 나타났다. EfficientNet 모델이 VGG 모델보다 근소한 차이로 높고 ResNet 모델에서 조금 더 큰 차이를 나타내고 있다.

위 [그림 4-7] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활폐기물 이미지보다 F1 스코어가 전반적으로 18.69%에서 ~ 25.38%의 다소 높은 차이를 나타내고 있다.

(나) 데이터 # 1 (비닐류)




[그림 4-8] # 1(비닐류)에 대한 모델별 정밀도 비교

데이터셋 # 1(비닐류)의 정밀도를 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 81.43%, VGG 모델 80.28%, ResNet 모델이 73.97%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 1.57%, 7.46% 정밀도가 약간 높게 나타났다. EfficientNet 모델이 VGG 모델보다 ResNet 모델에서 다소 큰 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과도 EfficientNet 모델이 60.25%, VGG 모델 59.40%, ResNet 모델이 56.50%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 0.85%, 3.75% 정밀도가 높게 나타났다. EfficientNet 모델이 VGG 모델과 ResNet 모델에서 5% 범위에서 다소

근소한 차이를 나타내고 있다.

위 [그림 4-8] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활폐기물 이미지보다 정밀도가 크게 낮음을 알 수 있다




[그림 4-9] # 1(비닐류)에 대한 모델별 재현율 비교

데이터셋 # 1(비닐류)의 재현율을 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 95.00%, VGG 모델 93.44%, ResNet 모델이 84.38%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 1.56%, 10.62% 재현율이 높게 나타났다. EfficientNet 모델이 VGG 모델에서는 근소한 차이를 ResNet 모델에서는 큰 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과도 EfficientNet 모델이 69.79%, VGG 모델 67.91%, ResNet 모델이 65.57%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 1.88%, 4.22% 재현율이 높게 나타났다

다. EfficientNet 모델이 VGG 모델보다 근소한 차이로 높고 ResNet 모델에서 큰 차이를 나타내고 있다.

위 [그림 4-9] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활폐기물 이미지보다 재현율이 전반적으로 18.81%에서 ~ 25.21%의 다소 높은 차이를 나타내고 있다.



[그림 4-10] # 1(비닐류)에 대한 모델별 F1 스코어 비교


데이터셋 # 1(비닐류)의 F1 스코어를 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 87.69%, VGG 모델 77.04%, ResNet 모델이 78.83%로 나와 EfficientNet > ResNet > VGG모델 순으로 EfficientNet 모델이 각각 8.86%, 10.65% F1 스코어가 높게 나타났다. EfficientNet 모델이 VGG 모델보다 ResNet 모델에서 큰 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과는 EfficientNet 모델이 64.67%, VGG 모델 63.37%, ResNet 모델이 60.70%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 1.30%, 3.97% F1 스코어가 높게 나타

났다. EfficientNet 모델이 VGG 모델보다 근소한 차이로 높고 ResNet 모델에서 큰 차이를 나타내고 있다.

위 [그림 4-10] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활폐기물 이미지보다 F1 스코어가 크게 낮음을 알 수 있다.

(다) 데이터 # 2 (캔류)




[그림 4-11] # 2(캔류)에 대한 모델별 정밀도 비교

데이터셋 # 2(캔류)의 정밀도를 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 82.19%, VGG 모델 82.61%, ResNet 모델이 78.95%로 나와 VGG > EfficientNet > ResNet 모델 순으로 EfficientNet 모델이 각각 VGG 모델보다는 -0.42% 낮게, ResNet 모델보다는 3.24% 정밀도가 높게 나타났다. EfficientNet 모델이 VGG 모델보다 ResNet 모델에서 큰 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과는 EfficientNet 모델이 55.43%, VGG 모

델 55.43%, ResNet 모델이 54.73%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 0.85%, 7.53% 정밀도가 높게 나타났다. EfficientNet 모델이 VGG 모델보다 근소한 차이로 높고 ResNet 모델에서 큰 차이를 나타내고 있다.

위 [그림 4-11] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활폐기물 이미지보다 정밀도가 크게 낮음을 알 수 있다.




[그림 4-12] # 2(캔류)에 대한 모델별 재현율 비교

데이터셋 # 2(캔류)의 재현율을 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 95.24%, VGG 모델 91.94%, ResNet 모델이 89.55%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 5.25%, 9.25% 재현율이 높게 나타났다. EfficientNet 모델이 VGG 모델보다 ResNet 모델에서 큰 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과도 EfficientNet 모델이 74.53%, VGG 모

델 73.17%, ResNet 모델이 73.33%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 1.36%, 1.20% 재현율이 높게 나타났다. EfficientNet 모델이 VGG 모델과 ResNet 모델에서 1%대 범위에서 아주 근소한 차이를 나타내고 있다.

위 [그림 4-12] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활폐기물 이미지보다 재현율이 크게 낮았지만, 6개의 데이터셋 분류체계에서 전반적으로 두 이미지 군에서 재현율이 가장 높음을 나타내고 있다.




[그림 4-13] # 2(캔류)에 대한 모델별 F1 스코어 비교

데이터셋 # 2(캔류)의 F1 스코어를 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 88.24%, VGG 모델 87.03%, ResNet 모델이 83.92%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 1.21%, 4.32% F1 스코어가 높게 나타났다. EfficientNet 모델이 VGG 모델보다 ResNet 모델에서 큰 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과도 EfficientNet 모델이 63.58%, VGG 모델 63.08%, ResNet 모델이 62.68%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 0.50%, 0.90% F1 스코어가 높게 나타났다. EfficientNet 모델이 VGG 모델과 ResNet 모델에서 1% 범위에서 아주 근소한 차이를 나타내고 있다.

위 [그림 4-13] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활폐기물 이미지보다 F1 스코어가 크게 낮음을 알 수 있다.

(라) 데이터 # 3 (나무류)




[그림 4-14] # 3(나무류)에 대한 모델별 정밀도 비교

데이터셋 # 3(나무류)의 정밀도를 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 80.00%, VGG 모델 81.54%, ResNet 모델이 75.00%로 나와 VGG > EfficientNet > ResNet 모델 순으로 EfficientNet 모델이 각각 VGG 모델보다는 -1.54% 낮게, ResNet 모델보다는 5.00% 정밀

도가 높게 나타났다. EfficientNet 모델이 VGG 모델보다 ResNet 모델에서 큰 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과도 EfficientNet 모델이 52.68%, VGG 모델 50.76%, ResNet 모델이 50.79%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 1.92%, 1.89% 정밀도가 높게 나타났다. EfficientNet 모델이 VGG 모델과 ResNet 모델에서 2% 범위에서 아주 근소한 차이를 나타내고 있다.

위 [그림 4-14] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활폐기물 이미지보다 정밀도가 크게 낮음을 알 수 있다.




[그림 4-15] # 3(나무류)에 대한 모델별 재현율 비교

데이터셋 # 3(나무류)의 재현율을 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 93.33%, VGG 모델 85.48%, ResNet 모델이 82.26%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모

델이 각각 7.85%, 11.07% 재현율이 높게 나타났다. EfficientNet 모델이 VGG 모델보다 ResNet 모델에서 큰 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과도 EfficientNet 모델이 63.76%, VGG 모델 71.86%, ResNet 모델이 63.89%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 타 모델보다 각각 -8.10%, -0.13% 재현율이 낮게 나타났다. EfficientNet 모델이 VGG 모델보다 낮고 한 차이로 높고 ResNet 모델에서 다소 크게 낮은 재현율을 나타내고 있다.

위 [그림 4-15] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활폐기물 이미지보다 재현율이 크게 낮음을 알 수 있다.



[그림 4-16] # 3(나무류)에 대한 모델별 F1 스코어 비교


데이터셋 # 3(나무류)의 F1 스코어를 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 86.15%, VGG 모델 83.46%, ResNet 모델이 78.46%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모

델이 각각 2.69%, 7.69% F1 스코어가 다소 높게 나타났다. EfficientNet 모델이 VGG 모델보다 ResNet 모델에서 큰 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과도 EfficientNet 모델이 57.75%, VGG 모델 59.49%, ResNet 모델이 55.90%로 나와 VGG > EfficientNet > ResNet 모델 순으로 EfficientNet 모델이 각각 -1.74%, 1.85% F1 스코어가 근소하게 나타났다. EfficientNet 모델이 VGG 모델과 ResNet 모델에서 아주 근소한 차이를 나타내고 있다.

위 [그림 4-16] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활폐기물 이미지보다 F1 스코어가 크게 낮음을 알 수 있다.

(마) 데이터 # 4 (도기류)




[그림 4-17] # 4(도기류)에 대한 모델별 정밀도 비교

데이터셋 # 4(도기류)의 정밀도를 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 80.28%, VGG 모델 80.28%, ResNet 모델이

78.57%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 0.00%, 1.71% 정밀도가 같거나 아주 근소하게 나타났다. EfficientNet 모델이 VGG 모델과 ResNet 모델에서 1% 범위에서 아주 근소한 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과도 EfficientNet 모델이 51.82%, VGG 모델 50.15%, ResNet 모델이 51.94%로 나와 ResNet > EfficientNet > VGG > 모델 순으로 EfficientNet 모델이 각각 VGG 모델보다는 1.67% 높게, ResNet 모델보다는 -0.12% 정밀도가 낮게 나타났다. EfficientNet 모델이 VGG 모델보다 근소한 차이로 높고 ResNet 모델에서 근소한 차이로 낮게 차이를 나타내고 있다.

위 [그림 4-17] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활폐기물 이미지보다 정밀도가 크게 낮음을 알 수 있다.




[그림 4-18] # 4(도기류)에 대한 모델별 재현을 비교

데이터셋 # 4(도기류)의 재현율을 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 96.61%, VGG 모델 91.94%, ResNet 모델이 88.71%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 4.67%, 7.90% 재현율이 높게 나타났다. EfficientNet 모델이 VGG 모델보다 ResNet 모델에서 큰 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과도 EfficientNet 모델이 78.10%, VGG 모델 57.14%, ResNet 모델이 65.69%로 나와 EfficientNet > ResNet > VGG 모델 순으로 EfficientNet 모델이 각각 12.41%, 20.96% 재현율이 높게 나타났다. EfficientNet 모델이 ResNet 모델보다 다소 높고 VGG 모델에서 큰 차이를 나타내고 있다.

위 [그림 4-18] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활폐기물 이미지보다 재현율이 전반적으로 26.63%에서 ~ 30.13%의 높은 차이를 나타내고 있다.




[그림 4-19] # 4(도기류)에 대한 모델별 F1 스코어 비교

데이터셋 # 4(도기류)의 F1 스코어를 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 87.69%, VGG 모델 85.72%, ResNet 모델이 83.33%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 1.97%, 4.36% F1 스코어가 높게 나타났다. EfficientNet 모델이 VGG 모델과 ResNet 모델에서 1% 범위에서 아주 근소한 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과도 EfficientNet 모델이 62.30%, VGG 모델 53.42%, ResNet 모델이 58.01%로 나와 EfficientNet > ResNet > VGG 모델 순으로 EfficientNet 모델이 각각 4.29%, 8.88% F1 스코어가 높게 나타났다. EfficientNet 모델이 VGG 모델과 ResNet 모델에서 다소 큰 차이를 나타내고 있다.

위 [그림 4-19] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활폐기물 이미지보다 F1 스코어가 크게 낮음을 알 수 있다.

(바) 데이터 # 5 (플라스틱류)




[그림 4-20] # 5(플라스틱류)에 대한 모델별 정밀도 비교

데이터셋 # 5(플라스틱류)의 정밀도를 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 84.06%, VGG 모델 83.58%, ResNet 모델이 78.08%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 0.48%, 5.98% 정밀도가 높게 나타났다. EfficientNet 모델이 VGG 모델과 ResNet 모델에서 5%대 범위에서 다소 근소한 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과도 EfficientNet 모델이 59.26%, VGG 모델 54.83%, ResNet 모델이 57.55%로 나와 EfficientNet > ResNet > VGG 모델 순으로 EfficientNet 모델이 각각 1.71%, 4.43% 정밀도가 높게 나타났다. EfficientNet 모델이 VGG 모델과 ResNet 모델에서 5% 범위에서 다소 근소한 차이를 나타내고 있다.

위 [그림 4-20] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활폐기물 이미지보다 정밀도가 크게 낮음을 알 수 있다.




[그림 4-21] # 5(플라스틱류)에 대한 모델별 재현율 비교

데이터셋 # 5(플라스틱류)의 재현율을 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 95.08%, VGG 모델 90.32%, ResNet 모델이 93.44%로 나와 EfficientNet > ResNet > VGG 모델 순으로 EfficientNet 모델이 각각 4.76%, 1.64% 재현율이 높게 나타났다. EfficientNet 모델이 VGG 모델과 ResNet 모델에서 5% 범위에서 다소 근소한 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과도 EfficientNet 모델이 70.80%, VGG 모델 67.25%, ResNet 모델이 72.95%로 나와 ResNet > EfficientNet > VGG 모델 순으로 EfficientNet 모델이 각각 -2.15%, 3.55% 재현율이 높게 나타났다. EfficientNet 모델이 VGG 모델보다 아주 근소한 차이로 낮고 ResNet 모델에서 근소한 차이를 나타내고 있다.

위 [그림 4-21] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활폐기물 이미지보다 재현율이 크게 낮음을 알 수 있다.



[그림 4-22] # 5(플라스틱류)에 대한 모델별 F1 스코어 비교

데이터셋 # 5(플라스틱류)의 F1 스코어를 보면 전체 이미지에 대한 모델별 결과를 보면 EfficientNet 모델이 89.23%, VGG 모델 86.86%, ResNet 모델이 85.07%로 나와 EfficientNet > VGG > ResNet 모델 순으로 EfficientNet 모델이 각각 2.37%, 4.15% F1 스코어가 높게 나타났다. EfficientNet 모델이 VGG 모델과 ResNet 모델에서 5% 범위에서 다소 근소한 차이를 나타내고 있다.

부분 이미지에 대한 모델별 결과도 EfficientNet 모델이 64.52%, VGG 모델 60.41%, ResNet 모델이 64.34%로 나와 EfficientNet > ResNet > VGG 모델 순으로 EfficientNet 모델이 각각 0.85%, 7.53% F1 스코어가 높게 나타났다. EfficientNet 모델이 VGG 모델과 ResNet 모델에서 5% 범위에서 다소 근소한 차이를 나타내고 있다.

위 [그림 4-22] 차트 결과를 볼 때 부분 이미지인 음식물쓰레기 이물질 이미지가 전체 이미지인 생활폐기물 이미지보다 F1 스코어가 크게 낮음을 알 수 있다.

지금까지 전체 이미지와 부분 이미지에 적용된 모델별 분류 결과를 보았다. 결론적으로, 플라스틱류를 측정하기 우수한 모델은 ResNet 모델이고, 캔류는 VGG 모델, ResNet 모델이 있으나 조금 더 높은 성능을 VGG 모델이, 비닐류는 단연 EfficientNet 모델로 나타났다.

4) EfficientNet 모델 적용한 집하장 이미지 분류 결과

우리는 앞서 전체 이미지와 부분 이미지에 대한 딥러닝 알고리즘 모델별 실험을 통하여 EfficientNet 모델이 가장 높은 정확도가 나타났음을 알 수 있었다. 그렇다고 하면 실제 집하장에서의 음식물쓰레기 이물질을 얼마나 잘 분류하는지 가장 정확도가 높게 나타난 EfficientNet 모델로 실험하였다.



[그림 4-23] 집하장 음식물쓰레기 이물질 선별 작업대




[그림 4-24] 집하장 음식물쓰레기 이물질 이미지

실험 측정에 대한 성능평가를 전부 이미지와 부분 이미지 결과와 함께 정밀도, 재현율, F1 스코어에 대한 비교 분석을 하였다.

[표 4-7] 집하장 이미지 EfficientNet 분류 모델 분류 결과

	Precision	Recall	F1-Score	Support
# 0	0.6312	0.8436	0.7221	185
# 1	0.7383	0.8434	0.7874	240
# 2	0.7129	0.8926	0.7927	216
# 3	0.6742	0.8696	0.7595	120
# 4	0.6860	0.8850	0.7729	180
# 5	0.6630	0.9412	0.7780	240
accuracy			0.7545	1,181
macro avg	0.6843	0.8792	0.7688	1,181
weighted avg	0.6843	0.8792	0.7688	1,181

먼저, 집하장에서 측정한 결과 내용을 보면, 집하장에서의 측정은 기존과 비슷하게 6개의 카테고리로 측정하였다. [표 4-7]과 같이 # 0(고철류) 185개, # 1(비닐류) 240개를 포함하여 전체 1,181개에 대한 이물질에 대해 측정을 하였다. 그 결과 전체적인 정확도는 68.43%이고 정밀도 평균은 87.92%, F1 스코어 평균은 76.88%로 나타났다.




[그림 4-25] EfficientNet 모델의 카테고리별 정밀도 비교

먼저, 정밀도에 대한 비교 분석 결과는 [그림 4-25]와 같다. 전반적으로 집하장 이미지가 부분 이미지보다는 상당히 높은 정밀도를 나타내고 있다. 이는 전체 이미지와 부분 이미지에 대한 학습된 결과를 가지고 테스트하였기에 나타난 결과라고 볼 수 있다. 전체 이미지는 평균 81.80%이고 부분 이미지는 55.28%, 집하장 이미지 68.42%로 전체 이미지에 대한 부분 이미지 차가 26.51% 임을 감안하면 집하 이미지는 전체 이미지의 13% 범위에서 높은 정밀도를 나타내고 있다.



[그림 4-26] EfficientNet 모델의 F1 스코어와 정확도 비교

다음은 F1 스코어와 정밀도를 비교 분석한 결과로 [그림 4-26]와 같다. F1 스코어가 정확도보다 집하장 이미지가 76.88%로 부분 이미지 62.23%보다 높게 나타났으며, 전체 이미지 87.49%의 10% 범위에서의 차이를 보이고 있고, 정확도는 집하장 이미지가 75.45%로 부분 이미지 74.89%와 비슷한 정확도를 나타내고 있지만, 이 역시 전체 이미지 85.69%의 10% 범위에서 정확도를 나타내고 있다.



[그림 4-27] EfficientNet 모델의 정밀도와 재현율 비교

마지막으로 [그림 4-27]은 F1 정밀도와 재현율을 비교 분석한 결과이다. 정밀도는 집하장 이미지가 68.43%로 부분 이미지 55.29%보다 매우 높게 나타났다으며, 전체 이미지 81.80%의 13% 범위에서의 차이를 보이고 있고, 재현율은 집하장 이미지가 87.92%로 부분 이미지 71.52%보다 월등히 높게 나타났다으며, 전체 이미지 94.08%의 6% 범위에서 높은 재현율을 나타내고 있다. 전체적으로 집하 이미지가 부분 이미지보다 F1 스코어, 재현율, 정밀도가 월등히 높게 나타났으며, 전체 이미지의 10% 범위에서 근접한 결과를 나타내고 있음을 알 수 있고, 이는 집하장에서의 분류가 잘 이루어질 수 있음을 입증하는 유의미한 결과라고 볼 수 있다.

제 3 절 연구의 성과

1) 이물질 구분시스템의 기대 효과

본 연구에서 제안하는 이물질 구분시스템은 크게 세 가지의 기대 효과를 얻을 수 있다.

가) 인적자원 감소 및 안전사고 예방

이물질 구분시스템을 통해 얻을 수 있는 가장 큰 효과는 인적자원 감소이다. 기존에는 작업자들이 배치되어 수작업으로 분류 작업하던 방식을 본 시스템의 활용으로 이물질로 인해 투입되는 작업자의 업무량이 줄어들어 업무시간을 크게 단축하여 준다. 현재 수작업을 위해 투입되는 인원이 보통 4~5명이라고 한다. 시스템을 도입하면 설비관리를 위한 인원 1명이면 가능할 것으로 기대된다. 업무량 절감뿐만 아니라 위생적이고 편리한 작업으로 인해 끼임 사고 등 안전사고 예방을 할 것으로 기대할 수 있다. 특히나 요즘 인력 시장에 있어 3D 업종은 인력 채용도 힘든 만큼 이러한 애로사항을 해결할 수 있고 탄력적으로 근무를 할 수 있다.

나) 처리시설 운영 예산 및 유지보수 절감

음식물쓰레기에 혼합 배출된 비닐, 사골 뼈, 수저와 같은 이물질이 투입구나 이송로 끼임으로 인해 과부하를 일으켜 처리시설의 고장의 원인이 되고 있고 한번 고장이 나면 이를 수리하기 위해 민간에 의뢰하는데 통상 8천여만원의 비용이 들어가고 연간 수십억의 고비용 들고 있다.

예를 들어 연간 10억의 비용이 든다고 했을 때 이를 절반으로 줄인다고 해도 5억의 비용 절감 효과가 있는 것이다. 이 비용도 문제지만 이로 인한 시설가동을 하지 못해 음식물쓰레기 처리가 지연되어 더 큰 문제가 발생한다.

이 시스템 도입으로 음식물쓰레기 이물질 제거가 사전에 되기 때문에 막대한 유지보수비가 크게 절감되고 시설의 내수 수명도 길어져 자원 활용에 경쟁력 강화를 기대할 수 있다.


다) 2050 탄소중립 기여

기후 위기의 현 상황인 요즘 전 세계에서 버려지는 음식물쓰레기는 9억 3,100톤에 이른다고 한다. 이는 글로벌 온실가스 전체 배출량의 8~10%를 차지하는 것이다. 본 시스템의 활성화로 2050년 탄소중립 실현을 위한 탄소 제로! 음식물쓰레기를 줄이는 음쓰 제로! 화로 음식문화 개선할 것으로 기대된다.

2) 이물질 구분시스템의 시사점

가) 시스템 자동화 체계 구축

기존 방식에서 이물질 구분시스템을 활용하여 각 집하장 설비에 맞게 자동화 설비에 대한 체제 구축이 가능할 것으로 본다. 즉, 이물질 분류시스템에 의해서 이물질 제거를 위한 시스템을 체계화하는 것이 가능할 것으로 기대된다.



[그림 4-28] 이물질 제거 시스템

[그림 4-28]은 향후 이물질 제거 시스템을 위한 흐름도이다. 즉, 1단계에서는 가벼운 비닐류나 플라스틱류 이물질을 제거하고, 2단계에서 고철류 등 자석으로 제거가 가능한 것을 제거하고, 3단계에서는 작업자가 직접 수작업으로만 가능한 이물질을 제거하는 방식이다. 또한, 이물질 혼합 통계 자료로 활용이 가능할 것으로 기대된다. 예를 들어 어떤 이물질이 섞이고, 어디서 이물질 들어오는지에 대한 통계 자료 활용이 가능하다.

나) 1차 수거지 음성안내 서비스 제공

본 이물질 구분시스템 연구는 집하지 문제로 시작하였지만 집하지에서 문제점은 근본적으로 1차 수거지인 가정이나 상가에서 비롯되었으므로 이 시스템을 1차 수거지에 그간 축적된 데이터를 활용하여 카메라를 설치하여 배출자들이 수거통에 버릴 때 이물질 발견 시 음성으로 안내하여 이물질이 혼입되지 않도록 사전 예방과 생활용품 분실 예방 효과가 있을 것으로 본다.

다) 고객의 니즈 반영

본 시스템이 1차 수거지인 상가에 반영이 된다고 하면 수거통이나 주변에 설치된 카메라로 배출된 음식을 분석할 수 있을 것으로 본다. 즉, 고객이 어떤 음식을 좋아하고 싫어하는지를 배출된 음식을 통해서 고객만족도를 분석할 수 있고 이를 분석한 데이터로 향후 음식 개발에 바로 피드백이 가능할 것으로 본다.

제 5 장 결 론

우리의 일상생활은 의식주로 시작한다. 그중에서도 먹는 것은 빼놓을 수 없는 부분이다. 하루에 버리는 쓰레기는 54만 872톤에 이른다. 연간 약 1.1억 톤이 배출되며 이는 15톤 트럭 1,300만 대 분량이다. 특히나 지난 3년 가까이 코로나19로 인해서 사회적 거리두기를 하면서 비대면 하는 시간이 늘어나면서 택배와 음식을 시켜서 먹는 배달 음식이 2019년 대비 8.8% 증가하게 되었다(한국환경공단 2022.1). 코로나19 이전에도 음식물쓰레기로 사회적, 경제적 문제가 대두되고 있었는데 배달 음식문화가 활성화되면서 환경 문제로 더욱 시급한 과제가 되었다. 국제적으로도 이러한 문제가 대두되면서 2050 탄소 중립화를 각국에서는 선언하고 이에 대한 실천 대책을 마련하고 있다.

2012년부터 시행해온 음식물쓰레기 종량제를 돌이켜 보면서 음식물쓰레기 감량 효과도 있지만 다른 한편으로는 음식물쓰레기 이물질로 인한 인적자원 및 설비파손으로 피해 규모가 의외로 크다는 뉴스를 통해 종종 들을 수 있다. 본 연구에서는 사회적 문제로 대두되고 있는 음식물쓰레기 이물질과 국제적으로 심각한 환경 문제로 부각이 되는 이산화탄소 제로화에 기여를 위해서 딥러닝 알고리즘 모델을 통해서 음식물쓰레기 이물질 구분을 위한 시스템을 구현하고자 하였다.

본 연구에서는 이물질 구분시스템을 위해서 이미지 기반 딥러닝 알고리즘 모델인 VGG, ResNet, EfficientNet 3개의 모델을 제시하였다. 3개의 모델들은 우수한 성능을 지닌 이미지 기반 모델들이다. 테스트 데이터셋은 이물질 관련 이미지 수집이 한계가 있는 점을 감안하여 공개데이터 사이트인 AI-허브 데이터인 생활 폐기물 이미지 중에서 음식물쓰레기에 이물질로 혼입될 만한 이미지로 온전한 전부 이미지로 일차적으로 측정하였고, 두 번째 측정은 음식물쓰레기에 다양한 형태의 이물질이 있을 것을 가정하여 데이터 증식, 전이 학습, 다양한 각도에서의 부분 슬라이스 이미지인 부분 이미지를 가지고 실험하였다. 끝으로, 집하장 현장의 이미지를 대상으로 1, 2차 측정에서 우수

한 정확도를 나타낸 알고리즘 모델인 EfficientNet 모델로 실험하였다.

첫 번째와 두 번째 시험 결과는 전부 이미지가 부분 이미지보다 20~30% 높은 정확도를 나타냈고, 가장 높은 정확도를 보인 모델은 EfficientNet 모델이 선정되었다. 다음으로는 VGG, ResNet 순이었다. 6개의 카테고리에서는 다소 차이가 있는데 먼저 전부 이미지에서는 # 5 (플라스틱류)가 높은 정확도(84.06%)를 나타내고 # 3 (나무류)가 가장 낮게(80.00%) 나타났다. 부분 이미지에서는 # 1 (비닐류)가 높게(30.25%) 나타나고, # 4 (도기류)가 낮게(51.82%) 나타났다. 부분 이미지에서 # 1 (비닐류)가 높게 나타나는 것은 그만큼 현 음식물쓰레기 이물질에 다양한 비닐류가 포함되어 있다는 걸 알 수 있다. 현재의 데이터로는 층이 깊은 학습을 시키기에는 부족함이 있음을 확인했다. 마지막 실험 결과는 높은 정확도를 보인 EfficientNet 모델로 집하장 현장 이미지로 측정을 한 결과 전부 이미지 측정 결과의 10% 범위에서 높은 정밀도 및 재현율, F1 스코어를 나타냈지만, 정확도는 부분 이미지와 별반 차이가 없음을 나타냈다. 이는 성능개선을 위해서는 추가적인 대량의 데이터 확보를 통해 모델 학습하면 더 높은 분류성능이 나타날 것으로 기대한다.

향후 추가되는 연구를 통해 좀 다양한 개선된 모델링을 통해 학습시키면 정확도를 지금보다 더 많이 높아진다고 하면 작업자의 안전과 설비 수명 연장으로 경제적 비용이 많이 절감될 것으로 본다.

이외에 음식물 낭비와 음식물쓰레기의 환경적인 영향에 대한 인식이 증가와 지속 가능성이 관련된 소비자의 생활방식이 변화하고 있어 음식물쓰레기 처리와 관련하여 제품에 대한 수요는 지속적으로 증가할 것으로 예상된다. 연구개발을 통해서 음식물쓰레기 통합관리 솔루션이나 음식물쓰레기 처리 관련 제품으로 새로운 시장 진출 기회를 도모할 수 있을 것으로 기대된다.

생활 폐기물 이미지로 학습된 모델을 활용하여 주민이 직접 스마트폰으로 앱으로 대형폐기물 사진을 찍어 등록하면 이를 인식하여 폐기물 자동 분류하고 수수료 안내하고 해당 주민 해당 수수료를 결제하면 앱에서 배출일시 및 위치 정보를 수거업체에 안내하여 신속하게 처리하는 시스템을 추가적으로 응용할 수 있을 것으로 기대한다.

참 고 문 헌

1. 국내문헌

- 강남구 보건소. <https://health.gangnam.go.kr>
- 강병모, 홍인식. (2017). RFID와 NFC 태그를 이용한 상수도 시설물 자산관리 시스템에 관한 연구. 『Journal of The Korea Knowledge Information Technology Society(JKITS)』, 12(3), 447-456.
- 고광은, 심귀보. (2017). 딥러닝을 이용한 객체 인식 및 검출 기술 동향. 『제어로봇시스템학회지』, 23(3), 18.
- 구훈영. (2010). RFID 도입을 위한 경제성분석 방안에 관한 연구 : 택배 물류 산업을 중심으로. 『한국전자거래학회지』, 15(1), 11-137.
- 국민일보. <https://m.kmib.co.kr/view.asp?arcid=0922697553>
- 권철민. (2022). 『파이썬 머신러닝 완벽 가이드』, 서울: 위키북스
- 김동건. (2022). 합성곱 신경망을 이용한 COVID-19 예측=Prediction of COVID-19 Using Convolutional Neural Network, 계명대학교 대학원 석사학위논문.
- 김범석. (2018). 컨볼루션 신경망을 이용한 쓰레기 분류 연구, 울산대학교 대학원 석사학위논문.
- 김병근. (2022). ResNet을 이용한 카메라 모듈 얼룩불량 검출, 충북대학교 대학원 석사학위논문.
- 김은수. (2021). EfficientNet을 이용한 악성코드 이미지 유형 분류 = Classification of malware image types using EfficientNet, 아주대학교 대학원 석사학위논문.
- 김지훈, 이대식, 이민호. (2016). CNN을 사용한 차선검출 시스템, 대한임베

- 디드공학회논문지, 11(3), 163-171.
- 김진성, 송재열, 김하얀, 이진국. (2017). 딥러닝 기반 이미지 자동인식 기술을 활용한 사무집기 자동인식과 정보관리 시스템과의 연동방안. 『한국퍼실리티매니지먼트학회논문집』, 12(2), 73-80.
- 나무위키. <https://namu.wiki/w/RE100>
- 노은솔, 이사랑, 김민수, 홍석무. (2020). CNN 및 모델 시각화 기법을 사용한 코팅 볼트 불량 판별, 대한기계학회, 44(11), 835-842.
- 녹색성장위원회, (2010). 『음식물쓰레기 줄이기 종합대책』, 환경부
- 대전광역시 생활정보. <https://www.daejeon.go.kr>
- 라우포조니백. (2021). Steel Surface Defect Detecting Using EfficientNet Neural NetWork, 전남대학교 일반대학원 석사학위논문.
- 박재람. (2021). 생활폐기물 고형연료화 시설에서 배출되는 선별 잔재물의 Bio-drying 공정 적용에 관한 연구. 서울시립대학교 대학원 박사학위논문.
- 박재현, 김철홍. (2022). CNN 기반 딥러닝을 이용한 베어링 고장 진단의 정확도 및 계산 복잡도 분석, 한국차세대컴퓨팅학회, 18(1), 7-18.
- 박진현, 황광복, 박희문, 최영규. (2019). 어종 분류를 위한 CNN의 적용, 한국정보통신학회논문지, 23(1), 39-46.
- 박차길, 이선규. (2008). RFID 응용 기술의 도입에 미치는 영향 요인에 관한 연구. 『한국산학기술학회』, 9(4), 1018-1029.
- 박해선. (2020). 『혼자 공부하는 머신러닝+딥러닝』, 서울: 한빛미디어
- 박혜빈. (2022). 전이 학습을 이용한 흑색종 병변 부위 크기 식별 연구, 경북대학교 대학원 석사학위논문.
- 박희준, 압둘 레만, 이창형, 진성훈, 강승택. (2019). 『RFID 태그 안테나들의 초근접 시의 격리도 및 전기적 특성을 향상시키는 설계』. 대한전기학회, 68(2), 334-341.

- 방희석, 강동준, 나정호. (2009). RFID 시스템의 도입요인과 효과에 관한 연구. 『전자무역연구』, 7(1), 65-89.
- 변민지, 전은주, 김지수, 황재준, 정승화. (2021). VGG-16 딥러닝 알고리즘을 활용한 우식 치아와 건전 치아 분류, Journal of Korean Academy of Oral Health, 45(4), 227-232.
- 서지영. (2021). 『딥러닝 텐서플로 교과서』, 서울: 길벗
- 세바스찬 라시카, 바히드 미자리리, 박해선. (2021). 『머신러닝 교과서 with 파이썬, 사이킷런, 텐서플로(개정 3판)』, 서울: 길벗
- 오정익, 이현정, 석희진. (2010). 음식물쓰레기 자원화를 위한 공동주택 거주자의 음식물쓰레기 배출량 및 자원화 의향에 관한 분석. 『대한환경 공학회지』, 32(10), 905-915.
- 윙뉴스. (<https://www.wip-news.com/news/articleView.html?idxno=13422>)
- 윤여찬, 상종희, 박수영. (2018). 이미지 기반의 식물 인식 기술 동향. 『한국 전자통신연구원』, 전자통신동향분석, 33(4), 54-60.
- 이기성. (2015). 음식물쓰레기 자원화 산업에서의 공유가치창출(CSV) 모델에 관한 연구:E사를 중심으로. 한양대학교 기업경영대학원 석사학위논문.
- 이사빈. (2017). 음식물 쓰레기 종량제 RFID 도입요인과 효과성 분석. 서울 대학교 대학원 박사학위논문.
- 이주열. (2020). 인공지능 이미지 인식 기술 동향. 『한국정보통신기술협회』, TTA Journal, 187, 44-51.
- 임세현, 정남호. (2010). 성공적인 RFID 도입에 있어서 정보기술 역량의 영향 : 기대 효익, 신뢰 그리고 위험의 역할. 『대한경영학회지』, 23(5), 2543-2563.
- 자원순환보급금관리센터. <https://www.cosmo.or.kr/home/main.do>
- 정해준, 한대희, 장태우, 김현수. (2010). 제조업 중심의 RFID 시스템 ROI 분석 프레임워크. 『한국로지스틱스학회』, 18(1), 103-120.

조재형. (2019). RFID 태그를 이용한 실내 위치 추적 시스템에 관한 연구.

『디지털융복합연구』, 17(12), 211-217.

최종희, 김수엽, & 이호춘. (2007). 향만물류 선진화를 위한 RFID 기술 도입 방안. 연구보고서, 1-182.

티아미스 스터디 블로그.

<https://tyami.github.io/machine%20learning/ensemble-1-basics/>

폐기물관리법시행규칙 별표 4(제4조의2제1항 관련). (<https://www.law.go.kr>)

프랑소와 솔레, 박해선. (2022). 『케라스 창시자에게 배우는 딥러닝 개정 2판, 서울:길벗

한국환경공단, (2013). 『RFID 음식물쓰레기 관리체계 사업 및 운영관리 매뉴얼(수정본)』, 환경부

환경오염에 대한 경각심.

(<https://blog.naver.com/mynameisatolee/222364158589>)

2. 국외문헌

- A. Sepas-Moghaddam, & F. Pereira. (2019). A Double-Deep Spatio-Angular Learning Framework for Light Field-Based Face Recognition, in IEEE Transactions on Circuits and Systems for Video Technology, 30(12), 4496-4512.
- AI-허브. <https://www.aihub.or.kr/>
- Angeles, R. (2009). Anticipated IT infrastructure and supply chain integration capabilities for RFID and their associated deployment outcomes. International Journal of Information Management, 29(3), 219-231.
- B. Li and Y. He. (2018). An Improved ResNet Based on the Adjustable Shortcut Connections, in IEEE Access, 6, 18967-18974.
- C. S. Won. (2020). Multi-Scale CNN for Fine-Grained Image Recognition, in IEEE Access, 8, 116663-116674.
- GitHub Gist. <https://gist.github.com/yrevar/942d3a0ac09ec9e5eb3a>
- Haque, M. F., Lim, H. Y., & Kang, D. S. (2019). Object detection based on VGG with ResNet network. In 2019 International Conference on Electronics, Information, and Communication (ICEIC), 1-3.
- J. Kim, A. -D. Nguyen and S. Lee. (2019). Deep CNN-Based Blind Image Quality Predictor, in IEEE Transactions on Neural Networks and Learning Systems, 30(1), 11-24.
- K. Simonyan and A. Zisserman. (2014). Very deep convolutional networks for large-scale image recognition, arXiv Prepr.arXiv1409.1556, 1-14.
- Karen simonyan, Andrew Zisserman. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition, Published as a conference paper at ICLR 2015, 1-14.

- Kaur, T., & Gandhi, T. K. (2019). Automated brain image classification based on VGG-16 and transfer learning. In 2019 International Conference on Information Technology (ICIT), 94–98.
- Lim, P., Goh, C. K., & Tan, K. C. (2016). Evolutionary cluster-based synthetic oversampling ensemble (eco-ensemble) for imbalance learning. *IEEE transactions on cybernetics*, 47(9), 2850–2861.
- M. A. Dede, E. Aptoula and Y. Genc. (2019). Deep Network Ensembles for Aerial Scene Classification, in *IEEE Geoscience and Remote Sensing Letters*, 16(5), 732–735.
- Roy, S. K., Krishna, G., Dubey, S. R., & Chaudhuri, B. B. (2019). HybridSN: Exploring 3-D–2-D CNN feature hierarchy for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 17(2), 277–281.
- Song, S., Lam, J.C., Han, Y., & Li, V.O. (2020). ResNet–LSTM for Real–Time PM_{2.5} and PM₁₀ Estimation Using Sequential Smartphone Images. *IEEE Access*, 8, 220069–220082.
- Taranjit Kaur, Tapan Kumar Gandhi. (2019). Automated brain image classification based on VGG-16 and transfer learning, 2019 International Conference on Information Technology (ICIT), 94–98.
- V7. <https://www.v7labs.com/blog/transfer-learning-guide>
- X. Liu, Z. Liu, G. Wang, Z. Cai and H. Zhang. (2018). Ensemble Transfer Learning Algorithm, in *IEEE Access*, 6, 2389–2396
- Y. Jiang, Y. Li and H. Zhang. (2019). Hyperspectral Image Classification Based on 3-D Separable ResNet and Transfer Learning, in *IEEE Geoscience and Remote Sensing Letters*, 16(12), 1949–1953.

ABSTRACT

A Study on the Application of Deep Learning for Foreign Object Classification in Food Waste

Kim, Yong-II

Major in Smart Convergence Product

Dept. of Smart Convergence Consulting

The Graduate School

Hansung University

There is something that has increased with the rapid development of modern society into industrialization. Those are all kinds of household waste and food waste around us. Moreover, due to COVID-19, which began at the end of 2019, social distancing has led to more time indoor activities than outdoor ones for nearly two and a half years. As a result, the food delivery culture has developed and disposable containers and food waste have increased.

Disposal of food has become a social issue because it is included in the food waste that we inadvertently throw away. The foreign objects in the food waste that are mixed and discarded in this way must be collected by someone during the recycling process. For this purpose, food waste resource conversion facilities are installed and the refined food waste usually are used for composting and feeding. The main purpose of

waste recycling is to reduce costs and protect the environment by reducing food waste. However, maintenance costs are increasing due to facility damage caused by foreign objects in the food waste filtering and collecting process. In fact, these problems can be easily solved by using food handlers that can be used at home, which are often seen in TV commercials these days. However, there is a real problem. Most of the pulverized food handlers are sink-installed disposals, which is a method of pulverizing food first and discharging food treated secondarily. However, there is an illegal controversy because the nation's sewage law prohibits the discharge of more than 20 percent of pulverized food into sewage. And also other products are controversial due to the burden of filter costs, electricity bills, and odor problems.

Therefore, this study recognizes these problems and attempts to solve them by using a deep learning model to classify foreign objects in food waste. In order for the experiment for learning process, all the public data was collected through AI Hub, an open data site. We tried to find the optimal model through comparative analysis by applying it to various models of deep learning. Based on the collected data, three models of image-based classification algorithms VGG, ResNet, and EfficientNet of deep learning were selected.

The experimental method is as follows. First, the image of household waste is tested after learning and verifying. Usually the data classified as household waste images were actually decomposed and mostly mixed with food waste, so the comparative measurement was to learn, verify, and test with similar images obtained through data growth and transfer learning. Six classification models were created for each algorithm to measure the classification accuracy of the test data of each data set. The EfficientNet model was the most accurate through the two experimental measurements, and the final measurement was not higher

than the entire image, but the accuracy was not much different from the partial image, although it was much higher than the partial image.

Based on the above results, the proposed idea in this paper would be used to classify foreign objects in collection centers and private facilities. It is expected that workers at collection centers would show high productivity and also automation systems for recycling resources would be deployed quickly with better working environments and safe working and stable facilities. And it could be expected that we can greatly contribute to carbon neutralization if we can recycle resources by separating and operating systematically.

【keyword】 Deep Learning, Foreign Object Classification, Artificial Intelligence, Carbon Neutrality, EfficientNet

감사의 글

학위논문을 마치면서 가장 먼저 본 논문이 있기까지 4년간 믿음을 가지고 끝까지 격려와 아낌없는 배려, 마지막까지 세심하게 검토를 해주신 김승천 교수님께 깊은 감사를 드립니다. 그리고 논문의 형식과 완성도를 위해서 질책과 조언을 아낌없이 해주신 노광현 교수님, 홍정완 교수님, 임황용 박사님, 임진호 박사님께도 감사드립니다.

항상 곁에 있으면서 학업에 지원을 아끼지 않으시고 따뜻한 배려를 해주신 이정호 대표이사님께 깊은 감사의 말씀을 드리고 보답이 되었으면 합니다. 또한, 이번 논문 준비과정에서 실습에 대한 전폭적인 지원을 해주신 김성훈 박사님, 긴장을 늦추지 않도록 해주신 이정우 박사님과 동기이자 먼저 학위를 취득하신 미안함에 적극적으로 협조를 해주신 김재표 박사님께도 여러모로 받은 도움에 감사를 표하고 싶습니다. 2022년도 1년 동안 논문 준비를 위해 같이 동고동락하면서 이번에 학위를 같이 받게 될 예비 박사 김철림 대표, 류태하 수석에게도 축하의 인사를 전합니다.

마지막으로 남편을 위해 뒷바라지를 마다하지 않고 적극적인 지원과 믿음과 할 수 있다는 따뜻한 격려를 해준 아내에게 보답이 되었으면 합니다. 또한, 몇 년간 시간이 없다는 핑계로 같이 자주 함께 해주지 못했음에도 잘 자라준 두 아들 윤중, 효중에게도 미안함과 오늘이 있기까지 항상 큰아들 걱정 에 노심초사하시는 어머님과 지금은 함께 하지 못하지만, 항상 나의 인생에 롤 모델이 되어준 아버님, 그리고 형제들, 지금 지병으로 인해 병상에 누워 계시는 큰어머님의 빠른 쾌차를 빌면서 또한, 많은 친·인척분들, 작고하신 장인어른과 장모님, 장인·장모님의 역할을 해주시는 처형과 형님, 이모부를 신뢰와 격의 없이 잘 따르는 재준, 정인 두 조카를 생각하면서 이번 계기로 가족의 소중함을 새삼 느끼면서 항상 함께 해준 가족들에게 논문을 바칩니다.

2022년 12월 김용일 드림