

Deep Learning 기반의 폐기물 선별 Vision 시스템 개발

한봉석¹ · 권혁원² · 신봉철[†]

(주)엔에이치씨 CEO¹, (주)엔에이치씨 기술연구소², 인하대학교 기계공학과[†]

Development of Deep Learning based waste Detection vision system

Bong-Seok Han¹ · Hyeok-Won Kwon² · Bong-Cheol Shin[†]

President & CEO, NHC Inc.¹; President & CEO, R&D Team, NHC Inc.²

Department of Mechanical Engineering, Inha National University[†]

(Received November 16, 2022 / Revised December 28, 2022 / Accepted December 31, 2022)

Abstract: Recently, with the development of industry and the improvement of living standards, various wastes are generated along with the production of various products. Most of these wastes are used as containers for products, and plastic or aluminum is used. Various attempts are being made to automate the classification of these wastes due to the high labor cost, but most of them are solved by manpower due to the geometrical shape change due to the nature of the waste. In this study, in order to automate the waste sorting task, Deep Learning technology is applied to a robot system for waste sorting and a vision system for waste sorting to effectively perform sorting tasks according to the shape of waste. As a result of the experiment, a Deep Learning parameter suitable for waste sorting was selected. In addition, through various experiments, it was confirmed that 99% of wastes could be selected in individual & group image learning. It is expected that this will enable automation of the waste sorting operation.

Key Words: Deep Learning, Detection, Robot, Vision, Waste

1. 서 론

최근 산업의 발달 및 제조 생산 시스템의 발전으로 인해 다양한 제품의 생산이 이루어지고 있는 상황이다. 이러한 다양한 제품들의 경우 포장을 위한 알루미늄 및 플라스틱 사출성형품을 이용하여 포장 및 용기로 사용하고 있고 이는 다시 재활용할 수 있다는 장점이 있다. 하지만 플라스틱의 경우 무분별한 사용으로 인해 해마다 사용량이 증가되고 있고 따라서 폐기물의 사용량도 증가하고 있는 실정이다. 이러한 현상은 플라스틱 포장 및 용기 제품의 경우 사출공정으로 제작이 쉽고 대량 생산이 가능하여 아직도 다양한 분야에서 많이 사용하고 있는 실정이다.

1. (주)NHC : 대표이사
† 인하대학교 : 기계공학과
E-mail: 220351@inha.ac.kr

기존에는 다양하게 혼합된 폐기물을 인력을 이용하여 소재별로 분류하고 이를 다시 재활용하려는 의지와 분위기가 조성되고 또한 대체 제품인 친환경 소재로의 변화를 추구하고 있다.¹⁾

폐기물 분류를 통해 폐기물의 재활용 비율을 증가해야 하는 현재 상황에서는 인력을 이용한 방법에 한계성이 있다. 폐기물 양에 따른 물류 작업을 위해 많은 인력이 필요하고 이로 인한 인건비 상승이 필수적으로 발생하게 된다.

이를 개선하기 위해서는 자동화가 필수적으로 필요성이 대두되고 있고 이와 같은 형상 인식시스템에 관한 연구가 오래전부터 다양하게 이루어지고 있다. 금형 형상 판별을 위해 정형화된 형상을 vision을 통해 형상 인식하여 사물의 분류를 2차원 그래픽으로 구현하는 방법이 있었으며 최근에는 사물의 인식성을 보다 효과적이고 인식율을 높이기 위해 AI, Deep Learning과 같은 시스템을 접목하여

보다 형상 인식을 효과적으로 하는 방법의 연구가 진행되고 있다.²⁻⁵⁾

하지만 대부분의 연구는 정형화된 형상을 이용하여 학습을 통해 물체 및 형상 등을 인식하는데 쓰레기 또는 폐기물의 경우 정형화된 정상적인 형상이 아닌 기하학적으로 찌그러지거나 파손된 형태로 인해 vision의 인식 및 이에 따른 로봇의 반응에 문제가 발생하게 된다.

본 논문에서는 vision 측정시스템의 검사 알고리즘에 Deep Learning 기술을 이용하여 형상의 기하학적 변화에 따른 인식 및 판별에 관한 학습을 통해 분류 작업의 효율성을 높이고 로봇과의 연동을 통해 폐기물의 분류를 연구하고자 한다. 이를 통해 기존의 폐기물 및 해양 폐기물의 소재 및 종류별 분류 작업을 효과적으로 진행이 가능할 것이라 예상하고 이를 통해 재활용 비율을 효과적으로 증대할 수 있다고 예상된다.

2. Deep Learning

Deep Learning은 인공신경망(Artificial Neural Networks) 기반으로 여러 레이어를 사용하여 입력에서 더 높은 수준의 분별을 점진적으로 추출하는 일종의 머신러닝 알고리즘이며 이를 통해 이미지 처리에서, 하위 계층은 에지를 식별할 수 있지만 상위 계층은 숫자는 물론 문자 또는 얼굴과 같은 개념을 식별할 수 있다.⁶⁻⁸⁾

이러한 Deep Learning 모델은 인공 신경망 중 CNN(Convolutional Neural Networks) 기반이며 심층망 또는 deep Boltzmann machines의 노드와 같은 계층(레이블) 단위로 구성된 제안식 또는 잠재 변수를 포함하고 있을 수도 있다. Deep Learning에서 각 레벨은 입력 데이터를 약간 더 추상적이고 복합적인 표현으로 변환하는 방법을 배우며 이미지 인식 애플리케이션에서, 미 가공 입력은 픽셀의 매트릭스이고 제1 표현 계층은 픽셀들을 추상화하고 에지를 인코딩할 수 있으며 제2 계층은 에지의 배열을 구성하고 인코딩할 수 있고 제3 계층은 코와 눈을 인코딩 할 수 있고 그리고 제4 계층은 이미지가 얼굴을 포함한다는 것을 인식할 수 있다. 중요한 것은 Deep Learning 프로세스가 어떤 기능을 자신의 레벨에 최적으로 배치할 수 있는지 배울 수 있다는 것이다.⁹⁾

Deep Learning을 이용한 다중 추상화 계층 분석

에 대해 첫 번째 계층에서는 외형 선분만 인식하며 심층화되어 갈수록 분석하고자 하는 에지의 배열이 늘어가며 분류하게 된다. 결국 "Deep Learning"에서 "Deep"이라는 단어는 데이터가 변환되는 레이어 수를 나타내며 Deep Learning 시스템은 실질적인 신용 할당 경로 (CAP) 깊이를 갖는다.

이러한 딥 모델 (CAP> 2)은 얇은 모델보다 더 나은 기능을 추출할 수 있으므로 추가 레이어는 기능을 효과적으로 학습하는 데 도움이 되며 추상화를 풀고 어떤 기능이 성능을 향상 시키는지 파악하는 데 도움이 된다.¹¹⁻¹²⁾

3. 실험

3.1. 시스템 구성

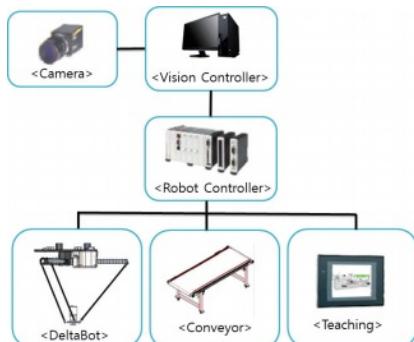
본 연구에서는 폐기물 분류 시스템을 구성하기 위해 제품 이송용 컨베이어, 폐기물 분류를 위한 멜타 로봇, 형상을 인식하기 위한 vision 및 조명 시스템으로 시스템을 구성하였다. (Fig.1)

Table 1 Specifications of vision system

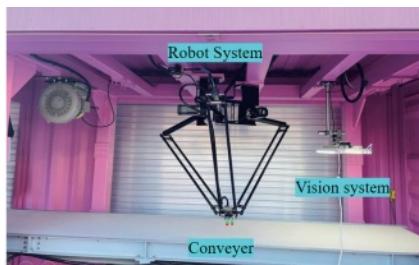
ITEM	Specification
Defect detection	Color, shape detection
Camera	RGB ,1920 x 1080, 30fps
Pixel resolution	about 500 um
FOV	960 x 540 mm
Detection resolution	20 mm over
Working distance	550 mm over
Scan speed	Max 15,000mm/s
Controller	i7Core, Memory 16G, SSD
Deep Learning program	Neuro-T

컨베이어의 경우 형상 인식에 따른 속도 변화를 위한 이송 속도 컨트롤이 가능하도록 제작하였으며 폐기물의 분류 작업은 자유도의 확장성 및 속도가 높은 멜타 로봇으로 선정하였다.

Vision 시스템의 경우 table 1과 같이 폐기물 종류에 따라 분류가 수월한 color vision과 컨베이어의 영역을 고려하여 FOV 960 x 540을 이용하였으며 형상 인식을 위해 사용한 Deep Learning 프로그램은 Neuro-T를 이용하였다.



(a) Structure of classification system



(b) Classification system set-up

Fig. 1. Vision inspection system

3.2. 시스템 동기화

Vision 시스템에서 분류를 진행한 폐기물의 경우 텔타 로봇을 이용하여 분류 작업을 진행하는데 이를 위해서는 vision과 로봇의 좌표에 대한 보정이 우선적으로 필요하다.

본 연구에서는 calibration에 필요한 좌표변환은 아래 그림과 같이 2단계로 이루어진다.

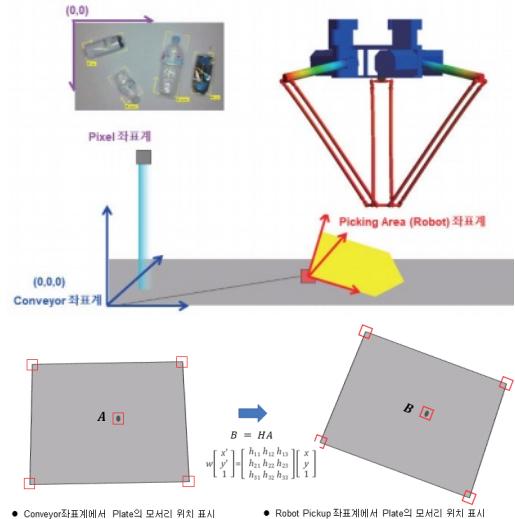
- 1) Vision 시스템에서 획득한 영상의 pixel 좌표계를 conveyor상의 좌표계로 변환

- 2) Conveyor의 좌표계를 실제로 로봇이 pickup하는 좌표계로 변환

Vision system과 컨베이어의 영상 획득 동기화를 위해서 컨베이어에 엔코더를 설치하였으며, 2D vision 시스템에서 좌표변환 SW를 진행하였다. 장비 가동 후 첫 번째 영상을 기준으로 GUI상에 setting한 FOV의 Y축 값마다 영상을 획득할 수 있도록 SW를 구현하여 calibration 진행하였다. 기준자를 이용하여 X 방향과 Y 방향의 calibration을 진행한 후 recipe에 저장하여 적용될 수 있도록 개발하였다.

컨베이어와 로봇의 경우 calibration plate에서 3점 이상의 모서리 좌표를 구한 후, 실제 robot의 motion

좌표에서 각 모서리의 위치를 구하였다. 컨베이어를 입력 좌표계, robot을 출력 좌표계로 하여 변환행렬(Homogeneous matrix)을 구하여, 이 변환행렬을 이용하여 converting 함수를 구현하였다.(Fig.2)

**Fig. 2.** Calibration of system coordinate

3.3. 실험방법

3.3.1 Deep Learning setting

Deep Learning 시스템을 학습 시키기 위한 라벨 정보를 제공하기 위해 Fig.3와 같이 학습용 입력 영상내의 객체에 대한 이름 및 위치 정보(Bounding Box)를 포함하고 하나의 영상에 하나의 객체가 있도록 획득한 영상을 이용하여, 하나의 영상에 1개의 바운딩 박스가 존재 존재하고 이를 이용하여 학습을 진행한다.

실험을 위해 실험 조건은 다음과 같다.

- Label 종류 : Object Detection / Box Label
- Train 옵션 : Search Space : Fast Inference Speed : Unchecked
- 학습 이미지 : Train Set - 100장(60%) Test Set - 40장(40%)
- Error data : 과검출, 오류검출, 미검출

실험에서는 2가지 parameter의 data 변경을 통해 진행하였고 다음과 같다.

- Threshold - Deep Learning에서 받아들일 입력

- 변수(Feature)의 score를 설정
 • Density - 표본추출밀도를 설정
 (Feature와 얼마나 겹치는지를 결정)



Fig. 3. Learning sample image

3.3.1 Threshold parameter 선정

본 실험에서 변경 parameter는 density, threshold로 density는 3으로 고정하고 threshold는 20, 50, 80으로 진행하였다. table 2에서와 같이 20일 때가 process time이 오래 걸리는 단점이 있으나 error비율이 낮고 검출률이 제일 좋게 나왔다.

Table 2 Detection rate according to threshold value

Feature Size	Density	Threshold	OK (%)	Error (%)	Processing Time
166*128	3	20	55.4	44.6	40.5
166*128	3	50	42.9	57.1	36.4
166*128	3	80	34.8	65.2	43.7



Fig. 4. Detection image by changing Threshold Parameter

3.3.2 Density parameter 선정

본 실험에서는 앞에서의 실험에서와 유사한 방법으로 parameter에서 density를 1, 2, 3으로 진행하였고 threshold 50으로 설정하였다. 실험 결과 density가 2일 때가 1일 때 보다 process time이 약간 높게

나왔으나 3에 비해서는 반이하로 빠른 process time을 나타내고 있다. 더불어 2일 때의 검출률이 제일 좋고 error률이 낮게 나와 Deep Learning 학습에서의 최적의 parameter는 density를 2로 고정하고 threshold를 20으로 고정하여 진행하였다.(Table 3)

Table 3 Detection rate according to density

Feature Size	Density	Threshold	OK (%)	Error (%)	Processing Time
166*128	1	50	30.4	69.7	14.2
166*128	2	50	43.2	56.8	15.8
166*128	3	50	42.9	57.1	36.4



Fig. 5. Detection image by changing density parameter

3. 실험 결과 및 분석

폐기물의 형상은 기하학적으로 변형되어 이를 정확하게 제품 및 형상에 따라 분류하기 위해서는 크게 3가지 방법으로 Deep Learning을 진행하였다.

개별 이미지, 그룹 이미지, 개별&그룹 이미지를 이용하여 효과적이고 선별 효과를 극대화 할 수 있는 방법을 선정하려고 한다.

개별 이미지 Deep Learning의 process 과정은 우선 선정된 개별 이미지를 이용하여 제품별 라벨링을 진행하고 이를 기반으로 다양한 제품 중에서 라벨링을 통해 학습을 진행하고 선별은 진행하였다.(Fig.6)

그룹 이미지 Deep Learning의 process 과정은 우선 다양한 제품들로 구성된 이미지에서 제품 개별로 각각 라벨링을 진행하고 다양한 제품 중에서 학습은 진행하고 선별은 진행한다.(Fig.7)

개별&그룹 이미지 Deep Learning의 process 과정은 우선 개별 이미지를 통해 라벨링하고 그룹 이미지에서도 제품별로 라벨링을 진행한다. 여기서 개별

및 그룹에서 라벨링 된 데이터를 통합하여 학습을 진행하고 선별을 진행한다.(Fig.8)

Deep Learning을 통한 학습 결과 개별 이미지 학습의 경우 정상 선별이 76%이고 과분류(Over Detection) 16.2%, 미분류(Miss Detection) 7.8%로 나왔다.

그룹 이미지 학습의 경우에는 정상 선별이 개별 학습보다 높은 95.8%이고 과분류(Over Detection) 4.2%로 낮게 나왔으며 미분류(Miss Detection) 0%로 나왔다.

마지막으로 개별+그룹 이미지 학습의 경우 정상 선별이 99%이고 과분류(Over Detection) 1%, 미분류(Miss Detection) 0%로 나왔다.



(a) Individual training source image



(b) Individual Learning Labeling Images



(c) Individual learning results image

Fig. 6. Deep Learning results of Individual learning



(a) Group learning original image



(b) Group Learning Labeling Image



(c) Group learning result image

Fig. 7. Deep Learning results of Group learning



(a) Individual + group learning original image



(b) Individual + Group Learning Labeling Images



(c) Individual + group learning results image

Fig. 8. Deep Learning results of Individual & group learning

Table 4 Deep Learning results according to Image type

Type of learning	OK (%)	Over Detection (%)	Miss Detection (%)
Individual learning	76	16.2	7.8
group learning	95.8	4.2	0
Individual + group learning	99	1	0

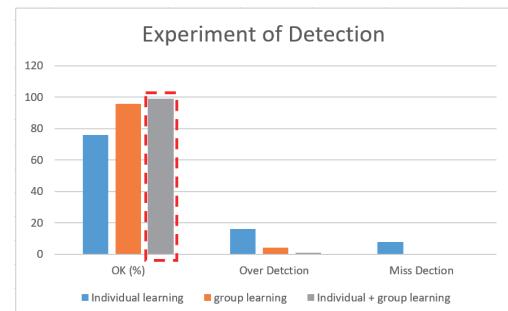


Fig. 9. Detection result according to Deep Learning

이러한 결과 개별&그룹 이미지 학습이 가장 효과적인 결과를 도출하였으며 이를 통해 기존에 인력으로 진행되었던 폐기물 자동 분류 작업에서 자동화를 통해 효과적인 결과 도출이 가능하다 예상된다.

4. 결론

본 연구에서는 vision 시스템에 Deep Learning 기술을 적용하여 폐기물 종류에 따라 기하학적 형상 변화에 따른 선별을 효과적으로 진행하였으며 다음과 같은 결과를 얻을 수 있었다.

1) Deep Learning 학습을 위한 인자로 threshold,

density를 검출률과 공정시간을 고려하여 최적값을 도출하였다.

2) 효과적인 폐기물의 선별 작업을 위해 개별 이미지, 그룹 이미지, 개별 + 그룹 이미지를 이용해 다양한 Deep Learning 학습을 진행하였다.

3) 개별 + 그룹 이미지의 학습을 수행한 결과에서 99%의 폐기물 분류 효과를 얻을 수 있어 Deep Learning 기술의 효율성을 입증하였다.

향후 본 시스템을 이용하여 실제 폐기물 분류 현장에서의 적용을 통해 효율성 있는 자동화 분류 작업이 가능하다 예상한다.

후기

본 논문은 해양수산부 “해양 플라스틱 쓰레기 저감을 위한 기술개발”사업(20200584)의 연구과제로 수행되었음.

참고문헌

- 1) H. S. Jang “Research on plastic regulation trends and innovation business models in major countries”, Institute for international tradn No.13 pp. 2093-3118, 2019.
- 2) J. H. Choi, B. C. Jeon, M. W. Cho. “ Development of Web Based Mold Discrimination System using the Matching Process for Vision Information and CAD DB” Transactions of the Korean Society of Machine Tool Engineers, Vol.15 No.5, pp 37-43 2006.
- 3) H. Y. Bae, H. J. Kim, J. I. Paeng, H. S. Sim, S. H. Han, J. C. Moon “ A Study on Shape Recognition Technology of Die Casting and Forging Parts Based on Robot Vision for Inspection Process Automation in Limit Environment” Journal of The Korean Society of Industry Convergence Vol.21, No.6 pp. 369-378 2018.
- 4) M. Y. Cho1, M. S. Jang, C. S. Jang, D. H. Lee “Evaluation of Object Recognition Intelligence of Social Robots” 19th International Conference on Control, Automation and Systems, 2019.
- 5) K. K. Kim, S. S. Kang, J. B. Kim, J. Y. Lee, H. M. Do, T. Y. Choi, J. H. Kyung “ Object Recognition Method for Industrial Intelligent

Robot” J. Korean Soc. Precis. Eng., Vol. 30, No. 9, pp. 901-908 2013.

- 6) Y. Bengio, A. Courville, P. Vincent, "Representation Learning: AReview and New Perspectives". IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol35, issue8, pp. 1798 - 1828. 2013.
- 7) Y. Bengio, Y. LeCun, G. Hinton, "Deep Learning". Nature. Vol.521 pp. 436 - 444, 2015.
- 8) L. Deng, D. Yu, "Deep Learning: Methods and Applications" Foundations and Trends in Signal Processing, Vol. 7, 2014.
- 9) Y. LeCun, Y. Bengio, G. Hinton, "Deep learning". Nature. Vol. 521, pp. 436 - 444. 2015.
- 10) J. Schmidhuber, J. "Deep Learning in Neural Networks: An Overview", Neural Networks. Vol. 61, pp. 85 - 117, 2015.
- 11) Y. Bengio, A. Courville, P. Vincent, "Representation Learning: AReview and New Perspectives". IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 35, issue. 8, pp. 1798 - 1828. 2013.
- 12) https://en.wikipedia.org/wiki/Deep_learning

저자 소개

한봉석(Han Bong Seok)

[정회원]



- 2020년 08월 : 인하대학교 기계공학과 (공학박사)
- 1997년 11월~2021년 12월 TSC멤버스(구.파이컴) 제어팀 팀장
- 2012년 01월~2014년 14월 : 주루Ken 테크놀러지 기술연구소, 연구소장
- 2015년 05월~현재: (주)엔에이치씨 대표이사

< 관심분야 >
딥러닝, 비전 검사 및 측정

권혁원(Kwon hyeok won)

[정회원]



- 2016년 02월 : 상명대학교
한국어문학과 (학사)
- 2017년 06월 ~ 현재 : 주엔에이치씨
개발3팀 과장

< 관심분야 >
딥러닝, 비전 검사 및 측정

신 봉 철(Bong-Cheol Shin)

[정회원]



- 2010년 2월 : 인하대학교
기계공학과 (공학박사)
- 2011년 7월 ~ 2018년 2월 : 삼성전기
생산기술연구소, 책임연구원
- 2018년 9월 ~ 현재: 인하대학교 기계
공학과, 강사

< 관심분야 >
마이크로 절삭, 마이크로 EDM, 공정 모니터링, 정밀 측정