

의류 이미지 내 손상 영역 탐지 및 분류에 관한 연구

권용민¹, 김건호¹, 박윤진¹, 우현서¹, 이종호¹, 옥창안², 고석주³

¹경북대학교 컴퓨터학부 학부생

²리터놀 주식회사 개발총괄이사

³경북대학교 컴퓨터학부 교수

rnjs5540@gmail.com, kgh67811@naver.com, et1505@naver.com, wndlthsk@naver.com,
hopaper2367@naver.com, ca.ock@lipis.kr, sjkoh@knu.ac.kr

Study on the Detection and Classification of Damage Areas in Clothing Images

Yong-Min Kwon¹, Geon-Ho Kim¹, Yoon-Jin Park¹, Hyun-Seo Woo¹, Jong-Ho Lee¹, Chang-An Ock²,
Seok-Joo Koh³

¹Dept. of Computer Science and Engineering, Kyung-Pook National University

²Returnall Inc.

³Dept. of Computer Science and Engineering, Kyung-Pook National University

요 약

의류 상품의 반품 처리 과정은 판매자와 기업에 막대한 비용을 야기하고 있다. 인공지능을 이용한 반품 적정 여부 자동화 검사는 인력 및 시간 절감을 통한 효율성 향상과 응답 시간 단축을 통한 고객 만족도 향상에 기여할 수 있다. 본 논문에서는 자동화 시스템의 초기 단계로, Faster R-CNN을 활용하여 의류 이미지에서 손상 영역을 탐지하고 분류하는 방법을 제안함으로써 향후 실제 운영 모델 개발의 가능성을 보여준다.

1. 서론

2023년 미국의 온라인 의류 시장에서는 연간 약 380억 달러의 반품과 약 251억 달러의 반품 처리 비용이 발생하였다[1]. 이러한 반품 과정에서 발생하는 배송비, 인건비, 보관비 등의 추가 비용은 판매자와 기업에 경제적 부담을 주었으며, 반품 제도를 악용한 사기와 소비자의 악성 클레임 문제로 이어지고 있다.

인공지능을 활용한 반품 적정 여부 자동화 검사는 인력 및 시간 절감을 통한 효율성 향상과 응답 시간 단축을 통한 고객 만족도 향상에 기여할 수 있다. 이 기술은 대량의 역물류 운영 데이터를 분석하여 반품 검사의 정확도와 속도를 개선하고, 제품 손상 정보를 감지하는 자동화 시스템 구축을 목표로 한다.

2. Faster R-CNN

Faster R-CNN[2]은 객체 감지 분야에서 Region Proposal Network(RPN)를 도입하여 Fast R-CNN[3]의 속도 문제를 해결한다. RPN은 이미지에서 객체가 있을 법한 영역을 생성하며, 이를 Fast R-CNN과 통합하여 end-to-end 학습을 가능하게 한다. Faster R-CNN은 RPN

을 통해 Region Proposal 생성 과정을 CNN 내부로 통합함으로써 객체 감지 성능을 향상시킨다. 또한, 다양한 크기와 비율의 anchor box를 사용하여 객체 크기와 형태 변화에 효과적으로 대응할 수 있게 되었다. 이를 통해 다양한 크기와 비율을 가진 객체를 빠르고 정확하게 탐지할 수 있었으며, 여러 벤치마크 데이터셋에서 우수한 성능을 보여준다. 본 연구에서는 Faster R-CNN을 의류 이미지 내 손상 영역 탐지 및 분류에 적용하고자 한다.

3. 제안 방법

3.1 데이터셋 구성

학습 데이터셋은 리터놀 주식회사에서 제공한 의류 이미지와 의류의 손상 영역 정보를 포함한다. 테스트 데이터셋은 CSV 파일에 있는 모든 이미지 경로 중 학습 데이터에 사용된 이미지를 제외한 나머지 정보로 구성된다.

3.2 데이터 전처리

이미지를 읽어 RGB 색상 공간으로 변환한다. 손상 유형 레이블은 숫자로 매핑한다. 이미지 크기에 맞게 바운딩 박스 좌표를 조정하고, 색상 정규화 등의 기법을 적용하여 모델의 학습 성능을 향상시킨다.

3.3 데이터 로더

PyTorch의 Data Loader를 사용하여 데이터를 배치 단위로 로드한다. 데이터 로더는 리터놀 주식회사에서 제공한 의류 이미지와 해당 이미지의 손상 영역 정보를 반환한다.

3.4 모델 구성

손상 영역 탐지 및 분류를 위해 Faster R-CNN 모델을 사용한다. 백본 네트워크로는 Pre-trained ResNet-50을 사용하며, RPN을 통해 잠재적 객체 영역을 예측한 후, RoI Pooling과 fully connected layer를 거쳐 손상 영역의 바운딩 박스와 클래스를 예측한다. 최적의 성능을 위해 모델의 입력 크기, RoI Pooling 크기, fully connected layer의 크기 등의 파라미터를 조정한다.

3.5 학습

모델을 데이터셋으로 학습시킨다. SGD 옵티마이저를 사용하여 모델의 파라미터를 업데이트하고, 손실 함수로는 바운딩 박스 회귀 손실과 클래스 분류 손실의 합을 사용한다. 학습률, 모멘텀, 가중치 감소 등의 하이퍼파라미터를 조정하여 학습 성능을 최적화한다.

3.6 평가

학습된 모델을 테스트 데이터셋으로 평가하여 모델의 손상 영역 탐지 및 분류 성능을 측정한다. 평가 지표로는 손실률, 탐지 시간, 탐지 횟수, 탐지 정확도를 사용한다.

3.7 YOLOv8x와 비교

의류 손상 영역 탐지 및 분류 작업에 있어 Faster R-CNN과 최신 모델인 YOLOv8x의 성능을 비교한다. 이를 통해 각 모델의 장단점을 파악하고 가장 적합한 모델을 선정한다.

4. 실험 결과

	Faster R-CNN	YOLOv8x
TP(True Positive)	280	33
TN(True Negative)	0	0
FP(False Positive)	265	8
FN(False Negative)	0	247

(표 1) Confusion Matrix

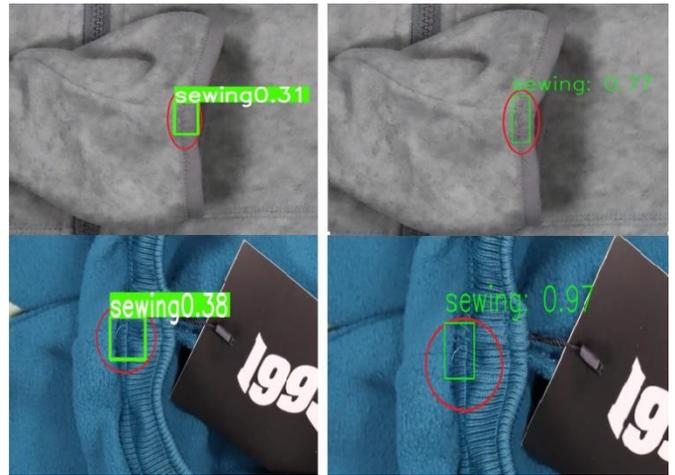
Method	The Clothes Image Dataset		
	Accuracy (%)	Precision (%)	Recall (%)
Faster R-CNN	51.4	51.4	100
YOLOv8x	11.5	80.5	11.8

(표 2) 의류 이미지 데이터셋에 대한 탐지 결과

Accuracy = (TP + TN) / (TP + TN + FP + FN)으로, Precision = TP / (TP + FP), Recall = TP / (TP + FN)의 식을 사용하여 산출한다.

그 결과, Faster R-CNN은 높은 정확도와 재현율을 보이지만 정밀도는 YOLOv8x에 비해 낮다. 반면 YOLOv8x는 정밀도는 높지만, 정확도와 재현율이 현저히 낮다.

Faster R-CNN은 정확한 객체 탐지에 유리하고, YOLOv8x는 실시간 처리 속도는 빠르지만, 정확도가 떨어지는 경향이 보인다.



(그림 1) YOLOv8x Detect (그림 2) Faster R-CNN Detect

5. 결론 및 기대효과

본 연구에서는 Faster R-CNN 모델과 YOLOv8x를 이용해 이미지를 통한 훼손 부위 탐지를 비교 분석하였다. 실험 결과, 앞에서 계산된 Accuracy, Precision, Recall을 고려했을 때, 속도가 중요하다면 YOLO가, 정확도가 중요하다면 Faster R-CNN을 선택하는 것이 유리하다고 볼 수 있다.

제안된 방법은 CSV 파일 내 이미지 경로와 손상 영역 정보를 활용하여 데이터셋을 구성하고, Faster R-CNN 모델을 학습시켜 손상 영역 탐지 및 분류가 가능함을 보여준다. 향후 연구에서 더 큰 규모의 데이터셋과 다양한 손상 유형에 대한 실험을 통해 모델의 성능을 향상시킬 계획이다.

이를 통해 산업에서 자동화와 효율성 향상을 기대할 수 있으며, 이는 인력 비용 절감과 고객 서비스 개선으로 이어질 것으로 기대된다.

사사문구

“이 연구는 과학기술정보통신부 및 정보통신기획평가원의 SW 중심대학사업 지원을 통해 수행되었음”(2021-0-01082)

참고문헌

- [1] Zheng, Sunny. “The True Cost of Apparel Returns: Alarming Return Rates Require Loss-Minimization Solutions.” *Coresight Research*, 4 April 2023. <https://coresight.com/research/the-true-cost-of-apparel-returns-alarming-return-rates-require-loss-minimization-solutions/>
- [2] Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28, 91-99.
- [3] Girshick, Ross. "Fast R-CNN." 2015 IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, 2015, pp. 1440-1448