

전동 킥보드 헬멧 착용 탐지

이선엽, 부세영, 박종일¹

한양대학교 컴퓨터소프트웨어학부

srg03021@hanyang.ac.kr, iguilty@hanyang.ac.kr, jipark@hanyang.ac.kr

Detection of Helmet on Electric Scooter

Seon-yeop, Lee, Shirong, Fu, Jong-il, Park

Dept, of Computer Science Hanyang University

요 약

최근 전동 킥보드 사용량이 크게 늘었으나, 다른 이동수단 대비 낮은 안정성과 사용자들의 헬멧 착용에 대한 인식 부족으로 인해 사고의 위험성이 큰 상황이다. 이에 대하여 정부는 헬멧 착용을 강제하는 법률을 제정하였으나, 경찰력의 한계에 따른 단속 미비로 여전히 헬멧 착용율은 낮다. 본 연구는 YOLO v3 알고리즘을 통해 학습시킨 딥러닝 모델을 활용하여 도로 상황을 촬영한 동영상 내에서 헬멧 착용자와 미착용자를 구분하고 미착용자 탐지 시 알람을 제공하는 시스템을 제시한다. 기존 YOLO 알고리즘 및 신경망을 적용하되, 전동 킥보드 데이터를 새로 수집하고 클래스를 구분하여 학습시켰다. 소수의 탐지 및 분류 오류를 보정하기 위해, 히스토그램 간 유사도를 측정해 최종적으로 객체를 추적 및 확정하고, 객체에 대한 헬멧 착용 여부를 통계적으로 확인한다.

1. 서론

최근 전동 킥보드 산업이 발전하면서 그 사용량이 크게 늘었다[1]. 상대적으로 저렴한 가격과 편의성에 힘입어 대여 사업을 비롯한 전동 킥보드 시장이 확대되었으나, 그 위험성도 함께 증가하고 있다. 전동 킥보드는 그 속도 대비 낮은 차체 및 작은 바퀴로 인해 사고 발생의 위험과 부상의 정도가 다른 이동수단 대비 심한 편이다[2]. 이에 따라 정부는 2021년 5월 도로 교통법 개정안을 시행하며 전동 킥보드 탑승 시 헬멧 착용을 강제하고 있다. 하지만 경찰력의 부족함에 따라 단속이 제대로 이루어지지 않고 있어, 여전히 이용자들의 헬멧 착용률은 미비한 상황이다. 따라서 CCTV 영상에서 전동 킥보드 이용자들의 헬멧 착용을 자동적으로 확인할 수 있다면 이용자들에 대한 어느정도 경고를 주고 헬멧 착용율을 높일 수 있다.

헬멧 탐지에 대한 기존 연구들은 공사 현장에서의 헬멧 착용

여부, 혹은 오토바이 탑승자에 대한 헬멧 착용 여부만을 탐지하였다[3,4]. 전동 킥보드 산업이 상대적으로 신생 산업이고 헬멧 착용에 대한 법률적 강제성이 다른 이동수단에 비해 상대적으로 빈약하였기에 이에 대한 연구는 부족한 상황이며, 전동 킥보드 이미지 데이터베이스를 비롯한 일련의 과정에 대한 제약이 있다.

본 논문에서는 전동 킥보드 이용자의 헬멧 착용 여부를 자동으로 판별하는 방법에 관한 것으로, 인공지능을 사용하여 전동 킥보드 이용자들의 이미지를 YOLO 알고리즘으로 학습하고, 인식 및 분류하는 시스템을 제안한다[5]. 또한, 한 동영상 및 실시간 카메라 영상에서 등장하는 여러 객체에 대해 각 객체를 추적하고 최종적인 헬멧 착용 여부를 확인할 수 있는 방법을 제안한다.

¹: 교신저자

본 논문의 구성은 다음과 같다. 2 절에서는 관련 연구에 대해 설명하고, 3 절에서는 본 논문에서 제안하는 전동 킥보드 헬멧 착용 탐지 시스템을 설명한다. 4 절에서는 실험에 대해서 분석하고, 마지막 5절에서는 결론 및 향후 과제에 대해 언급한다.

2. 관련 연구

2.1 YOLO 알고리즘

YOLO[5]는 복잡한 객체 검출 과정을 하나의 회귀 문제로 처리한다. YOLO는 입력 이미지를 하나의 신경망에 통과시키는데, 이 때 입력 이미지의 크기를 변환하고 S x S 그리드로 나누어 각 그리드 셀에서 몇 개의 바운딩 박스와 각 바운딩 박스에 대한 클래스 확률을 계산한다. 이 후 임계치 이상의 신뢰도를 가지는 바운딩 박스만을 최종 출력한다. 입력 이미지에 대한 출력은 Figure 1과 같다.



Figure 1. YOLO Detection Input / Output.

YOLO는 하나의 신경망만을 이용하므로 기존 객체 탐지 알고리즘보다 빠른 속도를 보여주며, 클래스의 모양에 대한 정보뿐만 아니라, 이미지 전체 즉, 주변 정보까지 학습하여 처리하므로 background error 가 적은 장점을 가진다.

2.2 히스토그램 유사도

이미지의 히스토그램의 유사도를 측정하는 방법은 상관 관계, 카이 제곱, 교차 등이 있다. 이들을 다음과 같이 정의할 수 있다.

상관 관계[6]는 값이 높을수록 두 히스토그램이 유사함을 나타낸다. 완전히 일치하는 경우는 1 로, 거의 불일치하는 경우는 -1 로 표현하며 두 히스토그램 이 전혀 연관이 없는 경우는 0 으로 표현한다. 식(1)과 같이 구할 수 있으며, H(I)는 히스토그램 내 양자화된 밝기값을 의미한다.

$$d(H_1, H_2) = \frac{\sum_I (H_1(I) - \bar{H}_1)(H_2(I) - \bar{H}_2)}{\sqrt{\sum_I (H_1(I) - \bar{H}_1)^2 \sum_I (H_2(I) - \bar{H}_2)^2}}$$

$$\bar{H}_k = \frac{1}{N} \sum_J H_k(J) \quad (1)$$

카이 제곱[6]은 낮은 값을 가질 경우 두 히스토그램이 더 유사함을 나타낸다. 완벽히 일치하는 경우는 값이 0이고, 불일치하면 값이 커진다. 범위는 히스토그램의 크기에 따라 달라진다. 식 (2)은 두 블록 사이의 히스토그램 카이 제곱의 거리를 나타낸 것이다.

$$d(H_1, H_2) = \sum_I \frac{(H_1(I) - H_2(I))^2}{H_1(I)} \quad (2)$$

교차[6]는 히스토그램이 일치할수록 높은 점수로 불일치할수록 낮은 점수로 표현한다. 두 히스토그램 모두 1 로 정규화 되어있다면, 완벽한 일치의 경우는 1 로 표현하고, 완전 불일치 할 경우에는 0 으로 표현한다.

$$d(H_1, H_2) = \sum_I \min(H_1(I), H_2(I)) \quad (3)$$

3. 헬멧 착용 탐지 시스템

3.1 딥러닝 모델 학습

Google, Ms Coco 등을 비롯한 open data set에 전동 킥보드와 관련된 클래스가 없는 상황이다. 따라서, 인터넷 상에서 검색할 수 있는 전동 킥보드 관련 이미지 및 도로 현장에서 촬영한 전동 킥보드 탑승 사진을 이용한다. 해당 방법만으로 충분한 데이터를 확보하기에 어려움이 있으므로, Data Augmentation 기법을 충분히 활용하여, 10배 가량의 데이터를 추가로 생성하여 총 4,500여장의 이미지 데이터를 확보하였다[7]. Data Augmentation 기법의 종류에는 좌우반전, 회전, 기울임, Drop out, 눈/비 효과 등을 이용하였다.

수집한 이미지에 대해 직접 클래스 및 박스 크기를 지정해주는 라벨링 작업을 진행한다. 전동 킥보드, 사람, 헬멧으로 클래스를 지정하는 대신, 세가지를 하나로 보고 크게 '헬멧을 착용한 전동 킥보드 이용자'와 '헬멧을 쓰지않은 전동 킥보드 이용자'로 이진 분류할 수 있도록 클래스를 설정한다. 이러한 클래스 구분은 Figure 2와 같이 보여진다.




Figure 2. 헬멧 착용자(좌), 헬멧 미착용자(우)

3.2 객체 추적 시스템

존재하는 객체를 저장해두고 동영상 프레임을 진행시키면서, 다음 프레임에서는 기존에 저장된 객체와의 거리, 히스토그램 유사도를 비교해 현재 검출된 객체가 기존의 어떤 객체가 이동한 것인지 파악해낸다. 그 알고리즘은 다음과 같다.

1. 현재 프레임 이미지에서 딥러닝 모델을 통해 label과 바운딩 박스 좌표를 획득.
2. 1에서 획득한 객체의 바운딩 박스와, 이전 프레임에서 추적된 객체의 바운딩 박스 사이의 중심거리를 계산.
3. 이전에 추적된 객체들 중, 현재의 객체와 가장 짧은 거리를 가지는 객체를 선정.
 - 3-1. 객체 간 최소거리가 임계치보다 크면 새로운 객체로 지정.
4. 3에서 선정된 객체와 현재 프레임 상 객체의 이미지 간 히스토그램 유사도를 비교하여, 유사도가 더 높은 객체를 선정.
 - 4-1. 히스토그램 유사도가 임계치보다 작으면 새로운 객체로 지정.
5. 추적하고 있는 객체의 정보(이미지, 중심좌표)를 현재의 객체정보로 갱신.
6. 현재 프레임에 존재하는 모든 객체에 대해 1~5의 과정을 반복.

위의 알고리즘으로 객체의 이동 양상을 파악한 뒤, 각 객체가 가졌던 헬멧 착용/ 미착용 클래스 기록들을 저장한다. 어느 정도의 기록이 쌓인다면 더 많이 기록된 클래스를 최종적으로 산출해낸다. 이를 통해 소수의 클래스 분류 오류를 보정한다.

4. 실험 및 결과

4.1 모델 학습 결과

학습 단계에서 사용한 적 없는 이미지 및 그에 대한 data augmentation을 통해 수집 및 라벨링을 거친 350여장의 실험 데이터 셋에 대해, 딥러닝 모델을 통한 inference 결과를 분석해보았다. Inference의 결과로 클래스, 이미지 내 바운딩 박스의 좌표를 추출하였으며, 해당 자료와 라벨링 작업 당시 직접 획득한 클래스, 바운딩 박스 좌표를 비교해보았다. 분석 대상은 분류 정확도, 객체 중복 검출률, 객체 미검출률, 바운딩 박스 크기 오차 비율이다. 그 결과는 Table 1과 같다.

각 항목에 대해 살펴보면, 첫 번째로 분류 정확도의 경우, 더 많은 데이터로 학습할수록 분류 정확도가 더 증가하는 경향을 보인다.

같은 객체에 대하여 여러 개의 바운딩 박스가 검출되는 중복 검출 항목을 살펴보면, 중간에 3400여개의 데이터셋을 이용한 실험에서 그 수치가 크게 증가하는 부분이 있다. 데이터셋을 분석해본 결과, 해당 부분에서 헬멧 착용 클래스 / 헬멧 미착용 클래스 간 비율이 불균형한 것을 알아냈다. 데이터 수집의 어려움 때문에 그 비율이 1 : 2 수준까지 편차가 생겨 객체 중복 검출 사례가 생긴 것으로 보인다. 이 후 불균형을 해소하는 데 중점을 두고 데이터를 수집하여 어느정도는 문제를 해소하였다.

Table 1. Model Performance Test Result

데이터셋 크기	분류 정확도	중복 검출	미검출	박스 크기 오차
700	53.1%	7.4%	9.2%	-8.8%
1300	59.1%	3.5%	6.5%	-1.4%
1900	57.0%	4.4%	15.8%	-7.6%
2600	82.6%	8.9%	2.0%	2.2%
3000	84.7%	6.8%	2.0%	-0.9%
3400	84.4%	22.9%	3.2%	1.7%
4000	87.4%	6.8%	2.3%	0.48%

객체 미검출 항목을 살펴보면, 1900여개의 데이터셋을 이용한 실험에서 그 수치가 크게 증가하였다. 데이터셋을 분석해본 결과, 라벨링 과정에서 박스 크기 설정 당시 기존 데이터 대비 크게 바운딩 박스를 설정해두어, 실험 단계에서 적절한 바운딩 박스를 찾지 못해 객체 미검출로 이어진 것으로 보인다. 이후의 데이터에서는 다시 적합한 수준의 바운딩 박스 크기를 설정해주자 해당 문제는 어느정도 해소되었다. 객체가 미검출되는 실험 데이터를 살펴본 결과, 객체의 크기가 너무 작거나, 너무 커서 미검출 사례가 발생한 것으로 파악되었는데, 동영상 내에서는 프레임의 변화에 따라 객체가 적정 위치로 이동하므로 큰 문제가 아니다.

사람이 지정한 바운딩 박스 크기와 inference 결과를 비교한 수치를 보면, 객체 미검출 항목과 같이 중간에 박스 크기 설정의 오류로 수치가 크게 증가하는 부분이 있다. 하지만 데이터 양을 늘릴수록 해당 오류가 통계적으로 개선되는 모습을 보여, 바운딩 박스 크기에 대한 오류는 거의 없어졌다.

4.2 객체 추적 시스템 결과

객체 추적에 적절하게 쓰일 수 있는 히스토그램 유사도 임계치를 알아보기 위해 같은 동영상에서 획득한 남/녀 객체에 대해 교차를 이용한 히스토그램 유사도를 비교해보았다. 단, Figure 3의 ⑤ 객체는 이전과 다른 배경에서 추출했다.




Figure 3. 전동 킥보드 이용 객체 이미지

Table 2. 히스토그램 유사도 측정 결과

비교대상 1	비교대상2	유사도
①	③	0.4384
①	②	0.3177
②	③	0.3045
②	④	0.4392
①	⑤	0.0445

Table 2의 결과를 살펴보면, 비슷한 배경에 키포드 탐승 상태이므로 객체 간 유사도 차이가 크게 벌어지지 않는다. 하지만, ①과 ⑤의 결과를 살펴보면 배경이 달라졌을 때, 유사도가 크게 낮아지는 것을 볼 수 있다. 위의 결과를 보고 0.4정도의 값을 다른 객체로 구분하는 임계치로 사용하였다.

객체 추적에 가장 어려움을 겪는 때는 서로 다른 방향으로 진행되는 객체가 마주보고 다가와 겹치는 경우이다. 위와 같은 알고리즘으로 실험해보았을 때, 다른 객체로 헛갈리는 문제는 발생하지 않았다. 하지만 객체가 겹칠 때, 뒤쪽에 위치하는 객체가 사라졌다가 다시 나타나는 형태이므로 사라졌다가 다시 나타났을 때 이전 기록에 없는 완전히 새로운 객체로서 id를 가지는 문제가 발생하였다. 이는 차후 더 학습된 딥러닝 모델과, 더 높은 성능의 GPU를 사용해 초당 프레임 처리량을 늘린다면 개선할 수 있다.

5. 결론 및 향후 연구 방향

도로 위 전동 키포드 이용자의 헬멧 착용 여부를 파악하는 시스템은 경찰력 낭비를 막고 이용자의 안전을 보장하기 위해 필요하다. 우리는 전동 키포드 이용자의 이미지 데이터를 확보하고 YOLO 알고리즘으로 학습시킨 후, 그 분류 결과와 히스토그램 유사도 비교를 통한 객체 추적 결과를 종합해 헬멧 미착용 이용자를 통계적으로 확인하는 시스템을 제안했다. 본 논문에서 제안한 방법을 실험으로 분석하였으며, 제한된 데이터와 GPU 등의 환경에서도 의미 있는 결과를 얻을 수 있었다.

향후 연구 방향은 다음과 같다. 현재 데이터 수집의 어려움 때문에 충분한 데이터를 확보하지 못해 딥러닝 모델의 성능이 부족한 상황이다. 도로 CCTV 등 국가 인프라를 활용하여 더욱 많은 데이터를 확보할 수 있다면 분류 정확도, 객체 중복 검출 및 미검출 등에 대한 개선이 가능하다. 또한 국가 사업으로서 여러 전동 키포드 대여 사업체와 연계하여 각 전동 키포드의 위치 정보 및 이용자 정보에 대한 데이터베이스 이용이 가능하다면 헬멧 미착용자에 대한 직접적인 단속이 가능할 것이다.

감사의 글

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 SW 중심대학지원사업의 연구결과로 수행되었습니다. (2016-0-00023)

참고문헌

- [1] Korea Transportation Institute, 2017 Micromobility Transportation Policy Support Project.
- [2] Trivedi, T., Liu, C., Antonio, A., Wheaton, N., Kreger, V., Yap, A., Elmore, J. (2019). Injuries Associated With Standing Electric Scooter Use. *Journal of the American Medical Association*, 1-9.
- [3] R. Silva, K. Aires, T. Santos, K. Abdala, R. Veras, and A. Soares, "Automatic detection of motorcyclists without helmet," in *Computing Conf. (CLEI), XXXIX Latin American*, Oct 2013, pp. 1-7.
- [4] Li, K., Zhao, X., Bian, J. and Tan, M., 2018. Automatic Safety Helmet Wearing Detection. *arXiv preprint arXiv:1802.00264*.
- [5] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, RealTime Object Detection," *arXiv e-prints*, p. arXiv:1506.02640.
- [6] Gary Bradski, Adrian Kaehler, "Learning Opencv: Computer Vision with the Opencv Library", ch 7, 2008
- [7] Shorten, C.; Khoshgoftaar, T.M. A survey on image data augmentation for deep learning. *J. Big Data* 2019, 6, 60.