

회랑 감시를 위한 딥러닝 알고리즘 학습 및 성능분석

Deep Learning Algorithm Training and Performance Analysis for Corridor Monitoring

정우진¹ · 홍석민² · 최원혁^{3*}

¹한서대학교 항공전자공학과

²한서대학교 무인항공기학과

³캐스트유한회사

Woo-Jin Jung¹ · Seok-Min Hong² · Won-Hyuck Choi^{3*}

¹Department of Avionics, Hanseo University, Seosan, 31962, Korea

²Department of Unmanned Aeronautics, Hanseo University, Seosan, 31962, Korea

³Caest Limited Company, Seosan, Korea, 31962, Korea

[요 약]

K-UAM은 2035년까지의 성숙기 이후 상용화될 예정이다. UAM 회랑은 기존의 헬리콥터 회랑을 수직 분리하여 사용될 예정이기에 회랑 사용량이 증가할 것으로 예상된다. 따라서 회랑을 모니터링하는 시스템도 필요하다. 최근 객체 검출 알고리즘이 크게 발전하였다. 객체 검출 알고리즘은 1단계 탐지와, 2단계 탐지 모델로 나뉜다. 실시간 객체 검출에 있어서 2단계 모델은 너무 느리기에 적합하지 않다. 기존 1단계 모델은 정확도에 문제가 있었지만, 버전 업그레이드를 통해 성능이 향상되었다. 1단계 모델 중 YOLO-V5는 모자이크 기법을 통한 소형 객체 검출 성능을 향상시킨 모델이다. 따라서 YOLO-V5는 넓은 회랑의 실시간 모니터링에 가장 적합하다고 판단된다. 본 논문에서는 YOLO-V5 알고리즘을 학습시켜 궁극적으로 회랑 모니터링 시스템에 대한 적합도를 분석한다.

[Abstract]

K-UAM will be commercialized through maturity after 2035. Since the Urban Air Mobility (UAM) corridor will be used vertically separating the existing helicopter corridor, the corridor usage is expected to increase. Therefore, a system for monitoring corridors is also needed. In recent years, object detection algorithms have developed significantly. Object detection algorithms are largely divided into one-stage model and two-stage model. In real-time detection, the two-stage model is not suitable for being too slow. One-stage models also had problems with accuracy, but they have improved performance through version upgrades. Among them, YOLO-V5 improved small image object detection performance through Mosaic. Therefore, YOLO-V5 is the most suitable algorithm for systems that require real-time monitoring of wide corridors. Therefore, this paper trains YOLO-V5 and analyzes whether it is ultimately suitable for corridor monitoring. K-uam will be commercialized through maturity after 2035.

Key word : Deep learning, K-uam, Object detecting, R-cnn, Yolo.

<http://dx.doi.org/10.12673/jant.2023.27.6.776>



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Received 20 November 2023; **Revised** 5 December 2023
Accepted (Publication) 13 December 2023 (29 December 2023)

***Corresponding Author:** Won-hyuck Choi

Tel: *** - **** - ****

E-mail: choiwh@hanseo.ac.kr

I. 서론

도심 항공 모빌리티 (이하 UAM; urban air mobility)는 차세대 항공 모빌리티 (AAM; advanced air mobility)의 하위 개념으로, 도심 내, 외의 저고도 환경을 운항하는 운용 체계를 말한다. UAM은 기존 교통수단보다 빠른 속도로 도심 지점간을 운항할 수 있다. 한국형 도심항공교통 (K-UAM)은 2025년부터 2030년까지의 초기단계, 2030년부터 2035년까지의 성장기, 2035년 이후의 성숙기를 통해 상용화될 예정이다. UAM의 자유로운 비행을 허가할 경우 위험요소가 많기에 UAM 전용 회량을 지정할 필요가 있다. 현재는 헬기 회량을 수직 분리하여 사용하는 계획이 진행되고 있다.

UAM이 상용화 됨에 따라 회량의 용량이 증가하고 이를 감시하기 위한 모니터링 시스템이 필요하다. 모니터링 시스템을 수행하기 위해서 객체 탐지알고리즘을 통해 UAM이라는 객체를 훈련 및 학습해야 한다.

기존의 객체 탐지 알고리즘으로 훈련 및 학습을 진행할 경우 다량의 데이터를 처리하는 실시간 객체 감지에 있어서 적합하지 않다. 최근 몇 년 사이 이미지 처리 기술과 인공지능 기술이 빠르게 발전하면서 동영상 및 딥러닝 기반 표적검사 모델들이 발전하였다.

그렇기에 본 논문에서는 회량 내 이동하는 물체인 UAM을 탐지하기 위한 실시간 객체 탐지가 가능한 딥러닝 알고리즘을 제안하고 알고리즘 훈련 및 성능 평가를 통해 적합도 분석을 수행한다.

II. 기존의 객체 탐지 알고리즘

기존의 객체 탐지 알고리즘은 일반적으로 수동 추출을 통해 특징을 추출한다. 움직이는 물체는 비디오 시퀀스에서 추출되고 추출된 특징은 객체 식별 목적을 달성하기 위해 분류기에 의해 분류된다.

객체 탐지 방법으로는 백그라운드 업데이트 방법, 프레임 차이 방법, 광학흐름방법이 있다.

백그라운드 업데이트 방법은 가중치 평균이라는 아이디어를 사용하며, 백그라운드 업데이트 영향은 종종 대상 추출의 완성도와 대상 탐지의 정확도에 영향을 미친다.

프레임 차이 방법은 인접한 프레임 간의 차이를 계산하여 대상 추출 목적을 달성하는 것을 목표로 한다. 이 방법은 종종 차량의 속도와 연속 프레임 사이의 시간 간격에 의해 크게 영향을 받는다. 광학 흐름 방법은 픽셀 레벨에서 밀도를 추정하는 방법이다. 이전 프레임과 현재 프레임의 차이를 이용하고 픽셀값과 주변 픽셀들과의 관계를 통해 이동을 계산하여 추출한다. 조명의 변화가 없어야 한다는 조건이 필요함으로 알고리즘을 구현하는데 있어서 많은 어려움이 있다.

분류 컨트롤러는 후보 상자에서 각 대상의 특정 위치를 분류

하고 정확하게 찾는데 사용된다. 실시간 탐지를 하는 데 있어서 다량의 데이터는 분리함이 있기에 사용되는 알고리즘은 제한적이다. 일반적으로 SIFT, HOG, Harr 등이 있다. 분류 제어기 장치에는 SVM과 Adaboost 등이 있다.

III. 실시간 객체 탐지 알고리즘

3-1 실시간 객체 탐지 알고리즘

실시간 객체 탐지를 위해 사용하는 알고리즘은 두가지 범주로 나눌 수 있다. 하나는 후보 영역의 두 단계를 기반으로 한 R-CNN 계열 연산 방법이다.

R-CNN (region based convolutional neural network)은 2014년 로스 거식이 제안한 신경망 구조이다. R-CNN은 영역 기반 신경망 구조 중 가장 기본적인 모델로 Classification과 Localization이 순차적으로 일어나는 알고리즘이다. R-CNN의 기본 구성 요소는 RoI 추출기, 특징 추출 모듈, 분류 모듈, 위치 특정 모듈이다.

R-CNN[1] 이미지 한 장마다 2,000개 이상의 RoI가 제안되고 이들 영역이 모두 전체 파이프라인을 통과하는 구조이기 때문에 계산 부하가 매우 크고 느리다. 이러한 문제점을 개선하기 위해 2015년에 로스 거식의 Fast R-CNN, 2016년에 샤오칭 렌의 Faster R-CNN으로 발전해왔다. Faster R-CNN 알고리즘의 구조는 그림. 1.과 같다.

Faster R-CNN[1] 알고리즘은 기존의 R-CNN을 기반으로 선택 검사 대신 RPN(region proposal network)을 도입했고, RPN은 선택적 검색 대신 RPN을 깊이감권 신경망에 추출하여 각 위치에서 대상 경계상자와 카테고리의 신뢰도 점수를 동시에 예측하여 네트워크 계산을 빠르게 했다.

R-CNN의 계열은 투-스테이지 객체 탐지 알고리즘이기에 영역후보를 선정하고 객체를 분류하는 작업이 동시에 일어나지 않는다. 그렇기에 속도에 있어서 추후 설명하는 알고리즘 대비 성능이 좋지 않다. Faster R-CNN에서 이러한 문제점을 개선하였지만, 개선한 성능치 역시 뒤에 나오는 알고리즘에 비해 낮은 수치이다.

행하였고, 총 소요시간은 2시간이다.

4-2 알고리즘 성능평가

딥러닝 객체 탐지 알고리즘의 성능 평가 지표로 가장 많이 사용되는 것은 초당 프레임 수(FPS)와 평균평균정밀도(mAP; mean average precision)이다. FPS는 탐지 속도를 평가하는 지표로 2단계에 거쳐서 영역을 확보하는 R-CNN 계열 대비 원-스테이지로 영역을 확보하는 SSD, YOLO 계열의 성능이 우수하다.

평균평균정밀도(mAP)는 0~100의 값을 나타내며 100으로 갈수록 좋은 성능을 나타낸다. 평균평균정밀도에 영향을 주는 요소는 중첩률(IoU)와 PR곡선이다.

중첩률은 2개의 경계 박스가 중첩되는 정도를 나타내는 값을 의미한다. 정답 경계 박스와 예측 경계 박스가 있다고 가정할 때 IoU를 계산하여 해당 탐지 결과가 유효한지(true positive), 아닌지(false positive)를 결정할 수 있다.

정답 경계 박스(Bgt)는 수동으로 레이블링된 경계 박스를 의미하고 예측 경계 박스(Bp)는 모델의 예측 결과를 나타낸다. 두 박스가 겹치는 부분의 면적을 두 박스를 합한 영역의 면적으로 나누어 중첩률을 계산한다.

중첩률은 mAP의 임계값을 설정하는 데 사용된다. mAP@0.5의 경우 중첩률의 임계값이 0.5를 의미하며 mAP@0.75는 중첩률의 임계값이 0.75이다. 임계값을 초과하면 해당 예측은 정답을 맞힌 것(TP)으로 간주하고 임계값보다 낮을 시 틀린 것(FP)으로 간주한다.

PR곡선은 재현율과 정밀도를 각각 x, y축 위에 표시한 곡선이다.

재현율은 실제값이 Positive인 대상 중에 예측값과 실제값이 Positive로 일치한 데이터의 비율을 뜻하며 민감도, 또는 TPR(true positive rate)라고도 불린다.

정밀도는 예측을 Positive로 한 대상중에 예측값과 실제값이 Positive로 일치한 데이터의 비율을 뜻한다. Positive 예측 성능을 더욱 정밀하게 측정하기 위한 평가 지표로 양성 예측도라고도 불린다.

아래 표 1은 알고리즘 성능 평가에 사용되는 혼동 행렬이다.

아래 수식 1와 수식 2는 각각 정밀도와 재현율의 수학적 모델이다.

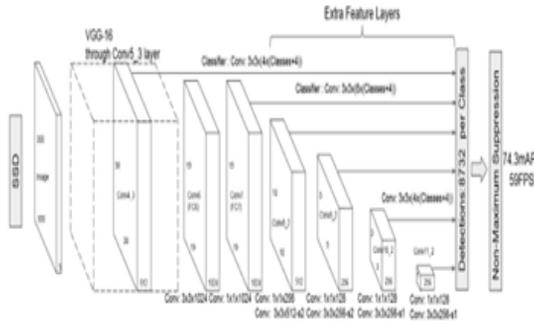


그림 4. SSD
Fig. 4. SSD

3-3 선별 알고리즘

최근의 YOLO 모델들은 기존의 YOLO 모델에 FPN, FPN+PAN, CSP 모듈을 통해 정확도를 꾸준히 향상시켰다. 그 중 YOLO V5 모델은 인풋 모듈에 Mosaic 데이터를 넣어 작은 객체 탐지 성능을 강화하였다. 이는 광활한 범위를 실시간 스트리밍을 통해 감시하는 회랑 감시 시스템에 적합한 알고리즘이다.

따라서 본 논문은 YOLO V5 알고리즘을 헬기 이미지와 드론 이미지를 통해 훈련시킨 후 테스트를 통해 회랑 감시 적합성을 분석한다.

IV. 알고리즘 훈련 및 성능 평가

4-1 데이터 세트 분류 및 학습

Roboflow의 헬기, 드론 이미지를 3829개의 Train 이미지, 692개의 Validation 이미지, 1476개의 Test 이미지로 나누어 학습을 진행하였다.

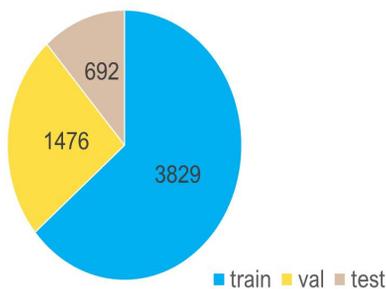


그림 5. 알고리즘 훈련
Fig. 5. Algorithm Training

배치와 에포크는 각각 16, 30으로 설정하여 시뮬레이션을 진

표 1. 혼동행렬

Table 1. Confusion Matrix

| | | True Class | |
|-----------------|----------|---------------------|---------------------|
| | | Positive | Negative |
| Predicted Class | Positive | True Positive (TP) | False Positive (FP) |
| | Negative | False Negative (FN) | True Negative (NP) |

재현율 = $TP / (FN + TP)$ (1)

정밀도 = $TP / (FP + TP)$ (2)

4-3 결과 분석

학습을 통해 얻은 재현율과 정밀도의 값은 아래와 같다.

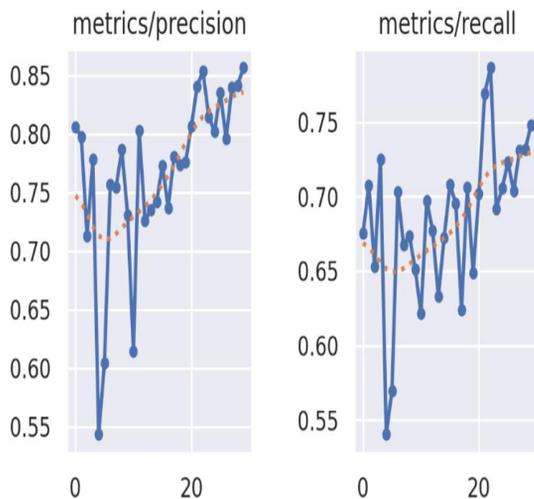


그림 6. 시뮬레이션 결과

Fig. 6. Results

재현율은 훈련이 진행됨에 따라 0.75의 값을 나타내었고, 정밀도는 0.85이상의 높은 값을 나타내었다. 재현율과 정밀도를 통해 구현한 PR곡선의 결과값은 그림 7과 같다.

헬리콥터 클래스와 드론 클래스의 mAP@0.5는 각각 0.906, 0.800으로 헬리콥터의 이미지 내의 객체 크기가 드론 객체보다 크기에 헬리콥터의 예측값이 더 높게 나왔다. 두 클래스의 mAP@0.5의 평균값은 0.853으로 높은 수치를 나타내며 이는 회랑 내의 객체 탐지에 있어서 적합한 수치라고 판단된다.

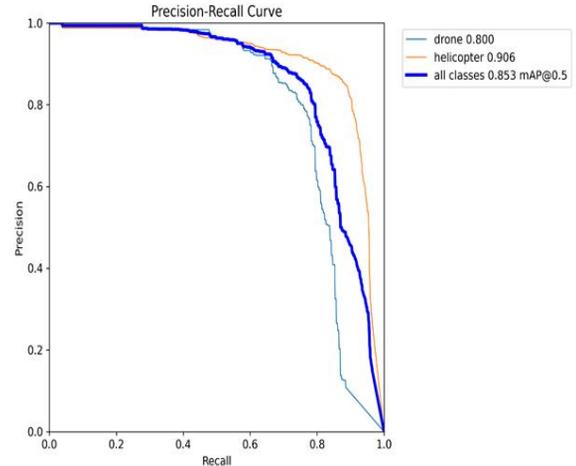


그림 7. PR곡선

Fig. 7. PR-Curve

V. 결론

본 논문에서는 실시간 객체 탐지 알고리즘의 종류와 발전과정에 대해 소개하였다. 알고리즘 별 장단점을 분류하고 궁극적으로 회랑 감시를 위한 딥러닝 알고리즘으로 YOLO V5 모델을 선정하였다. 이를 학습시켜 실제 YOLO V5 알고리즘이 회랑 감시를 위해 적합한 지에 대해 분석하였다. YOLO V5 알고리즘의 학습 결과 평균 0.853의 높은 mAP@0.5의 결과값을 나타내었다.

FPS에 장점이 있는 YOLO 알고리즘이 정확도까지 개선하였기에 클래스의 세분화와 데이터 세트의 정교화 및 양적 강화를 통해 학습된 모델은 실시간 회랑 감시 시스템에 충분히 사용될 수 있는 성능을 보유하고 있다고 판단된다.

Acknowledgments

본 연구는 2023년도 중소벤처기업부의 기술개발사업 지원에 의한 연구임[202201410002]

References

[1] S. Ren, K. He, Cho, R. Girshick, and Jiam Sun, "Faster r-cnn: Toward real-time object detection with region proposal networks," *Advances in neural information processing systems* 28, 2015

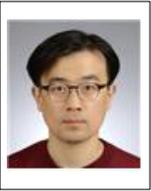
[2] J. Redmon, S. Divvala, R. Girshik, and A. Farhadi, "You only look once: Unified, real-time object detection," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016

[3] J. A. Bochkovskiy, C. Y. Wang, and H. M. Liao, "Yolov4: Optimal speed and accuracy of object detection," arXiv preprint arXiv:2024.10934, 2020



정우진 (Woo-Jin Jung)

2023년 2월 : 한서대학교 항공전자공학과 학부
※관심분야 : 딥러닝, 영상처리, 통신



홍석민 (Seok-Min Hong)

2014년 : 과학기술연합대학원대학교 (공학박사)
2014년 3월 ~ 2015년 12월 : 한국과학기술연구원 (박사후과정)
2016년 1월 ~ 2017년 3월 : 인체감응솔루션연구단 연구원
2017년 4월 ~ 현재 : 한서대학교 무인항공기학과 조교수
※관심분야 : 로봇자세제어, 휴머노이드 보행제어, 로봇동작제어



최원혁 (Won-Hyuck Choi)

2006년 2월 : 한국항공대학교 항공전자공학과 (공학박사)
2014년 2월 ~ 현재 : 한서대학교 항공전자공학과 교수
2022년 3월 ~ 현재 : 캐스트유한회사 대표
※관심분야 : 임베디드 시스템, 사물인터넷, 무선통신