

# 딥러닝 기반 객체탐지 및 추적기법을 활용한 군 제대규모 판단

김민우, 마정목\*  
국방대학교 국방과학학과

## Determining the Scale of Military Echelon Using Deep Learning-Based Object Detection and Tracking Techniques

Minwoo Kim, Jungmok Ma\*  
Department of Defense Science, Korea National Defense University

**요약** 4차 산업혁명 기술의 발전과 인구절벽 등 여러 요인으로 인해 군이 맞닥뜨리게 될 미래 작전환경에서 전투행위의 주체는 무인 중심으로 전환될 것이다. 그중 감시정찰 분야는 가장 먼저 무인체계에 의해 임무가 대체 되어가고 있다. 본 논문에서는 딥러닝 기반의 알고리즘을 활용하여 지상 감시 간 기동하는 군 제대의 규모를 판단하기 위한 연구를 수행하였다. 딥러닝 알고리즘 중 객체탐지와 객체추적 기법을 활용하여 영상 내 특정 무기체계를 식별하고 탐지된 객체의 계수를 통해 제대 규모를 판단하였다. 특히 기동 및 화력 무기체계인 자주포, 전차, 장갑차를 기준으로 제대규모를 판단하였으며, 제대의 규모를 판단할 수 있는 특정 무기체계에 대한 탐지와 추적, 계수에 집중하였다. 모델은 객체탐지 알고리즘인 YOLOv8s를 객체 검출기, 다중 객체추적 알고리즘에서 높은 성능을 보여주는 BYTE 알고리즘을 추적기로 구성하여 객체탐지와 추적을 수행한다. 마지막으로 객체탐지와 추적에 이어 클래스별로 객체를 계수하고 계수된 값에 의해 규모를 판단하는 알고리즘을 추가하여 모델을 완성하였다. 학습 데이터는 지상에서 촬영된 이미지를 클래스별로 수집하였고 클래스는 자주포, 전차, 장갑차 3가지로 구성하였다. 모델 평가를 위해 제대규모를 반영한 테스트 영상으로 모델의 정확도를 확인하였으며 80%의 정확도를 나타내었다. 본 연구를 통해 향후 지상 감시장비를 활용해 군 제대규모를 판단할 수 있는 방법을 제시하였다는 것에 의의가 있다.

**Abstract** The development of the Fourth Industrial Revolution, along with factors, such as population decline, will lead to a shift towards uncrewed systems in the future battlefield. The military will increasingly rely on uncrewed systems to carry out operations. Among them, uncrewed systems are replacing the surveillance and reconnaissance field. In this study, deep learning-based algorithms were used to judge the scale of ground-based military echelons moving in the surveillance area. A specific military unit was identified in the video using object detection and tracking techniques, and the scale of the military echelons was determined based on the count of detected objects. In particular, this study focused on detecting, tracking, and counting specific weapon units, such as self-propelled artillery, tanks, and armored vehicles. The model consists of the YOLOv8s object detection algorithm as an object detector and the BYTE algorithm as a multi-object tracking algorithm, showing high performance in object detection and tracking. Finally, the model was completed by adding algorithms that count objects by class and judge the size based on the counting. The training data was collected by the three types of classes from images taken from a ground perspective: self-propelled artillery, tanks, and armored vehicles. This study evaluated the model accuracy using test videos, and the result had an accuracy of 80%.

**Keywords :** Military Echelon, Object Detection, Multi Object Tracking, Object Counting, Determining the Scale

\*Corresponding Author : Jungmok Ma(Korea National Defense Univ.)

email: jxm1023@gmail.com

Received March 22, 2023

Accepted May 12, 2023

Revised April 13, 2023

Published May 31, 2023

## 1. 서론

우리 군이 직면하게 될 미래 작전환경은 인구절벽과 과학기술의 발전으로 인해 많은 변화가 예상된다. 출산율의 급감과 고령화가 심화되면서 군의 전투력 유지에 절대적인 부분을 차지하는 현역가용자원이 부족해질 것이다. 변화가 예상되는 상황 속에서 군은 인공지능을 접목하여 전투 수행의 주체를 사람에서 무인으로 변화시키고자 노력하고 있다. 이러한 노력의 일환으로 유·무인 복합 전투체계, 무인 무기체계 개발에 박차를 가하고 있다. 특히, 무인 무기체계는 전투의 효율성 증대, 위험도 및 운용인력 감소를 위해 4D(Dangerous, Dirty, Dull, Difficult)분야를 위주로 확산되고 있다[1]. 4D 분야 중 하나인 적지중심지역의 감시 임무 역시 무인체계에 의한 대체가 예상된다.

현재 우리 군은 표적정보 수집 및 특정지역 감시정찰 임무를 위해 지난 2017년부터 2021년까지 4년에 걸쳐 다기능관측경을 도입하여 전력화하였으며 최근 추가 도입을 결정하였다[2]. 다기능관측경은 주,야 감시능력을 보유하고 있으며 표적의 좌표, 이동속도, 방위각, 표적까지의 거리 정보를 수집 및 실시간으로 송신할 수 있는 능력도 보유하고 있다. 그러나 수집된 정보들을 분석하고 판단하는 것은 사람에 의한 수작업에 의존하고 있으며, 다기능관측경을 포함한 군의 감시자산으로부터 수집된 정보들을 자동으로 분석해주는 시스템이 필요하다. 표적의 규모를 판단하는 것 역시 인력에 의해 수행되는데, 전투를 수행함에 있어 표적의 규모 판단은 화력유도, 지휘관의 전술 방책선정에 직접적으로 연관되기 때문에 매우 중요하다.

본 연구에서는 지상 감시 관측된 제대의 규모를 자동으로 판단할 수 있는 방법을 살펴볼 것이다. 그 중 비정형적이며 불확실성이 존재하는 전장상황에 적용하기 적합한 컴퓨터비전 분야의 딥러닝 기법을 활용하여 연구를 수행한다. 기존 연구들 중 딥러닝을 활용하여 군 제대 규모를 판단하려는 시도가 공개적으로 이루어지지 않았으므로 본 연구에서는 딥러닝 기법을 적용해 지상 감시 관측된 제대규모를 판단할 수 있는 모델을 제시하고 테스트 영상을 통해 그 성능을 확인한다.

## 2. 관련 연구

### 2.1 객체 규모 판단 연구

탐지된 객체의 규모를 판단하는 연구는 크게 군사분야와 민간분야로 구분할 수 있다. 민간분야에서 유동인구 파악을 위한 군중의 규모 판단(crowd counting), 교통량 측정, 농업 분야를 비롯한 여러 분야에서 연구가 수행되었다. 군중의 규모를 판단하는 연구들 중 Jeon et al.[3]은 배경 영역을 억제함으로써 탐지하려는 사람의 인식률을 향상 시켰으며, Sim et al.[4]은 딥러닝 알고리즘인 VGGNet을 활용하여 군중의 규모를 판단하고 그 결과를 설명가능한 인공지능(eXplainable-AI) 모델인 Grad-CAM을 통해 확인하였다. 교통량 측정을 위한 분야에서도 연구가 진행되었는데, Lee et al.[5]은 교차로를 통과하는 차량의 계수(traffic counting)를 위해 교통감시 영상을 활용하여 객체탐지 알고리즘인 YOLO(You Only Look Once)를 사용하였으며, YOLO의 버전인 YOLOv2와 YOLOv3의 성능을 비교하였다. Jung et al.[6]은 도로에서의 차량 계수를 위해 계수선(counting line)을 설정하였으며, 도로 형태에 따라 계수선의 효율적인 생성 방법에 대해 연구를 진행하였다. 농업 분야에서 Park[7]은 감자의 수확량을 측정하기 위해 계수선을 설정하였으며, YOLOv5와 객체추적 알고리즘인 DeepSort를 이용하였다. Lee et al.[8]은 해충 발생량을 파악하기 위해 딥러닝 기반의 멀티 어텐션 Centernet 모델을 제안하여 포집된 해충의 수를 측정하였다.

군사 분야에서는 Choi et al.[9]이 감시정찰 센서 네트워크에서 군 제대규모 판단을 위한 연구를 진행하였다. 제대가 이동하며 센서를 지나갈 때마다 수집된 시간 정보의 간격을 기준으로 규모판단에 활용하였다. 성능평가는 실제 제대들이 교리에 근거한 이동속도와 제대 간 거리간격에 맞춰 이동할 때 알고리즘에 의해 판단된 결과를 바탕으로 수행하였다. 하지만 인원 위주의 제대에 한정하여 연구를 진행하였고 육군의 교리에 의한 이상적인 부대이동 상황을 가정하였기에 전장상황을 충분히 반영하지 못하였다는 한계가 존재한다.

본 연구에서는 병력 위주의 제대들을 연구대상으로 선정한 기존 연구와 달리 제대 간 구분이 더욱 명확하고 군사작전에서 상대적으로 큰 영향력을 미치는 기동, 화력 무기체계 위주로 구성된 제대를 연구대상으로 설정하였다. 또한 딥러닝을 기반으로 실제 제대가 이동할 때 각각의 객체들을 탐지, 추적하여 카운팅하는 방식으로 규모를 판단하였기에 다양한 전장상황에서의 적용에 유리하다는 점이 기존 연구와의 차이점이다.

### 2.2 군 제대규모 판단 기준

제대는 군사분야에서 사용되는 용어로서 어떠한 부대를 하나의 구분체로 설명하기 위해 사용된다. 제대는 전쟁을 수행함에 있어 임무와 역할에 따라 범주가 나뉘게 되는데, 전쟁의 목적을 달성하기 위해 요망되는 목표들의 수준에 따라 각각 전략적 수준, 작전술 수준, 전술적 수준으로 나뉜다[10].

본 연구에서는 전술적 수준에 속하는 전술 제대에 한정하여 연구를 진행하였으며 전술 제대 중 기본 전술단 위부대[11]인 대대급 이하를 판단하고자 하였다. Table 1에서 보는 것과 같이 판단하고자 하는 제대의 규모를 군대부호와 함께 8가지로 제시하였고, 각 제대의 규모를 판단할 수 있는 특정 무기체계의 편성을 군사 보안상 임의로 설정하였다.

Table 1. Weapon systems in military echelons

Military echelons		Weapon systems in echelon			Military symbology
		SP artillery	Tank	APC	
Artillery	battery	6	.	.	
	battalion	18	.	.	
Tank	platoon	.	3	.	
	company	.	10	.	
	battalion	.	32	.	
Mechanized infantry	platoon	.	.	3	
	company	.	.	10	
	battalion	.	.	32	

\*SP artillery : Self Propelled artillery(자주포)  
 \*APC : Armored Personnel Carrier(장갑차)

### 3. 군 제대규모 판단 모델

#### 3.1 연구 흐름 및 모델 구성

군 제대규모 판단을 위한 전체적인 연구의 흐름은 Fig. 1에 제시하였다. 우선, 이미지 데이터 수집 및 라벨링을 통해 학습 데이터셋을 구성한다. 학습 데이터셋을 통해 객체탐지 모델 학습 및 평가를 진행하여 군 제대규모 판단에 적합한 모델을 획득한다. 획득한 모델을 추적 알고리즘에 객체 검출기(detector)로 적용하며, 객체 카운팅 조건을 추가하여 클래스 별 객체 숫자를 측정한다.

카운팅된 숫자를 기반으로 제대규모를 판단하도록 모델을 구성하며 최종적으로 구성된 모델은 테스트 영상을 통해 제대규모 판단이 잘 수행되는지 확인한다.

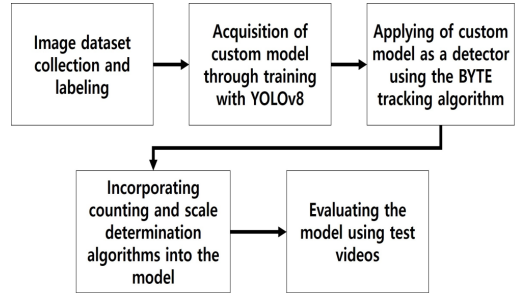


Fig. 1. Flowchart of the research

군 제대규모 판단 모델의 구성은 Fig. 2에 도식화하여 나타내었다. 데이터셋 학습으로 얻어진 커스텀 YOLOv8s 모델을 객체 검출기, BYTE 알고리즘을 추적기(tracker)로 구성하여 입력 영상 속 객체에 대한 탐지와 추적을 수행한다. 이후, 객체 카운팅 알고리즘과 규모 판단 알고리즘을 거쳐 제대의 규모가 출력 영상 내에 출력되게끔 모델을 구성하였다.

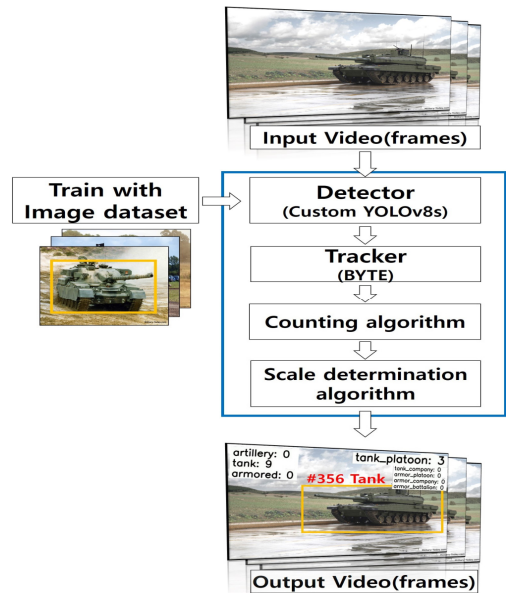


Fig. 2. Structure of the model determining military echelon scale

#### 3.2 군 제대규모 판단 모델 및 평가

##### 3.2.1 학습 데이터셋

학습 데이터셋의 클래스는 전차, 자주포, 장갑차 3가지로 구성하였다. 학습 데이터는 지상에서 촬영된 관점의 이미지를 수집하였으며, 자주포는 968장, 전차는 999장, 장갑차는 530장을 웹 브라우저인 구글(google) 검색 및 유튜브(youtube) 내의 동영상을 캡처하여 이미지를 직접 수집하였다. 자주포와 전차는 여러 각국의 무기체계를 수집하였으며, 장갑차는 국가별 형상이 다양하고 임무별 종류가 다양하여 궤도가 달린 장갑차를 기준으로 수집하였다.

수집된 이미지에 대해 라벨링을 실시하였으며 Yolo\_mark[12]라는 프로그램을 활용하여 클래스와 bounding box를 설정해주었다. Fig. 3은 클래스별 수집된 이미지와 Yolo\_mark를 이용하여 라벨링 처리한 이미지를 나타낸다.



Fig. 3. Dataset classes and labelling of images

모델 평가를 위해서 10개의 테스트 동영상을 활용하였으며 유튜브(youtube)의 군사 관련 채널[13]의 무기체계 영상을 사용하였다. 테스트 영상은 군 제대의 이동 모습이 담겨 있으며, 1920×1080픽셀, 초당 30 프레임의 영상이다. 테스트 영상은 도로 측면에서 도로를 따라 이동하는 객체들을 바라보는 관점에서 촬영되었으며, 한 지점에 고정되어 촬영된 영상을 사용하였다.

### 3.2.2 객체탐지 모델 평가지표

객체탐지 모델의 성능을 평가하기 위해 정밀도(precision), 재현율(recall), F1 score, mAP@0.5의 지표를 사용한다. 정밀도는 모델이 Positive로 예측한 샘플 중 실제로 Positive인 샘플의 비율을 의미하고, 재현율은 실제 Positive인 샘플 중 모델이 Positive로 예측한 샘플의 비율을 나타낸다. F1 Score는 정밀도와 재현

율의 조화평균으로 설명 가능하며 위 지표들은 아래 Eq. (1)~(3)으로 나타낸다.

$$Precision = \frac{TP}{(TP+FP)} \quad (1)$$

$$Recall = \frac{TP}{(TP+FN)} \quad (2)$$

Where, TP true positive, TN true negative, FP false positive, FN false negative

$$F1\ Score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} \quad (3)$$

mAP(mean Average Precision)값은 IOU(Intersection of Union) threshold 값(예측한 박스와 실제 박스 간의 IOU 임계치)을 사용하여 Precision-Recall 곡선의 면적을 평균화한 값을 의미한다. mAP@0.5는 IoU threshold가 0.5일 때의 정밀도 평균값을 나타낸다.

### 3.3 객체탐지

군 제대규모 판단 모델의 객체 검출을 위해 YOLOv8 [14]을 활용하였다. YOLO는 객체탐지를 위한 알고리즘으로 2016년 처음 공개되었으며, 최근 YOLOv8 버전이 공개되었다. YOLO의 특징으로는 one-stage 검출기로서 객체의 위치를 인식하고 객체의 클래스 분류를 하나의 과정으로 수행한다는 점이다. 기존 객체탐지 알고리즘에서 2단계로 나누어 실시하던 것과 비교하여 정확도는 거의 대등하나 연산속도가 월등하여 실시간 영상 속 객체탐지에 유리하다. YOLOv8의 구조는 backbone 네트워크와 neck, head로 이루어져 있다. backbone에서 입력 이미지의 특징을 추출하여 feature map으로 변형시켜주며 head에서는 클래스 예측과 bounding box의 위치를 예측하는 작업을 동시에 수행한다. YOLOv8의 가장 큰 특징은 anchor free detection 모델이라는 점이다. 기존 YOLO 버전에서는 bounding box의 anchor를 기준으로 예측을 수행하였으나 YOLOv8은 기본값으로 설정된 anchor를 사용하지 않는 대신에 객체의 중앙값(center value)을 우선적으로 탐색한다. 덕분에 사용자의 커스텀 데이터셋을 학습하는데 더욱 효과적이다. 또한 이전 버전인 YOLOv5에 비해 더 높은 정확도 성능을 보여준다[15].

군 제대규모 판단 모델에 적용할 객체 검출기를 얻기 위해 COCO 데이터셋으로 학습되어 있는 YOLOv8s 모델을 이용하여 전이학습을 실시하였으며, 학습 데이터셋

에 적합하게끔 fine-tuning의 과정을 거쳤다. YOLOv8은 네트워크의 크기에 따라 n, s, m, l, x 총 5개의 모델이 있는데, 이 중 n이 가장 작고, x가 가장 큰 모델이다. 크기가 작을수록 속도는 빠르지만 정확도가 낮아지며 큰 모델일수록 속도가 느려지는 대신 정확도는 높아진다. 본 연구에서는 상대적으로 낮은 정확도 성능을 보이지만 실시간 영상에 적합한 빠른 연산속도를 갖는 YOLOv8s가 적합하다고 판단하였다. 학습 데이터셋은 훈련, 검증, 테스트 샘플로 나누었으며 각각 8:1:1의 비율로 랜덤하게 나누어 학습을 진행한다. 훈련 샘플에 대하여 학습 파라미터는 epoch은 200, batch 크기는 16, 학습률 0.001, image size=640으로 설정하여 학습을 진행하였다. 모델 학습 간 환경은 Intel(R) Core(TM) i5-6200U CPU와 Windows 10, GPU는 구글에서 제공하는 Colab Pro의 클라우드 GPU(Tesla T4), 램은 83.5GB, Python 3.8.10버전, Pytorch 1.13.1, Cuda 11.6에서 학습을 수행하였다.

아래 Fig. 4는 학습된 객체탐지 모델의 Precision-Recall 곡선(이하 "PR 곡선")이다. PR 곡선의 넓이인 mAP@50이 클래스별로 0.990에서 0.994까지 높은 수준을 기록하였으며 전체 클래스에 해당하는 mAP@50은 0.992의 수치를 나타내었다.

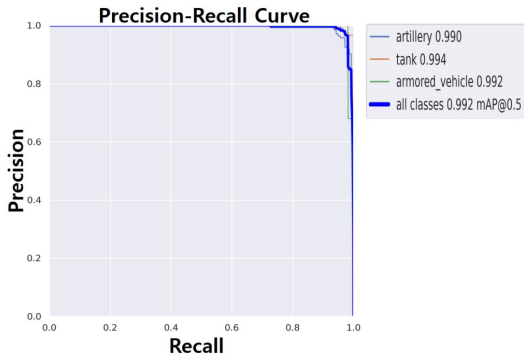


Fig. 4. Precision-Recall Curve of trained model

Table 2에서는 epoch에 따른 학습 모델의 성능을 나타내었고 epoch 100에서 가장 높은 성능을 기록하였으며 그 이후에는 유의미한 성능의 향상이 나타나지 않았다. 이를 통해 데이터셋에 대해 학습이 잘 이루어졌음을 확인할 수 있으며, 최적의 성능을 기록한 가중치를 사용하여 객체 검출기로 활용하였다.

Table 2. Performance of trained model

Epoch	Precision	Recall	F1 Score ↑	mAP@50 ↑
1	0.55679	0.59835	0.57682	0.56483
50	0.96620	0.96936	0.96777	0.99042
100	0.97986	0.97592	<b>0.97789</b>	<b>0.99147</b>
150	0.97789	0.97642	0.97715	0.9904
200	0.96979	0.96428	0.96703	0.98812

### 3.4 객체추적

BYTE[16]는 영상 내에서 다중 객체추적을 수행하기 위해 제안된 알고리즘이다. BYTE는 객체 검출기에 의해 탐지된 객체의 bounding box가 존재할 때, 다음 프레임에서의 객체 위치를 예측한 prediction box들을 생성한다. 그리고 영상이 진행되어 다음 프레임이 되었을 때, 탐지된 객체의 새로운 bounding box와 이전 프레임에서 예측한 prediction box들과의 유사성이 가장 높은 box들을 매칭하는 방식으로 추적을 수행한다. BYTE의 가장 큰 특징은 confidence score(탐지된 객체가 특정 클래스에 해당할 확률)의 높고 낮음에 따라 탐지된 bounding box를 두 가지로 분류하고, 낮은 confidence score를 갖는 bounding box는 추적에서 제거하지 않고 다음 프레임에서의 위치 예측을 한번 더 수행함으로써 추적 성능을 향상시켰다는 점이다. 이로 인해 객체가 순간적으로 가려지거나 일부 겹쳐져 confidence score가 순간적으로 낮아지더라도 객체에 대한 추적을 중단하지 않고 지속 수행한다.

본 연구에서는 학습된 객체탐지 모델을 검출기로 사용하여 객체추적을 실시하기 위해 BYTE 알고리즘을 활용한다. BYTE는 위와 같은 특징으로 다른 객체추적 알고리즘인 SORT, DeepSort, MOTDT와 비교하여 FPS는 대등한 수준을 유지하면서 추적 성능은 향상시켰으며 ID가 교차되는 현상도 감소시켰다. 이러한 특징을 고려하였을 때, BYTE 알고리즘이 이번 연구에 적합하다고 판단하였다.

### 3.5 객체 카운팅 및 제대규모 판단 알고리즘

2장에서 언급한 Jung et al.[6], Park[7]의 기존 연구들에서는 객체 카운팅 시에 계수선을 설정하고 객체가 선을 통과할 시 카운팅하는 방법을 사용하였다. 그러나 군 무기체계 특성상 일정한 형태를 갖춘 도로가 아닌 야지를 기동하는 일이 빈번하게 일어나고, 다양한 관측 시점이 존재하므로 계수선을 통해 카운팅을 하는 것은 적

합하지 않다. 그래서 이번 연구에서는 계수선을 설정하지 않고 영상 속 프레임 별 탐지된 객체의 confidence score를 기반으로 객체 카운팅을 진행한다.

제안하는 알고리즘은 다음과 같다. 우선 객체 검출기를 통해 프레임 단위로 객체가 탐지되면, 추적 알고리즘을 거쳐 각각의 객체에 고유한 ID가 부여되어 추적을 시작한다. 추적이 수행될 때마다 ID에는 검출기에 의해 분류된 클래스 정보와 confidence score가 기록되는데, ID마다 가장 높은 confidence score를 기록했던 순간의 클래스 정보를 저장한다. 이때, confidence score의 threshold를 0.9로 설정하여 0.9 이상의 값을 갖는 클래스만을 카운팅 대상으로 설정한다. threshold를 설정한 이유는 confidence score가 0.9 미만일 때는 클래스 분류의 정확도가 상대적으로 떨어져 카운팅의 오류가 증가하기 때문이다. threshold의 설정은 객체 검출기의 성능과 연관되는데, 본 연구에서는 객체 검출기의 학습이 잘 이루어져 탐지된 객체에 대해 0.9 이상의 값을 보이며 클래스 분류를 올바르게 수행한다.

confidence score 조건에 추가하여 ID가 일정 이상의 프레임에서 추적될 시에만 카운팅 대상이 되도록 설정하였다. 이때, 카운팅을 위해 추적되어야 하는 최소 프레임은 초당 30프레임 영상 기준, 60프레임(2초) 이상으로 설정하였다. 즉, confidence score가 0.9 이상이라든 60프레임 이상 추적되지 못한 ID는 카운팅에서 제외된다. 이러한 조건을 설정한 이유는 추적이 이루어지는 동안 순간적인 ID 교차, 중복 할당의 문제가 발생하여 1개의 객체에 여러 ID가 부여될 수 있으며, 이러한 문제의 대부분은 30프레임(1초) 미만에서 간헐적으로 발생하기 때문이다.

결론적으로 60프레임(2초) 이상 추적이 이루어지고, confidence score가 0.9 이상을 기록한 ID를 카운팅 대상으로 하게 된다. 그리고 대상이 된 각각의 ID마다 가장 높은 confidence score를 기록한 클래스를 최종적으로 카운팅 하도록 알고리즘을 구성하였다.

Fig. 5에는 프레임이 진행되며 객체가 카운팅되는 과정을 나타내고 있다. 프레임  $t_1$ 에서는 객체를 탐지하여 #410의 ID를 부여하여 추적하고 있고, 해당 클래스는 자주포, confidence score는 0.9이며 60프레임 이상 추적되었다. 이를 토대로 자주포 클래스가 1 카운팅 되었다. 영상이 진행되어 프레임이  $t_2$ 가 되었을 때, #410은 전차 클래스, confidence score는 0.68로 탐지되었으나 기존의 0.9보다 값이 낮기 때문에 업데이트 되지 못

하였으며, 카운팅에 영향을 주지 못하였다. 프레임이  $t_3$ 가 되었을 때, #410의 confidence score가 0.97로 이전까지 기록된 값들 중 가장 크므로 기존의 값을 업데이트하고, 최종적인 #410 객체는 해당 클래스인 전차로 카운팅 하게 되었다. 이때, ID #414도 탐지되었으나 60프레임 이상 추적되지 않았기 때문에 카운팅에서 제외되었다.

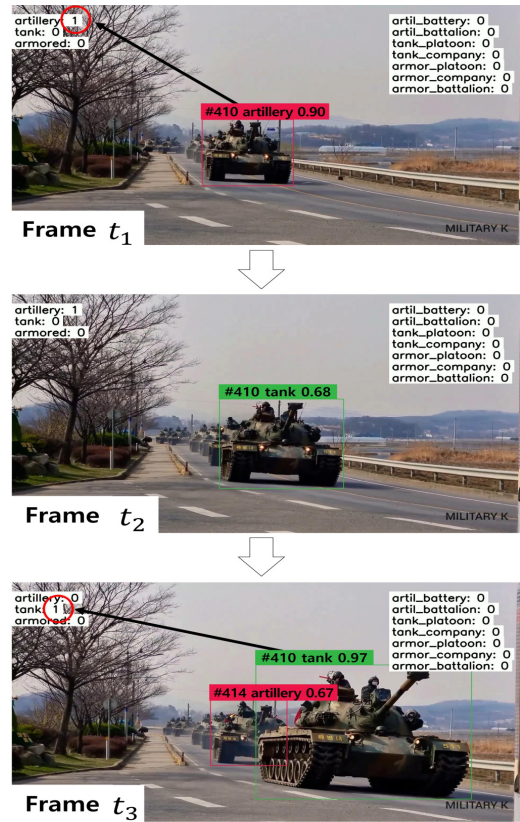


Fig. 5. The process of object counting as the frame advances

군 제대규모 판단은 클래스별 카운팅 된 객체 수를 기반으로 한다. 프레임이 진행되면서 각 클래스에 대한 객체 수를 업데이트하여 저장하고, 해당 제대의 조건을 충족했을 때 카운팅이 증가한다. 즉, 영상이 진행되면서 클래스별 객체 개수가 카운팅되어 누적되고, 그 결과값을 토대로 제대 규모가 결정되게 된다. Fig. 6에 나타난 것처럼 전차가 9대 카운팅되면 해당 조건을 만족하는 전차 소대 3개 규모로 판단됨을 확인할 수 있다.



Fig. 6. Object counting-based measurement of echelon scale

### 3.6 군 제대규모 판단 모델 평가

평가는 10개의 테스트 영상을 통해 수행하였다. 각 영상마다 모델에 의해 카운팅된 객체들의 수와 실제 객체 수를 비교하여 클래스별 객체 카운팅의 정확도(accuracy)를 구하였으며, 모델에 의해 판단된 제대규모와 실제 영상 속 제대규모를 비교하여 모델의 정확도를 구하였다. 정확도는 Eq. (4)와 같이 계산할 수 있다.

$$Accuracy = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (4)$$

Where, TP true positive, TN true negative,  
FP false positive, FN false negative

Table 3은 #1부터 #10까지 총 10개의 영상에 대한

실험의 결과를 나타내었으며, 영상별 실제 클래스별 객체 수, 카운팅된 객체 수, 영상의 제대 규모를 올바르게 판단했는지에 대해 결과를 표시하였다. #1의 실험에서는 장갑차 1대에 대해 2개의 ID가 중복으로 할당되며 추적되어 장갑차를 1대 더 카운팅하는 오류가 있었으나 제대 규모 판단에는 영향을 주지 못하였다. 하지만 #4의 실험에서는 장갑차 2대에 대해, 1대는 미식별, 1대는 전차로 오인하여 카운팅하는 오류가 발생하여 제대규모를 오판하게 되었다. #7 실험에서는 전차 1대에 대해 2개의 ID가 할당되었는데, 1개는 전차, 나머지 1개는 장갑차로 판단하여 카운팅되었다. 결과적으로 장갑차가 1대 더 카운팅되어 제대규모를 오판하게 되었다. #9의 실험에서도 #7과 마찬가지로 이유로 장갑차가 1대 더 카운팅되었고, 구난전차를 장갑차로 오인하여 1대 더 카운팅하여 결과적으로 장갑차가 총 2대 더 카운팅되는 오류가 발생하였다. 하지만 제대규모 판단에는 영향을 주지 않았다. 그 외 실험에서는 객체 카운팅과 제대판단을 정확하게 수행하였다.

Table 4는 Table 3의 결과를 바탕으로 각 클래스의 객체 카운팅의 정확도와 제대규모 판단의 정확도를 수치로 나타냈다. 장갑차의 카운팅 정확도가 전차와 자주포에 비해 다소 떨어지는 것을 확인하였으며 장갑차가 아닌 객체에 대해 장갑차로 오인 식별하는 사례가 다수 식별되었다. 이는 장갑차의 외관적 특성을 전차와 상당 부분 공유하고 있기 때문으로 판단된다. 결론적으로 제대 규모 판단은 총 10번의 실험 중 8번에서 정확히 측정하였다.

Table 3. The experiments results of the military echelon scale measurement

Experiments		#1	#2	#3	#4	#5	#6	#7	#8	#9	#10
Counting value by the algorithm	SP artillery	·	·	·	·	6	7	·	·	·	10
	Tank	5	4	·	1	·	·	26	13	10	·
	APC	4	5	7	8	1	·	3	2	2	1
Ground truth value of class counts	SP artillery	·	·	·	·	6	6	·	·	·	10
	Tank	5	4	·	·	·	·	26	13	10	·
	APC	3	5	7	10	1	·	2	2	·	1
Results of the military echelon scale assessment											
Ground truth value of military echelon scale											

Table 4. Accuracy of the counts for each class and echelon scale measurement

Class	SP artillery	Tank	APC	Echelon scale measurement
Accuracy(%)	95.6	95.0	82.3	<b>80.0</b>

### 4. 결론

본 연구에서는 딥러닝 기반 객체탐지와 추적 기법을 통해 기동하고 있는 제대의 규모를 판단할 수 있는 알고리즘을 제시하였으며 각 제대 별 테스트 영상을 통하여 성능을 확인하였다. 하지만 연구는 전술 제대 중 대대급 이하 규모에 한정하여 진행하였으며 기동 및 화력 무기 체계 위주에 국한하였다는 한계가 있다. 또한 영상 관점에 따라 가려짐(occlusion)이 발생하거나 객체 검출기 성능에 따라 동일 객체에 ID가 중복되는 경우가 발생한다. 이로 인해 1개의 객체에 2개 이상의 ID가 할당되어 카운팅 될 경우, 제대규모 판단에 영향을 줄 수 있다는 한계가 존재한다.

그럼에도 본 연구는 딥러닝을 기반으로 군 제대규모를 판단하려는 기존에 없던 시도를 하였으며, 이를 통해 향후 지상 감시장비를 활용해 군 제대규모를 판단할 수 있는 방법을 제시하였다는 것에 의의가 있다.

또한 군과 관련된 기존 연구들과의 학습 데이터의 양을 비교하였을 때, 본 연구에서는 클래스별 500장에서 많게는 1000여장에 가까운 학습 데이터셋을 확보하여 모델의 신뢰도를 높이고자 시도하였다.

향후 연구에서는 클래스를 세분화하여 제대를 구성하고 있는 무기체계의 다양성을 반영할 필요가 있다. 이를 위해 더욱 많은 무기체계 이미지를 수집하고 제대규모 판단의 조건도 구체화한다면 더 정확한 모델을 구현할 수 있을 것으로 기대한다.

### References

[1] C. J. Jung, Future Operational Environment Analysis, p.127, ROKA Training & Doctrine Command, 2022, pp.8-33.  
 [2] Defense Acquisition Program Administration(DAPA), Deployment of MPOD with Improved Performance on the Battlefield Begins, DAPA press release, released 2022 Dec 20, Available From:

<https://www.dapa.go.kr/dapa/na/ntt/selectNttInfo.do?bbsId=326&nttSn=42906&menuId=678> (accessed Feb. 24, 2023)  
 [3] Y. R. Jeon, J. P. Heo, "Improved Crowd Counting and Localization based on Background Suppression" *The Korea Software Conference 2021*, The Korean Institute of Information Scientists and Engineers, Pyeong-chang, Korea, pp.1,478-1,480, Dec. 2021.  
 [4] K. W. Sim, J. M. Son, K. H. Kang, "Crowd counting based on Deep Learning", *The KSCI summer Conference 2021*, The Korea Society of Computer Information, Jeju, Korea, pp.17-20, July 2021.  
 [5] T. H. Lee, Y. S. Park, Y. M. Kim, D. H. Choi, "A Method of Counting Vehicle with High Accuracy Using YOLOv3", *Transactions of KSAE*, Vol.29, No.3, pp.283-288, March 2021.  
 DOI: <https://doi.org/10.7467/KSAE.2021.29.3.283>  
 [6] H. S. Jung, S. J. Lim, R. Lee, M. W. Park, S. H. Lee, W. J. Kim, "Adaptive Counting Line Detection for Traffic Analysis in CCTV Videos", *Journal of Broadcast Engineering*, Vol.25, No.1, pp.48-57, January 2020.  
 DOI: <https://doi.org/10.5909/JBE.2020.25.1.48>  
 [7] S. H. Jang, S. H. Lee, Y. Choi, T. H. Kim, S. Y. Shin, "Design of a Potato Yield Monitoring System Using Deep-Learning", *Journal of the Korea Academia-Industrial cooperation Society*, Vol.23, No.5, pp.217-224, May 2022.  
 DOI: <https://doi.org/10.5762/KAIS.2022.23.5.217>  
 [8] W. D. Won, J. H. Lee, G. E. Kim, C. H. Son, H. J. Lee, "Multiscale Attention CenterNet for Pest Counting", *Proceedings of the 2022 KIIT Autumn Conference*, Korean Institute of Information Technology, Jeju, Korea, pp.497-501, December 2022.  
 [9] J. H. Choi, T. W. Kwon, "Echelons Scale Identification Scheme of Surveillance and Reconnaissance Sensor Network", *The Korea Institute of Military Science and Technology*, Vol.13, No.3, pp.438-444, June 2010.  
 [10] ROKA Field Manual 0-1, "Tactics", Republic of Korea Army Headquarters, 2013.  
 [11] ROKA Field Manual 3-0-1, "Military Glossary", Republic of Korea Army Headquarters, 2012.  
 [12] A. Bochkovskiy, Available From: [https://github.com/AlexeyAB/Yolo\\_mark](https://github.com/AlexeyAB/Yolo_mark) (accessed Feb. 10, 2023)  
 [13] Military K. Y. W. Yoo TV, Youtube channel, Available From: <https://www.youtube.com/@militaryk2178/featured>, <https://www.youtube.com/@TV-hg1nn/featured> (accessed Feb. 12, 2023)  
 [14] G. Jocher, Ultralytics YOLOv8, Available From: <https://github.com/ultralytics/ultralytics> (accessed Feb. 25, 2023)  
 [15] G. Jocher, Performance of YOLOv5 models, Available From: <https://github.com/ultralytics/yolov5> (accessed Feb. 25, 2023)



- [16] Y. Zhang, P. Sun, Y. Jang, D. Yu, F. Weng, Z. Yuan, P. Luo, W. Liu, X. Wang, "ByteTrack : Multi-Object Tracking by Associating Every Detection Box", *arXiv preprint arXiv:2110.06864v3*, revised 2022.
- 

김민우(Minwoo Kim)

[준회원]



- 2016년 2월 : 육군사관학교 무기시스템 공학과 (무기시스템 공학 학사)
- 2022년 2월 ~ 현재 : 국방대학교 국방과학학과 (석사과정)

<관심분야>

인공지능, 무기체계 획득관리

---

마정목(Jungmok Ma)

[정회원]



- 2002년 2월 : 육군사관학교 운영분석학과 (운영분석 학사)
- 2008년 8월 : 미국 펜실베이니아 주립대(PSU) (산업공학 석사)
- 2015년 5월 : 미국 일리노이대(UIUC) (산업공학 박사)
- 2015년 9월 ~ 현재 : 국방대학교 국방과학학과 교수

<관심분야>

국방 모델링 및 데이터 분석학, 무기체계 획득관리