

합성데이터 기반의 YOLOv8n 모델을 활용한 다중 거리 자동 표적 탐지 성능 분석

김동윤¹, 배기민², 박진우¹, 이진구¹, 이장형*¹

¹육군미래혁신연구센터, ²똑똑한청년들

johnkimdy@gmail.com, gm.bae@ddok.ai, pjw9825@gmail.com, lee.jingu@airsmed.com, leejangh@mnd.go.kr

Performance Analysis of Multi-Distance Automatic Target Detection Using Synthetic Data with YOLOv8n Model

Kim Dong Yoon¹, Bae Gi Min², Park Jin Woo¹, Lee Jin Gu¹, Lee Jang Hyong¹

¹Korea Army Research Center for Future and Innovation
²DDOK

요약

본 연구에서는 합성데이터를 활용하여 자동 표적 탐지 인공지능(AI)의 최적 학습 요구조건을 도출하고자 하였다. 이를 위해 ARMA3 기반의 합성 전장 환경에서 맑은 날, 주간 조건에서 다양한 거리와 각도로 전차 이미지를 생성하였다. 촬영 거리는 20m에서 200m까지 10m 간격으로 설정하였고, 카메라 시점은 고정된 객체를 중심으로 Yaw(Z축) 기준 5도, Pitch(Y축) 기준 4도 간격으로 회전시켜 다양한 각도의 이미지를 확보하였다. 학습 데이터는 근거리(20m), 중거리(80m), 원거리(150m)에서 선택된 이미지를 사용하였으며, 이 학습된 모델을 통해 20m부터 200m까지 10m씩 증가하는 거리에서의 표적 탐지 성능을 평가하였다. 실험 결과, 특정 거리와 각도에서 학습된 모델은 다른 거리에서도 일정 수준 이상의 탐지 성능을 유지했으나, 거리 및 각도 변화에 따른 성능 변동이 관찰되었다. 본 연구는 자동 표적 탐지 AI의 학습에 있어 촬영 거리와 각도가 모델 성능에 미치는 영향을 분석하고, 최적의 학습 조건을 도출하기 위한 기초 자료를 제공한다. 이를 통해 합성데이터 기반의 표적 탐지 AI 모델의 성능을 향상시키는 데 기여할 수 있을 것으로 기대된다.

I. 서론

최근 인공지능(AI) 기술의 급속한 발전은 다양한 분야에서 혁신을 일으키고 있으며, 특히 자동 표적 인식 분야에서도 AI의 도입이 활발히 이루어지고 있다. 자동 표적 인식 AI는 군사, 보안, 산업 등의 영역에서 정확하고 신속한 표적 탐지를 가능하게 하여, 작전 수행 능력과 효율성을 크게 향상시킬 수 있는 잠재력을 지니고 있다. 이러한 기술적 가능성으로 인해 표적 인식 AI의 개발과 적용에 대한 관심이 증가하고 있으며, 이에 따라 AI를 효과적으로 학습시키기 위한 다양한 연구가 진행되고 있다. [1]

그러나 표적 인식 AI를 학습시키기 위한 데이터셋 구축 및 모델 학습에 관한 표준화된 규칙이나 가이드라인은 아직 정립되지 않은 상황이다. 이는 AI의 성능에 큰 영향을 미칠 수 있는 학습 데이터의 구성 요소, 예를 들어 촬영 거리, 각도, 환경 조건 등의 변수들이 체계적으로 정의되지 않았기 때문이다. 이로 인해 개발된 AI 모델이 다양한 실전 환경에서 일관된 성능을 보장하기 어려워, 실제 적용에 한계가 있을 수 있다.

본 논문은 이러한 문제를 해결하고자, 합성 데이터를 기반으로 지상 표적 탐지 시스템의 AI의 학습에 필요한 최적의 요구조건을 도출하는 것을 목표로 한다. 이를 위해, ARMA3 기반의 합성 전장 환경에서 생성된 데이터를 활용하여 다양한 거리와 각도에서의 표적 인식 성능을 분석하고, 이를 바탕으로 표적 인식 AI 학습을 위한 최적의 데이터셋 구축 방안을 제안하고자 한다.

으로 설정하였으며 촬영 각도는 다양한 시점에서 표적을 학습할 수 있도록 조정되었으며, 객체를 중심으로 Yaw(Z축)을 기준으로 5도 간격으로 총 72번, Pitch(Y축)을 기준으로 약 4도 간격으로 총 20번씩 회전시켜 WXGA급(1280x800) 이미지를 거리별로 1,440장을 생성하였다. 촬영 거리 조정을 통해 자동 표적 탐지 AI가 근거리부터 원거리에 이르기까지 다양한 상황에서 표적을 인식할 수 있도록 하였으며 각도 조정을 통해 AI가 다양한 시점에서 표적을 효과적으로 탐지할 수 있도록 학습을 돕고, 실제 전장 환경에서의 탐지 성능을 강화하는 데 중점을 두었다.




그림1. 촬영 각도와 거리에 따른 합성데이터 생성 결과

II. 본론

그림 1은 촬영 각도와 거리에 따른 합성 데이터 생성 결과를 보여준다. 본 논문에서는 단일 전차 객체를 중심으로 20m에서 200m까지 10m 간격

데이터 라벨링은 인공지능(AI) 모델의 성능에 직접적인 영향을 미치지 않지만, 정확한 라벨링을 위해서는 많은 시간과 인력이 소요되는 문제가 있습니다. 특히 현실에서 획득된 데이터셋의 경우, 라벨링 과정이 매우 비용

소모적일 수 있어 효율적인 방법이 필요하다.

$$x' = \frac{f \cdot X}{Z} \quad y' = \frac{f \cdot Y}{Z} \tag{1}$$

본 논문에서는 식 1과 같은 카메라 투영 방식의 좌표 변환을 사용하여 3D 공간에서 생성된 정점 데이터를 기반으로 객체의 위치를 2D 이미지 상의 바운딩 박스로 변환하였다. 그림 2는 변환 과정의 예시로 초점거리 f 의 3D 공간의 좌표(X, Y, Z)를 2차원 이미지 평면의 좌표(x', y')로 변환된 결과를 보여준다.




그림2. 좌표 변환 방법

본 논문에서는 거리에 따른 자동 표적 탐지 AI의 성능을 평가하기 위해 학습은 표1에서와 같이 A)근거리(20m), B)중거리(80m), C)원거리(150m), D)근거리(20m)와 중거리(80m), E)근거리(20m)와 원거리(150m), F) 중거리(80m)와 원거리(150m), G)근거리(20m)와 중거리(80m)와 원거리(150m)를 학습하였고 평가는 학습한 거리를 제외한 나머지 거리를 평가하였다. 평가 지표는 mAP (Mean Average Precision)50-95를 사용하였으며 이는 모델이 얼마나 정확하게 객체를 탐지하고 분류하는지를 나타내며 IoU 임계값을 0.5에서 0.95까지 0.05 간격으로 다양하게 설정하여 각각의 mAP를 계산한 후, 그 평균을 구한 값이다.

학습에 사용된 모델은 YOLOv8n 모델을 사용하였다. [2] YOLOv8n 모델은 YOLO(You Only Look Once) 시리즈의 최신 버전 중 하나로, 경량화된 구조를 가진 nano 버전이다. 이 모델은 자원이 제한된 환경에서도 높은 성능을 유지하면서 빠른 속도로 작동할 수 있도록 최적화되어 있다. 이러한 특성은 드론, 무인 비행기(UAV), 무인 지상 차량(UGV) 등과 같은 플랫폼에서 실시간으로 활용될 수 있음을 나타낸다.

표 1. 모델별 학습한 이미지 종류

모델 거리	A	B	C	D	E	F	G
근거리 (20m)	○			○	○		○
중거리 (80m)		○		○		○	○
원거리 (150m)			○		○	○	○

표 2. 거리별 바운딩 박스 평균 비율

거리	비율	거리	비율	거리	비율	거리	비율
20m	12.1%	70m	0.81%	120m	0.27%	170m	0.13%
30m	4.85%	80m	0.61%	130m	0.23%	180m	0.12%
40m	2.61%	90m	0.48%	140m	0.20%	190m	0.10%
50m	1.64%	100m	0.39%	150m	0.17%	200m	0.09%
60m	1.12%	110m	0.31%	160m	0.15%		

표 2는 각 거리에 따른 이미지 내의 객체가 차지하는 비율의 평균값으로 근거리일수록 객체가 이미지 내에서 큰 비율을 차지하는것을 확인할 수 있다. 또한 촬영 거리가 60m 이상이 되는 경우 전체 이미지 크기 내 전차의 크기가 약 1% 이하로 낮아짐을 확인하였다.

표3은 학습 모델별 각 촬영 거리의 mAP50-90 실험 결과로 근거리(20m)서 학습된 모델은 근거리에서 매우 높은 성능을 보였으나, 중거리(80m)와 원거리(150m)에서는 성능이 급격히 감소하였다. 반면, 중거리나 원거리 데이터를 포함하여 학습한 모델은 다양한 거리에서 더 균형 잡힌 성능을 보였다. 이는 객체가 차지하는 비율이 비슷한 값을 가지기 때문으로 확인하였다.

또한, 단일 거리를 학습한 모델(A, B, C)에 비해 다중 거리를 학습한 모델(D, E, F, G)이 일반화된 성능을 발휘할 수 있음을 확인하였다.

즉, 실제 작전 환경에 적용하기 위해서는 다양한 거리에서의 데이터를 학습해야 함을 확인할 수 있었다. 특히, 근거리(20m), 중거리(80m), 원거리(150m) 데이터를 조합하여 학습한 모델이 다양한 거리에서 안정적인 성능을 보여주었으며, 특정 거리에 과적합되는 현상이 줄어들어 모델의 일반화 능력이 향상되었음을 확인할 수 있었다. 근거리, 중거리, 원거리 데이터를 종합하여 학습한 모델인 모델 G가 가장 많은 최고 성능과 차선택의 성능을 보이는 것을 확인할 수 있다. 이는 실제 데이터를 수집할 때 모든 거리의 데이터를 확보할 필요 없이, 근거리, 중거리, 원거리에 해당하는 중요한 거리 데이터를 중심으로 수집함으로써 비용과 시간을 절약할 수 있는 가능성을 나타낸다.

표 3. 실험 결과 (mAP50-95, 단위 : %)
: 최고성능 : 차선택 성능

모델 거리	A	B	C	D	E	F	G
20m	-	0	0	-	-	0	-
30m	86.58	0.15	0	87.76	85.87	0.71	87.39
40m	70.50	10.97	0	76.31	70.08	23.25	71.24
50m	45.08	72.42	0.06	80.46	45.05	77.25	73.68
60m	22.11	88.88	2.57	91.41	22.20	91.11	91.00
70m	5.06	93.41	22.44	92.76	22.37	93.25	93.91
80m	0.11	-	55.26	-	51.05	-	-
90m	0	63.41	76.66	91.09	74.27	94.28	94.13
100m	0	91.80	85.06	90.31	83.73	91.76	92.18
110m	0	83.94	89.09	83.53	87.00	91.74	90.86
120m	0	82.88	88.21	82.39	87.56	89.23	89.28
130m	0	81.73	88.17	80.44	86.54	89.20	88.55
140m	0	81.53	87.79	80.07	86.29	87.77	87.97
150m	0	79.77	-	77.97	-	-	-
160m	0	77.68	85.99	75.42	84.31	85.07	85.06
170m	0	73.42	84.00	70.88	83.32	83.63	83.94
180m	0	68.20	82.40	63.03	81.29	81.87	82.32
190m	0	62.38	82.73	54.06	81.86	81.69	82.38
200m	0	55.44	81.62	40.79	80.65	80.50	80.79

III. 결론

본 연구에서는 YOLOv8n 모델을 사용하여 다양한 거리에서 자동 표적 탐지 성능을 평가하였다. 근거리, 중거리, 원거리 데이터를 각각 학습한 모델과 이들의 조합을 학습한 모델을 비교한 결과, 다양한 거리 데이터를 함께 학습한 모델이 전체적인 탐지 성능에서 우수함을 확인할 수 있었다. 특히, 모델의 일반화 성능을 평가하기 위해 학습에 사용된 거리를 평가에서 제외한 실험에서, 다중 거리 학습이 단일 거리 학습에 비해 더 일관된 성능을 보였다. 더 구체적으로 우리는 객체로부터 20m-200m 사이의 연속적인 거리에서의 촬영이 아니더라도, 이산적인 거리인 20m, 80m, 150m, 이 세 거리에서만 드론촬영을 하여 얻은 이미지로도 20m-200m 사이의 객체인식이 원활이 된다는 증거가 된다, 이러한 결과는 자동 표적 탐지 AI의 실전 적용 시, 다양한 환경에서의 데이터 수집과 학습이 중요함을 시사한다. 앞으로의 연구에서는 다양한 환경 조건과 객체의 종류를 포함한 데이터셋을 활용하여, 모델의 실전 성능을 더욱 향상시키는 방안을 모색할 필요가 있다.

참 고 문 헌

[1] 이준희, 이용현, 유지상, 장경선 "위리어 플랫폼을 위한 YOLOv4 기반 자동 표적탐지" 정보과학회 컴퓨팅의 실제 논문지 30.3 pp.115-124 (2024) : 115.

[2] Jocher, Glenn, Ayush Chaurasia, and Jing Qiu. "Ultralytics YOLOv8." Version 8.0.0, 2023, <https://github.com/ultralytics/ultralytics>.