

딥러닝 기반 사격 정확도 판독 알고리즘 개발

윤성호*, 김재현*, 박희태**

* 국방기술품질원 기동화력센터

** 에스엔티모티브 주식회사

e-mail : engineer_ysh@dtaq.re.kr

A Study of a Deep Learning-Based Algorithm for Reading Shooting Accuracy

Seongho Yun*, Jaehyun Kim*, Heetae Park**

*Defense Agency for Technology and Quality

**SNT Motiv Company

요 약

본 연구에서는 소구경화기 품질적합성 검사의 실제 산출물인 사격표적 이미지를 활용하여 탄착군을 자동으로 판독하는 모델을 개발하였다. 탄착군 형성 패턴에 따라 클래스를 구분하고, 여러 발이 중첩되어 판독이 어려운 경우에는 이미지 후처리를 적용하여 예측 발수를 산출하였다. 대표적인 1-Stage detector인 YOLO v11 모델을 활용하여 객체에 대한 학습을 진행한 뒤 사람이 판정한 결과와의 비교를 통해 정확도를 분석하였다.

이를 통해 소구경화기의 품질적합성 검사 시 자동객체탐지 모델을 활용하여 탄착군의 인식 및 클래스 분류를 안정적으로 수행할 수 있었으며, 이미지 후처리를 이용하여 발사 수 예측의 정확도를 높일 수 있었다. 본 연구는 탄착군 자동판독에 대한 국내 최초 시도 중 하나로, 향후 국방 분야에서의 데이터 기반 정밀 진단 및 품질관리 자동화 연구에 기여할 것으로 기대된다.

1. 서론

우리나라의 제식소총의 역사는 M1 카빈 소총에서부터 시작한다. 제한된 생산수량과 운용 상 어려움 등 외국 생산기술 의존에 따른 어려움이 발생하였다. 이후 국내기술을 기반으로 독자적인 총기 개발 필요성이 제기되었고 5.56mm K2 소총이 제식 개인화기로 채택되었다. 2015년에는 K2 소총을 기반으로 피카티니 레일 및 개머리판 형상 변경 등을 통해 개선형인 K2C1 소총이 출시되었고 현재까지 대표적인 화기로 꾸준히 생산되고 있다.

소총의 정확도 및 분산도 시험은 총구로부터 규정된 거리에 표적지를 설치한 후, 10발 사격으로 형성된 탄착군을 관측하여 평가하는 방식으로 수행한다. 정확도 평가는 기계식 조준장치를 이용해 표적의 중심을 조준한 상태에서 사격하였을 때, 모든 탄착군이 내측 굽은 외형선을 초과하지 않는지를 기준으로 한다. 모든 탄착군이 내측 굽은 외형선의 내부에 형성된 경우, 가장 멀리 위치한 두 탄착군을 선택하여 이들 간 최대분산직경을 산출하고 해당 값이 규정된 기준 이하일 때 분

산도 요건을 충족한 것으로 판정한다.

조준점과 탄착군의 조정은 숙련된 기술자의 경험이 요구되는 공정이지만, 탄착군의 개수 확인 및 분산도 측정은 기본적인 관측과 계산만으로도 가능하다. 하지만 현재 사수가 직접 육안으로 확인 및 탄착군을 선정하여 최대분산직경을 계산해야 하는 불편함이 존재한다. 또한 표적 영상 모니터의 낮은 해상도로 인해 가시성이 저하되고 정확한 판독이 어려운 문제가 발생한다.

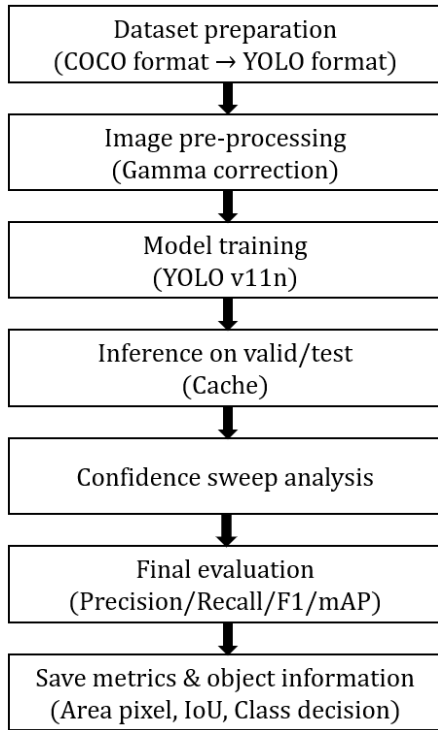
본 연구에서는 실제 품질적합성 검사 과정에서 획득한 표적 이미지를 활용하여 딥러닝 객체 인식 모델과 검출 모델을 이용해 탄착구멍 형태를 분류하고자 한다. 탄착구멍을 단발과 군집 형태로 분류하고 군집 탄착군에 대해서는 면적 기반 발수 추정 및 가중치 보정기법을 적용하여 발수를 자동 산출하였다.

2. 본론

2.1 모델 개발 프로세스

탄착구멍의 규격 만족 여부를 관독하기 위한 알고리즘 절차는 [그림 1]과 같다. 객체 검출을 수행할 모델을 선정하고 모델 학습에 필요한 데이터셋을 구축한다. 객체 인식 및 분류 정확도를 검증하기 위해 모든 데이터는 사람이 직접 라벨링한 뒤 학습(Train), 검증(Valid), 시험(Test) 용도로 분할하였다. 이는 모델이 학습 단계에서 특징을 학습하고 검증 단계에서 적정 성능을 확인하며 최종적으로 시험 단계에서 실제 인식 및 분류 성능을 평가하기 위함이다.

이후 이미지 후처리 기법을 적용하여 다수의 탄착구멍이 중첩되어 생성되는 경우 표적 넓이 기반 발수 예측을 수행하여 표적지의 총 발사 수를 산출하였다. 계산값과 사람이 관측한 값을 비교함으로써 제안 알고리즘의 정확도를 판단하였다.



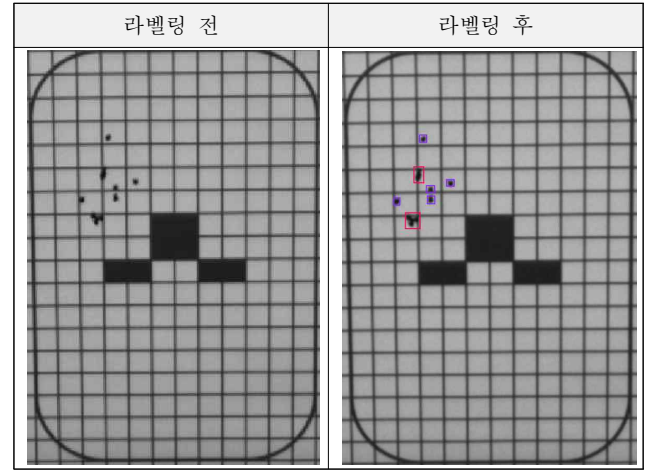
[그림 1] 모델 개발 프로세스

2.2 라벨링

라벨링 작업은 다양한 프로그램과 웹 기반 도구를 통해 수행할 수 있다. 이번 연구에서는 “Roboflow” 플랫폼의 주석(annotation) 도구를 활용하여 총 300장의 표적 이미지를 업로드 한 뒤, 각 이미지에서 생성된 탄착군을 대상으로 라벨링을 수행하였다. Roboflow는 데이터의 업로드, 주석작업, 모델 배포가 단일 플랫폼에서 이루어진다는 점에서 활용성이 높아 향후 데이터셋 확대 및 다양한 모델의 용이성을 고려해 본 연구의 데이터셋 구축 도구로 채택하였다[1]. 단일(Single) 탄착군은 대부분 원형에 가까운 형태를 보이므로 내접 사각형

으로 표시하였고 군집(Group) 탄착군은 다수의 원형 탄착구멍이 밀집하여 하나의 덩어리를 이루기 때문에 분리되지 않은 전체 영역을 하나의 구역으로 표시하였다.

[표 1] 이미지 라벨링



2.3 객체검출모델

객체검출 모델은 일반적으로 2-Stage detector와 1-Stage detector로 구분된다. 2-Stage detector는 물체의 위치를 탐지하는 단계와 객체의 종류를 분류하는 단계를 순차적으로 수행하는 구조를 갖는다. 대표적인 모델로는 CNN(Convolutional Neural Networks) 기반의 Faster R-CNN이 있으며 높은 검출 정확도를 제공하나 단계적 처리 과정으로 인해 상대적으로 속도가 느린 한계를 가진다[2].

반면 1-Stage detector는 객체의 위치탐지와 분류를 단일 단계에서 동시에 수행하는 방식으로 처리 속도가 빠르다는 장점이 있다. 입력 이미지를 일정한 크기의 grid로 분할한 후 각 grid에서 bounding box와 객체 클래스(class)를 동시에 예측한다[3][4]. 본 연구에서는 실시간 관독이 요구되는 탄착군 인식 특성에 적합하도록 1-Stage detector 기반의 Ultralytics YOLO v11-n(nano) 모델을 활용하여 분석을 수행하였다. 학습에 사용한 주요 파라미터 설정은 [표 2]와 같다.

[표 2] 모델 파라미터

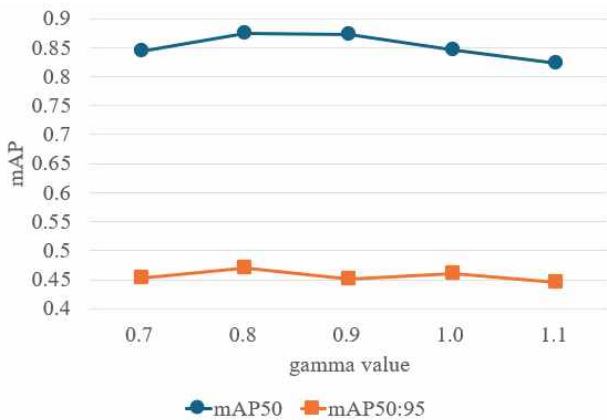
Model	epochs	batch size	image size	workers	learning rate	optimizer
YOLO v11 nano	100	16	640	2	0.01	SGD

2.4 모델을 이용한 객체분류 결과

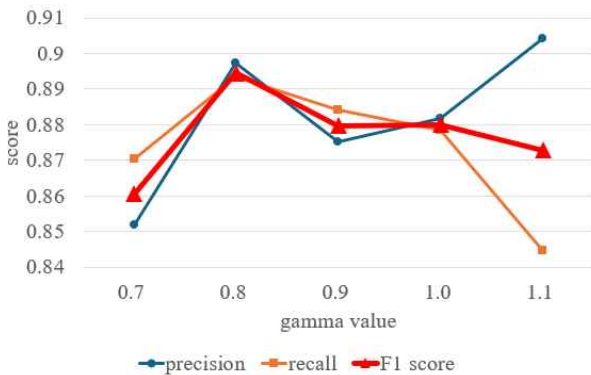
표적 이미지에 대한 라벨링 정보를 포함한 json 파일을 기반으로 YOLO v11-nano 모델을 사용하여 표적 이미지의 객체 분류를 수행하였다. Train, Valid, Test 단계를 구분하여 수행하였고 학습(Train) 단계에서는 총 210장의 이미지 데이터셋을 활용하여 모델을 학습하였다.

검증(Valid) 단계에서는 학습된 모델을 이용하여 Confidence threshold를 0.001로 설정해 예측을 수행하고 이때 생성되는 모든 예측 박스를 저장하였다. 0.00부터 0.95까지 구간에서 임계값을 변화시키며 각 threshold 별 Precision, Recall, F1-score를 계산하였다.

학습단계 전 탄착군 인식을 높이기 위해 모든 이미지에 감마보정을 실시하였다. 이는 표적이미지의 저해상도 문제 및 표적 중심에 탄착군 형성 시 인식·분류가 어려운 점을 해소하고자 수행하였다. 감마값을 0.7부터 1.1까지 0.1 단위로 설정하여 학습 시 가장 우수한 지표를 보이는 감마값을 설정하였다. 감마 보정값에 따라 mAP50, mAP50:95 값을 비교한 결과는 [그림 2]와 같고, precision, recall 및 F1-score 값을 비교한 결과는 [그림 3]과 같다.



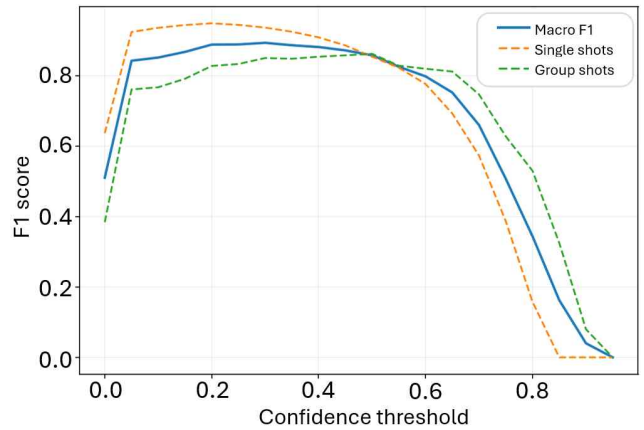
[그림 2] 감마 - mAP 곡선



[그림 3] 감마 - F1 score 곡선


최적의 성능을 보이는 감마값을 선택한 뒤, Confidence 값

선정을 위해 Confidence 값 변화에 따른 F1-score의 변동 양상을 확인하였고 결과는 [그림 4]와 같다.



[그림 4] Confidence - F1 score 곡선

Best confidence 값으로 도출된 0.3 지점에서 모델의 예측 결과와 실제 정답의 일치도를 분석하였다. 총 60장의 검증용 이미지에서 사람에 의해 라벨링 된 Ground truth 는 single class 431개, group class 72개였다. 해당 조건에서 학습된 모델을 적용하여 수행한 객체 분류 결과는 [그림 5]에 제시하였다.



[그림 5] Confusion matrix

위 결과를 바탕으로 탄착군 형태 별 Precision, Recall, F1-score를 정리하면 [표 3]과 같다. 단일 탄착군에서는 0.9379라는 비교적 높은 F1-score를 보였으나, group class의 성능은 상대적으로 낮은 것으로 나타났다. 이에 대해 여러 원인이 추정되나, 주로 사람이 부여한 라벨링 기준이 명확하

지 않아 모델의 학습에 혼동을 주었을 가능성이 존재한다. 또한 저화질 이미지로 인해 탄착군 인식이 애매한 부분에 대해 그룹을 잘못 판단하는 경우가 발생하였다. 군집 탄착군은 유사한 지역에 생성되기 때문에 정확한 탄착군 수 및 위치를 탐지하는 데 한계가 존재하였다.

[표 3] Conf = 0.3 에서의 검출결과

Class	TP	FP	FN	P	R	F1-score
single	393	14	38	0.9656	0.9118	0.9379
group	63	13	9	0.8289	0.875	0.8513

3. 결론 및 고찰

본 연구에서는 소구경 화기의 품질적합성 검사 과정에서 산출되는 사격 표적 이미지를 활용하여 탄착군을 자동으로 인식하고 생성 형태에 따라 Class를 분류하는 모델을 구축하고자 하였다. YOLO v11 모델을 이용하여 이미지 감마 보정, Best confidence 값을 탐색하여 최적의 탐지성능을 보이는 지점을 확인하였다. 이후 사람이 직접 라벨링한 지점과의 유사도 비교를 통해 발수 예측 정확도는 0.883의 결과를 확인하였다.

모델을 통해 높은 정확도의 판독을 확인하였으나, 실제 생산 현장에서는 다양한 경우의 표적지가 생성된다. 동일 지점에 여러 발이 중첩되어 형성되거나, 군집 탄착군이 식별하기 어려운 형태로 나타나는 경우 등 사람이 시각적으로 구분하기 어려운 사례가 존재한다. 본 모델을 기반으로 탄착군 인식을 하되 분산도 판독 모델도 추가로 도입하여 생산 현장에서의 작업 효율성을 증대시키고 사수의 부담을 감소시킬 수 있을 것으로 기대된다.

참고문헌

[1] Kanawade, A., P.D. Kale, Mahajan, T., Shete S., Jadhav. S., Comparative Analysis of Image Annotation Tools: LabelImg, VGG Annotator, Label Studio, And Roboflow", International Journal of Emerging Technologies and Innovative Research , Vol.11, Issue 5, 398-403

[2] Wu, X., Sahoo, D., & Hoi, S. C. (2020). Recent advances in deep learning for object detection.

Neurocomputing, 396, 39-64.

[3] Zou, Z., Chen, K., Shi, Z., Guo, Y., & Ye, J. (2023). Object detection in 20 years: A survey. Proceedings of the IEEE, 111(3), 257-276.

[4] Carranza-García, M., Torres-Mateo, J., Lara-Benítez, P., & García-Gutiérrez, J. (2020). On the performance of one-stage and two-stage object detectors in autonomous vehicles using camera data. Remote Sensing, 13(1), 89.