

우주 상황 인식을 위한 SpikeYOLO 와 DNN 탐지기 성능 비교 연구

박재현, 이은규*

인천대학교

{jhp, eklee*}@inu.ac.kr

Evaluating SpikeYOLO for Space Situational Awareness: A Comparative Study of SNN and DNN Object Detectors on SPARK 2022

Jae-Hyeon Park and Eun-Kyu Lee*

Incheon National Univ.

요 약

본 논문은 우주 상황 인식(Space Situational Awareness, SSA)을 위한 대표적인 공개 데이터셋인 SPARK 2022 를 활용하여, 기존 DNN 기반 객체 탐지 모델인 YOLOv5 및 YOLOv8 과 스파이킹 신경망 기반 모델인 SpikeYOLO 간의 성능을 비교/분석한다. 동일한 조건에서 두 모델의 정밀도, 재현율, mAP 등의 주요 지표를 바탕으로 성능을 평가하고, 전력 효율성과 실시간 처리 가능성 측면에서 SpikeYOLO 의 잠재력을 고찰한다. 또한, 향후 저궤도 위성 및 자원 제약 환경에서의 활용 가능성과 후속 연구 방향에 대해 논의한다.

I. 서 론

우주 환경 및 궤도 상 우주 물체를 모니터링하고, 이들에 대해 인식 및 특성화 하는 작업을 우주상황인식(SSA, Space Situational Awareness)이라고 한다. SSA 는 우주 영역 인식의 핵심 구성 요소로, 이는 우주에서 실제와 예상 운용 환경을 이해할 수 있는 능력을 의미한다. 보다 구체적으로 SSA 는 우주 물체 추적, 식별, 궤도 결정, 물체가 운용되는 시나리오에 대한 이해, 향후 위치 예측 및 기능 위험 요소 평가 등을 의미한다. SSA 는 우주 교통 관리와 관련된 모든 작업에 필수적인 요소이다. SSA 의 주요 역할 중 하나는 우주의 다양한 파편 혹은 다른 위성에 대응하는 것으로, 이는 모든 우주 시스템에 대한 위협이 될 수 있다. 중요한 과제 중 하나는 우주 물체를 그 특성에 따라 탐지하고, 분류하는 것이지만, 우주 물체에 대한 정보는 제한적인 경우가 많다. 인공지능(AI) 및 기계학습(ML) 시스템은 이러한 우주 물체를 탐지하고 분류하는 데 매우 유망한 기술로 볼 수 있다.[1] 실제 저궤도의 경우 최근 다양한 저궤도 위성으로 인해 SSA 에 대한 관심도가 증가하고 있으며, 저궤도 위성에서 COTS 장비를 활용하여 딥러닝 컴퓨팅을 시도하는 연구도 진행되고 있다.[2] 그러나, 현재 주로 사용되는 DNN 모델의 경우 많은 작업에서 높은 정확도를 얻더라도 높은 자원 소모로 인해 우주 환경에서 사용하기 어렵다는 점이 한계점으로 작용한다.

SNN(Spiking Neural Network)는 생물학적 신경망의 동작 원리를 모방하여 정보를 시간적 스파이크 형태로 처리하는 인공지능 모델로, 이벤트 기반 처리 방식을 사용하여 높은 에너지 효율성을 달성함과 동시에 최근 여러 작업에서 DNN 에 근사하거나 더 높은 정확도를 보이고 있다. 이러한 특성으로 인해 SNN 은 엣지 디바이스와 같은 저전력 환경이나 실시간성을 필요로 하는 환경에서의 활용 가능성이 매우 높다고 여겨지고 있다. 그러나 SNN 의 특성으로 인한 학습의 어려움으로 다양한 분야로의 확장에 한계가 있었으나, 최근 기존 YOLO 모델을 SNN 의 특성에 맞게 변형한 SpikeYOLO[3]가 기존 DNN 기반 YOLO 모델과 유사한 정확도를 달성함과 동시에 약 3.3 배의 에너지 효율성을

보여주어 SNN 기반 객체 인식 모델의 잠재력을 크게 부각했다.

본 논문에서는 SpikeYOLO 모델을 활용하여 SSA 데이터셋 중 하나인 SPARK 2022[4] 데이터셋을 활용하여 SSA 에 대한 SNN 모델의 평가 및 기존 모델과의 비교를 진행하여 추후 저궤도 위성에서의 모델 사용 가능성과 향후 연구 방향에 대해 논의한다.

II. 본론

실험에는 SPARK 2022 Stream 1 데이터셋을 사용했다. 이 데이터셋은 록셈부르크 대학교의 연구소에서 제작되었으며, 약 11 만 장의 1024x1024 해상도의 RGB 이미지와 11 개의 클래스로 이루어져 있다. 클래스의 분포 비율을 모두 동일하며, 달 탐사 위성 등 실제 발사된 다양한 위성과 우주선, 계획 단계였던 위성, 비활성 위성, 파편 등을 포함하는 클래스로 이루어져 있다. 해당 데이터는 Unity3D 기반의 렌더링 엔진을 활용하여 생성된 합성 이미지이며, 실제 수집된 이미지를 기반으로 한다. 또한, 노이즈, SNR, 높은 이미지 대비 등 실제 우주 환경에서 수집된 이미지의 특징을 모사하여 제작되었다. 본 데이터셋은 챌린지 용도로 제작되어 테스트 데이터셋에 대한 label 이 공개 되어있지 않아 학습 시에 학습 데이터셋을 8:2 로 나누어 각각 학습용, 검증용 데이터셋으로 사용하였으며, 검증용 데이터셋은 테스트용 데이터셋으로 사용하여 평가를 진행하였다.

| 모델명 | 파라미터 수 |
|------------|--------|
| YOLOv5s | 9.1M |
| YOLOv8s | 11.1M |
| SpikeYOLOn | 13.2M |
| SpikeYOLOs | 23.1M |

표 1 비교 모델의 파라미터 수

다른 모델과 비교 분석 및 평가를 진행할 때 자원 한계가 명확한 실제 우주 환경을 고려하여 파라미터 수가 낮은 모델들을 선정하였다. 기존 DNN 모델 중에서는 YOLOv5s, YOLOv8s 를 비교 군으로 사용하였으며, SpikeYOLO 의 경우 파라미터가 제일 적은

SpikeYOLOn 모델과 그 다음으로 파라미터 수가 많은 SpikeYOLOs 모델을 사용하여 SPARK 2022 데이터셋에 대한 평가를 진행하였다. 비교군 모두 유사한 파라미터 수를 가지고 있어 같은 데이터셋에 대해 평가를 진행하였을 때 충분히 공평한 결과를 얻을 수 있다.

표 1은 비교 대상 모델들의 파라미터 수를 나타낸다. 사용된 SpikeYOLOn 모델은 비교 대상군과 유사한 파라미터 수를 가지고 있으며, SpikeYOLOs 모델은 유사한 전력 소비를 가정하여 비교 항목에 포함되었다. SpikeYOLO 연구에 따르면, 약 23.1M의 파라미터를 가진 SpikeYOLOs는 21.2M 파라미터를 가진 YOLOv5 모델에 비해 약 5배 낮은 전력 소비를 기록하였다. 이는 단순한 연산량 또는 파라미터 수가 전력 소모를 정확히 반영하지 않으며, SNN의 스파이크 기반 회소 연산 특성이 에너지 효율에 중요한 영향을 미친다는 것을 시사한다. 따라서 SpikeYOLOs는 전력 수준을 맞추는 것을 기준으로 선정되었으며, 이는 정량적인 파라미터 수가 아닌 에너지 기반의 비교를 위한 설계이다.

실험은 동일 파라미터에서 진행되었으며, Early-Stop 기법을 사용해 20 Epoch 동안 정확도 개선이 되지 않을 경우 훈련을 중단하는 형태로 학습을 진행하여 모든 모델이 150±20 epoch 내에서 학습이 중단되었다. 최적화기는 SGD를 사용하였으며, 학습률은 0.01, 가중치 감쇠율은 $5e-4$, YOLO의 기본적인 일반화 및 증강 기법을 적용하여 학습을 진행하였다.

| 모델 | Precision | Recall | mAP0.5 | mAP0.5:0.95 |
|--------------------------|-----------|--------|--------|-------------|
| YOLOv5s | 0.473 | 0.644 | 0.43 | 0.283 |
| YOLOv8s | 0.463 | 0.65 | 0.425 | 0.29 |
| SpikeYOLOn | 0.482 | 0.841 | 0.49 | 0.362 |
| SpikeYOLOs | 0.483 | 0.847 | 0.488 | 0.365 |
| SpikeYOLOs (Pre-trained) | 0.496 | 0.91 | 0.518 | 0.41 |

표 2 테스트 데이터셋에 대한 모델 별 실험 결과



그림 1 YOLOv8s(좌), SpikeYOLO(우)의 실제 객체 탐지 예시

표 2는 테스트 데이터셋을 사용하여 평가를 진행했을 때 전체 클래스에 대한 각 모델 별 실험 결과를 나타낸다. 평가 진행 시 검증 데이터셋에 대해 가장 높은 정확도를 보였던 가중치를 사용하여 평가를 진행하였다. 실험 결과 사전 학습된 가중치를 적용 후 추가학습을 진행한 SpikeYOLOs 모델이 가장 높은 정확도를 보였다. 해당 모델을 제외하고 동일 조건에서 가중치 없이 학습된 모델에 대해 분석을 진행해보면 기존 DNN 기반 YOLO 모델의 경우 정확도 측면에서는 SpikeYOLO 모델에 비해 큰 차이가 나지 않지만 재현율 및 mAP50, mAP50:95 모두에서 다소 차이가 발생하는 것을 볼 수 있다. 이러한 결과는 데이터셋과 SNN의 특징으로 인해

도출된 결과라고 볼 수 있다. 먼저 사용된 데이터셋은 우주 환경을 모사하여 제작되었기 때문에 다른 데이터셋에 비하여 상대적으로 이미지에 노이즈가 많은 편이며, 배경이 어두워 일반적인 모델로는 물체를 식별하는데 어려움이 있다. 따라서 4개의 모델 모두 높은 정확도를 달성하지는 못했으나, SNN 모델의 특징인 강건성과 시간적인 특징을 사용하는 특성으로 인해 노이즈가 많고 어두운 이미지 내에서도 기존 YOLO 모델에 비해 상대적으로 더 높은 탐지율을 보였다고 분석할 수 있다.

그림 1은 YOLOv8s와 가장 높은 정확도를 보인 SpikeYOLOs 모델의 테스트 데이터셋에서의 객체 탐지 예시를 보여준다. YOLOv8s의 경우 해당 이미지에서 아무것도 탐지하지 못한 반면에 SpikeYOLO는 객체를 탐지하였다. 이때, 해당 이미지에서 객체를 2개로 오 탐지하였는데 이는 대부분의 이미지에서 모든 모델이 유사한 양상을 보였으며, 결과에서 정확도는 낮으나 재현율이 높게 나타난 원인 중 하나라고 볼 수 있다.

III. 결론

본 논문에서는 SSA 데이터셋인 SPARK 2022를 활용하여 SNN 기반 YOLO 모델인 SpikeYOLO 모델의 SSA 데이터셋에서의 정확도를 평가하고 기존 DNN 모델과 비교 분석을 진행하였다. SpikeYOLO는 SNN의 특징으로 인해 기존 DNN 모델보다 SSA 데이터셋에서 높은 정확도를 보였으며, 이는 보고된 바와 같이 전력 효율성이 기존 DNN 모델의 3배 이상임을 고려하면 SpikeYOLO가 SSA와 같은 작업에서 효율적인 모델이 될 수 있음을 시사한다. 추후 위성이나 엣지 디바이스 등 자원이 제한된 환경에서 기존 DNN 모델에 비해 사용 가능성이 높음을 확인하였으며, SpikeYOLO 모델은 SNN 기반 모델로서 추후 뉴로모픽 컴퓨팅을 통해 훨씬 더 큰 전력 효율을 달성할 수 있을 것으로 기대된다. 향후 연구에서는 SPARK 2022 이외의 다른 데이터셋에 대한 평가를 진행함과 동시에 YOLO 뿐만 아닌 다양한 객체 탐지 모델과도 비교를 진행할 예정이다.

ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학 ICT 연구센터사업의 연구결과로 수행되었음. (IITP-2025-RS-2023-00259061) 교신저자: 이은규 (eklee@inu.ac.kr)

참 고 문 헌

- [1] Massimi F. 외, "Deep Learning Methods for Space Situational Awareness in Mega-Constellations Satellite-Based Internet of Things Networks," *Sensors*, vol. 23, no. 1, pp. 1–20, Dec. 2022.
- [2] Xing R. 외, "Deciphering the Enigma of Satellite Computing with COTS Devices," *Proc. MobiCom '24*, pp. 1–16, Nov. 2024.
- [3] Luo X. 외, "Integer-Valued Training and Spike-Driven Inference Spiking Neural Network for Object Detection," *arXiv preprint, arXiv:2407.20708*, Apr. 2025.
- [4] Rathinam A. 외, "SPARK 2022 Dataset: Spacecraft Detection and Trajectory Estimation," *Zenodo Dataset*, Univ. of Luxembourg, 2022.