

비지도 학습 기반 이상 징후 검출 모델에서의 메모리 개선 방안 Memory Improvement Method for Unsupervised Anomaly Detection Models

김찬영* · 설상훈*
Chanyoung Kim* · Sanghoon Sull*

* 고려대학교
(cykim@mpeg.korea.ac.kr)

ABSTRACT

최근 국방 및 보안 설비 내 비디오 장비의 사용은 증가하고 있다. 획득한 동영상의 처리에 필요한 노동력을 절감하기 위해 이상 징후 자동 검출이 중요하며, 최근에는 딥러닝에 기반한 기술들이 주목할 만한 성능을 보이고 있다. 하지만 이는 많은 양의 학습 데이터가 요구되며 학습 데이터와 테스트 데이터 간의 유사도에 의존적인 성능을 보인다는 문제가 있다. 이러한 문제에 대응하기 위해 기존의 비지도 학습에 기반한 기술을 분석하고, 학습 데이터셋 외의 데이터셋에도 적용하기 위한 메모리 활용 방안을 제안한다. 해당 방안을 적용한 결과, ShanghaiTech 데이터셋에서 추가적 학습 없이 2.1%의 성능 향상을 보였다.

Key Words : Anomaly Detection, Model Generalization, Memory Augmentation

1. 서론

최근 국방 및 보안 설비 내 비디오 장비의 사용 시 저장된 동영상의 확인 작업이 필요하다. 수십 시간 길이의 동영상을 효율적으로 확인하기 위해서는 사용자에게 영상 내 이상 징후가 포함된 프레임을 검출 및 제시하는 기술이 필요하다. 최근에는 딥러닝에 기반한 연구들이 활발하게 진행되어 주목할 만한 성능을 얻고 있다. 하지만 딥러닝 기반 기술은 많은 라벨 데이터가 필요하고 학습 데이터와 테스트 데이터가 유사해야 한다는 제약이 있어 그대로는 실제 상황에 적용하기 어렵다는 문제가 있다.

본 논문에서는 이를 해결하기 위해 기존의 비지도 학습 기반 시스템 내에서의 메모리 활용 방안을 소개하고 개선된 성능을 다른 방법들과 비교한다.

2. 이상 징후 검출 기술

2.1 기존 비지도 학습 기반 이상 징후 검출 기술

라벨 데이터 없이 이루어지는 비지도 학습 기반 이상 징후 검출 기술 중 하나인 MNAD[1]를 비교군으로 선택하였다. 위 논문은 정상인 학습 데이터를 이용하여 인코더와 디코더로 구성된 모델의 학습과 메모리 구성을 수행한 후, 이를 이용하여 테스트 데이터에서 1) 영상 재구성/예측 가능한 정도, 2) 메모리 기준 집적도를 평가 후 종합하여 이상 징후가 포함된 프레임을 검출한다. 이 두 가지 기준은 각각 재구성/예측된 영상과 실제 영상 간의 PSNR, 각 입력 벡터들 $\{q_j\}_{j=1}^K$ 각각에 대해 가장 가까운 메모리 벡터 $p_{nearest}^k$ 와의 L2 거리의 합으로 계산되며 이는 다음 식과 같다.

$$PSNR(\hat{I}_t, I_t) = 10 \log_{10} \frac{\max(\hat{I}_t)}{\|\hat{I}_t - I_t\|_2^2 / L}$$

인코딩된 벡터 공간

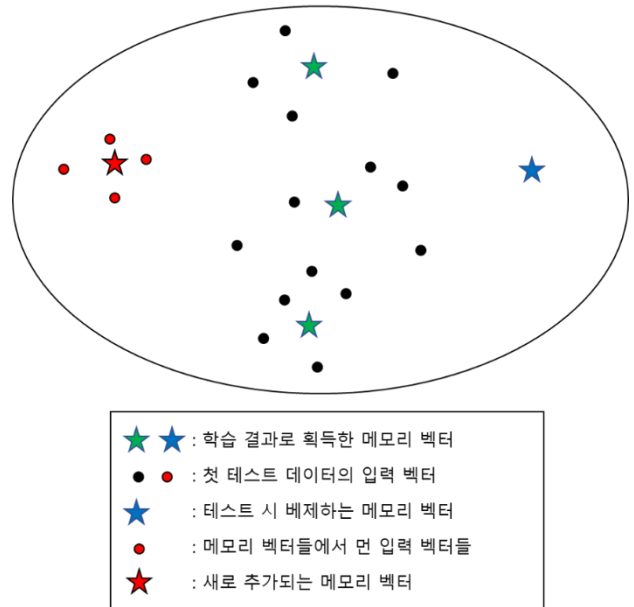


Fig 1. 테스트 단계에서의 메모리 개선 모식도

$$D(q_t, p) = \frac{1}{K} \sum_k \|q_t^k - p_{nearest}^k\|_2$$

최종 이상 징후 점수 S_t 는 다음과 같다.

$$S_t = \lambda \left(1 - g(PSNR(\hat{I}_t, I_t)) \right) + (1 - \lambda) g(D(q_t, p))$$

이 때 $g(\cdot)$ 는 동영상 내에서의 $\max(\cdot) - \min(\cdot)$ 값으로의 정규화 함수다.

테스트 시에는 테스트 데이터 내 포함된 이상 데이터가 메모리에 반영되는 것을 지양하기 위해 영상의 재구성/예측 정도에 따라 메모리 갱신에 제약을 둔다. 하지만 다른 데이터셋에 적용 시 재구성/예측 정도에 기반

한 제약은 일반적으로 작동하지 않을 수 있다. 다음 장에서는 일반적으로 적용 가능하게 하기 위한 테스트 단계에서의 메모리 개선 방안을 제시한다.

2.2 테스트 단계에서의 메모리 개선 방안

테스트 단계에서의 제안하는 메모리 개선 방안은 그림 1 과 같다. 학습 단계에서 구성된 메모리 벡터 $\{p_i\}_{i=1}^M$ 들 중 테스트 동영상의 초반 네 프레임의 입력 벡터들 $\{q_j\}_{j=1}^K$ 로부터 가장 코사인 유사도가 가장 작은 메모리 벡터의 인덱스 i^* 를 다음과 같이 구한다.

$$i^* = \underset{p_i}{\operatorname{argmin}} \sum_j^K p_i^T q_j.$$

이와 유사하게 메모리 벡터들에 대한 cosine 유사도가 가장 작은 $N = K \times r$ 개의 입력 벡터 $\{q_j^*\}_{j=1}^N$ 을 구한다. 이 때, K는 첫 프레임 내 입력 벡터의 수, r은 메모리에 반영될 벡터의 비율이다.

마지막으로, 메모리 벡터 p_{i^*} 를 다음과 같이 대체한다.

$$p_{i^*} \leftarrow f \left(\frac{1}{N} \sum_{j=1}^N q_j^* \right).$$

이 때, f 는 12-정규화 함수다.

2.3 실험 설계 및 결과

실험은 기존의 MNAD[1]에 기반하여 수행하였다. 실제 상황과 유사한 평가를 위해 학습은 Avenue 데이터셋[2]을 이용하되, 테스트는 ShanghaiTech 데이터셋[3]에서 수행하였다. 이 두 가지 데이터셋은 보행자들을 촬영한 감시 영상이지만 촬영 장소, 카메라 각도, 피사체와의 거리 등에서 차이를 보인다. 기본 모델과 같이 AUC를 평가하였으며 r 는 0.02로 사용하였다. 이외의 하이퍼 파라미터, 학습 방법 등은 기본 모델과 동일하게 진행하였다.

Table 1. 실험 결과 및 타 방법과의 비교

	AUC (%)
Base (ShanghaiTech)	67.9797
Base (Avenue)	69.2963
w/o memory update	69.3255
Memory update always	69.8046
Ensemble	70.5727
Ours	71.4143

Table 1에서 보여지는 것과 같이, 테스트 데이터에서 업데이트를 항상 수행하지 않은 경우 (3행), 항상 수행한 경우 (4행) 모두 [1](2행)보다 각각 0.03%, 0.5% 높은 성능을 보였고, 이들을 앙상블 하면 1.3% 더 높은 성능을 관찰할 수 있다. 이는 [1]에서 제안한 메모리 갱신 방법이 일반화되지 못함을 의미한다. 위 논문에서

제안한 방법은 2.1%로 가장 높은 성능 향상을 보였다.

또한 테스트 데이터인 ShanghaiTech 데이터셋에서 학습했을 때 (1행)보다도 Avenue 데이터셋에서 학습할 때 성능이 1.3% 향상됨을 관찰할 수 있었다. ShanghaiTech 데이터셋이 양이 더 많은 데이터임에도 불구하고 이러한 성능 차이를 보이는 것은, 이상 징후 검출 모델의 학습 결과가 단순히 데이터셋의 규모에만 의존하지 않음을 의미한다.

3. 결론

본 논문은 추가적 학습 없이 이상 징후 검출 모델이 학습 데이터셋과 동일하지 않은 테스트 데이터에서도 동작하도록 하는 메모리 개선 방안을 제시한다. 이상 징후 검출 만이 아니라 딥러닝을 접목한 다양한 분야에서 학습 환경과 실제 환경의 차이로 모델의 성능이 떨어지는 경우가 있다. 본 논문이 제시한 메모리 개선 방안은 이러한 문제에 적용할 수 있는 대안이 될 것이다.

Acknowledgement

본 연구는 방위사업청과 국방과학연구소의 지원 (UD190031RD)으로 한국과학기술원 미래 국방 인공지능 특화연구센터에서 수행되었습니다.

References

[1] Park, Hyunjong, Jongyoun Noh, and Bumsub Ham. "Learning Memory-guided Normality for Anomaly Detection." Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020.

[2] Lu, Cewu, Jianping Shi, and Jiaya Jia. "Abnormal event detection at 150 fps in matlab." Proceedings of the IEEE international conference on computer vision. 2013.

[3] Luo, Weixin, Wen Liu, and Shenghua Gao. "A revisit of sparse coding based anomaly detection in stacked rnn framework." Proceedings of the IEEE International Conference on Computer Vision. 2017.