

Scene Graph 생성에서 환각 완화를 위한 Negative Data Augmentation 기법

백종우, 소진현*
대구경북과학기술원

jaden9420@dgist.ac.kr, *jinhyun@dgist.ac.kr

Negative Data Augmentation for Mitigating Hallucination in Scene Graph Generation

Jongwoo Baek, Jinhyun So*
DGIST

요 약

Scene Graph는 이미지 내 객체와 그들 사이의 관계 및 속성을 구조적으로 표현함으로써 정밀한 시각적 이해를 가능케 한다. 그러나 현존하는 Scene Graph 데이터셋은 클래스 편향과 관계의 다양성 부족 문제를 내포하고 있어, 학습된 모델이 존재하지 않는 정보를 생성하는 환각(hallucination) 문제를 유발한다. 본 연구에서는 이러한 문제를 해결하기 위해 부정 데이터 증강(Negative Data Augmentation, NDA) 기법을 제안한다. NDA는 모델이 빈번히 혼동하는 관계 클래스를 기반으로 부정 후보를 생성하고 이를 학습에 활용하는 전략이다. 본 기법은 추가적인 데이터 수집 없이도 학습 데이터의 분포적 한계를 보완하여 모델 일반화 성능을 향상시킨다. 실험 결과, NDA를 Scene Graph 생성 모델에 적용하였을 때 환각 현상을 효과적으로 줄이고 다양한 관계 인식 성능을 개선함을 확인하였다.

I. 서 론

Scene Graph는 이미지 내 객체(object)뿐만 아니라 객체 간의 관계(relation)를 구조화된 그래프 형태로 표현하는 자료구조이다. 이 구조는 객체 간의 상호작용을 명시적으로 기술할 수 있어, 이미지 캡셔닝, 비디오 이해, 질의응답 등 다양한 시각-언어 응용 분야에서 평가 벤치마크 등으로 많이 사용된다.

Scene Graph 생성 모델은 이미지로부터 객체, 관계 클래스, 속성을 예측하여 Scene Graph를 구성하는 모델이다. 이러한 모델의 학습을 위해서는 이미지-그래프 쌍으로 구성된 데이터셋이 필요하다. 그러나 Public Scene Graph 데이터셋들은 수량과 품질 모두에서 한계를 지니고 있으며, 그림 1, 2에서 볼 수 있듯, 관계 클래스의 편향이 심각하다. 특히 그림 2의 Open Image[1], GQA[2] 데이터셋의 경우 상위 1~2개의 관계 클래스가 전체 관계의 90% 이상을 차지한다. 이러한 데이터 편향은 모델이 학습 중 특정 패턴에 과적합되어 존재하지 않는 객체나 관계를 생성하는 환각(hallucination) 문제를 야기한다[3].

본 연구는 이러한 환각 문제를 완화하기 위한 부정 데이터 증강(Negative Data Augmentation, NDA) 기법을 제안한다. NDA는 모델이 자주 혼동하거나 오답을 생성하는 관계 클래스의 특징을 학습에 반영하여, 학습 중 잘못된 일반화를 방지하고 모델의 강건성을 높인다. 본 기법은 추가적인 데이터 수집 없이도 데이터의 표현력을 향상시키는 데이터 중심 해결책으로 작용한다[4].

II. 배경 지식

Scene Graph 데이터셋 D 는 이미지-그래프 쌍의 집합으로 정의된다.

$$D = (I_n, G_n) | n = 1, \dots, N$$




그림 1 Visual Genome 데이터셋의 관계 클래스 분포




그림 2 Open Image, GQA 데이터셋의 관계 클래스 분포

여기서 I_n 은 이미지, G_n 은 이에 상응하는 그래프를 의미한다. 각 그래프 G_n 은 삼중항(triplet) T 의 집합이며, 각 triplet T_i 은 다음과 같이 정의된다:

$$T_i = (o_i, r_i, s_i, b_{o_i}, b_{s_i})$$

여기서 o_i 는 주체(subject), r_i 는 관계(relation), s_i 는 객체(object), b_{o_i} 와 b_{s_i} 는 주체와 객체의 바운딩 박스(bounding box)이다. 바운딩 박스는 객체의 위치를 명확히 정의하기 위해 사용되며, 최소 및 최대 좌표($x_{min}, y_{min}, x_{max}, y_{max}$) 형태로 표현된다.

III. 제안 기법: Negative Data Augmentation

본 연구에서는 사전 학습된 모델(Pre-trained Model)을 기반으로 오분류(class confusion)에 민감하게 반응하는 NDA 기법을 제안한다. 본 기법은 fine-tuning 단계에서 클래스 간 혼동(confusion) 정보를 활용하여, 모델의 일반화 성능을 향상시키고 드문 클래스의 예측 성능을 보완하는 것을 목표로 한다.

우선, 사전 학습된 모델을 이용하여 validation set 전체에 대한 예측 결과를 수집하고, 이로부터 정답 관계 클래스 c 에 대하여 모델이 오분류한 클래스들 간의 confusion matrix $\mathbf{M} \in \mathbb{R}^{C \times C}$ 를 구축한다. 여기서 C 는 전체 클래스 수를 나타낸다. 각 행 $\mathbf{M}_{c,:}$ 는 정답 c 에 대해 오답으로 예측된 클래스들의 수를 나타내며, 다음과 같이 정규화되어 확률 분포로 사용된다.

$$\tilde{\mathbf{M}}_{(c,j)} = \frac{\mathbf{M}_{(c,j)}}{\sum_{j \neq c} \mathbf{M}_{(c,j)}} \quad (\text{for } j \neq c)$$

이를 기반으로 데이터셋의 각 정답 클래스 $c^{(i)}$ 에 대하여, 정규화된 confusion 분포 $\tilde{\mathbf{M}}_{c^{(i),:}}$ 로부터 샘플링을 수행한다. 이를 통해 $c^{(i)}$ 마다 크기 k 의 negative label 집합 $N_{c^{(i)}} \subset \{1, \dots, C\}$ 가 정의된다.

fine-tuning 과정에서는 기존 손실 함수에 샘플링된 negative label의 예측을 억제하는 negative loss 항을 추가하여 진행된다. 각 입력에 대해 예측된 softmax 확률 벡터 $\mathbf{p} \in \mathbb{R}^C$ 에서 negative label $j \in N_c$ 에 해당하는 항만을 추출하여, 다음과 같이 손실을 정의한다:

$$L_{\text{neg}}^{(i)} = \gamma \cdot \frac{1}{|N_c^{(i)}|} \sum_{j \in N_c^{(i)}} -\log(1 - p_j^{(i)})$$

여기서 γ 는 negative loss 항의 기여 정도를 조절하는 하이퍼 파라미터이며, p_j 는 클래스 j 에 대한 예측 확률을 의미한다.

최종적으로 사용되는 loss 함수는 모델이 예측한 N_t 개의 클래스에 대하여 기존 모델의 loss 함수 L_{main} 에 L_{neg} 를 추가하여 다음과 같이 정의된다.

$$\begin{aligned} L_{\text{total}} &= L_{\text{main}} + L_{\text{neg}} \\ &= L_{\text{main}} + \sum_{i=1}^{N_t} \gamma \cdot \frac{1}{|N_c^{(i)}|} \sum_{j \in N_c^{(i)}} -\log(1 - p_j^{(i)}) \end{aligned}$$

이와 같이 손실 함수를 설계하여 모델이 자주 혼동하던 클래스에 대한 예측 확률이 억제되도록 한다.

IV. 실험

본 연구는 제안하는 NDA 기법의 유효성을 정량적으로 검증하기 위해 SOTA Scene Graph 생성 모델 ReTR[5]을 기반으로 Visual Genome[6], Open Images[1] 데이터셋에서 실험을 수행하였다.

모든 실험은 동일하게 150 epoch으로 사전 학습(pre-trained) 모델을 사용하였으며, NDA fine-tuning 10 epoch을 추가로 진행하였다. 클래스 당 부정 샘플 개수 $k=1$, negative loss의 하이퍼 파라미터 $\gamma=0.5$ 를 사용하였다.

성능 평가는 이미지 입력만으로 클래스 레이블, 위치 정보를 추론하는 SGDET(Scene Graph Detection) 환경에서 상위 K 개의 클래스 평균에 대한 관계 예측 정밀도(top-K mean Precision, mP@K)와 관계 예측 재현율(top-K mean Recall, mR@K)을 활용하였다.

Metric	mP@20	mP@50	mP@100
Baseline	5.159	2.837	1.691
NDA	5.118	3.116	2.066

Metric	mR@20	mR@50	mR@100
Baseline	5.685	8.393	9.869
NDA	6.042	8.548	9.867

표 1. Visual Genome 데이터셋에서의 SGDET 결과 (mean Precision 및 mean Recall)

Metric	mP@20	mP@50	mP@100
Baseline	3.806	1.962	1.185
NDA	3.812	2.038	1.260

Metric	mR@20	mR@50	mR@100
Baseline	6.673	9.378	10.719
NDA	6.675	9.122	10.372

표 2. Open Image 데이터셋에서의 SGDET 결과 (mean Precision 및 mean Recall)

실험 결과, NDA를 적용한 모델은 Baseline 대비 mean Precision 지표에서 전반적으로 향상된 성능을 보였다. Visual Genome의 경우 mR@20과 mR@50 구간에서 소폭 증가하였으며, mR@100에서는 거의 동일한 수준을 유지하였다. 반면 mP@20에서는 다소 감소가 관찰되었으나, mP@50과 mP@100에서는 뚜렷한 개선 효과가 확인되었다. Open Images에서는 mR@20이 거의 동일하고, mR@50과 mR@100에서 소폭 감소하는 양상을 보였으나, mean Precision은 모든 cutoff 구간에서 일관되게 향상되었다.

V. 결론

본 연구는 Scene Graph 생성 모델에서 학습 데이터의 클래스 편향으로 인해 발생하는 환각 문제를 완화하기 위해 부정 데이터 증강(Negative Data Augmentation, NDA) 기법을 제안하였다. NDA는 학습 과정에서 빈번히 잘못 예측되는 관계 클래스를 기반으로 negative label을 생성하고 이를 fine-tuning에 활용함으로써, 모델이 잘못된 관계를 반복적으로 예측하는 경향을 억제하여 일반화 능력을 확보한다.

실험 결과, NDA는 mean Precision 지표에서 뚜렷한 개선 효과를 보였으며, 특히 top-K 평가에서 K 값(상위 예측 개수)이 커질수록 개선 폭이 두드러져 모델이 전체 예측 분포 전반에서 성능을 향상시켰음을 확인할 수 있다. mean Recall은 데이터셋의 특성에 따라 소폭의 증감은 있었으나 전반적으로 baseline과 유사한 성능을 유지하였다. 이러한 결과는 추가적인 데이터 수집 없이도 Scene Graph 생성 모델의 일반화 능력을 강화할 수 있음을 보여준다.

ACKNOWLEDGMENT

이 논문은 2025년도 정부(과학기술정보통신부)의 재원으로 2025년 혁신거점 인공지능 데이터 융합과제 사업의 지원을 받아 수행된 연구임(S2201-24-1002)

This thesis was conducted with the support of the 2025 innovation base artificial intelligence data convergence project with the funding of the 2025 government (Ministry of Science and ICT) (S2201-24-1002)

참 고 문 헌

- [1] Open Images V7 Dataset: Krasin, Ivan, et al. OpenImages: A Public Dataset for Large-Scale Multi-Label and Multi-Class Image Classification. Google AI, 2017.
- [2] GQA Dataset: Hudson, Drew A., and Christopher D. Manning. GQA: A New Dataset for Real-World Visual Reasoning and Compositional Question Answering. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2019.
- [3] Li, Wei, et al. "Ppdl: Predicate probability distribution based loss for unbiased scene graph generation." *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2022.
- [4] Sinha, Abhishek, et al. "Negative data augmentation." arXiv preprint arXiv:2102.05113 (2021).
- [5] Cong, Yuren, Michael Ying Yang, and Bodo Rosenhahn. "Reltr: Relation transformer for scene graph generation." *IEEE Transactions on Pattern Analysis and Machine Intelligence* 45.9 (2023): 11169-11183.
- [6] Krishna, Ranjay, et al. "Visual genome: Connecting language and vision using crowdsourced dense image annotations." *International journal of computer vision* 123.1 (2017): 32-73.