

도메인 별 정규화를 활용한 제로샷 도메인 일반화 학습


(ECCV 2020)

XAI Online Workshop


서울대학교 한보형 교수님 연구실
발표자 : 서성욱

도메인 전이 문제 (Domain Adaptation)


개



코끼리



기타



사람



Art painting

Cartoon

Photo

소스 도메인

도메인 전이



Sketch

타겟 도메인

도메인 일반화 문제 (Domain Generalization)



- 도메인 전이 (Domain adaptation) 문제 :

소스 도메인 학습 데이터 + 분류되지 않은 타겟 도메인 학습 데이터

- 도메인 일반화 (Domain generalization) 문제:

소스 도메인 학습 데이터

(도메인 일반화 학습을 위해 보통 여러 개의 소스 도메인을 사용함)



도메인 일반화 문제 (Domain Generalization)

- 목표

- 도메인 변화에 공변하지 않는 강건한 표현 학습을 통해, 기존 학습 데이터에는 존재하지 않았던 **새로운 도메인**의 데이터에서도 잘 동작하는 모델을 학습하는 것.
- 실제 딥러닝을 적용하는 데 있어서, 학습할 때 전혀 보지 못한 도메인에서도 잘 동작하는 모델 학습을 목표로 하기 때문에, 타겟 도메인의 데이터를 필요로 하는 도메인 전이 문제보다 좀 더 현실적이고 실용적인 문제를 다룬다.





Content and style



- 이미지가 표현하는 정보는 크게 content와 style로 구분할 수 있다.
- 만약 각 이미지에서 style에 해당하는 정보만을 효과적으로 지울 수 있다면, 도메인에 불변하는 표현 학습이 가능하다.


정규화 (Normalization)

- 데이터의 범주를 바꾸어 정해진 스케일로 일치시키는 작업
- = Feature scaling



배치 정규화 (Batch Normalization)

- 네트워크의 각 레이어의 각 채널마다 정규화를 진행함으로써, 내부 공분산 변화를 줄이고 좀 더 안정적인 학습과 성능 향상에 도움을 준다.



제목

인용

연도

Batch normalization: Accelerating deep network training by reducing internal covariate shift

S Ioffe, C Szegedy
arXiv preprint arXiv:1502.03167

22462

2015

배치 정규화 (Batch Normalization)


- 배치 정규화는 일반적으로 잘 동작하지만, 학습과 테스트의 도메인이 달라지는 경우 오히려 성능을 저하시키기도 한다.

	Art painting	Cartoon	Sketch	Photo	Avg.
BN fixed	79.25	74.61	71.52	95.99	80.34
BN finetuned	78.47	70.41	70.68	95.87	78.86

- 배치 정규화의 분포가 학습 도메인에 과적합됨으로써, 기존에 보지 못한 새로운 도메인으로의 일반화에 악영향을 주기 때문이다.

도메인 별 정규화 (Domain-Specific Batch Normalization)



- 도메인 별 배치 정규화 (DSBN)^[1] 은 소스 도메인과 타겟 도메인 각각에 배치 정규화를 독립적으로 수행함으로써 도메인 전이 문제를 효과적으로 해결하였다



- 그러나 이 방법은 타겟 도메인을 모르는 경우에는 사용할 수 없기 때문에, 도메인 일반화 문제에는 적용할 수 없다.



인스턴스 정규화 (Instance Normalization)

- 인스턴스 정규화는 각 샘플 별로 정규화를 진행함으로써, 기존 배치 정규화 방법보다 더 효과적으로 style 정보를 제거한다 (style normalization).
- 주로 스타일 변환(style transfer)과 같은 task에서 사용된다.




인스턴스 정규화 (Instance Normalization)

- 인스턴스 정규화는 각 샘플 별로 정규화를 진행함으로써, 기존 배치 정규화 방법보다 더 효과적으로 style 정보를 제거한다 (style normalization).
- 주로 스타일 변환(style transfer)과 같은 task에서 사용된다.



인스턴스 정규화 (Instance Normalization)


- 하지만 때로는 style 정보도 content를 이해하는 데 중요한 역할을 하기 때문에, 인스턴스 정규화를 사용하면 기본적으로 성능 저하가 일어나게 된다.



- Style 정보를 효과적으로 제거하면서 모델의 성능도 잘 유지시키기 위하여, 두 가지 정규화 방법(배치 정규화, 인스턴스 정규화)를 결합한 방법을 제시한다.


도메인 별 최적 정규화

(Domain Specific Optimized Normalization)



도메인 별 최적 정규화

(Domain Specific Optimized Normalization)




실험 결과 : PACS 데이터셋


Table 2. Comparison with the state-of-the-art domain generalization methods (%) on the PACS dataset using ResNet-18 and ResNet-50 architectures. Column title indicates the target domain. *All experiments use the “train” split for the source domains, except MetaReg [2], which uses both “train” and “validation” splits.

Architecture	Method	Art painting	Cartoon	Sketch	Photo	Avg.
ResNet-18	Baseline	78.47	70.41	70.68	95.87	78.86
	JiGen [4]	79.42	75.25	71.35	96.03	80.51
	D-SAM [6]	77.33	72.43	77.83	95.30	80.72
	Epi-FCR [14]	82.10	77.00	73.00	93.90	81.50
	MetaReg* [2]	83.70	77.20	70.30	95.50	81.70
	MASF [7]	80.29	77.17	71.69	94.99	81.04
	MMLD [18]	81.28	77.16	72.29	96.09	81.83
	DSO (Ours)	84.67	77.65	82.23	95.87	85.11
ResNet-50	Baseline	80.22	78.52	76.10	95.09	82.48
	MetaReg* [2]	87.20	79.20	70.30	97.60	83.60
	MASF [7]	82.89	80.49	72.29	95.01	82.67
	DSO (Ours)	87.04	80.62	82.90	95.99	86.64

배치/인스턴스 정규화의 최적 조합 비율



(a) PACS



(b) Office-Home

Fig. 3. Analysis of the mixture weights with single-source and multi-source scenarios on the PACS (left) and Office-Home (right) datasets. We present the weight ratio of IN to BN in our DSON module. (Best viewed in color.)

인스턴스 정규화의 효과

Table 10. Single-source domain generalization accuracy on the PACS dataset. Rows and columns denote source and target domains, respectively. We compare DSON (ours) with BN in terms of the amount of change (%p).

	BN (%)				DSON (%p)			
	A	C	S	P	A	C	S	P
Art painting	89.42	60.71	48.74	94.25	- 1.20	+ 7.42	+ 20.36	- 0.44
Cartoon	69.68	94.51	71.60	81.56	+ 2.83	- 0.11	+ 0.88	+ 3.65
Sketch	44.34	63.65	93.50	49.28	+ 8.64	+ 0.64	- 0.67	+ 9.82
Photo	61.72	29.10	33.98	97.86	+ 3.56	+ 16.85	+ 1.19	- 0.52

- 같은 도메인에서 테스트할 때는 성능이 조금 하락하지만, 다른 도메인에서는 성능이 큰 폭으로 증가한다.
- 이는 인스턴스 정규화가 도메인 일반화를 위한 이상적인 **trade-off**를 제공함을 나타낸다.

결론

- 정규화는 도메인 전이와 도메인 일반화 문제를 푸는 중요한 요소 중 하나이고, 배치 정규화와 인스턴스 정규화의 조합을 통해, 타겟 도메인의 샘플 없이도 좋은 일반화 성능을 달성할 수 있다.
- Paper : <https://arxiv.org/abs/1907.04275>