

꼼꼼한 딥러닝 논문 리뷰와 코드 실습

Deep Learning Paper Review and Code Practice

나동빈(dongbinna@postech.ac.kr)


Pohang University of Science and Technology

Meta-Transfer Learning for Zero-Shot Super-Resolution (CVPR 2020)


- 본 논문의 **MZSR**은 한 장의 사진에서 약간의 업데이트만을 수행하여 우수한 해상도 복원 성능을 보입니다.
- MZSR의 특징은 무엇인가요?
 1. Transfer learning: 많은 수의 외부 이미지로부터 학습된 특징 정보를 활용합니다.
 2. Meta-learning: 다양한 커널(kernel)에 대하여 빠르게 적응(adaptation) 할 수 있습니다.



LR





ZSSR (2,850 updates)



MZSR (1 update)


연구 배경: Single Image Super-Resolution (SISR)

- 한 장의 저해상도 이미지(LR)를 고해상도 이미지(HR)로 변환하는 방법을 연구하는 분야입니다.
 - 딥러닝 이전의 전통적인 방법 예시 소개



연구 배경: Single Image Super-Resolution (SISR)

- 한 장의 저해상도 이미지(LR)를 고해상도 이미지(HR)로 변환하는 방법을 연구하는 분야입니다.
 - 최근 CNN 기반의 접근 방식이 높은 성능을 보이고 있습니다.



연구 배경: Single Image Super-Resolution (SISR)

- 전통적인 CNN 기반의 Super-Resolution은 다음과 같은 모델을 이용합니다.

$$\mathbf{I}_{LR}^k = (\mathbf{I}_{HR} * \mathbf{k}) \downarrow_s + \mathbf{n}$$

\mathbf{I}_{HR} : 고해상도 이미지(HR)

\mathbf{I}_{LR}^k : 저해상도 이미지(LR)


\mathbf{k} : 흐림 커널(Blur kernel)

$*$: 컨볼루션(Convolution)

\downarrow_s : 데시메이션(Decimation)

\mathbf{n} : 가우시안 노이즈(Gaussian noise)

LR 이미지로부터 HR 이미지를 예측할 수 있도록 학습 진행

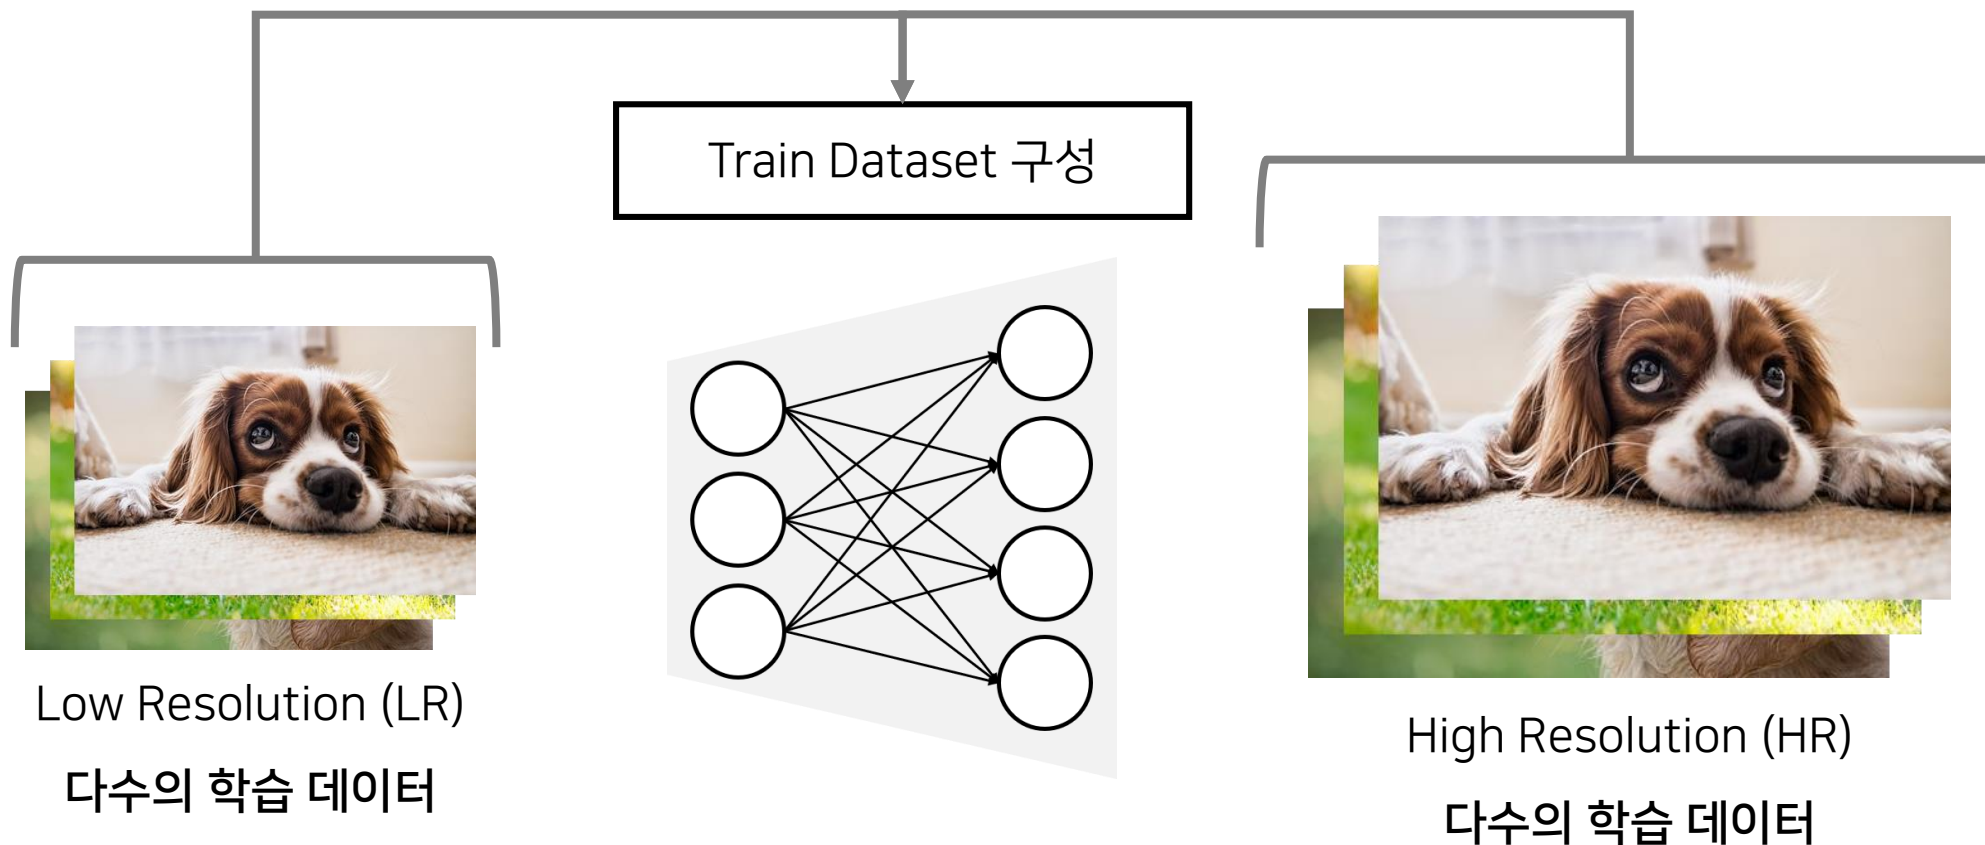


다만 downsampling 과정에서 **bicubic**과 같은 잘 알려진 커널만을 이용하면, non-bicubic 케이스에 대하여 성능이 떨어지는 **domain gap** 문제가 발생할 수 있습니다.

학습 방법에 따른 분류: **Externally** Trained Network (Supervised SISR)

- 학습 시기: 다수의 HR-LR 쌍에 대하여 학습을 진행합니다.

$$\mathbf{I}_{LR}^{\mathbf{k}} = (\mathbf{I}_{HR} * \mathbf{k}) \downarrow_s + \mathbf{n}$$






학습 방법에 따른 분류: Externally Trained Network (Supervised ISR)

- 테스트 시기: 다수의 데이터로 학습된 정보를 토대로 현재 테스트 데이터에 대한 고해상도 결과를 예측합니다.



Low Resolution (LR)

테스트 데이터




High Resolution (HR)

예측 결과

이미지의 자기 반복성

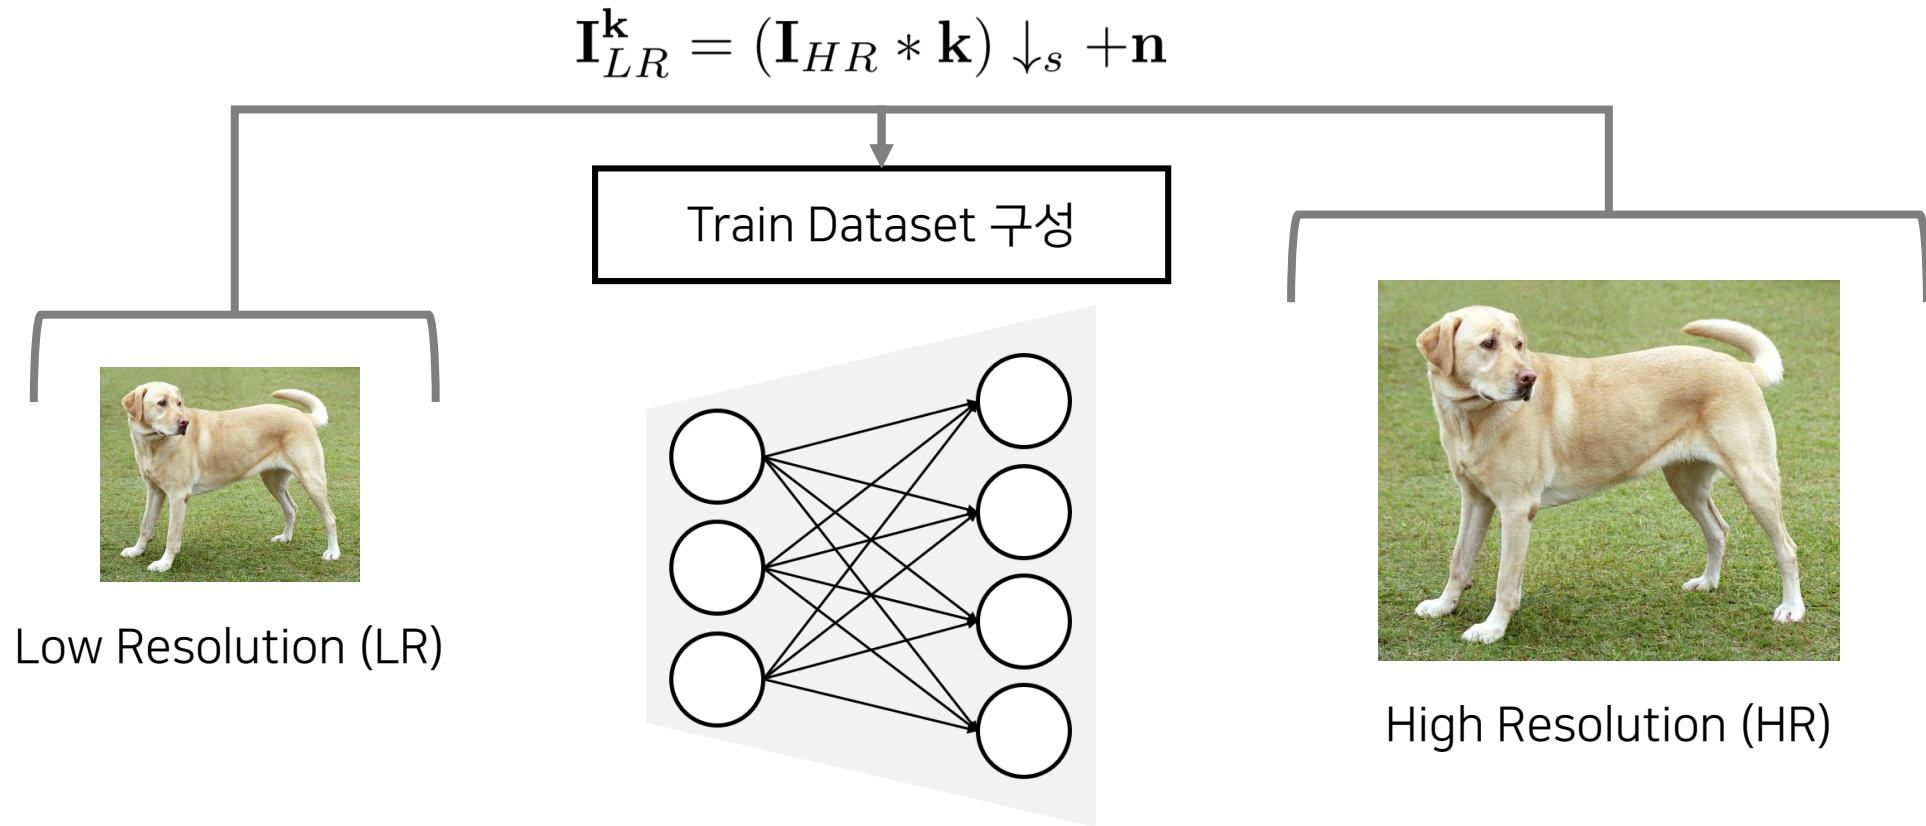
- 한 장의 이미지에도 자기 반복성(internal recurrence)이 존재합니다.
 - 많은 자연의 이미지들은 내재된 데이터 반복(internal data repetition)을 특징으로 가집니다.

“The only evidence to the existence of these tiny handrails exists internally, inside this image, at a different location and different scale. It cannot be found in any external database of examples, no matter how large this dataset is!”



학습 방법에 따른 분류: Internally Trained Network (Unsupervised "Zero-Shot" SISR)

- 학습 시기: **테스트 이미지 자기 자신**으로부터 추출된 HR-LR 쌍에 대하여 학습을 진행합니다.
 - 결과적으로 한 장의 이미지에 특화된 CNN이 학습됩니다.






학습 방법에 따른 분류: Internally Trained Network (Unsupervised "Zero-Shot" SISR)

- 테스트 시기: 한 장의 이미지에 내재된 특징 정보를 토대로 고해상도 결과를 예측합니다.



Low Resolution (LR)

한 장의 테스트 데이터 (원본)



High Resolution (HR)

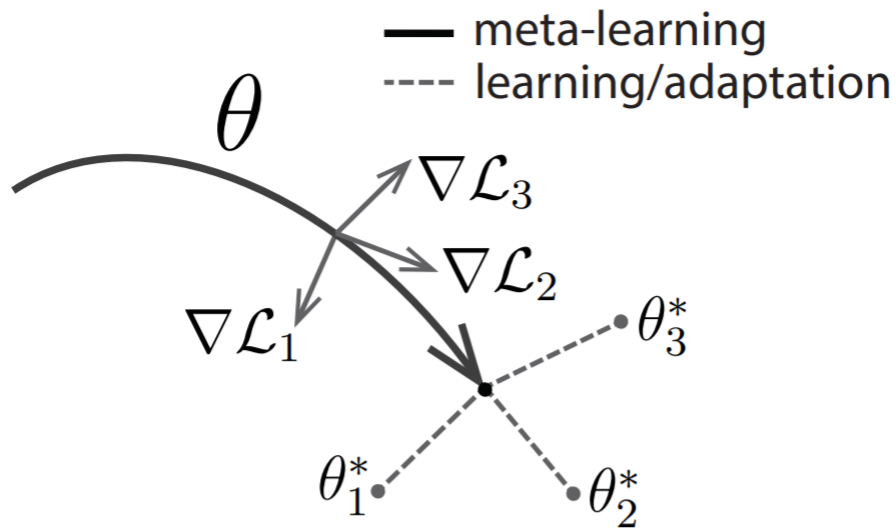
예측 결과



이렇게 학습된 네트워크는 해당 이미지에 대해서만 사용될 수 있습니다.
학습 속도를 더 빠르게 만들 수 있을까요?

Model-Agnostic Meta-Learning (MAML)

- 적절한 초기 가중치(weight)을 찾기 위한 방법입니다.
 - 다양한 작업(task)에 대해서 빠르게 적응(adaptation) 할 수 있는 가중치를 찾습니다.
 - Fine-tuning에 도움을 줄 수 있습니다.



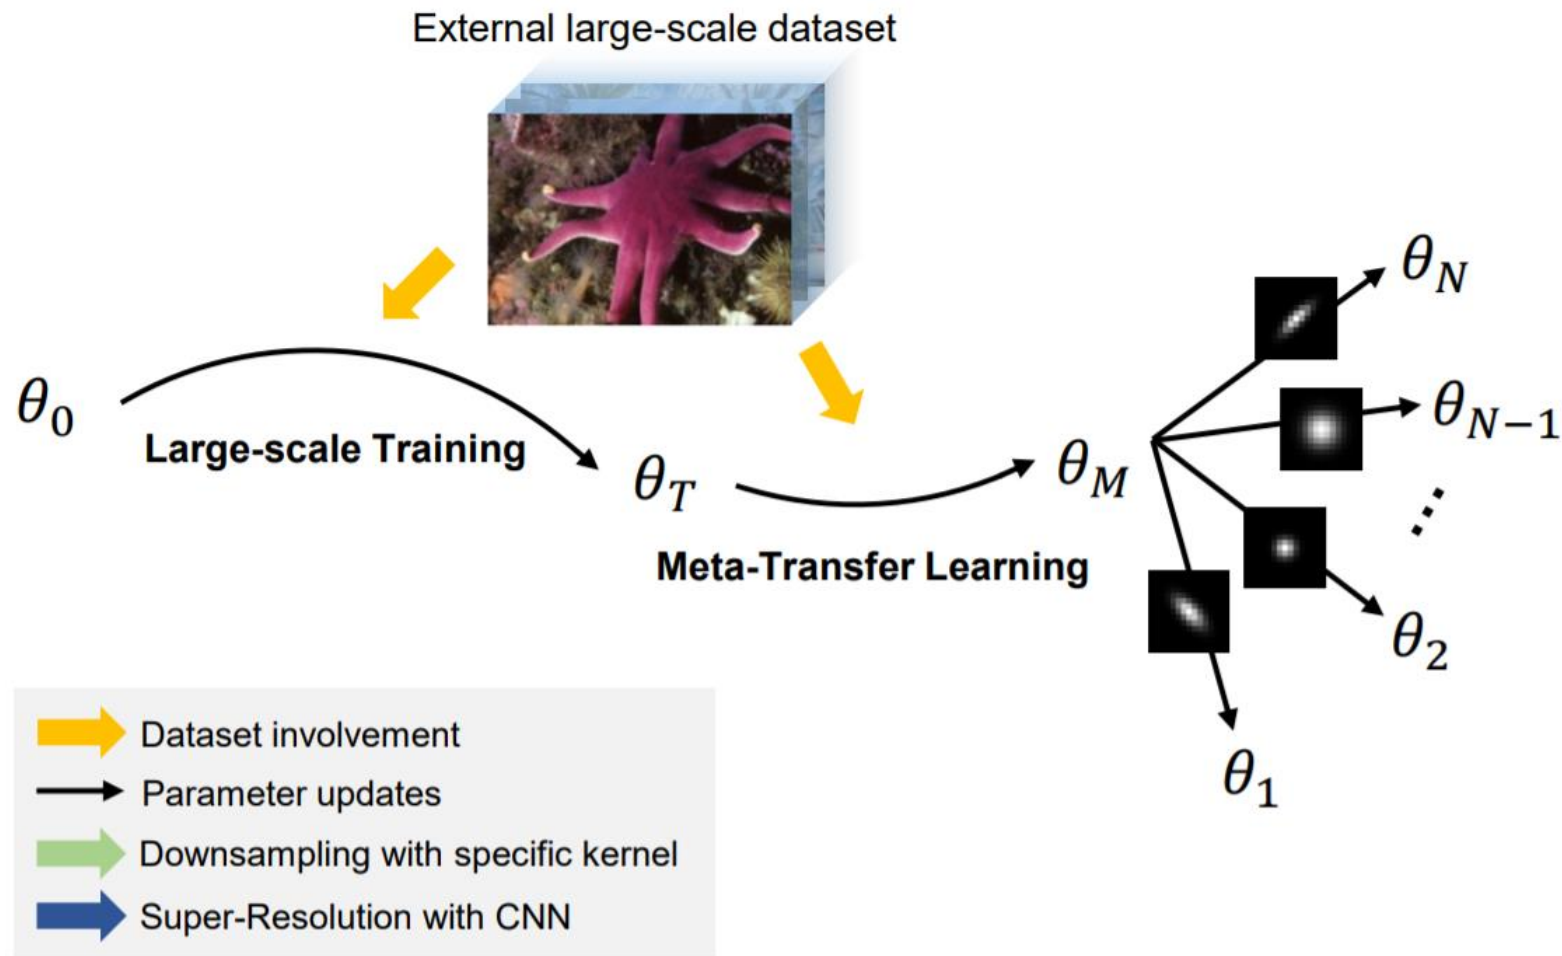
Algorithm 1 Model-Agnostic Meta-Learning

Require: $p(\mathcal{T})$: distribution over tasks

Require: α, β : step size hyperparameters

- 1: randomly initialize θ
 - 2: **while** not done **do**
 - 3: Sample batch of tasks $\mathcal{T}_i \sim p(\mathcal{T})$
 - 4: **for all** \mathcal{T}_i **do**
 - 5: Evaluate $\nabla_{\theta} \mathcal{L}_{\mathcal{T}_i}(f_{\theta})$ with respect to K examples
 - 6: Compute adapted parameters with gradient descent: $\theta'_i = \theta - \alpha \nabla_{\theta} \mathcal{L}_{\mathcal{T}_i}(f_{\theta})$
 - 7: **end for**
 - 8: Update $\theta \leftarrow \theta - \beta \nabla_{\theta} \sum_{\mathcal{T}_i \sim p(\mathcal{T})} \mathcal{L}_{\mathcal{T}_i}(f_{\theta'_i})$
 - 9: **end while**
-

MZSR의 전체 동작 과정



Self-supervised internal learning

