

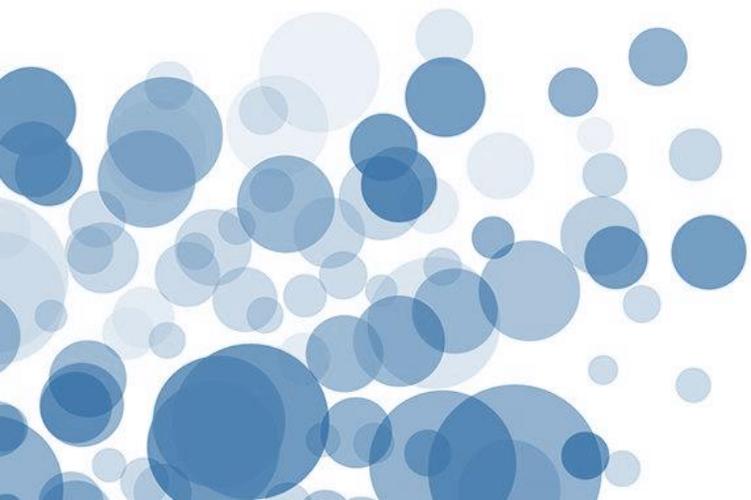
# Towards Contrastive Learning

---

Open DMQA Seminar

2021-01-29

곽민구



# 발표자 소개

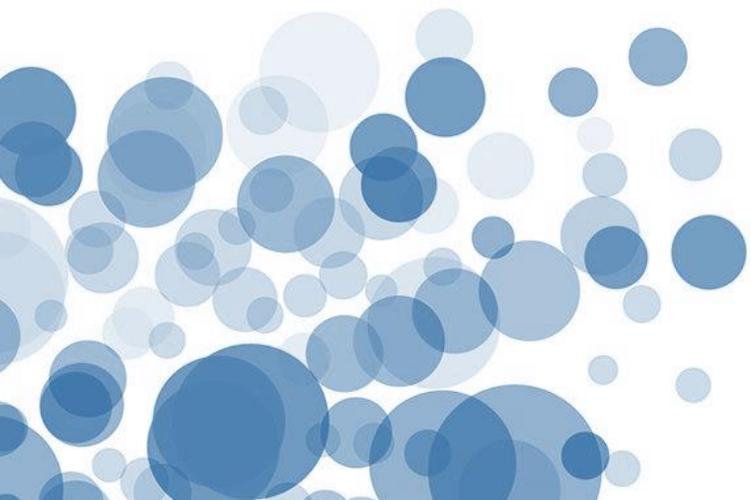


- 이름: 곽민구
- 학력
  - ✓ 2010.03 – 2016.02 | 학사 | 고려대학교 산업경영공학과
  - ✓ 2016.03 – 현재 | 석박사통합과정 | 고려대학교 산업경영공학과 (지도교수: 김성범)
- 연구분야
  - ✓ Self-supervised learning
  - ✓ Out-of-distribution detection
  - ✓ Signal data analysis
- e-mail: [min9kwak@korea.ac.kr](mailto:min9kwak@korea.ac.kr)

# 세미나 개요

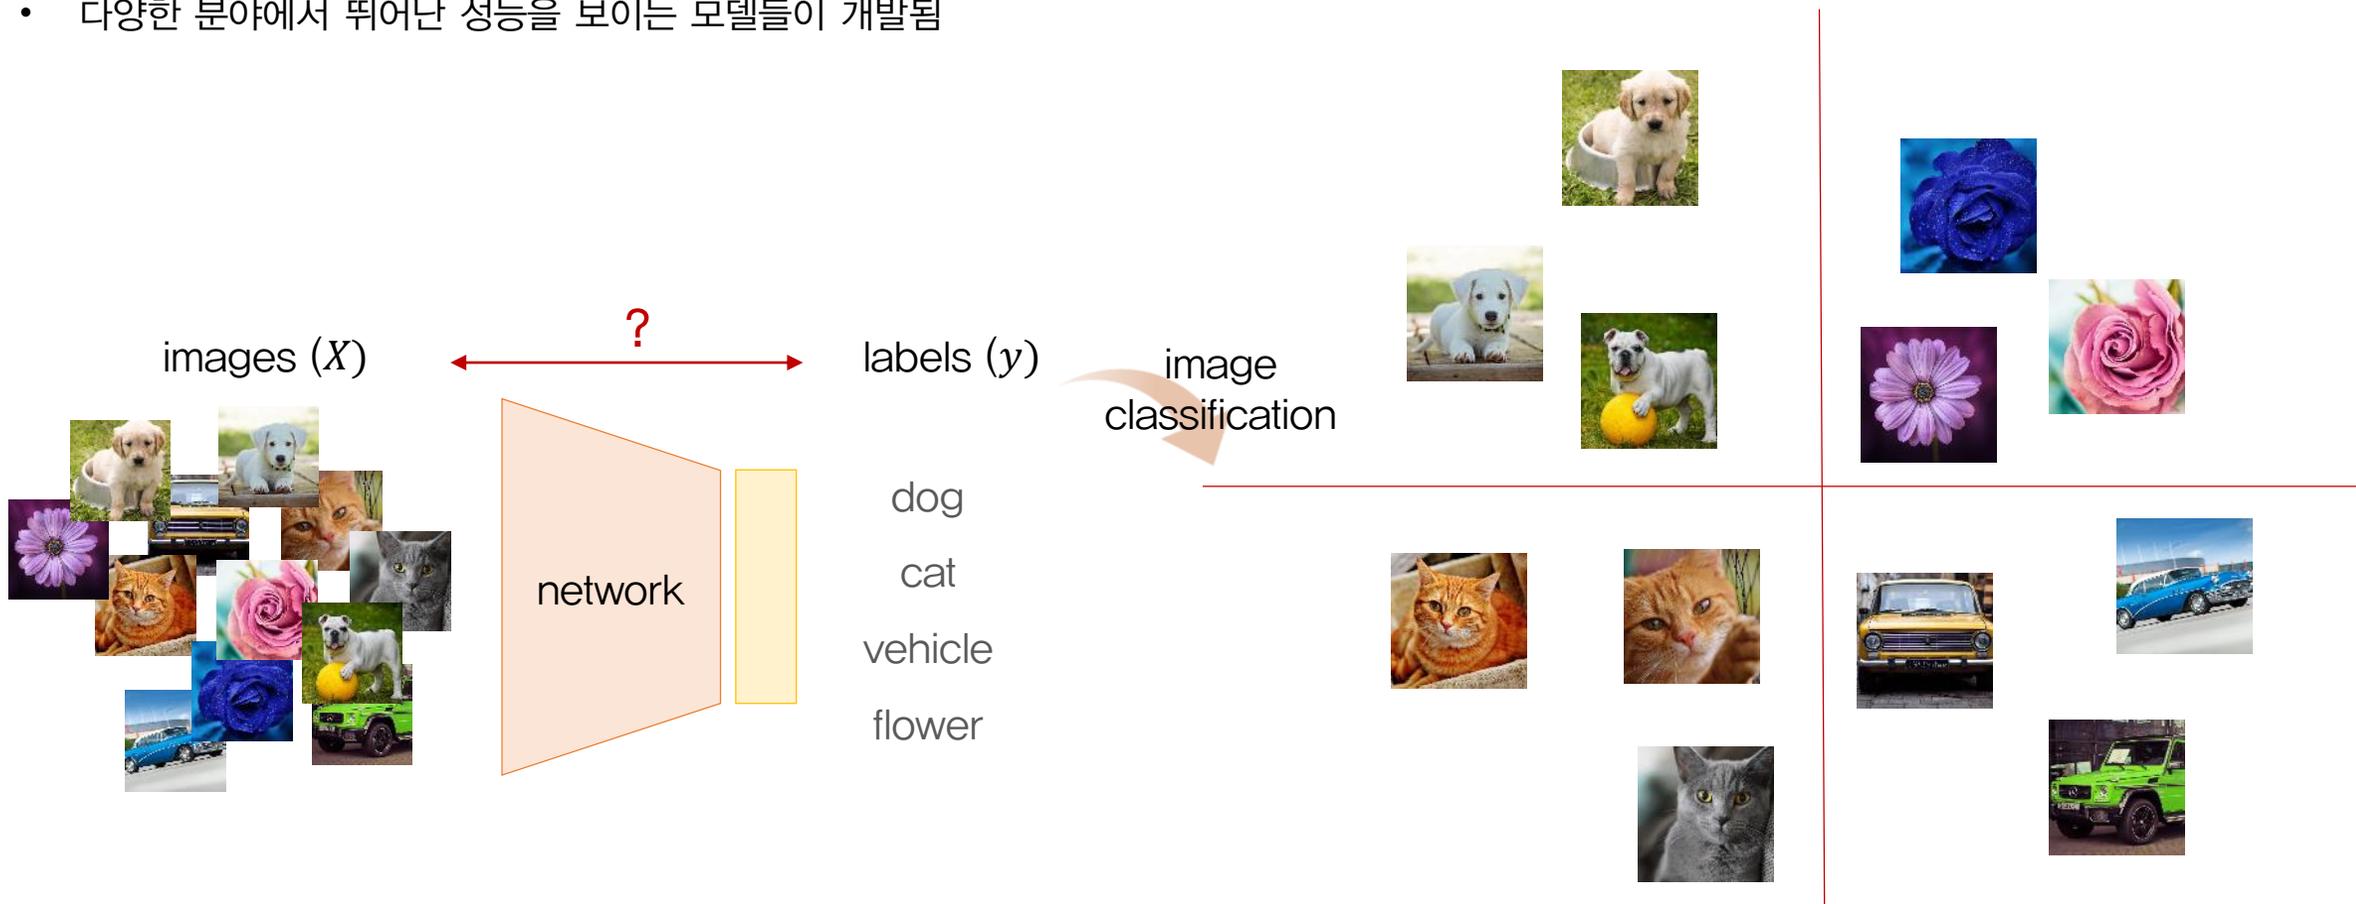
1. Contrastive learning and NCE loss
2. How to improve the contrastive learning?
  - ✓ Develop network
  - ✓ Robust data distribution
  - ✓ Define example nicely

story



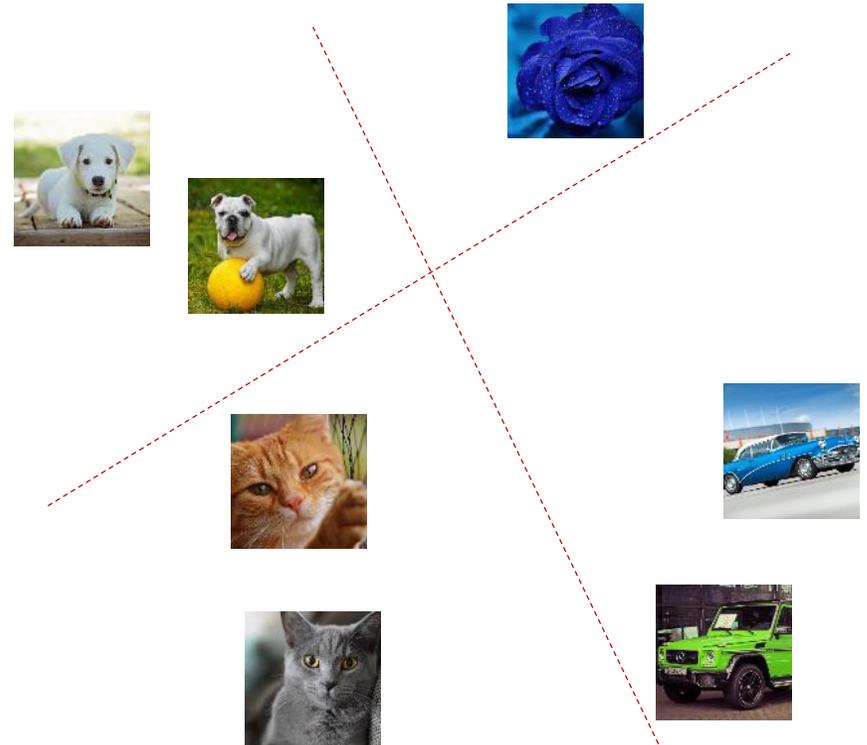
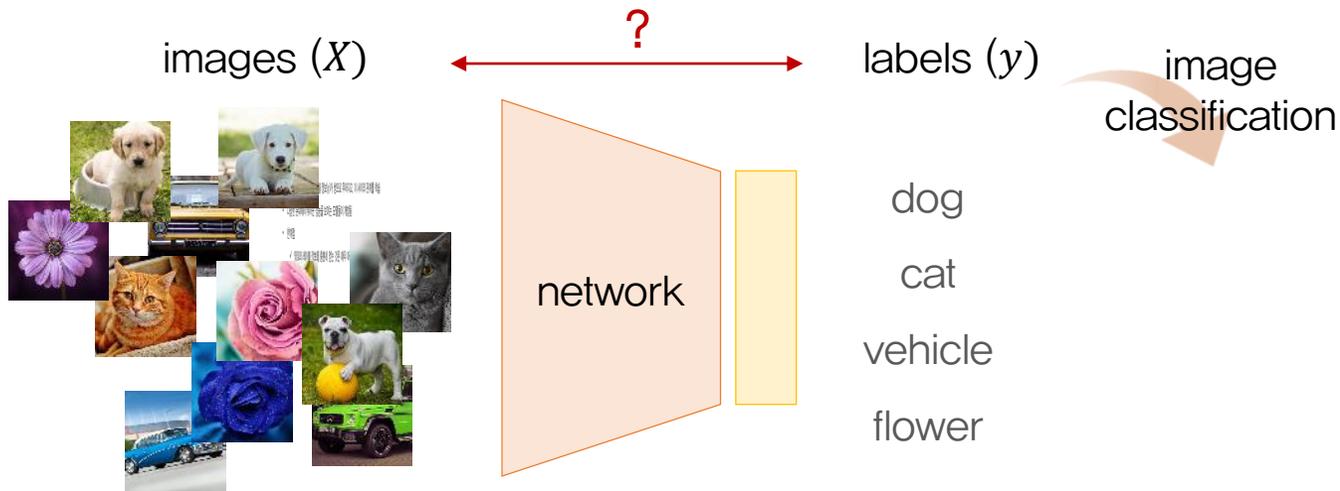
# 01 | Supervised Learning

- Input data ( $X$ )에 대한 레이블 정보( $y$ )가 쌍으로 주어지고, 이 사이의 관계를 학습
- 다양한 분야에서 뛰어난 성능을 보이는 모델들이 개발됨



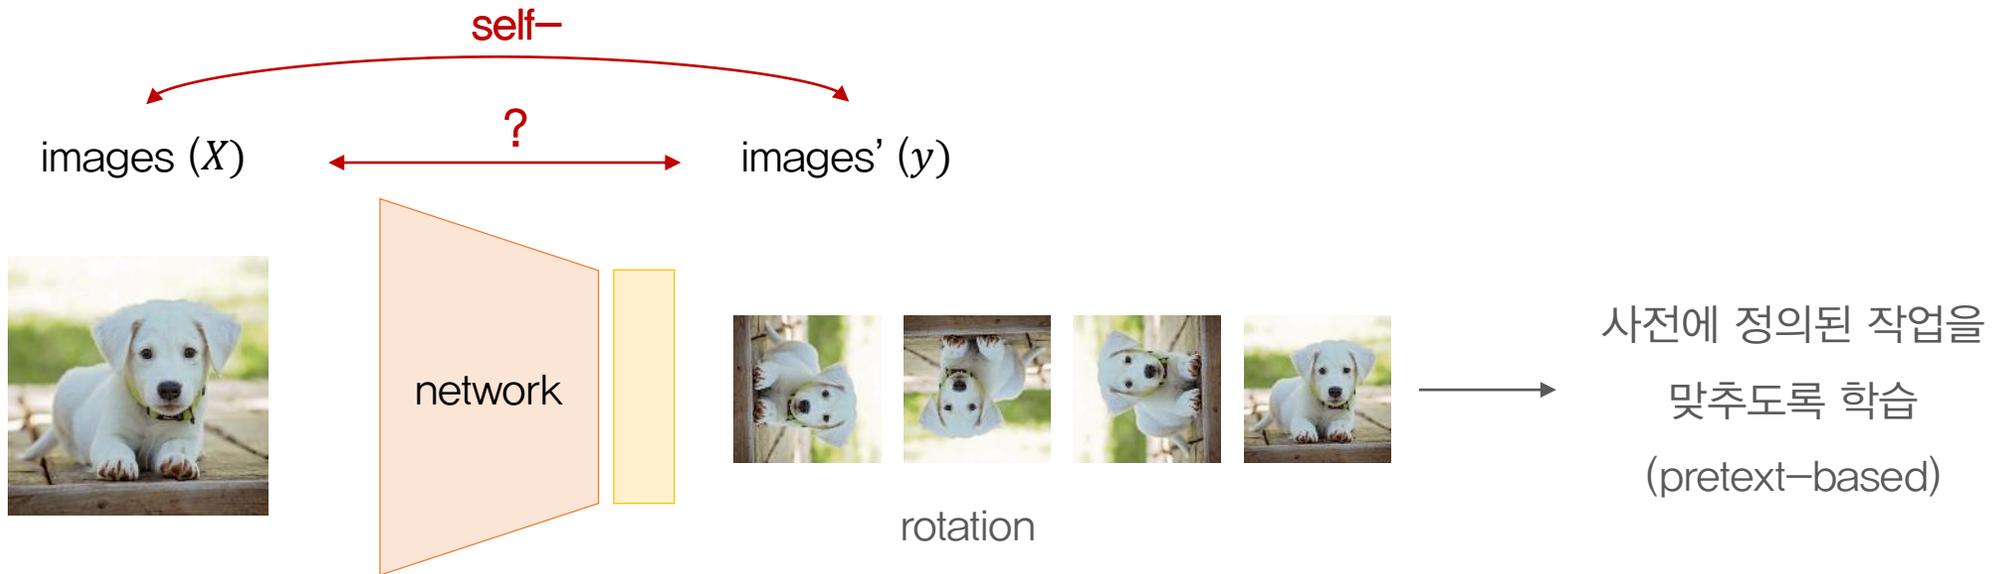
# 01 | Supervised Learning

- Input data ( $X$ )에 대한 레이블 정보( $y$ )가 쌍으로 주어지고, 이 사이의 관계를 학습
- 다양한 분야에서 뛰어난 성능을 보이는 모델들이 개발됨
- 한계점
  - ✓ 양질의 레이블 정보를 충분히 얻는 것은 매우 어려움



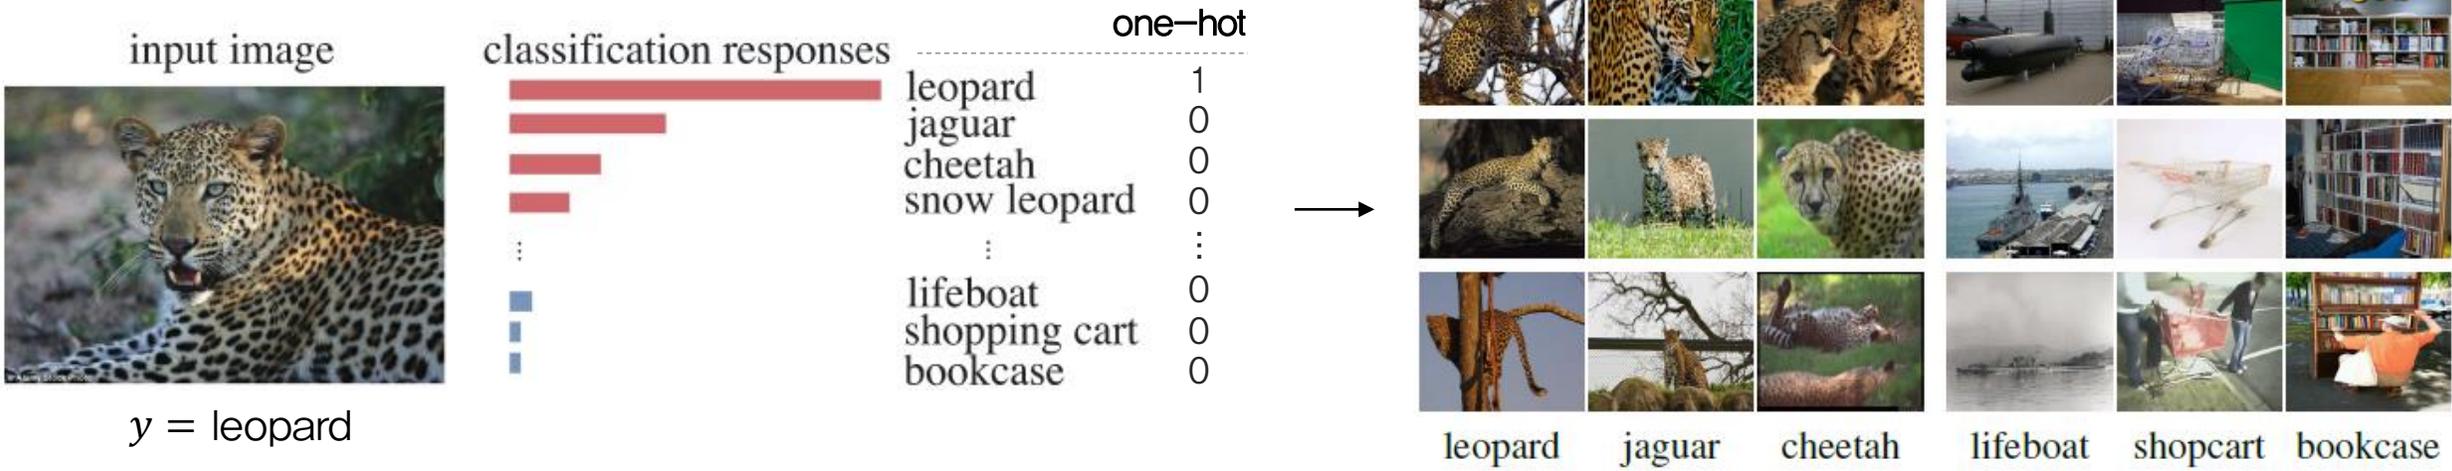
# 01 | Self-Supervised Learning

- Input data ( $X$ ) 자체에서 쉽게 얻을 수 있는 정보를 사용해서 좋은 representation을 학습
  - Pretext-based learning: jigsaw, colorization, rotation, etc
  - Contrastive learning: (without pretext) contrastive loss ... ??



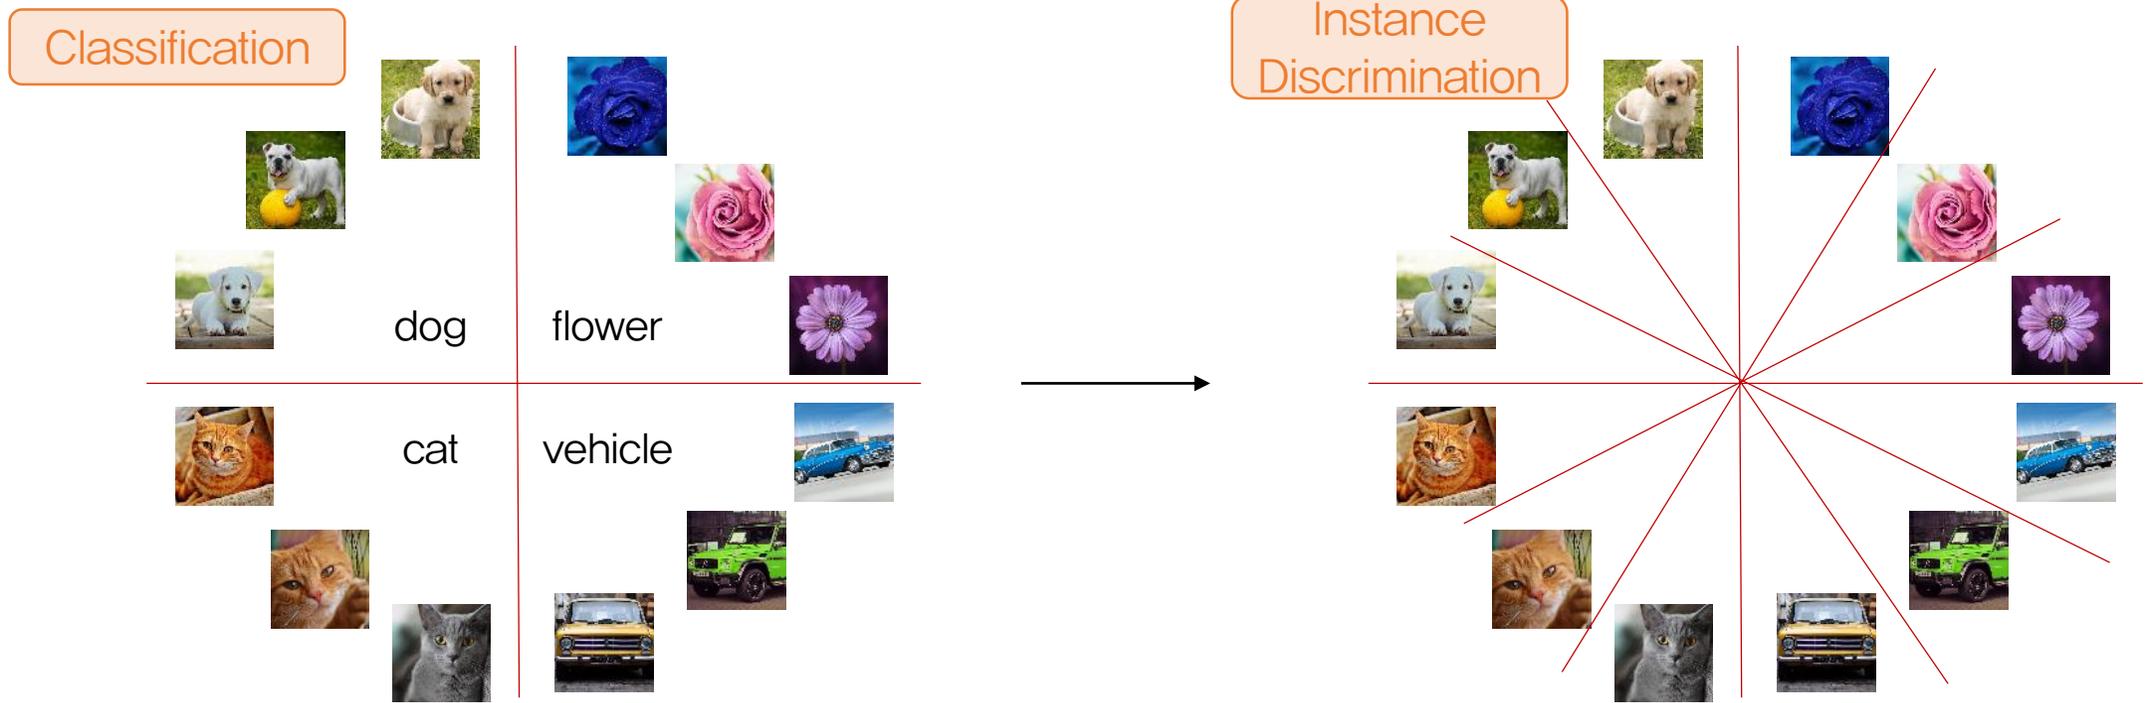
# 01 | Instance Discrimination

- Supervised learning에서는 이미지가 특정 클래스에 속하는지 아닌지를 구분하는 1 vs. 0으로 학습 (one-hot)
- Semantic labeling이 아님에도 불구하고, 확률값이 높은 클래스는 타겟 클래스와 시각적으로 유사한 것을 발견



# 01 | Instance Discrimination

- 레이블 정보 없이 관측치 레벨에서 학습 · 공유하는 representation · semantic structure가 있을 것이다.  
→ 관측치 사이의 유사성을 기반으로, 관측치끼리 구분하도록 학습을 한다면  
레이블 정보 없이도 좋은 representation을 얻을 수 있지 않을까?



# 01 | Instance Discrimination

- 수많은 관측치들을 어떻게 구분하도록 만들 수 있을까?
  - ✓ ImageNet 데이터는 약 1200만개 이상의 관측치를 갖고 있어 softmax를 단순히 사용하기에는 어렵다
  - ✓ 분모가 커짐으로 인해 확률값이 너무 작아져서 학습이 어려움

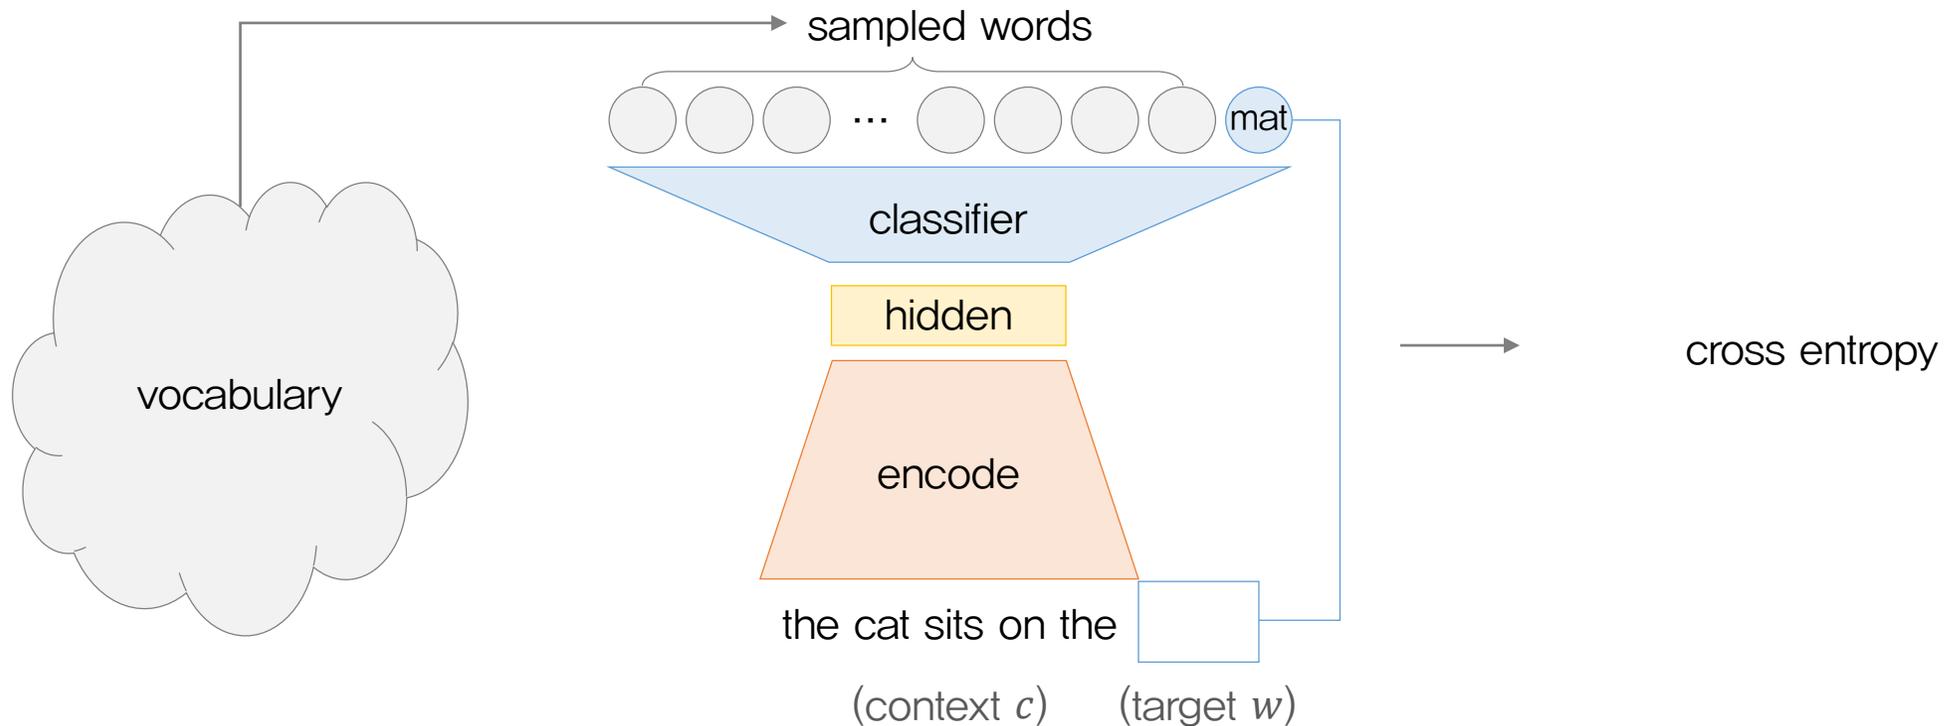
[학습 데이터셋 개요]



- MNIST  
클래스 - 10개  
관측치 - 60,000개
- CIFAR100  
클래스 - 100개  
관측치 - 50,000개
- ImageNet  
클래스 - 1,000개  
관측치 - 1,200,000개 이상  
→ 1,200,000 클래스…?

# 01 | Noise Contrastive Estimation

- 자연어 처리 (natural language processing) Word Embedding Model에서도 같은 문제를 해결해야 함
  - ✓ 단어 개수 = 클래스 개수
- Softmax에서 너무 많은 단어들에 대해서 계산을 해야 하니, **일부만 샘플링하여 계산하자**



# 01 | Intuitive Understanding



non-parameteric softmax

negative log-likelihood

memory bank

L2-normalization

**Non-Parametric Classifier.** The problem with the parametric softmax formulation in Eq. (1) is that the weight vector  $\mathbf{w}$  serves as a class prototype, preventing explicit comparisons between instances.

We propose a *non-parametric* variant of Eq. (1) that replaces  $\mathbf{w}_j^T \mathbf{v}$  with  $\mathbf{v}_j^T \mathbf{v}$ , and we enforce  $\|\mathbf{v}\| = 1$  via a L2-normalization layer. Then the probability  $P(i|\mathbf{v})$  becomes:

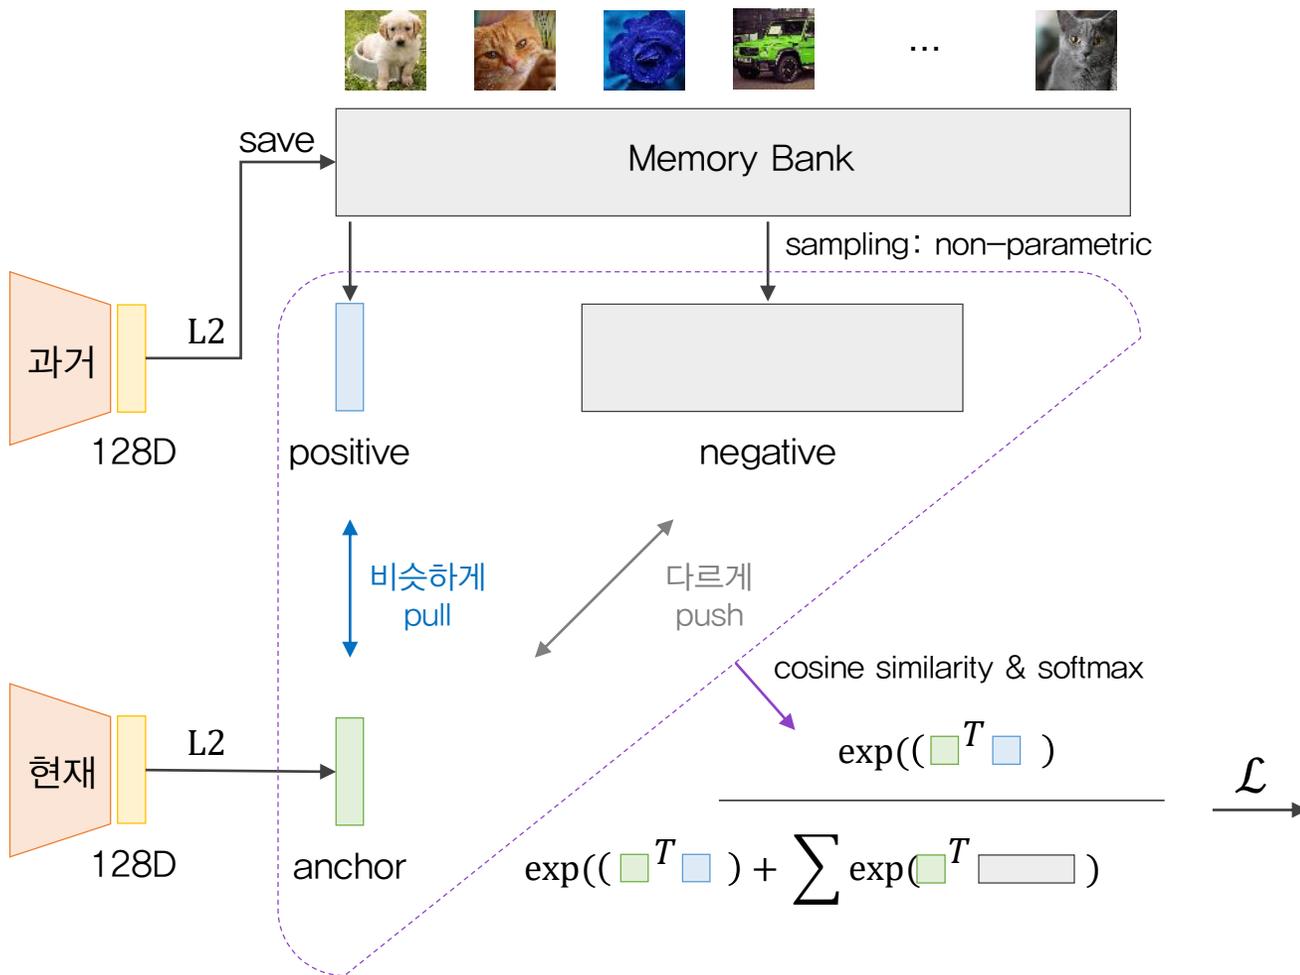
$$P(i|\mathbf{v}) = \frac{\exp(\mathbf{v}_i^T \mathbf{v} / \tau)}{\sum_{j=1}^n \exp(\mathbf{v}_j^T \mathbf{v} / \tau)}, \quad (2)$$

The learning objective is then to maximize the joint probability  $\prod_{i=1}^n P_{\theta}(i|f_{\theta}(x_i))$ , or equivalently to minimize the negative log-likelihood over the training set, as

$$J(\theta) = - \sum_{i=1}^n \log P(i|f_{\theta}(x_i)). \quad (3)$$

**Learning with A Memory Bank.** To compute the probability  $P(i|\mathbf{v})$  in Eq. (2),  $\{\mathbf{v}_j\}$  for all the images are needed. Instead of exhaustively computing these representations every time, we maintain a feature memory bank  $V$  for storing them [46]. In the following, we introduce separate notations for the memory bank and features forwarded from the network. Let  $V = \{\mathbf{v}_j\}$  be the memory bank and  $\mathbf{f}_i = f_{\theta}(x_i)$  be the feature of  $x_i$ . During each learning iteration, the representation  $\mathbf{f}_i$  as well as the network parameters  $\theta$  are optimized via stochastic gradient descent. Then  $\mathbf{f}_i$  is updated to  $V$  at the corresponding instance entry  $\mathbf{f}_i \rightarrow \mathbf{v}_i$ . We initialize all the representations in the memory bank  $V$  as unit random vectors.

# 01 | Intuitive Understanding



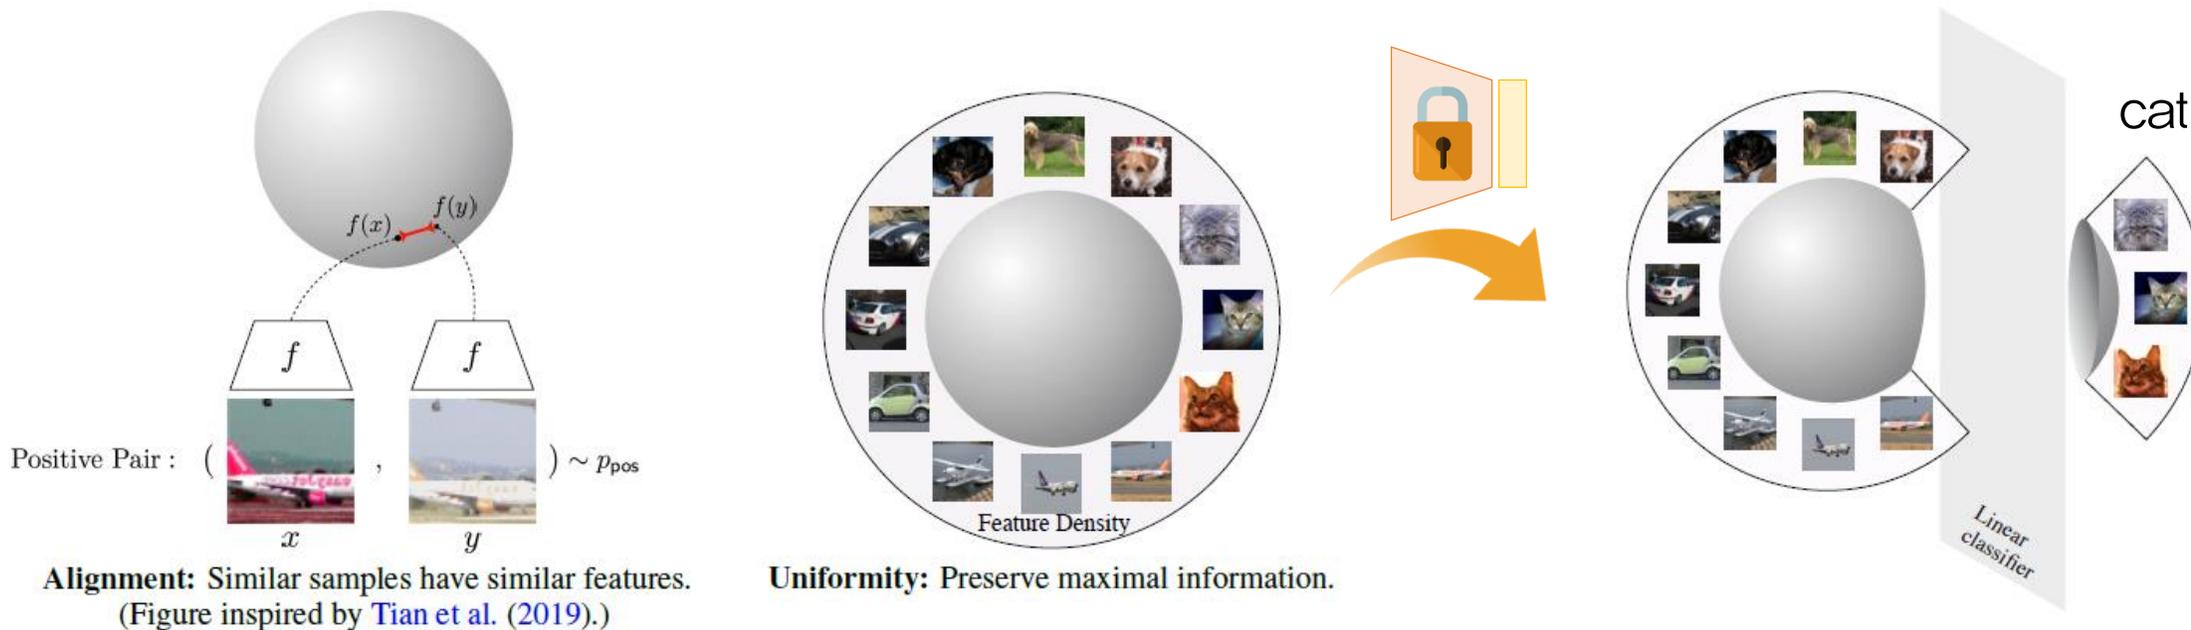
- ① Instance discrimination을 하기 위해 모든 데이터의 임베딩 정보를 저장한다. 이때 임베딩 크기를 맞추기 위해 L2-normalization을 수행한다.
- ② 현재 타겟 이미지의 과거 임베딩 벡터 & 나머지 이미지들의 일부 임베딩 벡터를 샘플링
- ③ 비슷한 정도를 측정하기 위해 cosine 유사도 측정 (L2 Euclidean - Cosine)
- ④ 나 자신에 대한 유사도는 높이며, 나머지는 내리고 싶다. Cosine 유사도를 logit으로 사용하고 확률로 표현하기 위해 softmax 적용 (NCE)  $\rightarrow P(i|v)$
- ⑤ Loss: 앞에서 얻은 cosine 유사도를 logit으로 사용하고, 타겟 클래스 레이블을 모두 0으로 cross entropy. (minimize negative log-likelihood)

$$J(\theta) = - \sum_{i=1}^n \log P(i|f_{\theta}(x_i)).$$

cross\_entropy(logit, target=0)

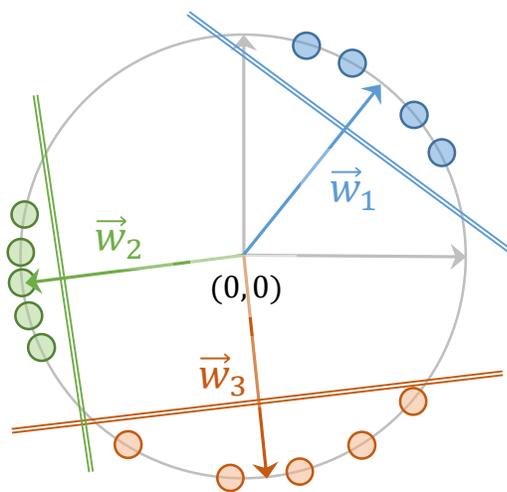
# 01 | Geometric Interpretation

- Contrastive learning이 잘 되었을 때, hypersphere를 따라서 semantic 정보가 유사한 관측치들끼리 모인다
- 학습된 representation의 성능 · 품질을 확인하기 위해서 모델 가중치를 고정시키고 linear classifier를 사용하여 분류 정확도를 산출



# 01 | Geometric Interpretation

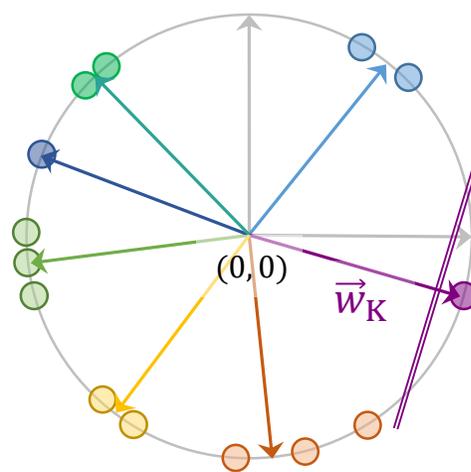
3-way classification



$$\max_{\vec{w}_c} \left\{ \frac{1}{N_c} \sum_i^{N_c} \vec{w}_c \cdot \vec{x}_i \right\}$$

solution:  $\{\vec{w}_1, \vec{w}_2, \vec{w}_3\}$

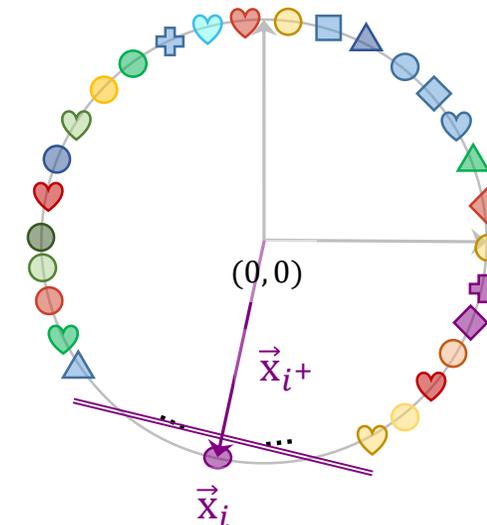
K-way classification



$$\max_{\vec{w}_k} \left\{ \frac{1}{N_k} \sum_i^{N_k} \vec{w}_k \cdot \vec{x}_i \right\}$$

solution:  $\{\vec{w}_1, \dots, \vec{w}_K\}$

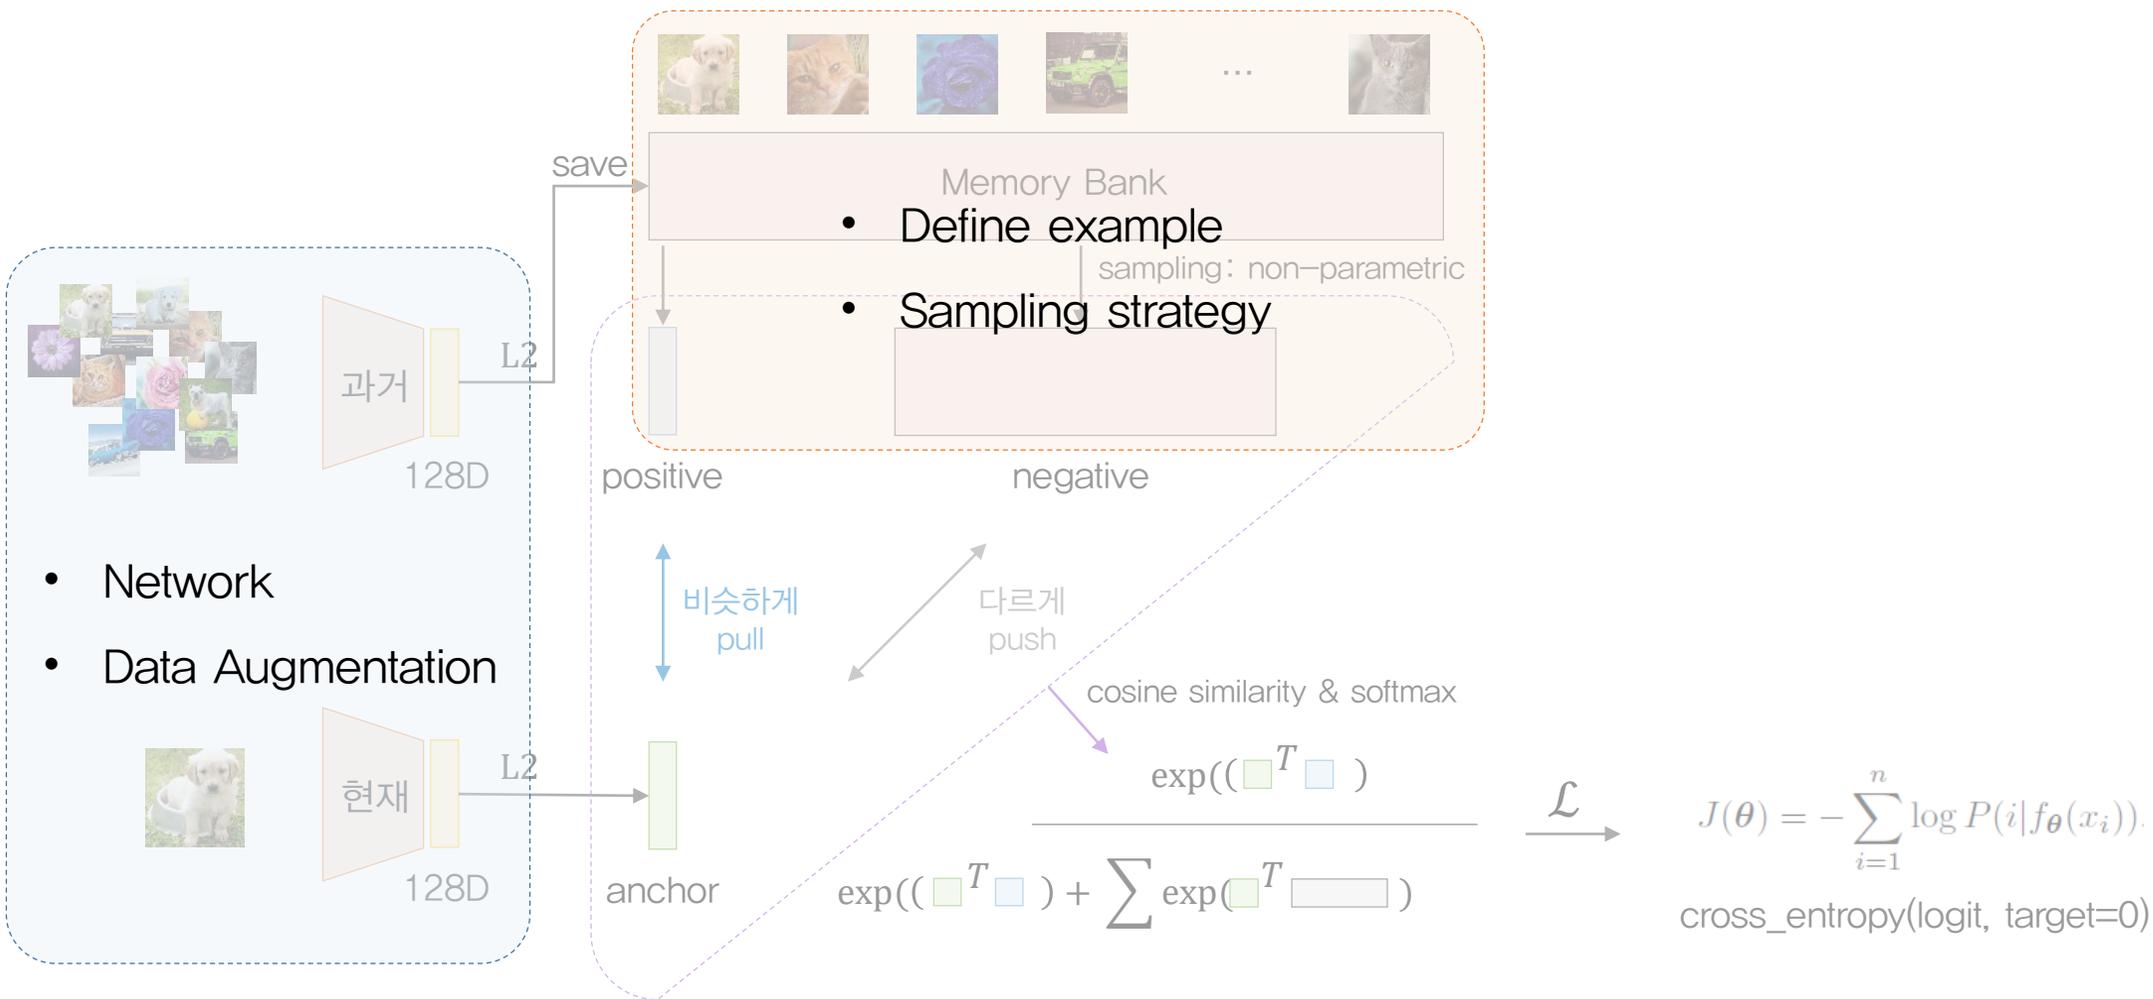
N-way classification  
(Instance discrimination)



$$\max_{\vec{x}_{i+}} \{ \vec{x}_{i+} \cdot \vec{x}_i \}$$

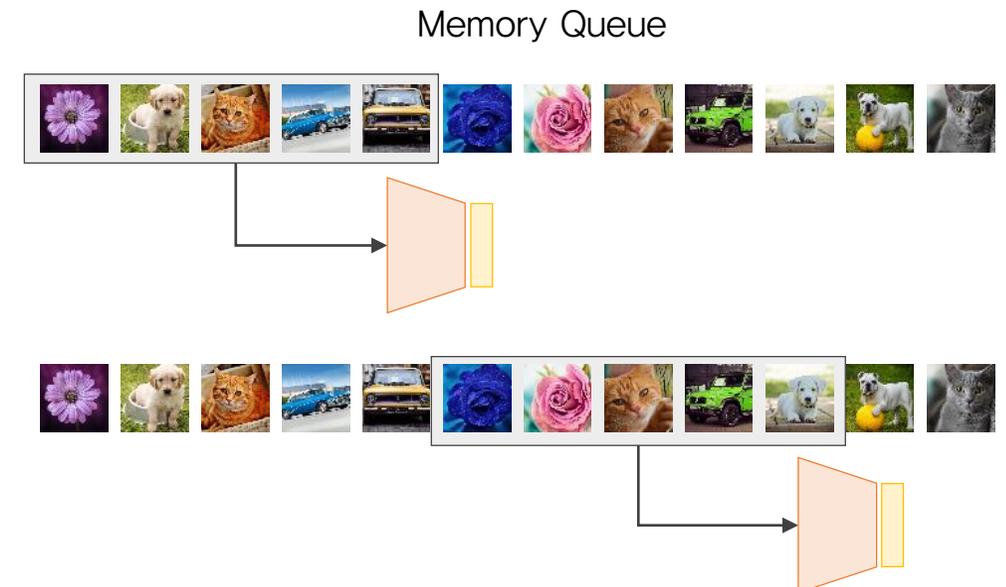
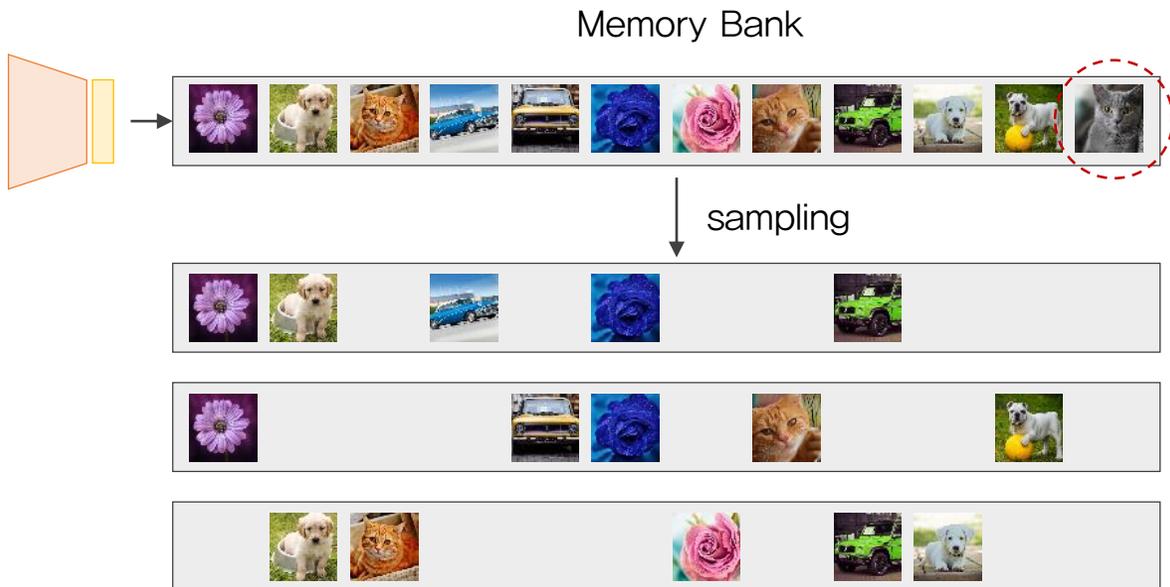
solution:  $\{\vec{x}_{i+}\}_{i=1}^N$

# 01 | Improve Performance



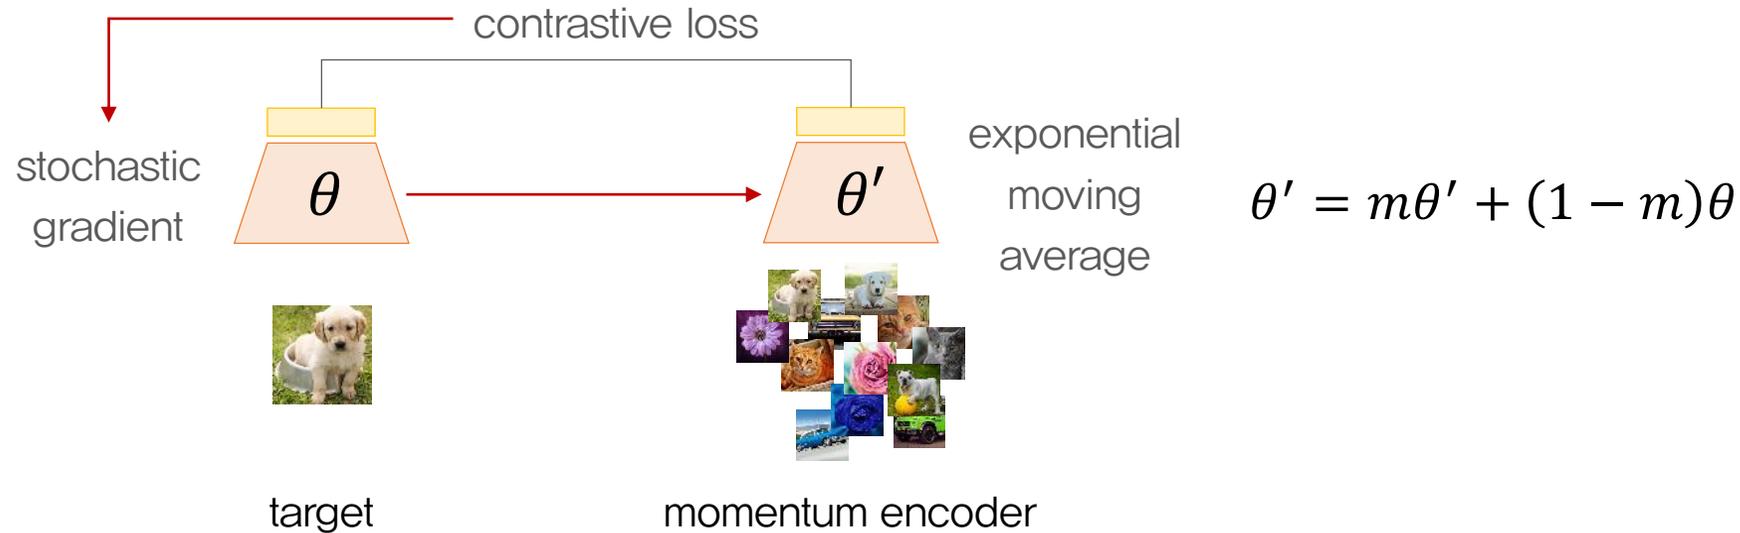
# 02 | MoCo

- Memory Bank의 단점
  - 관측치 전체에 대한 embedding 정보를 계속 저장하고 있어야 한다 - 메모리 이슈
  - 랜덤 샘플링을 통해 negative example을 구성 - 데이터 샘플별로 학습에 기여하는 정도가 다르다
- Memory Queue를 사용
  - First In First Out (FIFO)



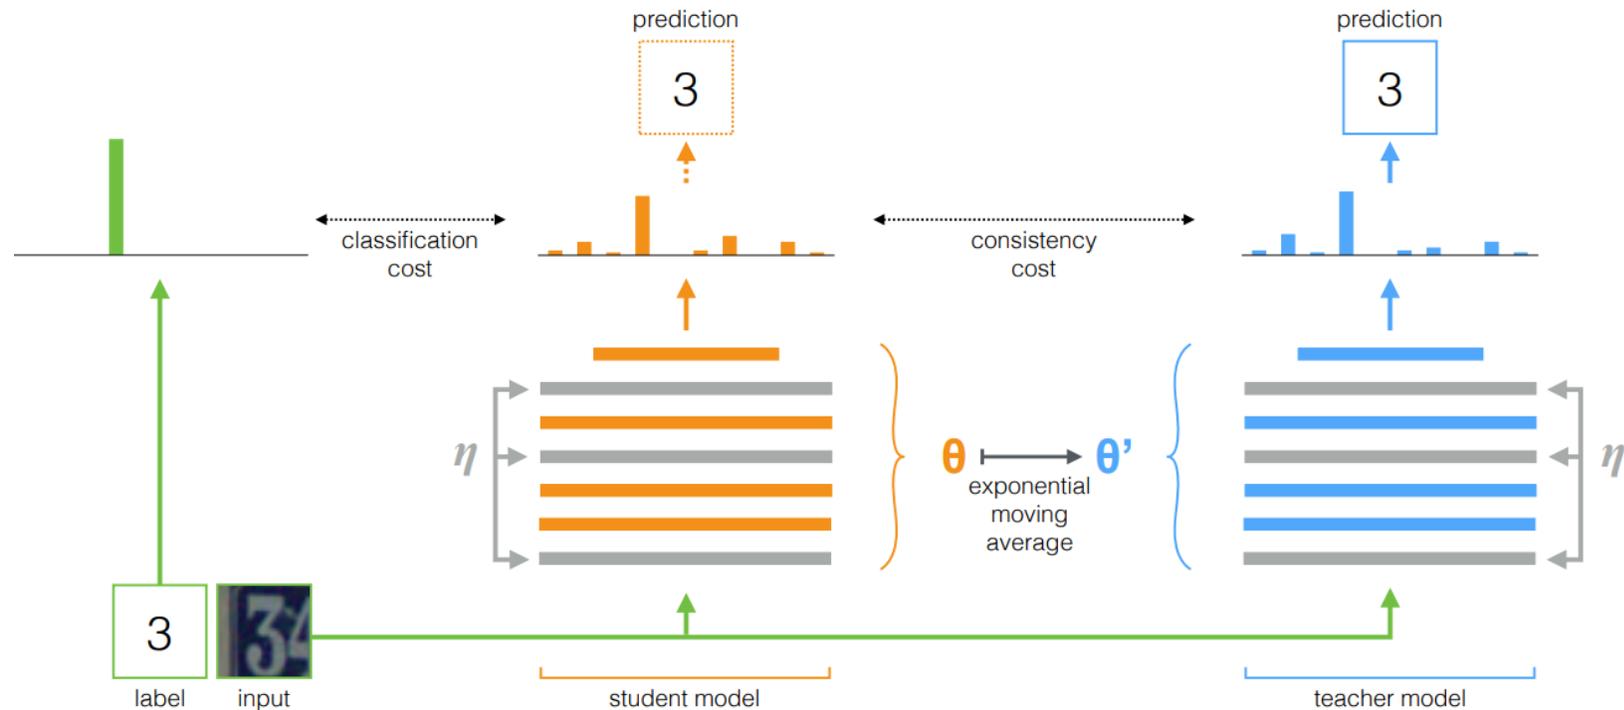
# 02 | MoCo

- Momentum Encoding
  - 과거 모델 weight들의 가중평균으로 업데이트
  - 과거의 나 자신들이 'teacher'가 되는 mean teacher 방식과 동일 (semi-supervised model)
  - Exponential moving average, momentum encoding, on-the-fly ensemble, mean teacher 등등 다양한 이름으로 사용



# 02 | MoCo

- Momentum Encoding
  - 과거 모델 weight들의 가중평균으로 업데이트
  - 과거의 나 자신들이 'teacher'가 되는 mean teacher 방식과 동일 (semi-supervised model)
  - Exponential moving average, momentum encoding, on-the-fly ensemble, mean teacher 등등 다양한 이름으로 사용

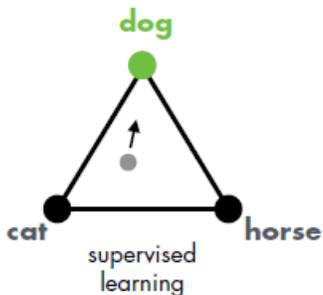


# 02 | MoCo

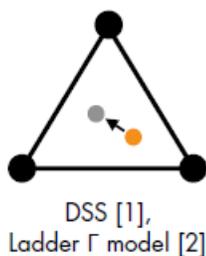
- Momentum Encoding
  - 과거 모델 weight들의 가중평균으로 업데이트
  - 과거의 나 자신들이 'teacher'가 되는 mean teacher 방식과 동일 (semi-supervised model)
  - Exponential moving average, momentum encoding, on-the-fly ensemble, mean teacher 등등 다양한 이름으로 사용

## HISTORY TOUR: TRAINING TO BE CONSISTENT WITH SELF-GENERATED LABELS

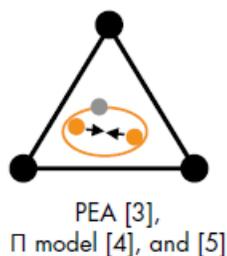
Let's train a classifier to recognise images of cats, dogs, and horses. A **known label** pulls the prediction to its direction.



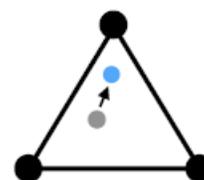
To train on an unlabelled example, we can add noise to the input and let the **clean prediction** pull the **noisy prediction**.



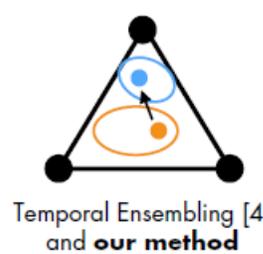
But the **clean prediction** may itself be an outlier, so it is better to let **two noisy predictions** pull each other.



Another way is to improve the **prediction** by (pseudo-)ensembling many models to form a **teacher prediction**.



Combining these ideas works even better: a noisy pseudo-ensembled **teacher prediction** pulls a noisy **student prediction**.



Other approaches:  
a) make **noisy sample adversarial**, then pull.  
b) pull towards the **closest class**.



# 02 | SimCLR

- Queue도 사용하지 않고 batch size를 늘려서 negative 생성을 batch 안에서 해결해보자
- 관측치별로 2번의 data augmentation을 적용

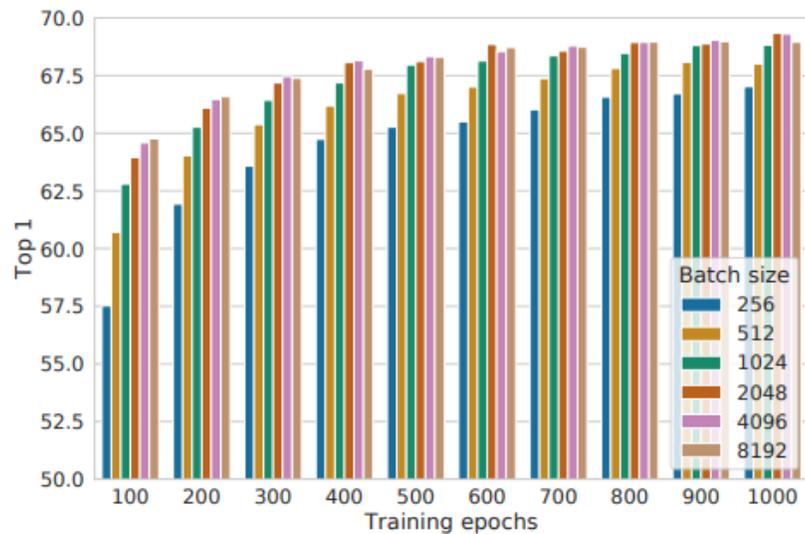
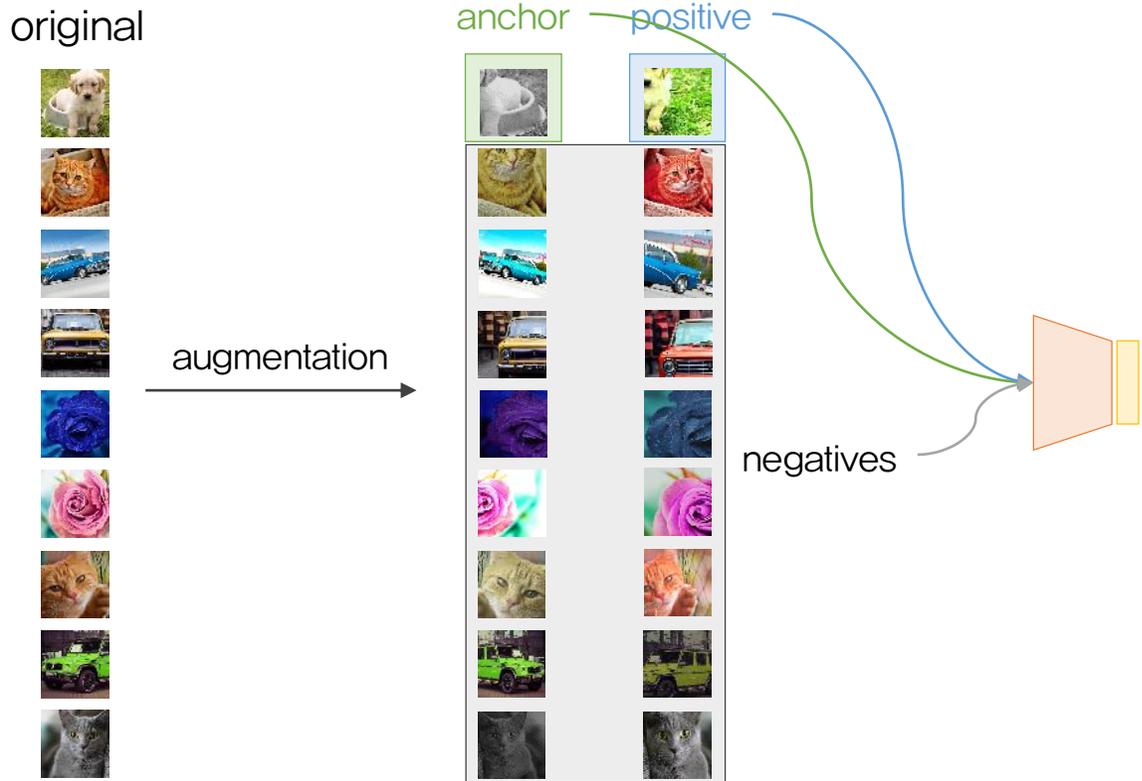


Figure 9. Linear evaluation models (ResNet-50) trained with different batch size and epochs. Each bar is a single run from scratch.<sup>10</sup>



## 02 | SimCLR

- 다양한 data augmentation 기법을 활용 (Augmentation: “The whys and hows of data augmentation, 강현구” 세미나 참고)
  - ✓ Robust data distribution
- 더 좋은 feature를 만들기 위해 embedding layer를 더 깊게 쌓자

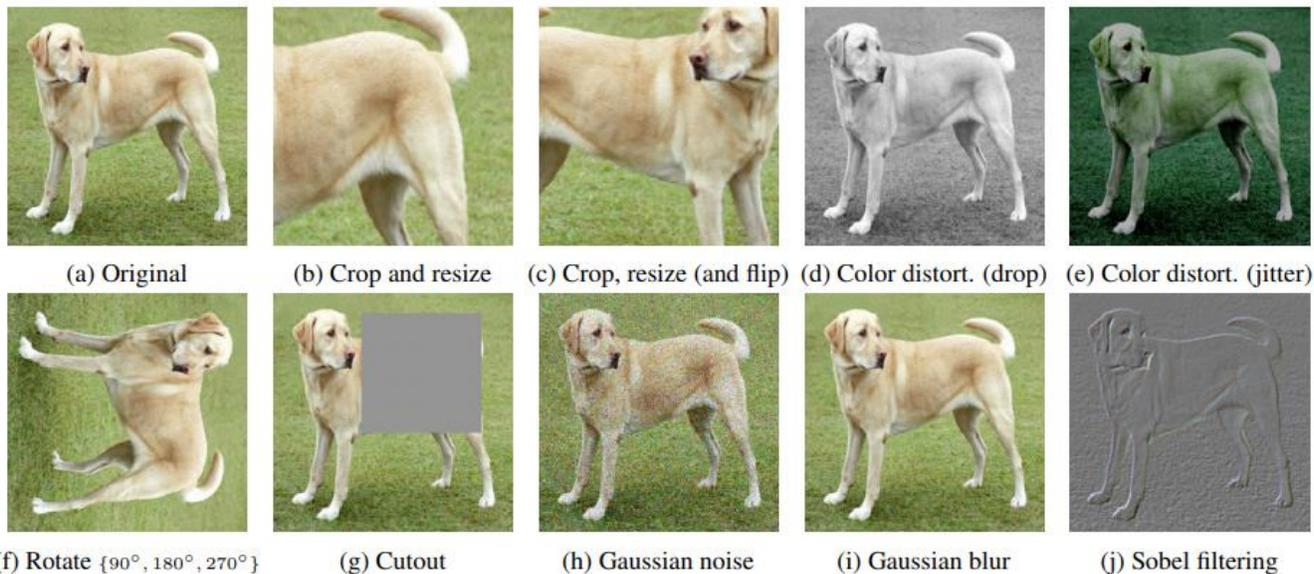
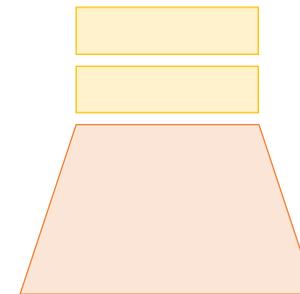


Figure 4. Illustrations of the studied data augmentation operators. Each augmentation can transform data stochastically with some internal parameters (e.g. rotation degree, noise level). Note that we *only* test these operators in ablation, the *augmentation policy used to train our models* only includes *random crop (with flip and resize), color distortion, and Gaussian blur*. (Original image cc-by: Von.grzanka)



## 02 | MoCo v2

- SimCLR에서 사용한 깊은 embedding layer & data augmentation 기법을 MoCo에 적용
  - ✓ Facebook vs. Google
- 높은 분류 정확도를 보임 (Table 2)
- Batch size를 엄청 크게 사용하는 SimCLR보다 메모리 효율 측면에서 좋음 (Table 3)

case	unsup. pre-train					ImageNet acc.
	MLP	aug+	cos	epochs	batch	
MoCo v1 [6]				200	256	60.6
SimCLR [2]	✓	✓	✓	200	256	61.9
SimCLR [2]	✓	✓	✓	200	8192	66.6
<b>MoCo v2</b>	✓	✓	✓	200	256	<b>67.5</b>
<i>results of longer unsupervised training follow:</i>						
SimCLR [2]	✓	✓	✓	1000	4096	69.3
<b>MoCo v2</b>	✓	✓	✓	800	256	<b>71.1</b>

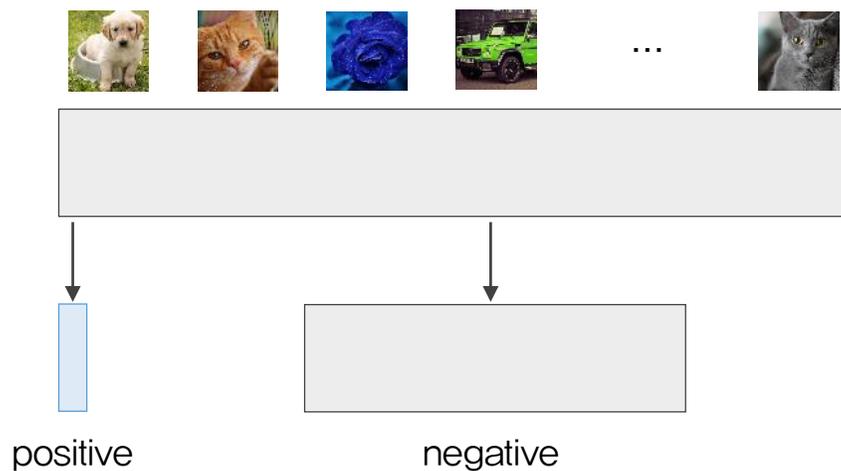
Table 2. **MoCo vs. SimCLR**: ImageNet linear classifier accuracy (ResNet-50, 1-crop  $224 \times 224$ ), trained on features from unsupervised pre-training. “aug+” in SimCLR includes blur and stronger color distortion. SimCLR ablations are from Fig. 9 in [2] (we thank the authors for providing the numerical results).

mechanism	batch	memory / GPU	time / 200-ep.
MoCo	256	<b>5.0G</b>	<b>53 hrs</b>
end-to-end	256	7.4G	65 hrs
end-to-end	4096	93.0G <sup>†</sup>	n/a

Table 3. **Memory and time cost** in 8 V100 16G GPUs, implemented in PyTorch. <sup>†</sup>: based on our estimation.

# 03 | Define Example Nicely

- 좀 더 좋은 positive를 정의할 수 있을까? 하나로 충분할까?
- 과연 적절한 negative일까? 더 좋은 샘플링 방법은 무엇일까?
  - ✓ Memory bank, queue, large batch – 3가지 방법 모두 결론적으로는 negative example 샘플링을 하는 것



# 03 | Prototype to Support Positive

- 뭉쳐있는 유사한 여러 이미지를 대표할 수 있는 prototype (원형)을 positive로 사용하는 것
  - 군집화 알고리즘(K-means)을 사용하여 prototype을 정의하고, contrastive learning을 수행
    - ✓ Fine-grained:  $K = 100,000$
    - ✓ Coarse-grained:  $K = 50,000$
- } Hierarchical Semantic Structure

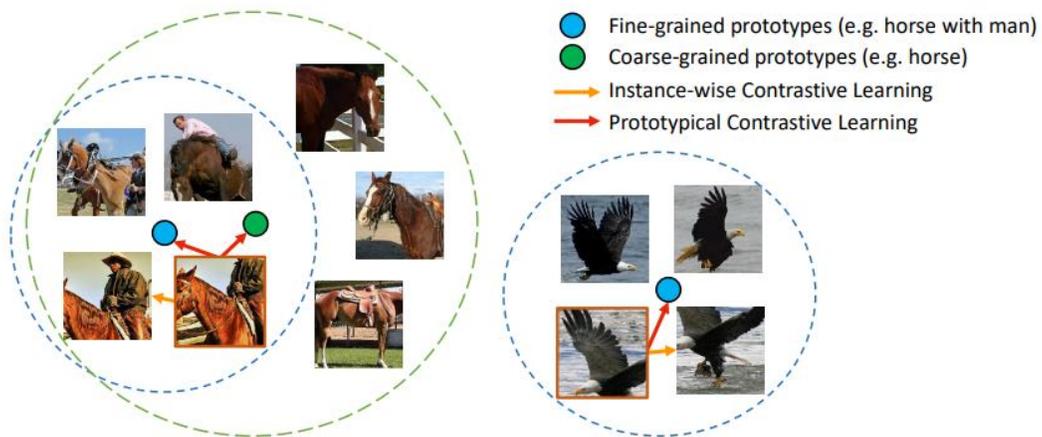


Figure 1: Illustration of Prototypical Contrastive Learning. Each instance is assigned to multiple prototypes with different granularity. PCL learns an embedding space which encodes the semantic structure of data.

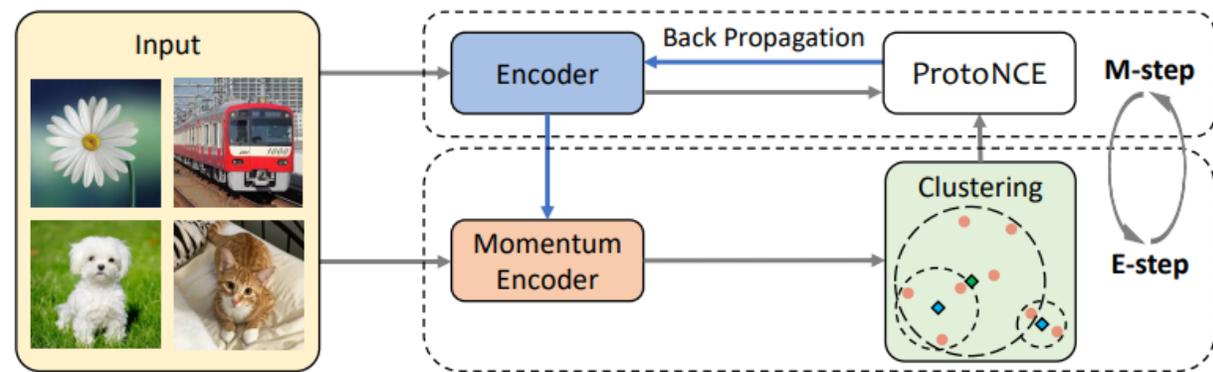
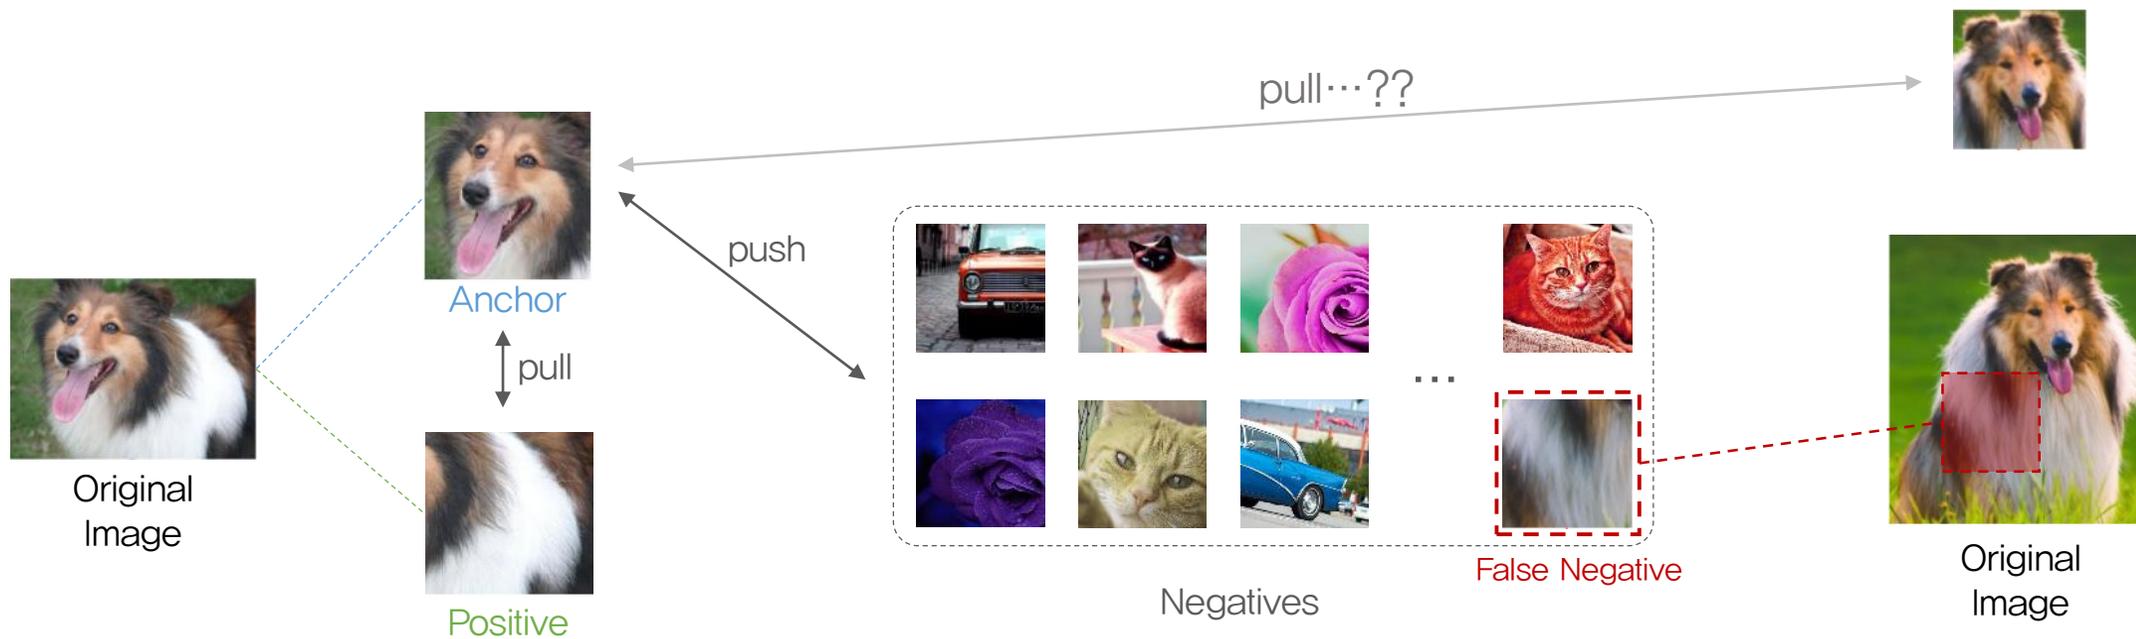


Figure 2: Training framework of Prototypical Contrastive Learning.

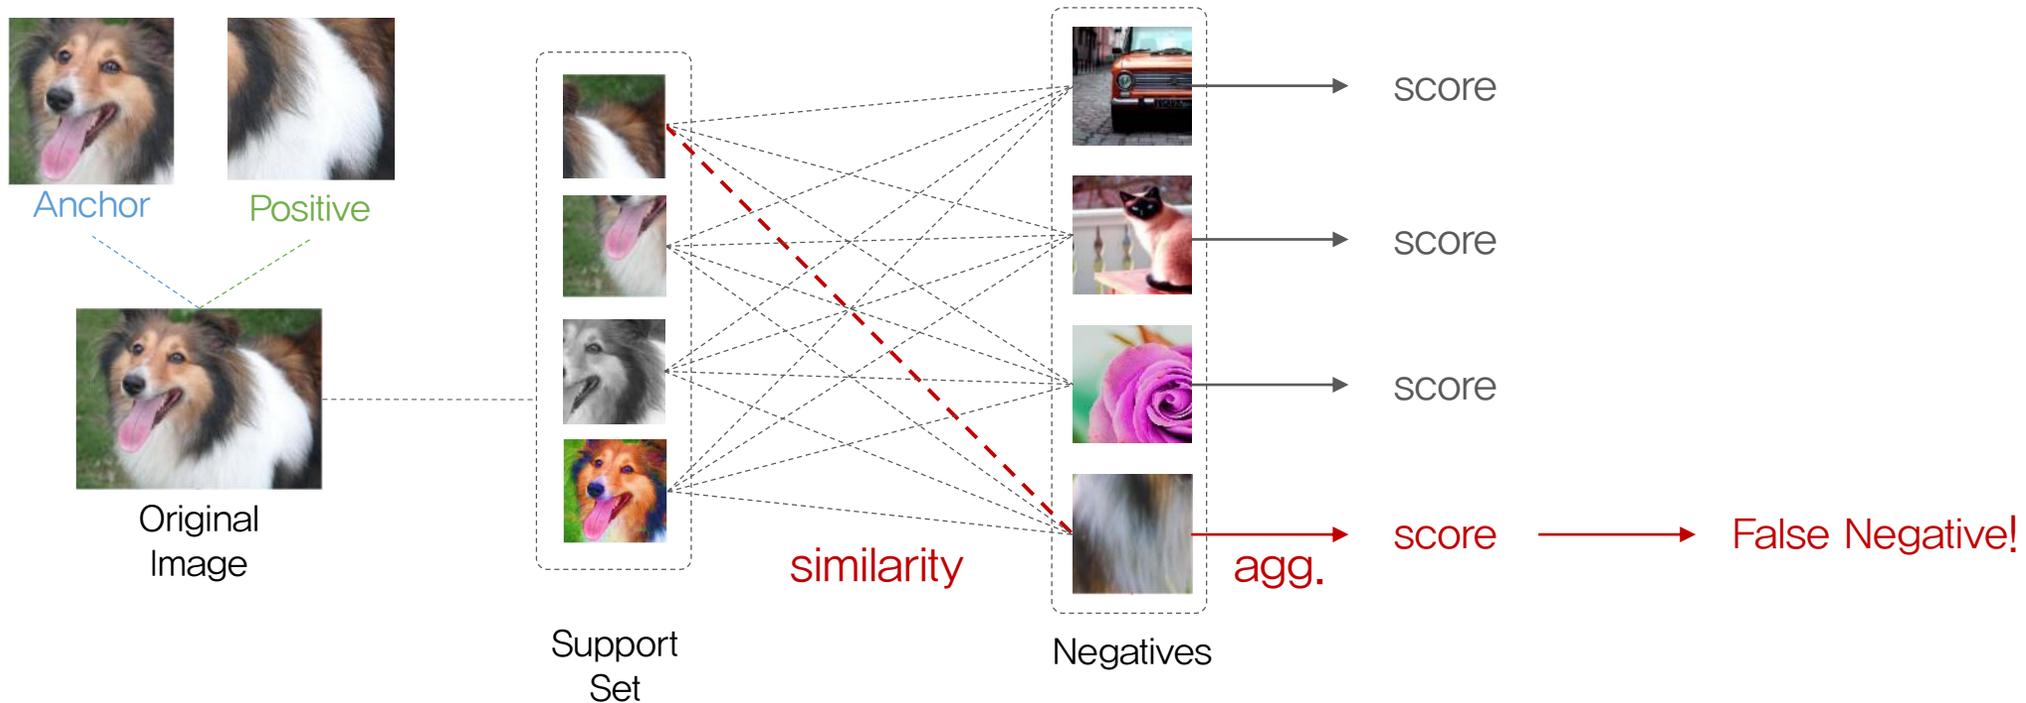
# 03 | False Negative Cancellation

- Negative examples 중에서 anchor와 원래는 유사한 semantic structure를 갖는 이미지가 섞여 있을 수도 있지 않을까?
- False Negative란?
  - ✓ Anchor와 다른 이미지로부터 생성되어 negative로 정의되었으나, 원본 이미지 기준으로는 어느 정도의 semantic 유사성은 있는 이미지
  - ✓ Augmentation의 종류에 따라 anchor와 유사성이 낮게 나올 수 있기 때문에 True-False 구분 짓기 어려움



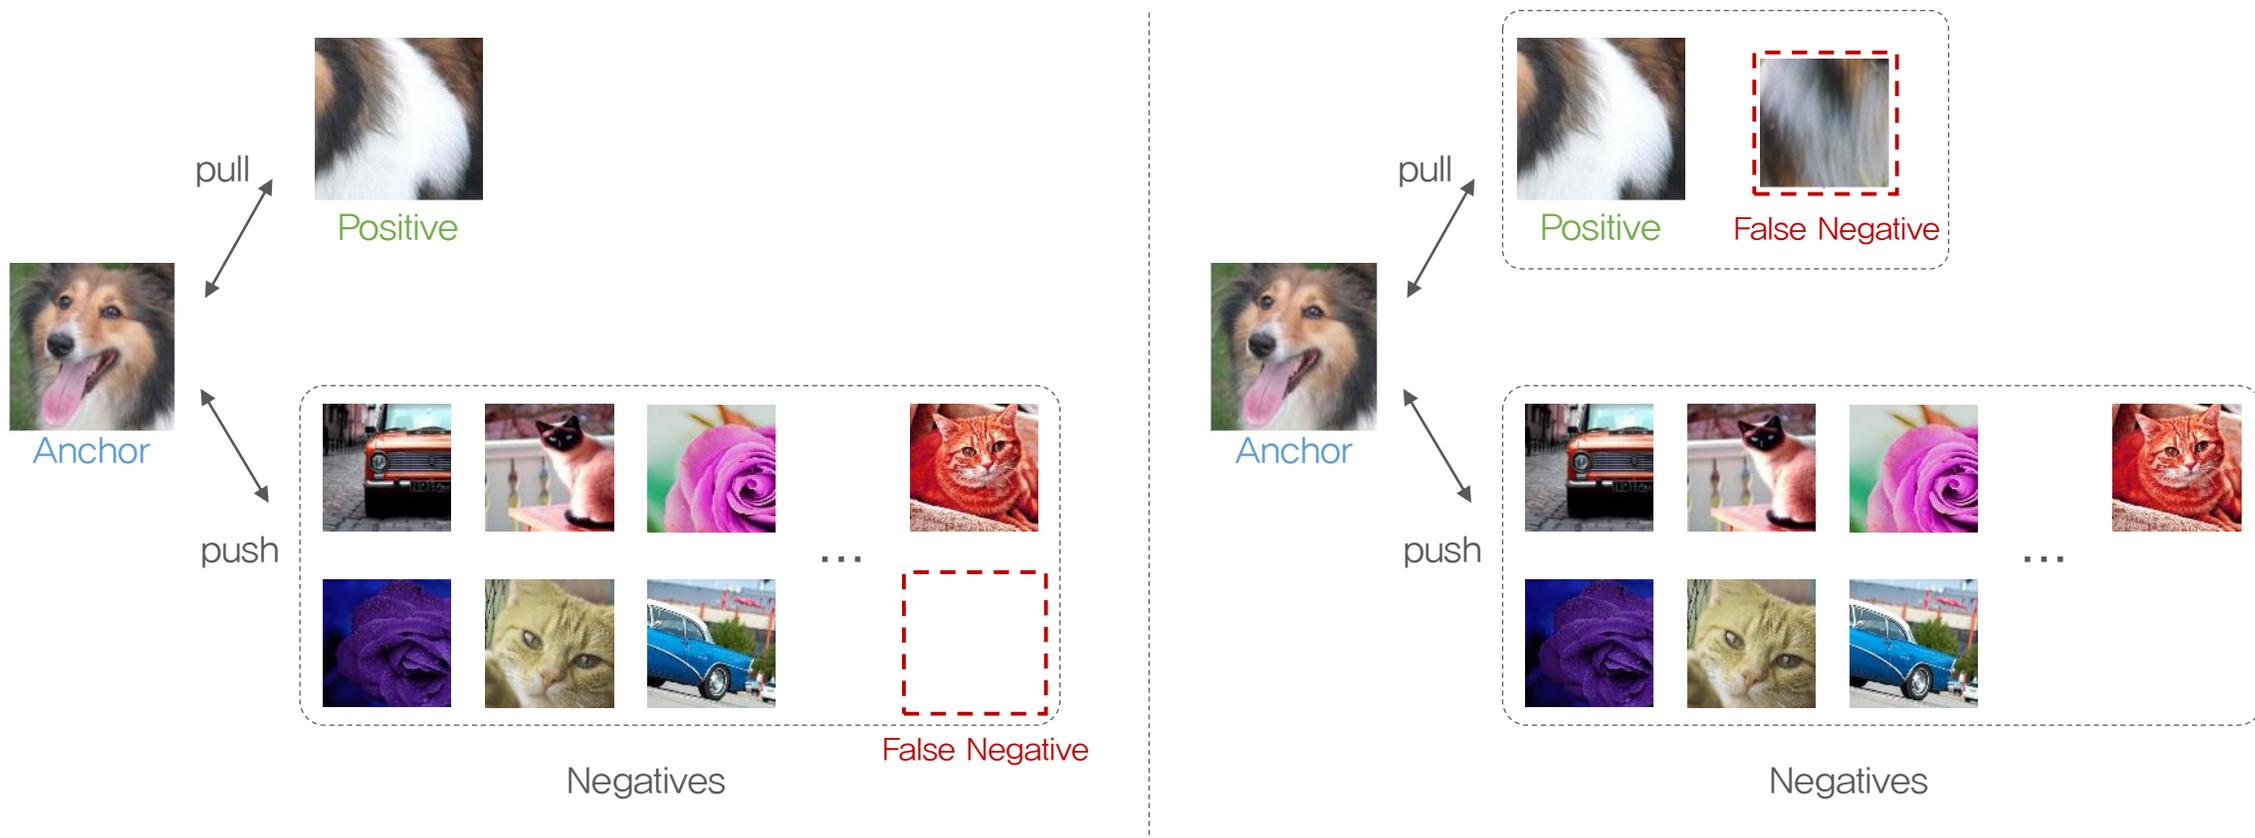
# 03 | False Negative Cancellation

- 해결 방법
  - ✓ anchor에 augmentation을 여러 번 적용해서 negative examples과의 similarity score를 측정



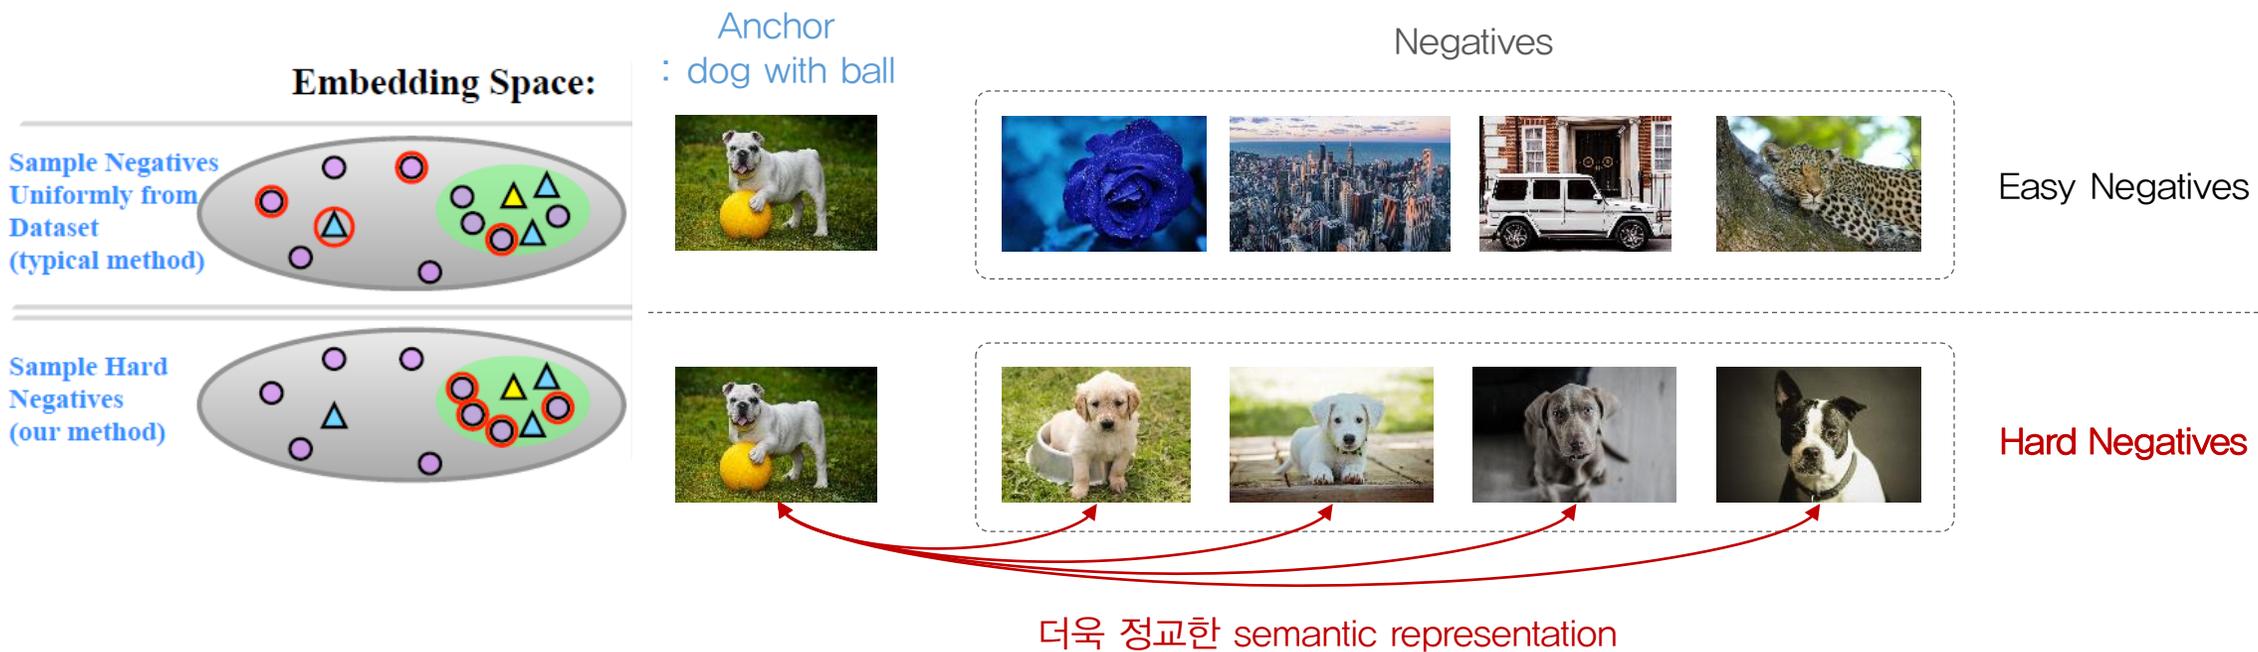
# 03 | False Negative Cancellation

- 최종적으로 false negative를 제거하거나, positive에 포함시키는 전략을 사용할 수 있음



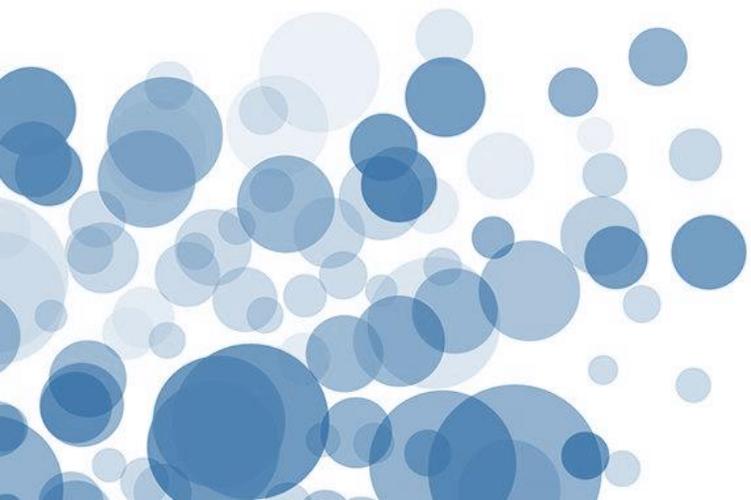
# 03 | Sample Hard Negatives

- Instance discrimination을 잘 하기 위한 negative sample은 어디에 위치해 있어야 할까?
  - Anchor와 멀리 있는 easy negatives: 구분하기 쉽지만 instance discrimination을 위한 representation을 학습하기에는 부적합
  - Anchor와 가까이 있는 hard negatives를 선택해야 한다
  - 관측치별로 주변 density를 측정하여 샘플링에 반영



# 세미나 요약

1. We can learn sophisticated representation without label
2. Why NCE loss is exploited in contrastive learning
3. How to improve the contrastive learning?
  - ✓ Deepen network and use data augmentation: MoCo (Facebook) and SimCLR (Google)
  - ✓ Define example nicely: select hard, but not false negatives



*Thank  
you*

