

---

# **Semi-supervised Learning of FixMatch and after FixMatch**

---

**Data Mining & Quality Analytics Lab.**

**2023년 2월 3일(금)**

**조용원**



# 발표자 소개



## ❖ 조용원(Yongwon Jo) – Ph.D. Candidate

- 고려대학교 산업경영공학과 석·박통합과정 8학기 재학 중
- Data Mining & Quality Analytics Lab (김성범 교수님)

## ❖ Research Interest

- Semantic Segmentation and its applications
- Anomaly Detection and Segmentation
- Semi-supervised Learning for the Regression Problem

- RUSBoost
- Mask R-CNN
- Weakly-supervised Semantic Segmentation
- Human Pose Estimation
- Skeleton-based Human Activity Recognition

| 제목 : A Hybrid Approach to Alleviating Class Imbalance                                  | 제목 : Mask R-CNN  | 제목 : Skeleton-based Human Activity Recognition                                |
|--|--|---|
| 19. 05. 17<br>Yongwon Jo<br>Data Mining & Quality Analytics Lab.                       | 2020년 01월<br>발표자: 조용원<br><br>예측 원인 파악 → Dense Con | 2022. 02. 04.<br>고려대학교<br>Data Mining and Quality Analytics                   |
| RUSBoost : A hybrid approach<br>발표자: 조용원<br>2019년 5월 17일<br>오후 1시 ~<br>고려대학교 신공학관 218호 | Mask R-CNN<br>발표자: 조용원<br>2020년 1월 10일<br>오후 1시 ~<br>고려대학교 신공학관 2:   | Introduction to V<br>발표자: 조용원<br>2020년 8월 21일<br>오후 1시 ~<br>온라인<br>온라인 비디오 시청 |
| <a href="#">세미나 정보 보기 →</a>  | <a href="#">세미나 정보 보기</a>  | <a href="#">세미나 정보 보기</a>   |

## 1. Introduction

## 2. FixMatch

## 3. SelfMatch

## 4. SimMatch

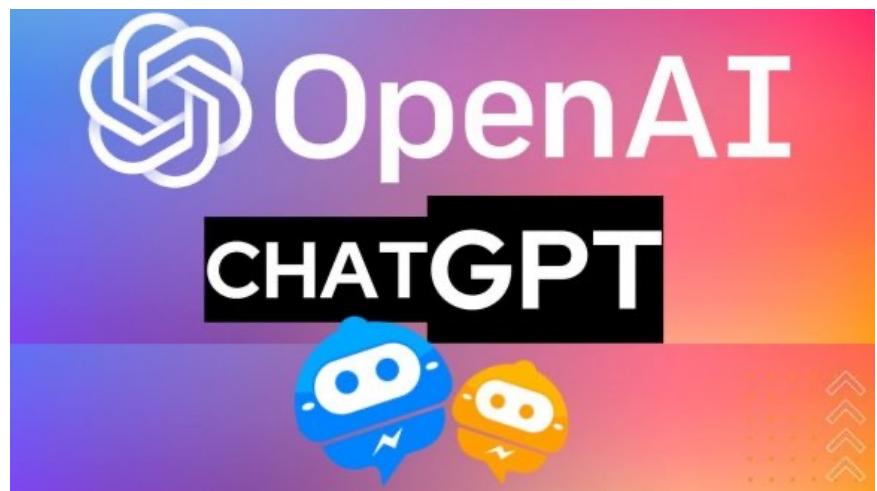
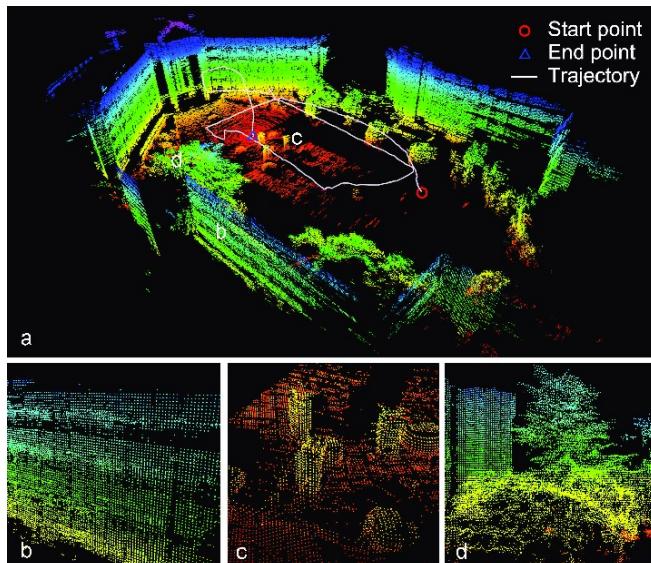
## 5. Conclusion



# 1. Introduction

## ❖ 최신 Deep Learning 기반 인공지능 기술

- 로봇을 작동시켜 Point Cloud 형태로 지형을 파악할 수 있는 Deep Learning 모델(SLAM)
- ChatGPT와 같이 자연스러운 대화 가능한 Deep Learning 모델
- 위와 같은 모델 학습을 위해서는 많은 (입력-출력) 데이터 필요



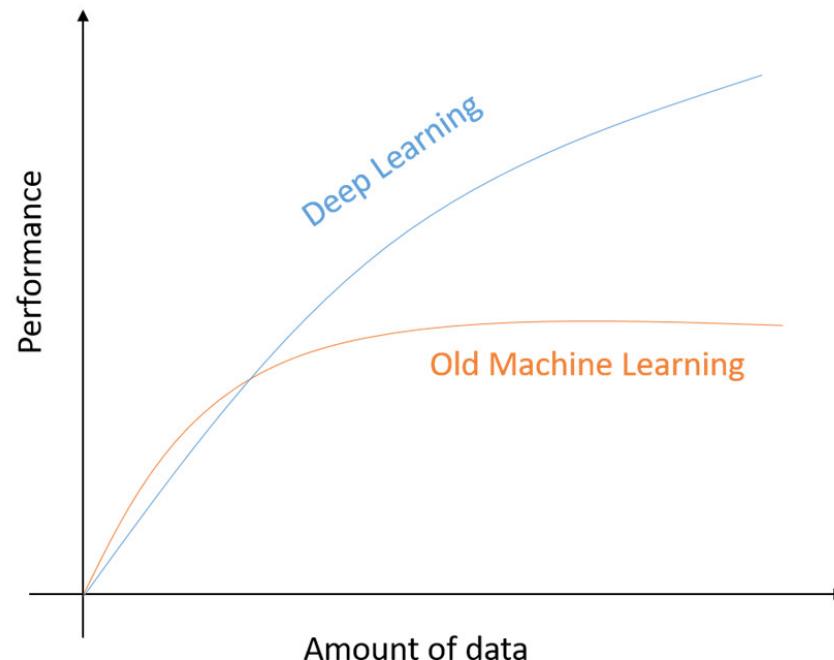
- [https://www.researchgate.net/figure/Map-of-a-plaza-reconstructed-by-GP-We-show-those-points-whose-uncertainty-are-below\\_fig1\\_343415025](https://www.researchgate.net/figure/Map-of-a-plaza-reconstructed-by-GP-We-show-those-points-whose-uncertainty-are-below_fig1_343415025)  
- <https://blogs.chapman.edu/academics/2023/01/09/what-is-chatgpt-what-can-educators-do-about-cheating/>



# 1. Introduction

## ❖ 최신 Deep Learning 기반 인공지능 기술

- Deep Learning 모델 성능은 관심 있는 현상을 설명할 수 있는 좋은 데이터가 많을수록 향상
- 즉, (입력-출력)으로 구성된 데이터(Labeled) 다수가 필요



- [https://www.researchgate.net/figure/The-performance-of-deep-learning-with-respect-to-the-amount-of-data\\_fig3\\_331540139](https://www.researchgate.net/figure/The-performance-of-deep-learning-with-respect-to-the-amount-of-data_fig3_331540139)

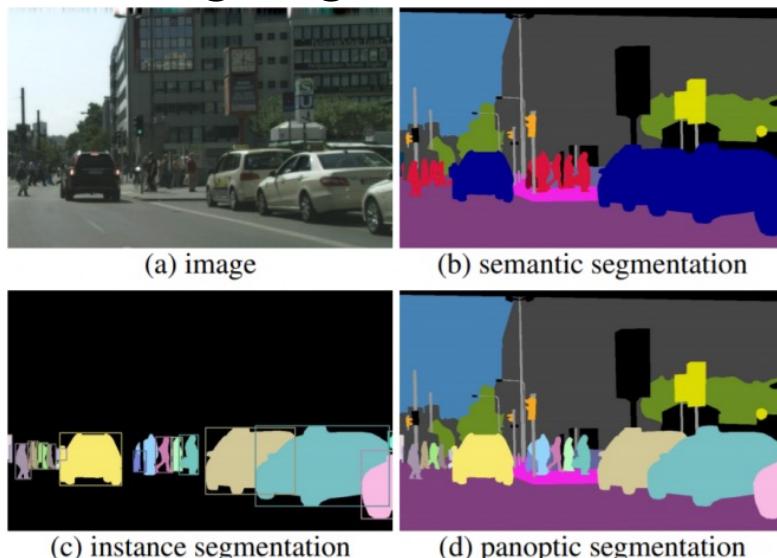


# 1. Introduction

## ❖ Labeled 데이터 수집 시 발생하는 어려움

- 일반적인 사람들이 쉽게 인식할 수 있는 범주를 픽셀별로 및 객체 경계 상자 표기 가능
- 하지만 표기해야 할 객체 수가 많아 특정 이미지 범주 표기 시 많은 인력 및 시간 필요

Image Segmentation 예시



6D Object Detection 예시



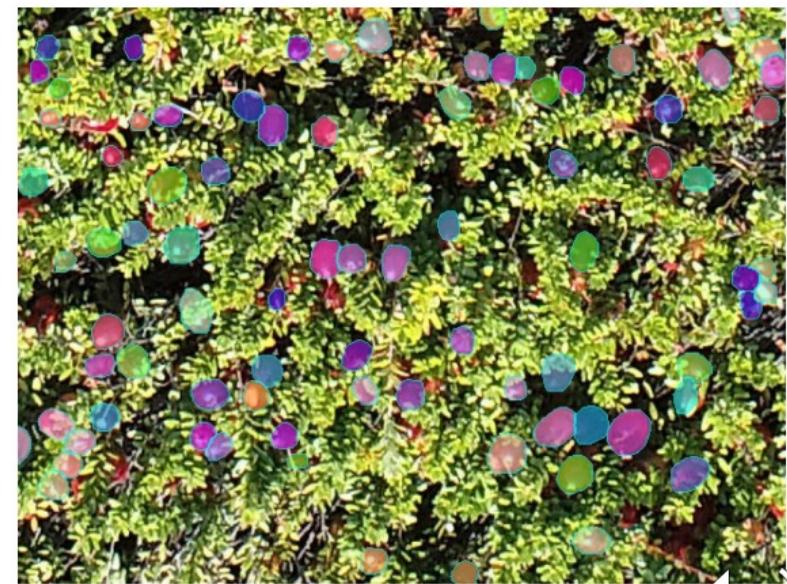
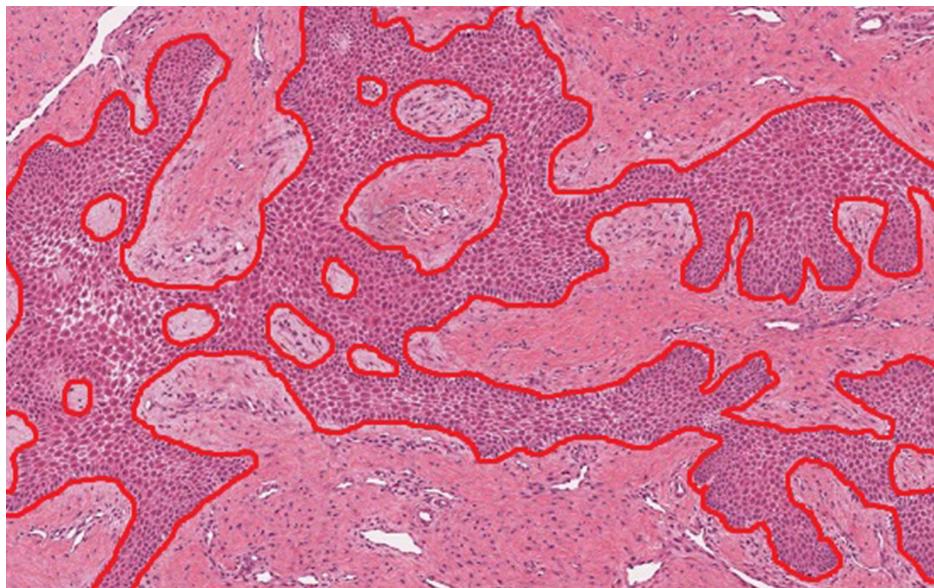
- <https://engineer-mole.tistory.com/273>



# 1. Introduction

## ❖ Labeled 데이터 수집 시 발생하는 어려움

- 의료 및 농업과 같이 특수한 분야에 대한 데이터 수집 시 전문가 지식 필요
- 즉, 전문가가 직접 데이터에 대한 레이블을 표기(Annotation) 해야 하는 상황
- 전문가 인원 수는 적고 인력 투입에 대한 비용은 크기에 데이터 수집이 어려움



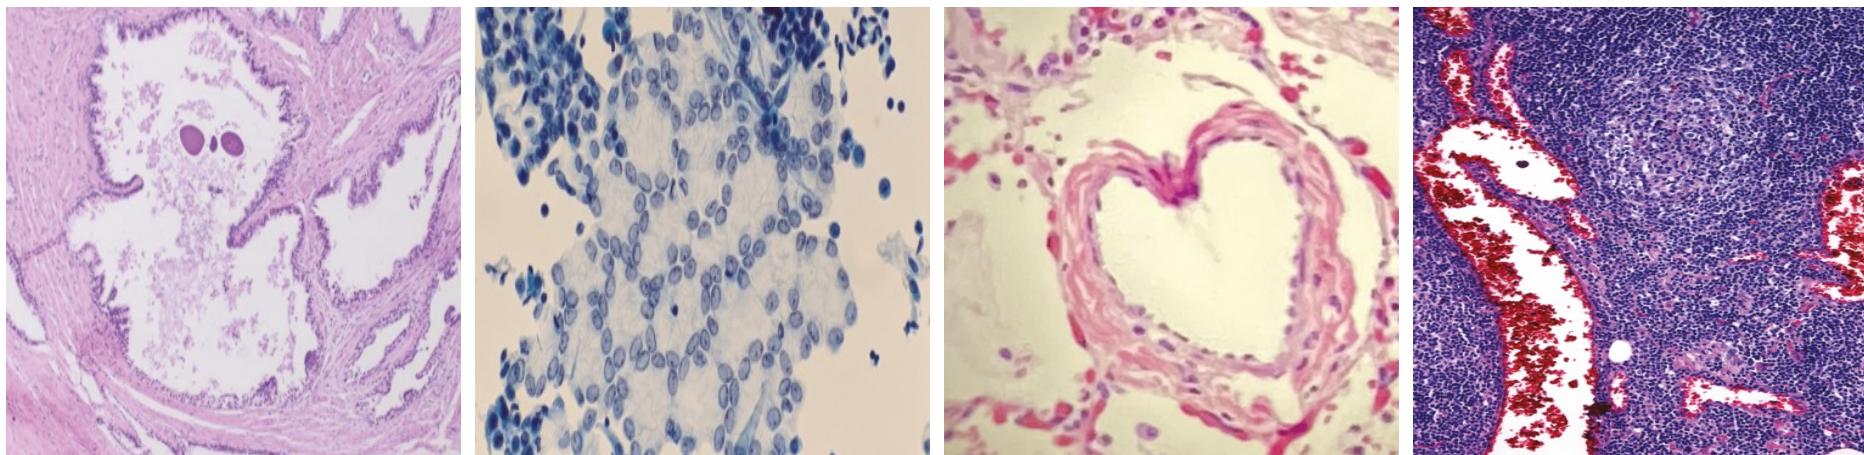
- <https://digitalpathologyplace.com/10-best-pathology-resources-for-designing-image-analysis-algorithms/>
- Akiva, P., Dana, K., Oudemans, P., & Mars, M. (2020). Finding berries: Segmentation and counting of cranberries using point supervision and shape priors. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (pp. 50-51).



# 1. Introduction

## ❖ 레이블링 되지 않은 데이터(Unlabeled)

- 데이터를 사용해 설명하고자 하는 현상 자체를 촬영하는 것은 상대적으로 쉬움
- 최근 많은 Unlabeled 데이터와 적은 Labeled 데이터를 활용해 예측 모델을 학습하고자 하는 연구 등장



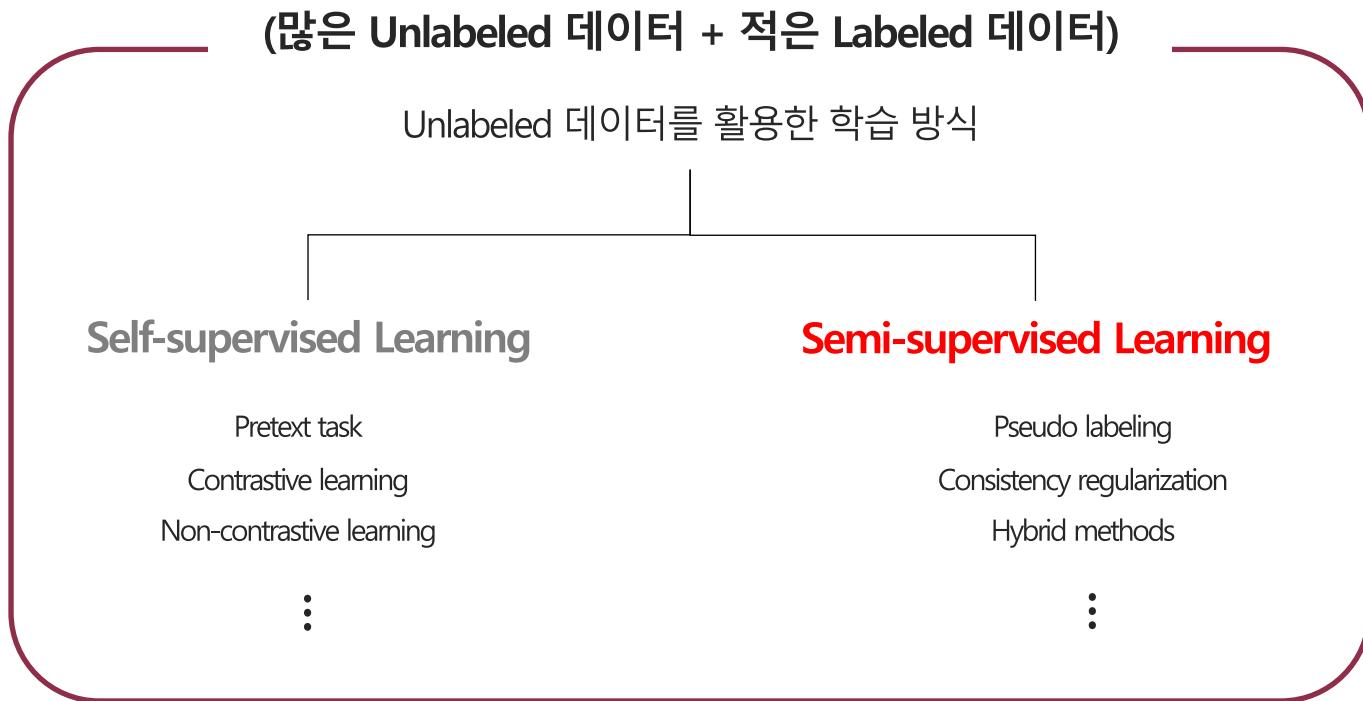
- <https://thepathologist.com/inside-the-lab/picture-perfect-pathology>



# 1. Introduction

## ❖ (많은 Unlabeled 데이터 + 적은 Labeled 데이터) 활용 연구 개요

- 해당 연구 분야는 크게 Self-supervised Learning과 Semi-supervised Learning로 구분 가능
- 두 연구 분야는 Unlabeled 데이터 활용 방식에 차이 존재



# 1. Introduction

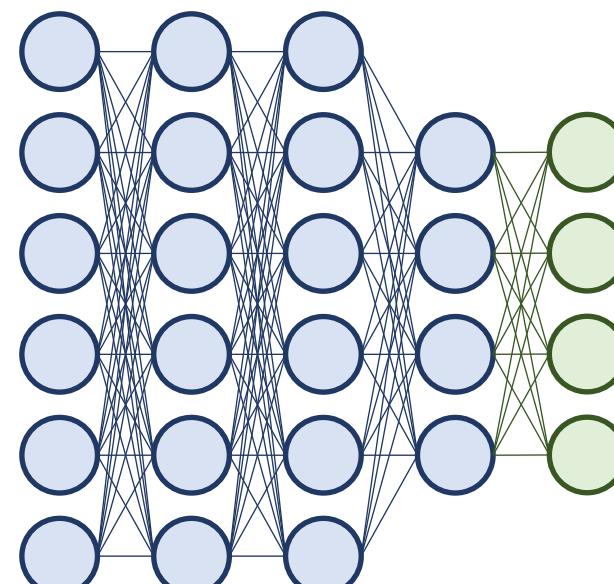
## ❖ Self-supervised Learning vs Semi-supervised Learning

- 두 단계로 나누어 원하는 예측 모델 학습 진행
  - 단계 1: Unlabeled 데이터에 대한 Supervision을 정의 후 신경망 모델 사전 학습 (Pre-training)
  - 단계 2: Labeled 데이터만 사용해 사전 학습된 모델을 미세 조정 진행 (Fine-tuning or Downstream)

Unlabeled 데이터



Labeled 데이터



### Self-supervision

- Pretext task
- Contrastive Learning
- Non-contrastive Learning

⋮



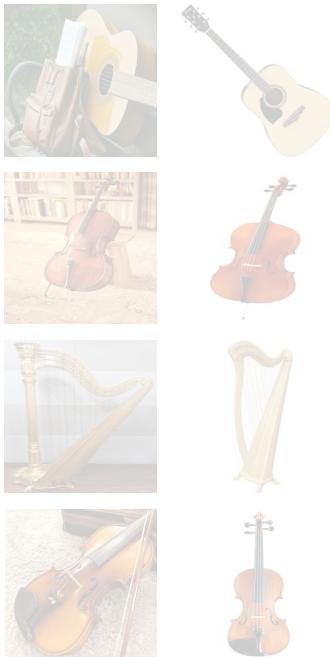
# 1. Introduction

## ❖ Self-supervised Learning vs Semi-supervised Learning

- 두 단계로 나누어 원하는 예측 모델 학습 진행

- 단계 1: Unlabeled 데이터에 대한 Supervision을 정의 후 신경망 모델 사전 학습 (Pre-training)
- 단계 2: Labeled 데이터만 사용해 사전 학습된 모델을 미세 조정 진행 (Fine-tuning or Downstream)

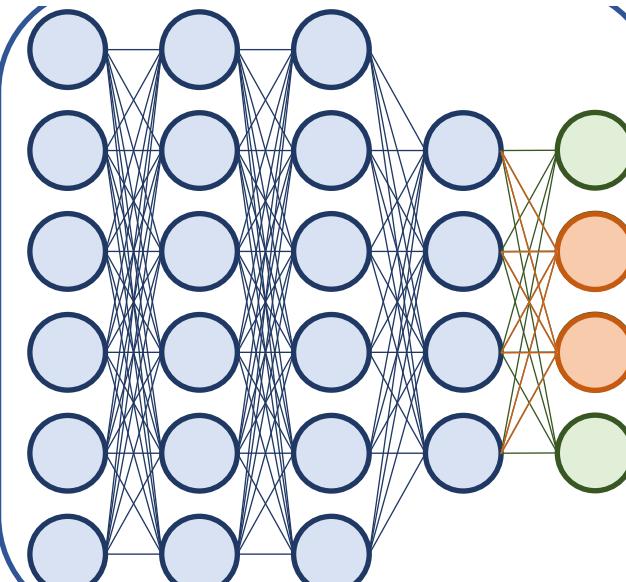
Unlabeled 데이터



Labeled 데이터



Unlabeled 데이터만 사용해 학습된 모델



Saxophone

Trumpet



# 1. Introduction

## ❖ Self-supervised Learning vs **Semi-supervised Learning**

- Self-supervised Learning과 달리 한번에 (Unlabeled & Labeled) 데이터 모두 사용
- Labeled 데이터, Unlabeled 데이터 각각에 대한 손실 함수를 정의하여 신경망 모델 학습

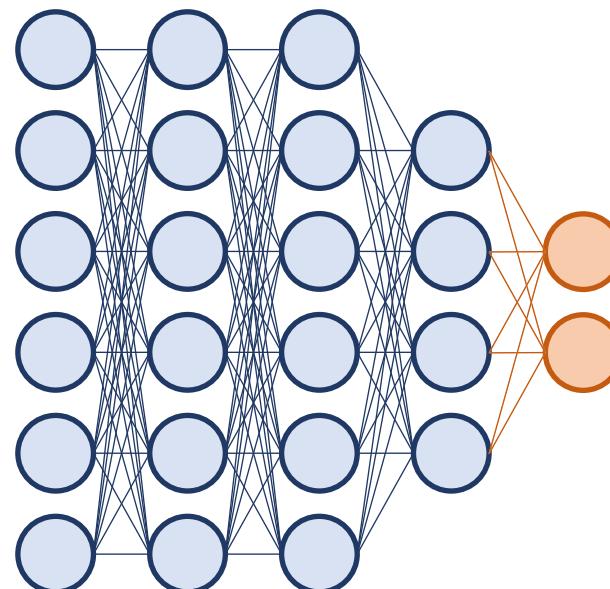
Unlabeled 데이터



Labeled 데이터



$$\mathbf{Loss}_{total} = \mathbf{Loss}_{labeled} + \mathbf{Loss}_{unlabeled}$$



Saxophone

Trumpet



# 1. Introduction

## ❖ Self-supervised Learning vs **Semi-supervised Learning**

- Self-supervised Learning과 달리 한번에 (Unlabeled & Labeled) 데이터 모두 사용
- Labeled 데이터, Unlabeled 데이터 각각에 대한 손실 함수를 정의하여 신경망 모델 학습
- 'Unlabeled 데이터에 대한 손실 함수는 어떤 특징이 있어야 하지? 어떻게 정의하지?'

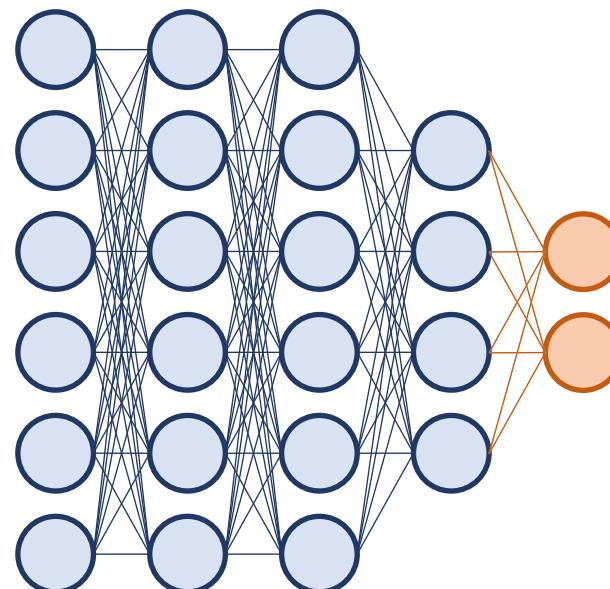
Unlabeled 데이터



Labeled 데이터



$$Loss_{total} = Loss_{labeled} + Loss_{unlabeled}$$



Saxophone

Trumpet



# 목차

---

1. Introduction

2. FixMatch

3. SelfMatch

4. SimMatch

5. Conclusion



## 2. FixMatch

---

### ❖ FixMatch: Simplifying Semi-Supervised Learning with Consistency and Confidence

- 2020년 11월 Neural Information Processing Systems(NeuralIPS)에서 발표된 방법론
  - 2023년 1월 29일 기준 1,520회 인용되었으며 Google Research 소속 연구원들이 발표한 방법론
- 최신 Semi-supervised Learning 방법론의 기초가 되는 방법론

### **FixMatch: Simplifying Semi-Supervised Learning with Consistency and Confidence**

---

Kihyuk Sohn\* David Berthelot\* Chun-Liang Li Zizhao Zhang Nicholas Carlini  
Ekin D. Cubuk Alex Kurakin Han Zhang Colin Raffel  
Google Research  
{kihyuks,dberth,chunliang,zizhaoz,ncarlini,  
cubuk,kurakin,zhanghan,craffel}@google.com



## 2. FixMatch

- ❖ **FixMatch:** Simplifying Semi-Supervised Learning with **Consistency** and Confidence
  - Semi-supervised Learning 방법론 가정 중 Consistency Regularization에 관한 내용

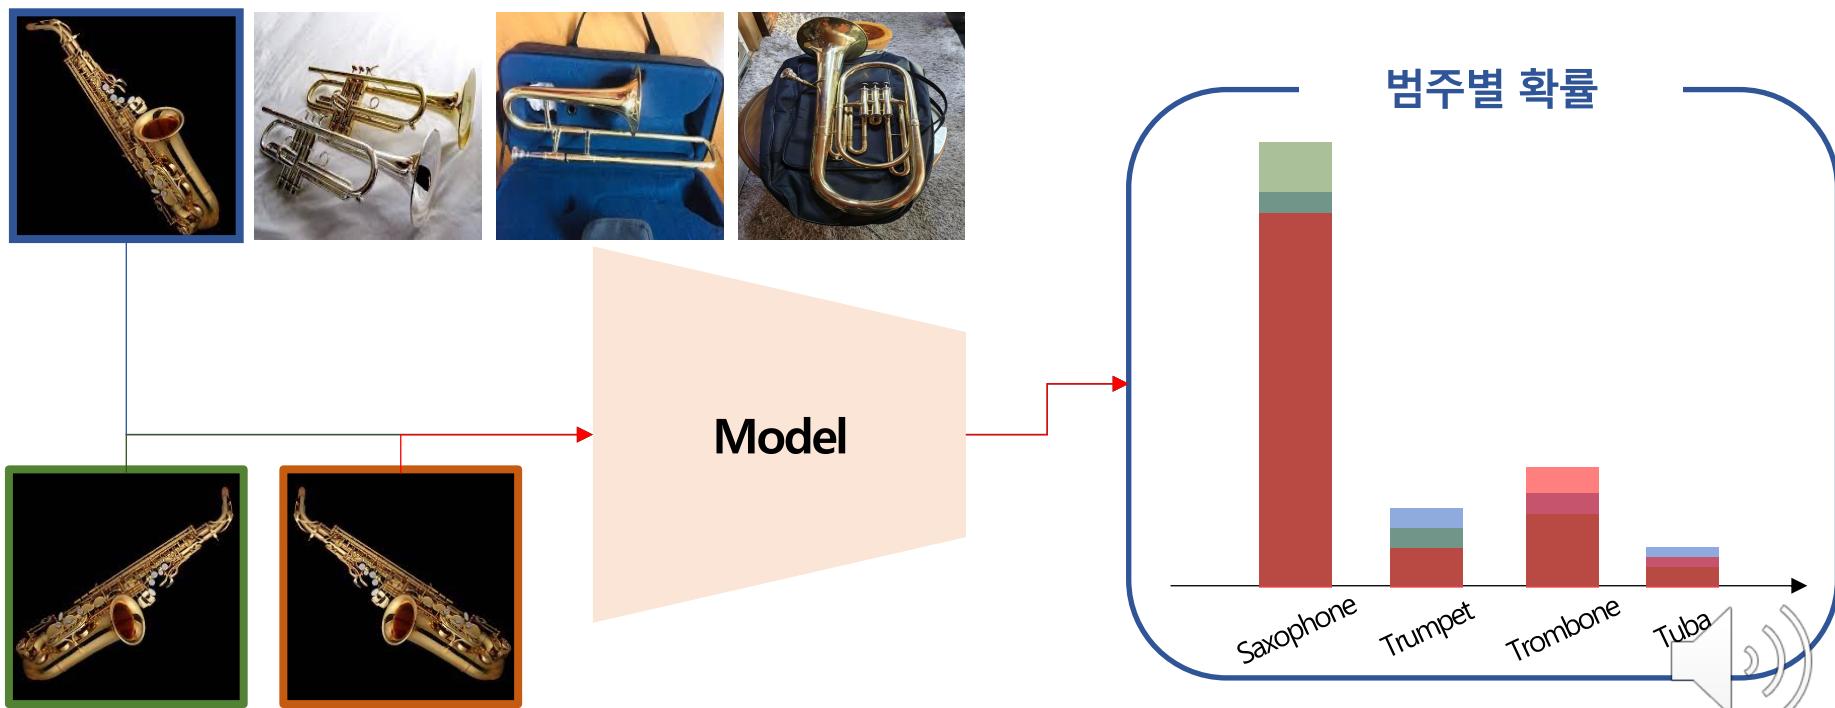
악기 종류를 분류하는 모델 학습 (총 범주는 4개)



## 2. FixMatch

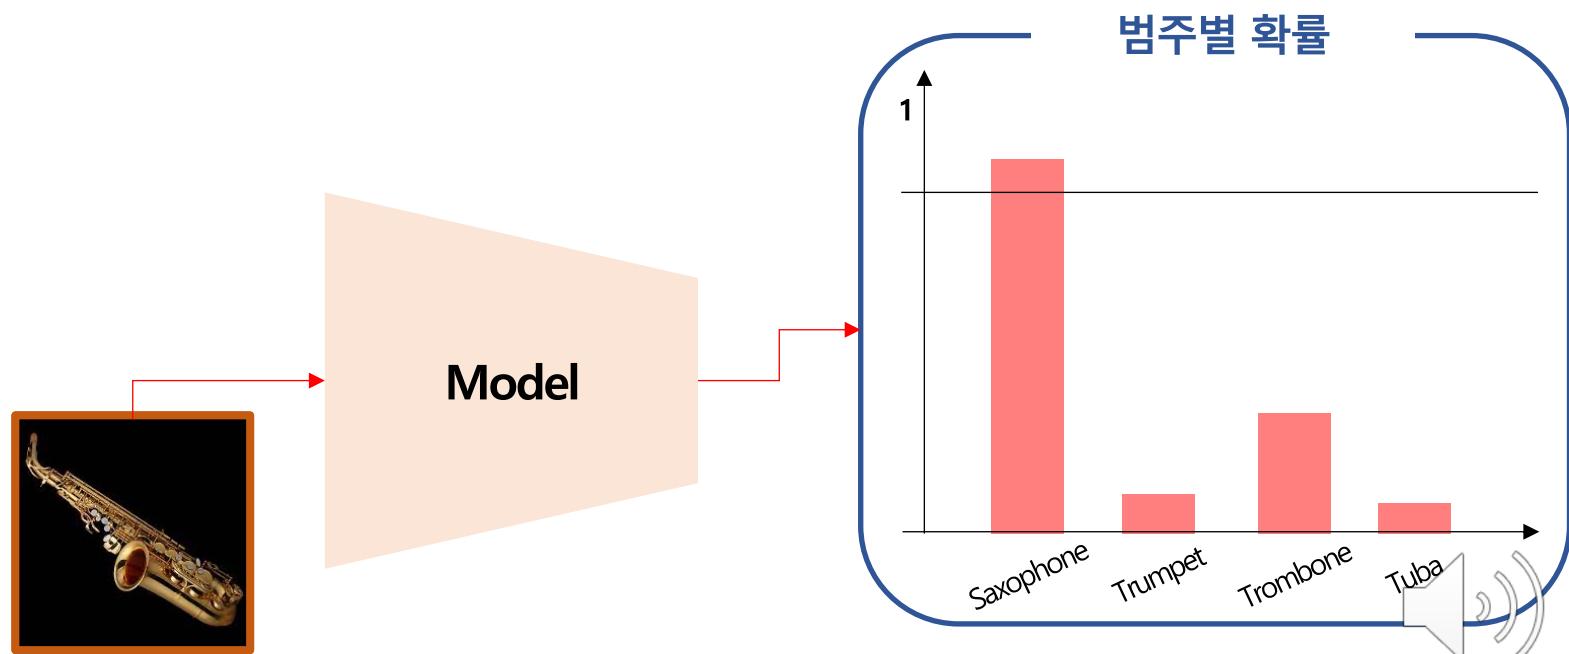
### ❖ FixMatch: Simplifying Semi-Supervised Learning with **Consistency** and Confidence

- Semi-supervised Learning 방법론 가정 중 Consistency Regularization에 관한 내용
- 입력 데이터에 증강 기법을 적용한 이미지를 다수 생성
- 증강된 이미지와 입력 데이터에 대한 예측 결과가 유사 해야 한다는 가정



## 2. FixMatch

- ❖ **FixMatch:** Simplifying Semi-Supervised Learning with Consistency and **Confidence**
  - Confidence 의미는 범주별 확률 값을 얼마나 신뢰할 수 있을지를 의미
  - 특히, Unlabeled 데이터에 대한 예측 확률이 어떻게 사용할지에 관한 지표

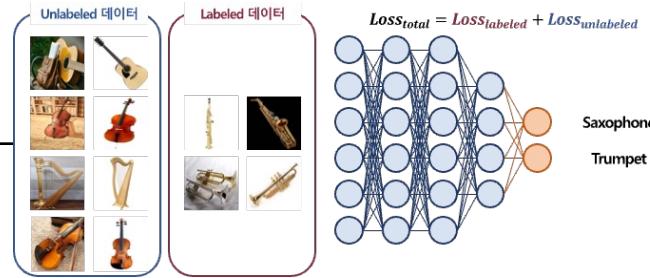


## 2. FixMatch

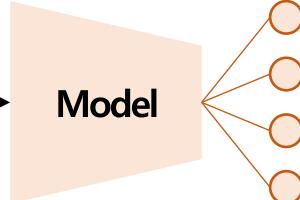
### ❖ FixMatch에서 손실 함수 산출 과정 (Labeled 데이터)

- 일반적인 지도학습과 같은 손실 함수를 사용

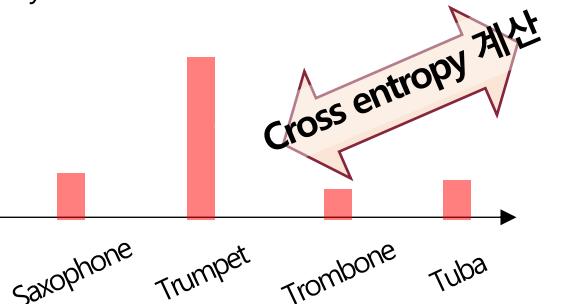
➤ FixMatch는 분류 문제에 대한 Semi-supervised Learning 방법론이기에 Cross entropy 사용



Labeled 데이터



Probability



## 2. FixMatch



### ❖ FixMatch에서 손실 함수 산출 과정 (Unlabeled 데이터)

- Unlabeled 데이터에 Weak & Strong Augmentation 적용

➤ **Weak Augmentation:** Flip, Shift와 같이 객체에 변화가 발생하지 않는 이미지 데이터 증강 기법

➤ Strong Augmentation: 픽셀 값을 변화시키는 여러 증강 기법 조합으로 생성

Unlabeled 데이터



Weak  
Augmentation



Model

Weak Augmentation  
레이블 생성

[1, 0, 0, 0]



# Pseudo Labeling!

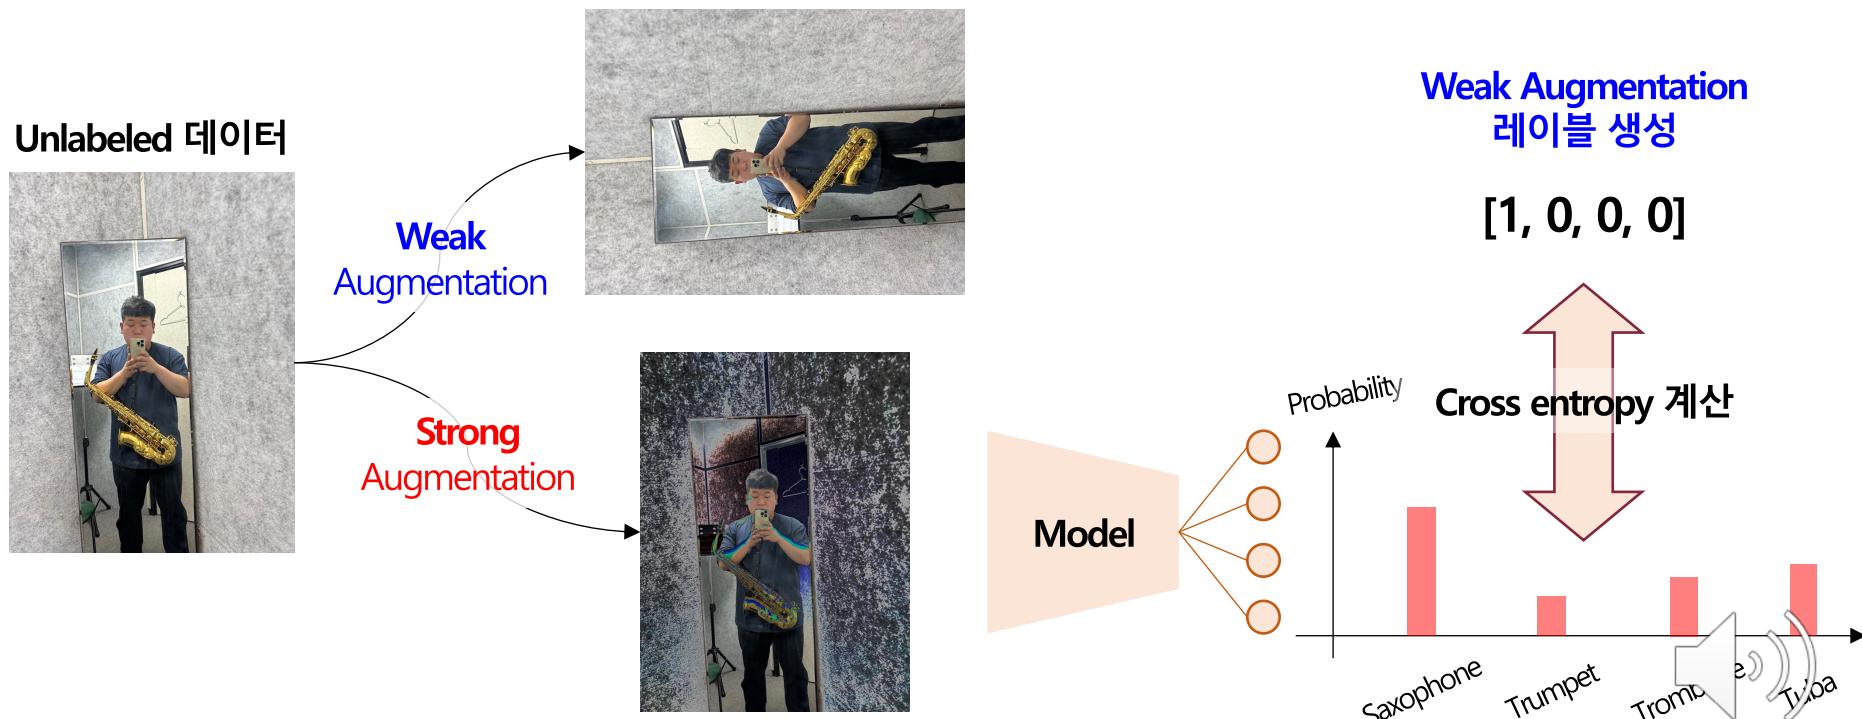


## 2. FixMatch

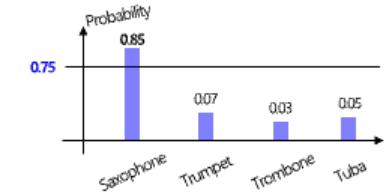


### ❖ FixMatch에서 손실 함수 산출 과정 (Unlabeled 데이터)

- Unlabeled 데이터에 Weak & Strong Augmentation 적용
  - Weak Augmentation: Flip, Shift와 같이 객체에 변화가 발생하지 않는 이미지 데이터 증강 기법
  - Strong Augmentation: 픽셀 값을 변화시키는 여러 증강 기법 조합으로 생성



[1, 0, 0, 0]



## 2. FixMatch

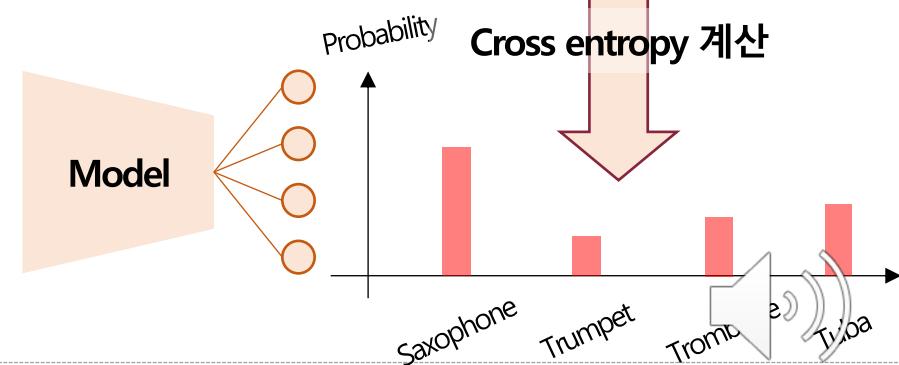
### ❖ FixMatch에서 손실 함수 산출 과정 (Unlabeled 데이터)

- Unlabeled 데이터에 두 데이터 증강 기법을 적용해 서로 다른 이미지 생성
- Weak Augmented 이미지 예측 값 중 임계값 이상인 경우 Pseudo Labeling 진행

Unlabeled 데이터

Weak  
AugmentationStrong  
AugmentationWeak Augmentation  
레이블 생성

[1, 0, 0, 0]

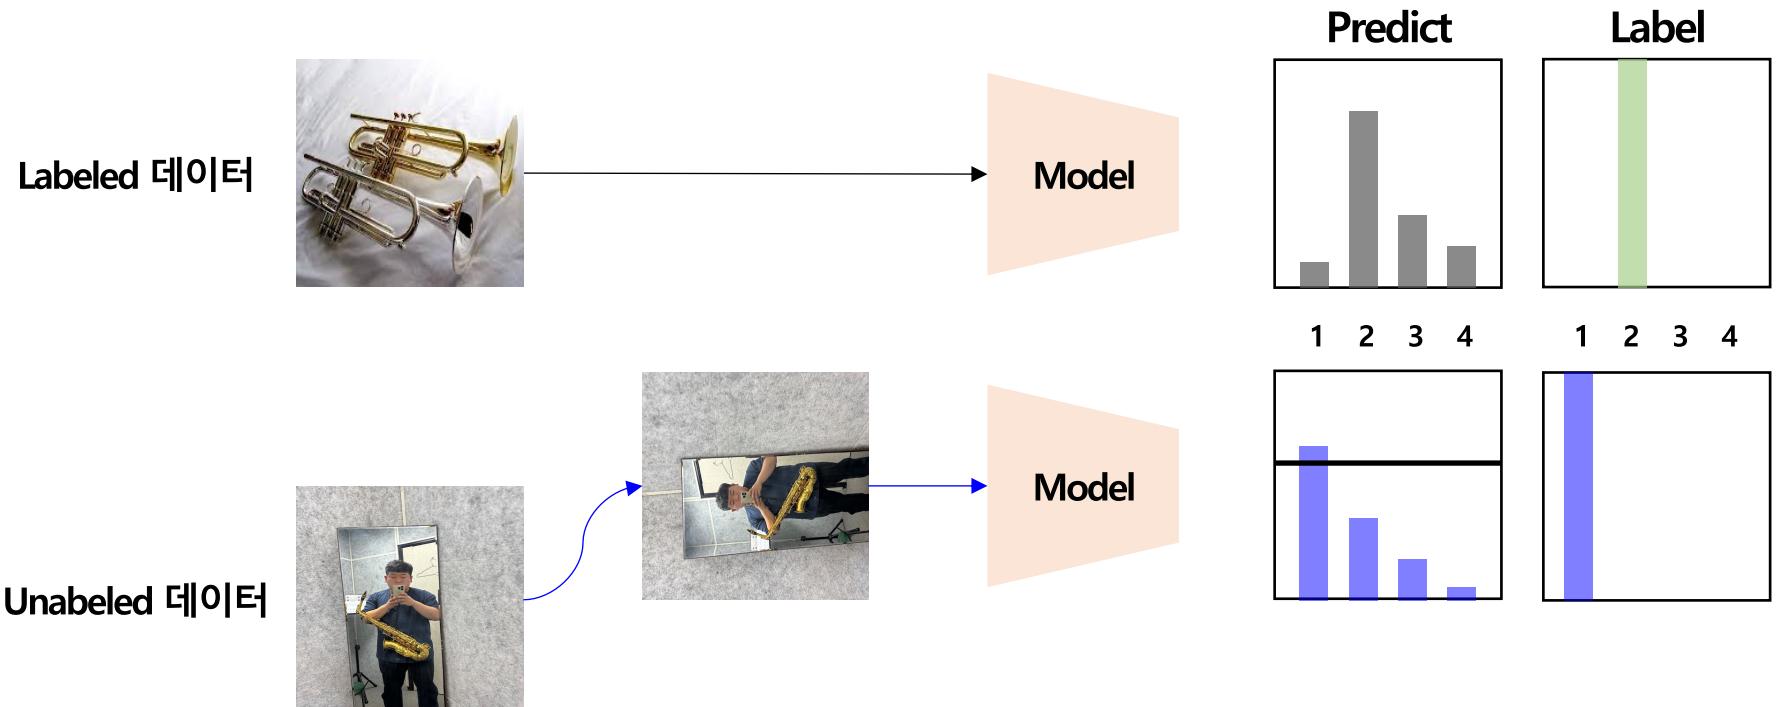


## 2. FixMatch



### ❖ FixMatch 요약

- $Loss_{total} = Loss_{labeled} + Loss_{unlabeled}$  를 계산해 심층 신경망 모델 학습

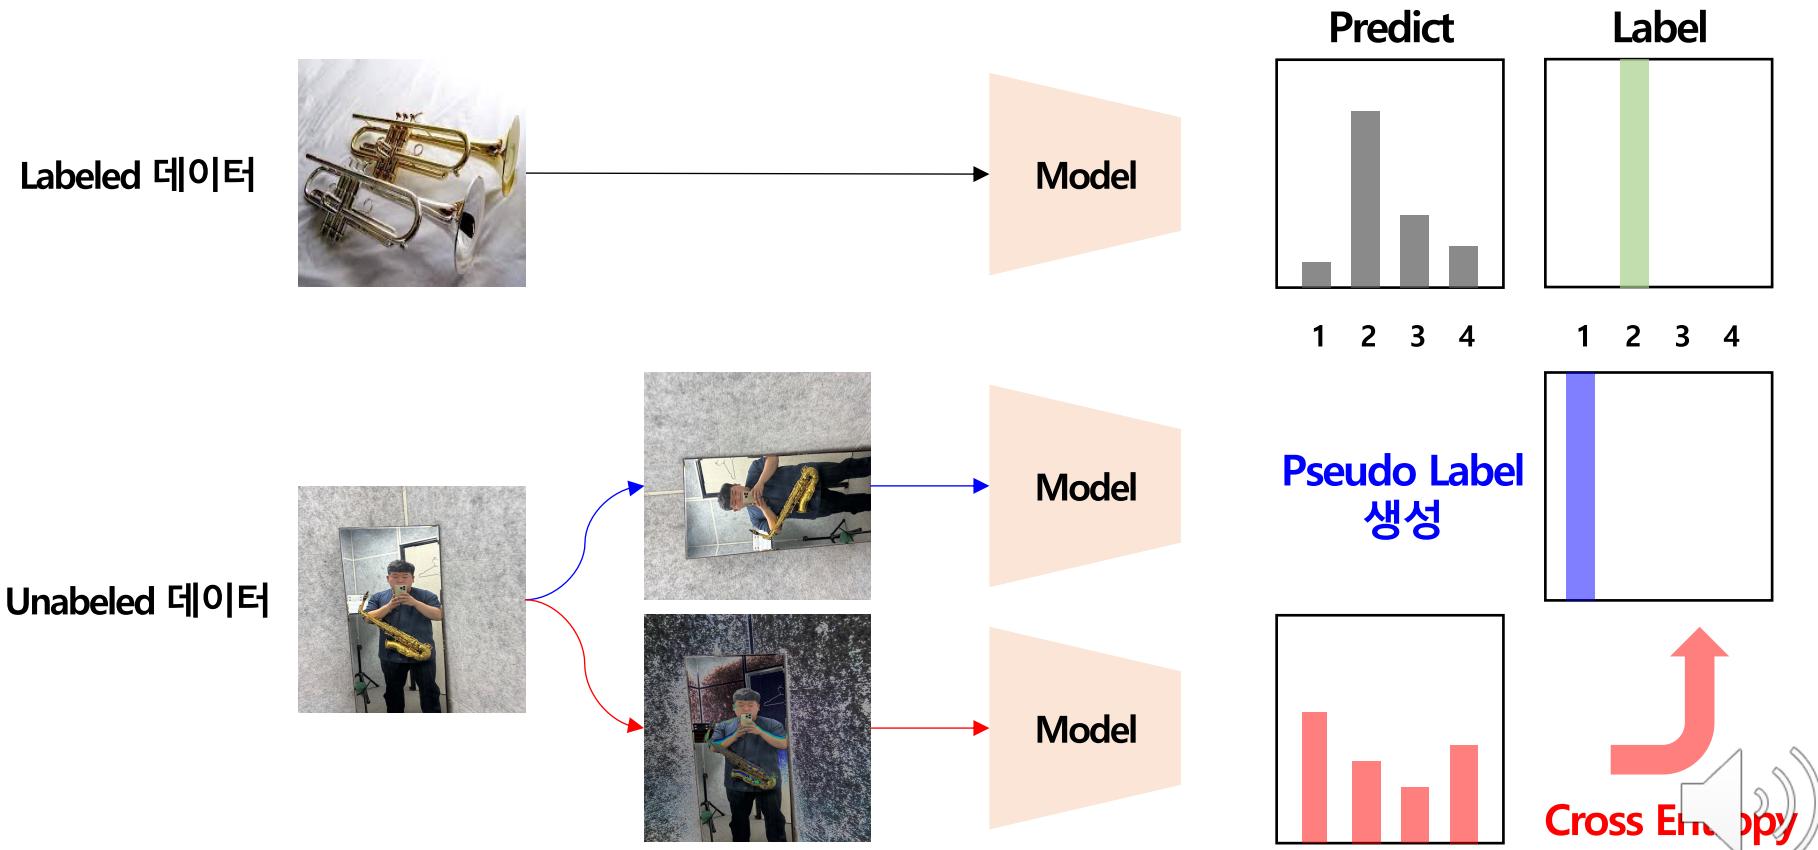


## 2. FixMatch



### ❖ FixMatch 요약

- $Loss_{total} = Loss_{labeled} + Loss_{unlabeled}$  를 계산해 심층 신경망 모델 학습



## 2. FixMatch



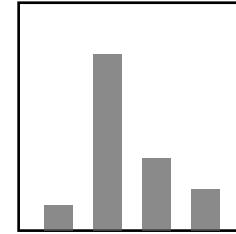
### ❖ FixMatch 요약

- $Loss_{total} = Loss_{labeled} + Loss_{unlabeled}$  를 계산해 심층 신경망 모델 학습

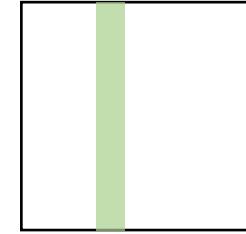
Labeled 데이터

$$Loss_{labeled} = \frac{1}{B} \sum_{b=1}^B CE(p_b, \hat{p}_b) \rightarrow \text{Model}$$

Predict

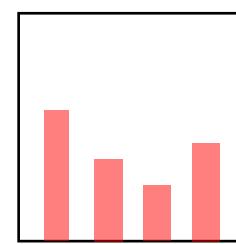


Label

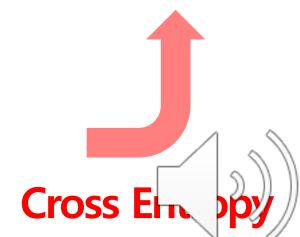


Unlabeled 데이터

$$Loss_{unlabeled} = \frac{1}{\mu B} \sum_{b=1}^{\mu B} \mathbb{I}(\max(q_{b,w}) > \tau) CE(q_{b,w}, q_{b,s}) \rightarrow \text{Model}$$

Pseudo Label  
생성

임계값 넘는 경우만 손실함수 산출

Pseudo Label  $\leftrightarrow$  Strong Augment 예측 값  
Cross Entropy

## 2. FixMatch

### ❖ FixMatch 실험 결과

- Strong Augmentation 조합 방법 두가지에 대한 실험과 기존 방법론 비교
  - RandAugment(RA), CTAAugment(CTA)
- 범주별 관측치 수를 변경하며 실험 진행해 학습 데이터 수가 적을 때 성능이 뛰어남을 확인

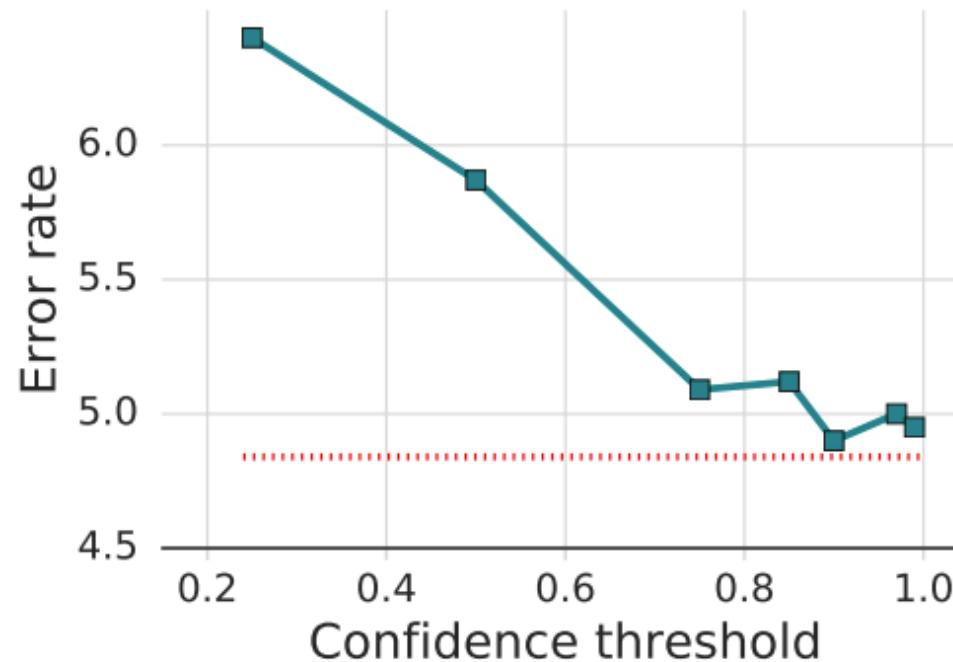
| Method          | CIFAR-10          |                  |                  | CIFAR-100         |                   |                   | SVHN             |                  |                  | STL-10           |
|-----------------|-------------------|------------------|------------------|-------------------|-------------------|-------------------|------------------|------------------|------------------|------------------|
|                 | 40 labels         | 250 labels       | 4000 labels      | 400 labels        | 2500 labels       | 10000 labels      | 40 labels        | 250 labels       | 1000 labels      | 1000 labels      |
| II-Model        | -                 | 54.26±3.97       | 14.01±0.38       | -                 | 57.25±0.48        | 37.88±0.11        | -                | 18.96±1.92       | 7.54±0.36        | 26.23±0.82       |
| Pseudo-Labeling | -                 | 49.78±0.43       | 16.09±0.28       | -                 | 57.38±0.46        | 36.21±0.19        | -                | 20.21±1.09       | 9.94±0.61        | 27.99±0.83       |
| Mean Teacher    | -                 | 32.32±2.30       | 9.19±0.19        | -                 | 53.91±0.57        | 35.83±0.24        | -                | 3.57±0.11        | 3.42±0.07        | 21.43±2.39       |
| MixMatch        | 47.54±11.50       | 11.05±0.86       | 6.42±0.10        | 67.61±1.32        | 39.94±0.37        | 28.31±0.33        | 42.55±14.53      | 3.98±0.23        | 3.50±0.28        | 10.41±0.61       |
| UDA             | 29.05±5.93        | 8.82±1.08        | 4.88±0.18        | 59.28±0.88        | 33.13±0.22        | 24.50±0.25        | 52.63±20.51      | 5.69±2.76        | 2.46±0.24        | 7.66±0.56        |
| ReMixMatch      | <b>19.10±9.64</b> | <b>5.44±0.05</b> | 4.72±0.13        | <b>44.28±2.06</b> | <b>27.43±0.31</b> | <b>23.03±0.56</b> | <b>3.34±0.20</b> | <b>2.92±0.48</b> | 2.65±0.08        | <b>5.23±0.45</b> |
| FixMatch (RA)   | <b>13.81±3.37</b> | <b>5.07±0.65</b> | <b>4.26±0.05</b> | 48.85±1.75        | 28.29±0.11        | <b>22.60±0.12</b> | <b>3.96±2.17</b> | <b>2.48±0.38</b> | <b>2.28±0.11</b> | 7.98±1.50        |
| FixMatch (CTA)  | <b>11.39±3.35</b> | <b>5.07±0.33</b> | <b>4.31±0.15</b> | 49.95±3.01        | 28.64±0.24        | 23.18±0.11        | 7.65±7.65        | <b>2.64±0.64</b> | <b>2.36±0.19</b> | <b>5.17±0.63</b> |



## 2. FixMatch

### ❖ FixMatch 실험 결과 – Ablation Study

- Weak Augmentation Pseudo Label 생성을 위한 임계값 변화에 따른 성능 변화
- Confidence 값이 높은 데이터만 손실 함수 산출에 사용한 경우 성능이 높음



## 2. FixMatch

### ❖ Related works in the FixMatch paper

- 관련 연구 세션을 살펴보면 아래와 같은 표 존재
- 기존 방법론을 빠르게 살펴본다면 위 정보가 유용할 것으로 생각
- 차이점 위주로 살펴보길 권유

| Algorithm                    | Artificial label augmentation | Prediction augmentation | Artificial label post-processing | Notes                                    |
|------------------------------|-------------------------------|-------------------------|----------------------------------|--|
| TS / Π-Model                 | Weak                          | Weak                    | None                             |  |
| Temporal Ensembling          | Weak                          | Weak                    | None                             | Uses model from earlier in training      |
| Mean Teacher                 | Weak                          | Weak                    | None                             | Uses an EMA of parameters                |
| Virtual Adversarial Training | None                          | Adversarial             | None                             |  |
| UDA                          | Weak                          | Strong                  | Sharpening                       | Ignores low-confidence artificial labels |
| MixMatch                     | Weak                          | Weak                    | Sharpening                       | Averages multiple artificial labels      |
| ReMixMatch                   | Weak                          | Strong                  | Sharpening                       | Sums losses for multiple predictions     |
| FixMatch                     | Weak                          | Strong                  | Pseudo-labeling                  |  |



# 목차

---

1. Introduction

2. FixMatch

**3. SelfMatch**

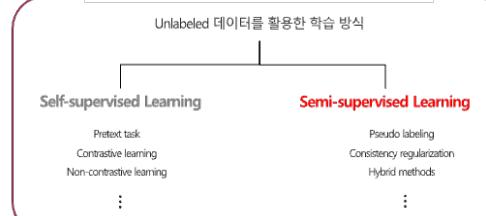
4. SimMatch

5. Conclusion



### 3. SelfMatch

(많은 Unlabeled 데이터 + 적은 Labeled 데이터)



#### ❖ SelfMatch: Combining Contrastive Self-supervision and Consistency

- 2021년 1월 arXiv에 올라온 방법론이며 삼성 SDS 소속 연구원들이 제안한 방법론
  - 2023년 1월 29일 기준 26회 인용
- Unlabeled 데이터 활용 방안 중 두 가지 학습 방식을 모두 사용

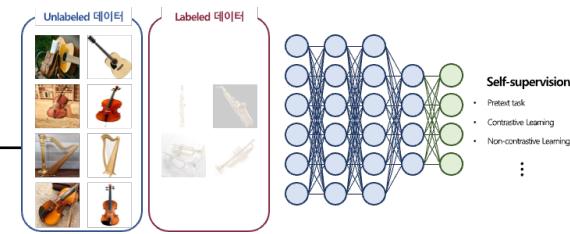
## SelfMatch: Combining Contrastive Self-Supervision and Consistency for Semi-Supervised Learning

**Byoungjip Kim, Jinho Choo, Yeong-Dae Kwon, Seongho Joe, Seungjai Min, Youngjune Gwon**  
Samsung SDS

{bjip.kim, jinho12.choo, y.d.kwon, drizzle.cho,  
seungjai.min, gyj.gwon}@samsung.com



# 3. SelfMatch

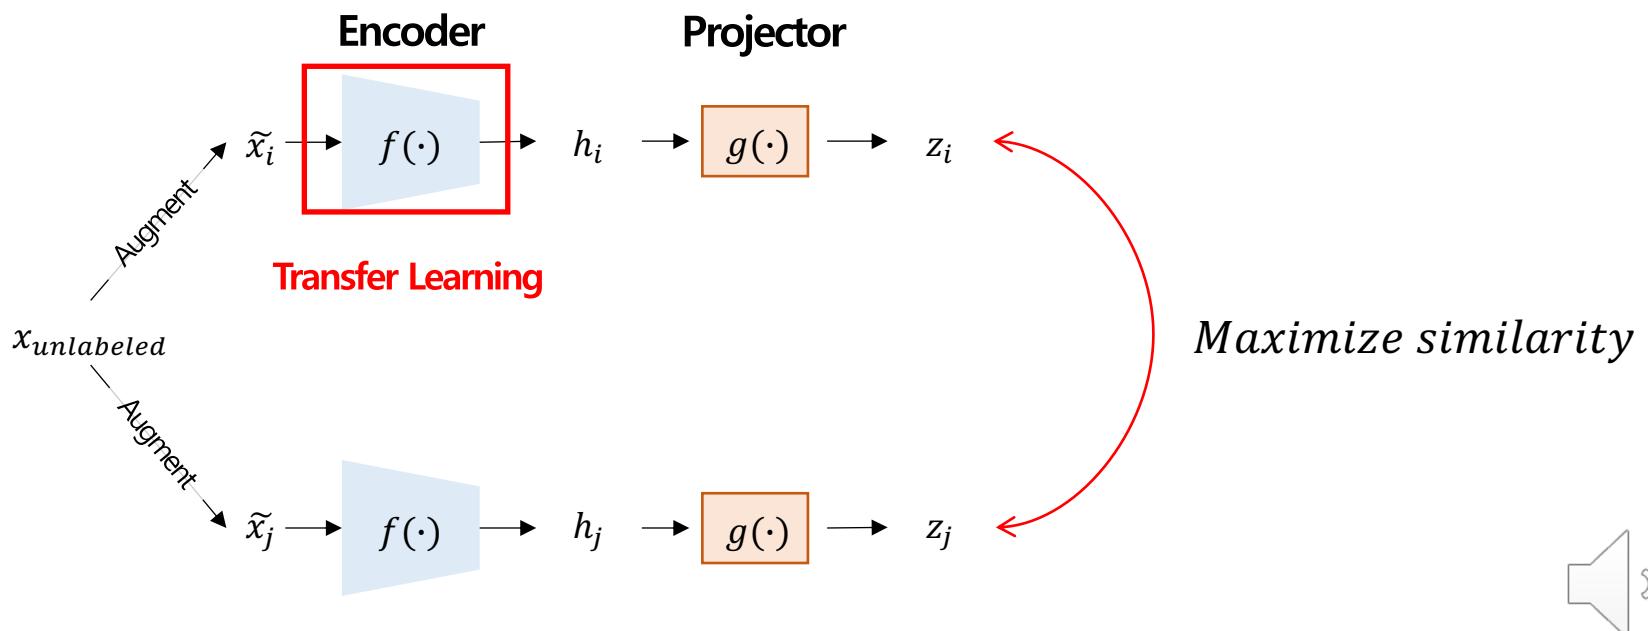


## ❖ SelfMatch: Combining Contrastive Self-supervision and Consistency

- SelfMatch 는 두 단계 학습으로 구성된 Semi-supervised Learning 방법론

➤ 단계 1: Unlabeled 데이터를 사용해 SimCLR 방식으로 Encoder 사전학습

- ✓ 같은 데이터에서 증강된 두 이미지(Positive pair)는 가깝도록 학습
- ✓ 특정 이미지가 아닌 나머지 이미지(Negative samples)는 모두 멀도록 학습



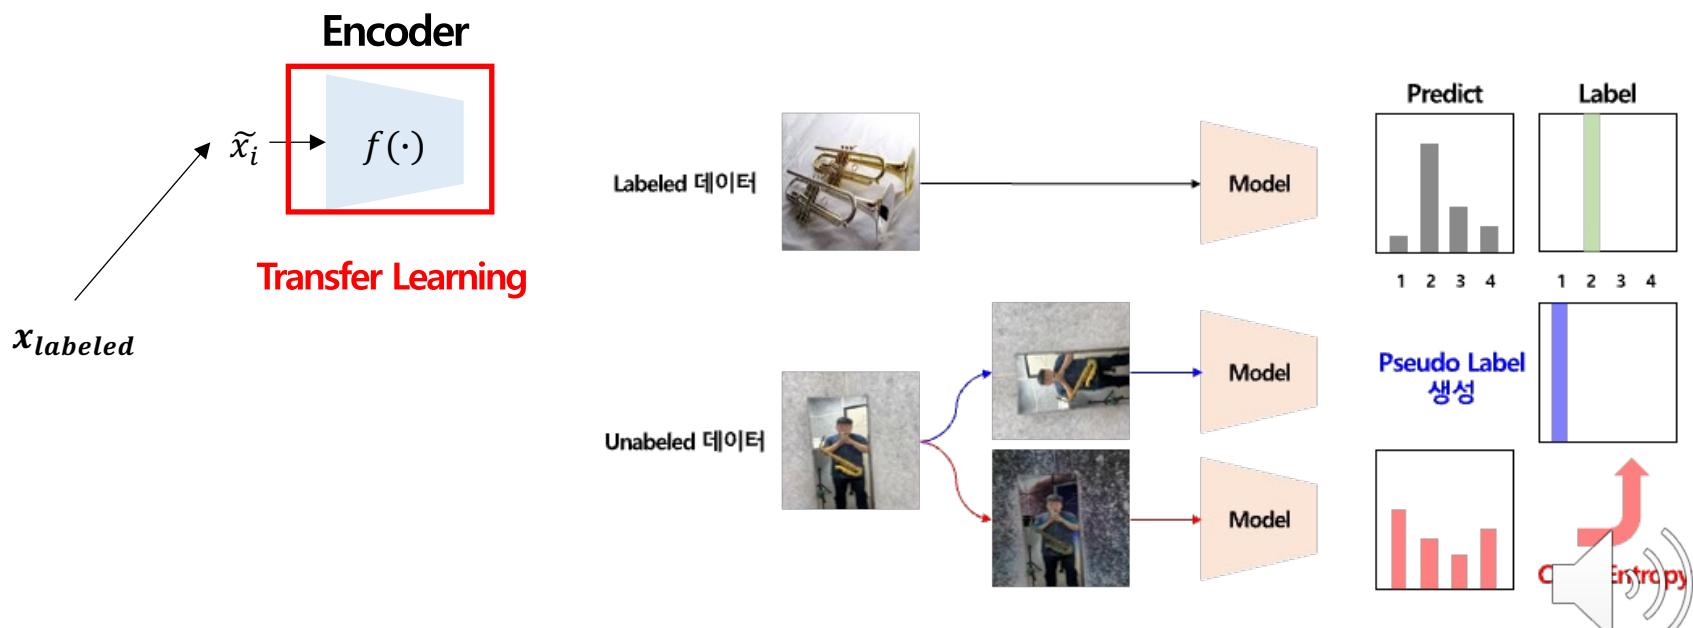
# 3. SelfMatch

## ❖ SelfMatch: Combining Contrastive Self-supervision and Consistency

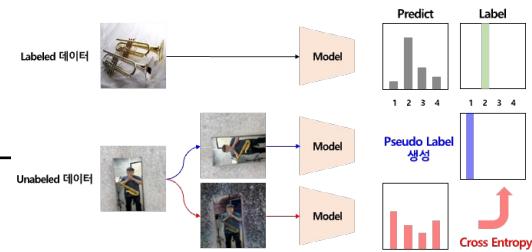
- SelfMatch 는 두 단계 학습으로 구성된 Semi-supervised Learning 방법론

➤ 단계 1: Unlabeled 데이터를 사용해 SimCLR 방식으로 Encoder 사전학습

➤ 단계 2: 사전 학습된 Encoder와 분류기에 대해 Labeled & Unlabeled 데이터를 사용해 FixMatch 방식으로 미세 조정 진행



### 3. SelfMatch



#### ❖ SelfMatch 실험 결과

- 사전 학습을 추가하여 기존 Semi-supervised Learning 방법론 대비 성능 향상 성공
- Self-supervised Learning 과 Semi-supervised Learning 을 모두 활용했다는 것이 특징
- 하지만 효과적으로 (Unlabeled & Label) 데이터를 모두 사용했다고 평가하기는 어려움

Table 1: Comparison of accuracy for CIFAR-10 and SVHN.

| Method           | CIFAR-10           |                    |                    | SVHN               |                    |                    |
|------------------|--------------------|--------------------|--------------------|--------------------|--------------------|--------------------|
|                  | 40 labels          | 250 labels         | 4000 labels        | 40 labels          | 250 labels         | 1000 labels        |
| Supervised       |                    | <b>95.87</b>       |                    |                    | <b>97.41</b>       |                    |
| Pseudo-Label     | -                  | 50.22±0.43         | 83.91±0.28         | -                  | 79.79±1.09         | 90.06±0.61         |
| II-Model         | -                  | 45.74±3.87         | 85.99±0.38         | -                  | 81.04±1.92         | 92.46±0.36         |
| Mean Teacher     | -                  | 67.68±2.30         | 90.81±0.19         | -                  | 96.43±0.11         | 96.58±0.07         |
| MixMatch         | 52.46±11.50        | 88.95±0.86         | 93.58±0.10         | 57.45±14.53        | 96.02±0.23         | 96.5±0.28          |
| UDA              | 70.95±5.93         | 91.18±1.08         | 95.12±0.18         | 47.37±20.51        | 94.31±2.76         | 97.54±0.24         |
| ReMixMatch       | 80.90±9.64         | 94.56±0.05         | 95.28±0.13         | <b>96.66</b> ±0.20 | 97.08±0.48         | 97.35±0.08         |
| FixMatch(RA)     | 86.19±3.37         | 94.93±0.65         | 95.74±0.05         | 96.04±2.17         | <b>97.52</b> ±0.38 | <b>97.72</b> ±0.11 |
| <b>SelfMatch</b> | <b>93.19</b> ±1.08 | <b>95.13</b> ±0.26 | <b>95.94</b> ±0.08 | <b>96.58</b> ±1.02 | <b>97.37</b> ±0.43 | <b>97.49</b> ±0.07 |



# 목차

---

1. Introduction

2. FixMatch

3. SelfMatch

**4. SimMatch**

5. Conclusion



# 4. SimMatch



## ❖ FixMatch 요약

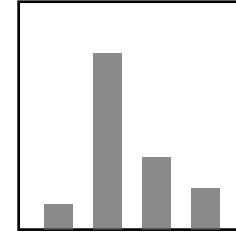
- $Loss_{total} = Loss_{labeled} + Loss_{unlabeled}$  를 계산해 심층 신경망 모델 학습

Labeled 데이터

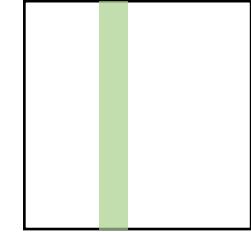
$$Loss_{labeled} = \frac{1}{B} \sum_{b=1}^B CE(p_b, \hat{p}_b)$$

Model

Predict



Label

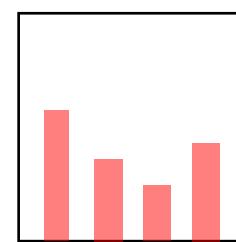


Unlabeled 데이터

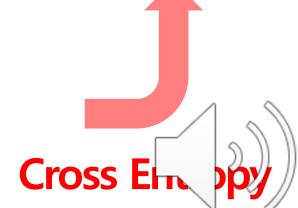
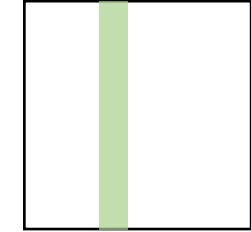
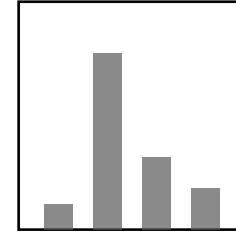
$$Loss_{unlabeled} = \frac{1}{\mu B} \sum_{b=1}^{\mu B} \mathbb{I}(\max(q_{b,w}) > \tau) CE(q_{b,w}, q_{b,s})$$

Model

Pseudo Label  
생성

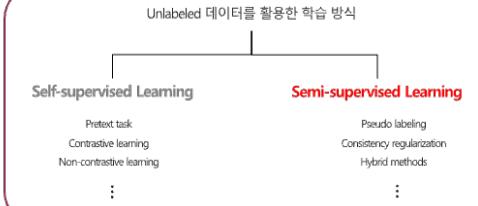


Predict



## 4. SimMatch

(많은 Unlabeled 데이터 + 적은 Labeled 데이터)



### ❖ SimMatch: Semi-supervised Learning with Similarity Matching

- 2022년 5월 Computer Vision and Pattern Recognition(CVPR)에서 발표된 방법론
  - 2023년 1월 29일 기준 25회 인용되었으며 여러 학교 및 기관이 합심해서 진행한 연구
- 기존 FixMatch에 Similarity 개념을 추가해서 성능 향상 성공

### SimMatch: Semi-supervised Learning with Similarity Matching

Mingkai Zheng<sup>1,2</sup> Shan You<sup>2\*</sup>  
Lang Huang<sup>3</sup> Fei Wang<sup>4</sup> Chen Qian<sup>2</sup> Chang Xu<sup>1</sup>

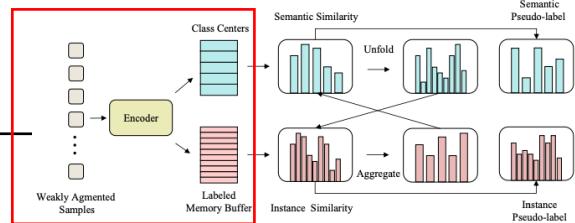
<sup>1</sup>School of Computer Science, Faculty of Engineering, The University of Sydney

<sup>2</sup>SenseTime Research <sup>3</sup>The University of Tokyo

<sup>4</sup>University of Science and Technology of China

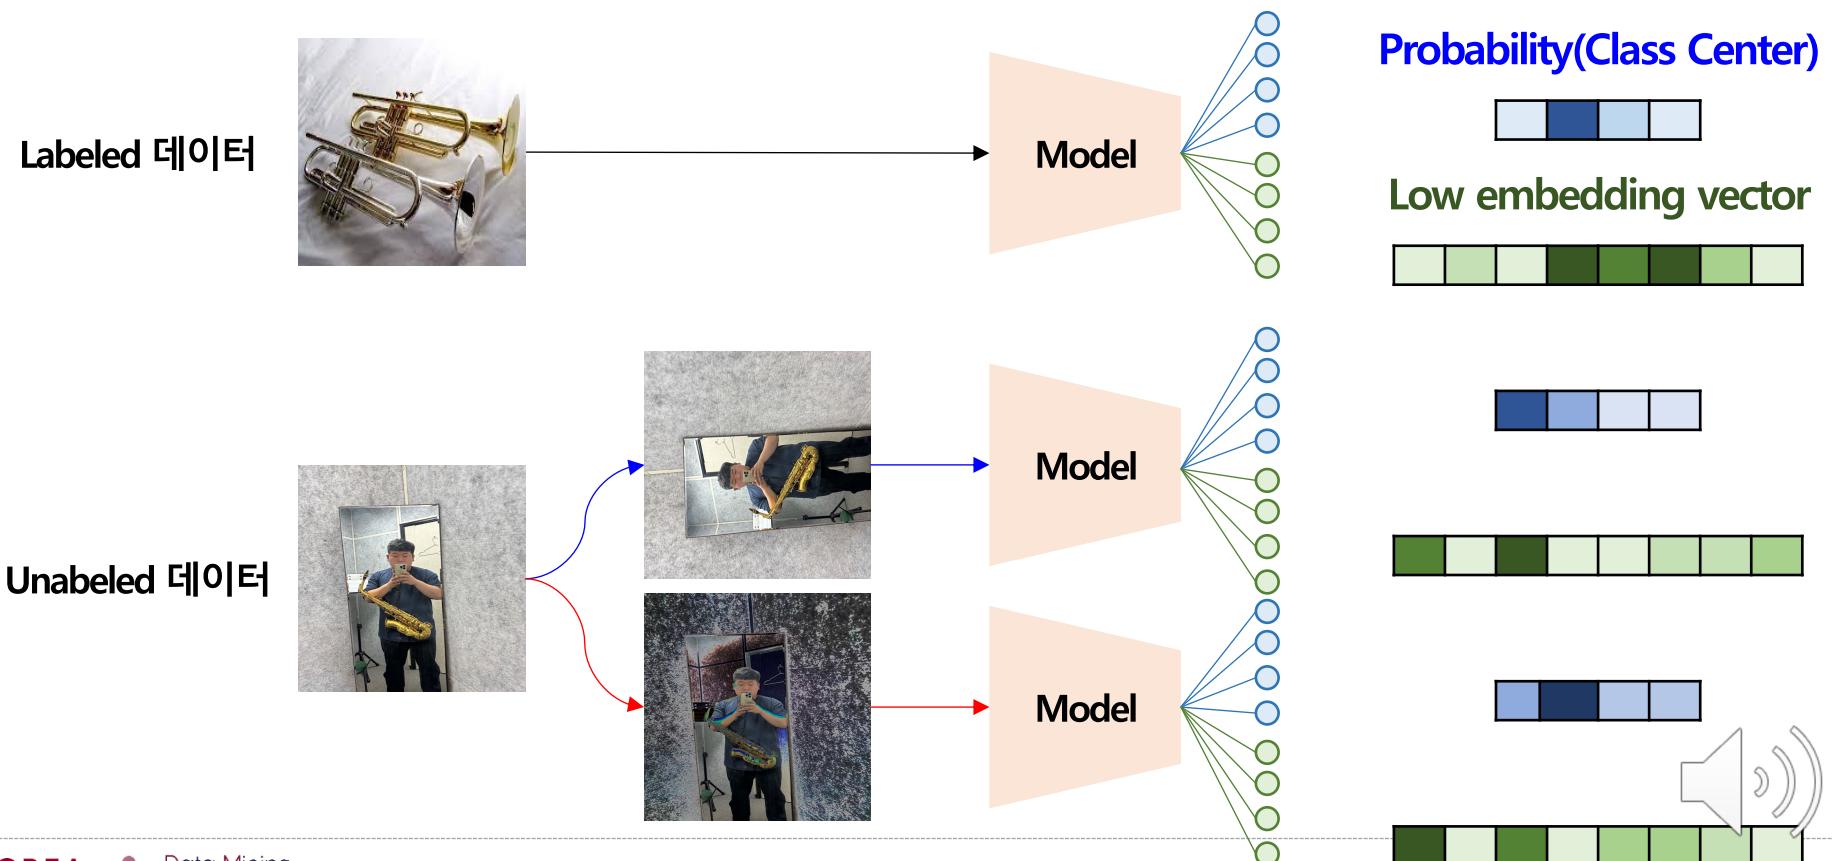


# 4. SimMatch

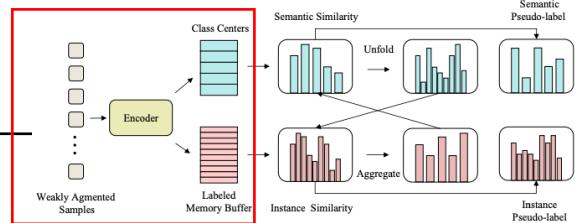


## ❖ SimMatch: Semi-supervised Learning with Similarity Matching

- FixMatch와 유사하게 Labeled 데이터와 Weak Augmented, Strong Augmented 데이터 사용
- Model 출력 값을 두 가지(Probability, Low embedding vector) 산출

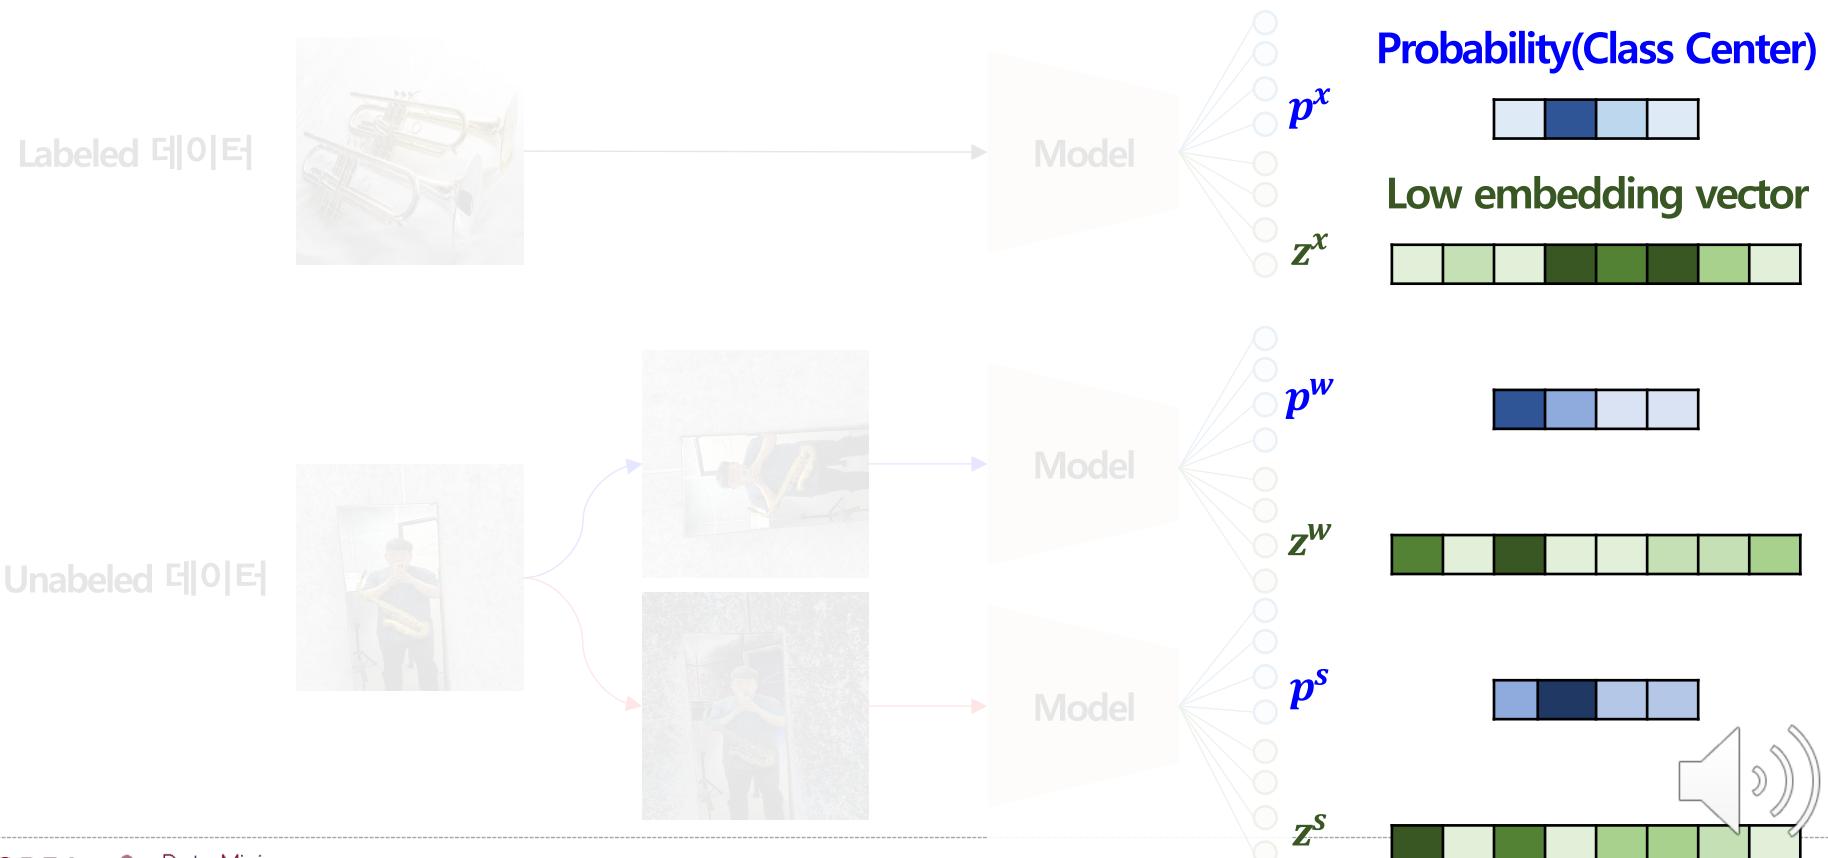


# 4. SimMatch

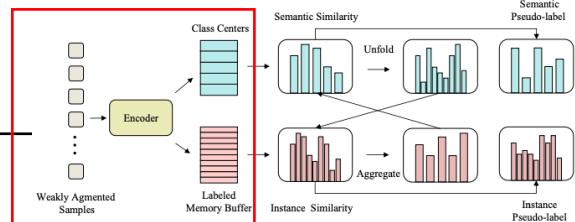


## ❖ SimMatch: Semi-supervised Learning with Similarity Matching

- Model 출력 값을 두 가지(Probability, Low embedding vector) 산출
- Probability는 Semantic Similarity 역할/ Low embedding vector는 Instance Similarity 역할



# 4. SimMatch

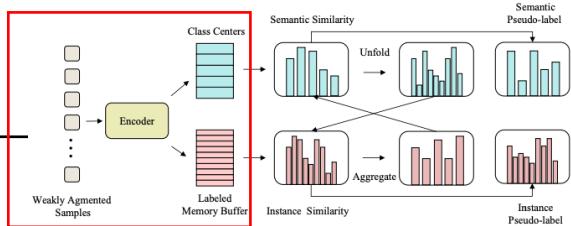


## ❖ SimMatch 내 Labeled 데이터에 대한 손실 함수

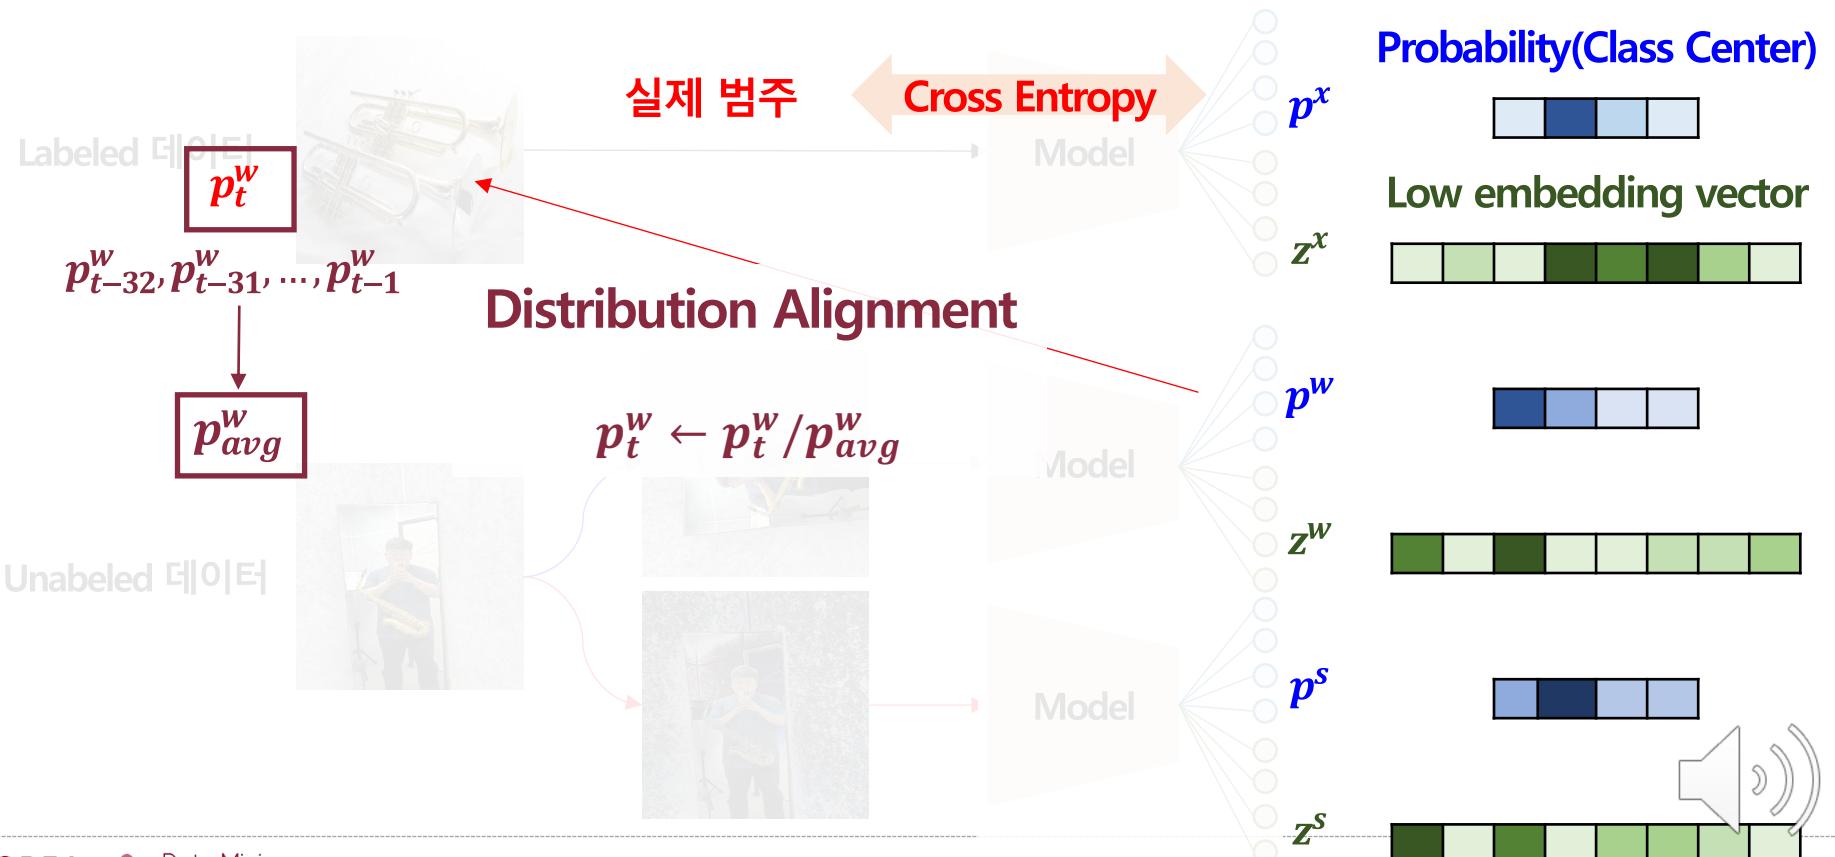
- Labeled 데이터에 대한 손실함수는 실제 Label과 예측 확률 사이 Cross entropy 계산



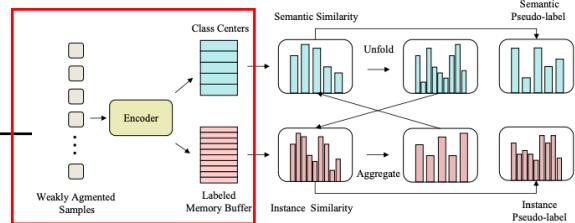
## 4. SimMatch



- SimMatch 내 **Unlabeled** 데이터에 대한 손실 함수(**Distribution Alignment, DA**)
    - Pseudo Label( $p_t^w$ ) 이 너무 급격하게 변화하면 학습에 부정적인 영향을 미친다고 알려짐
    - 따라서 Weak augmented 데이터에 대한 과거 32시점간 예측 확률 값 평균을 사용해  $p^w$  보정

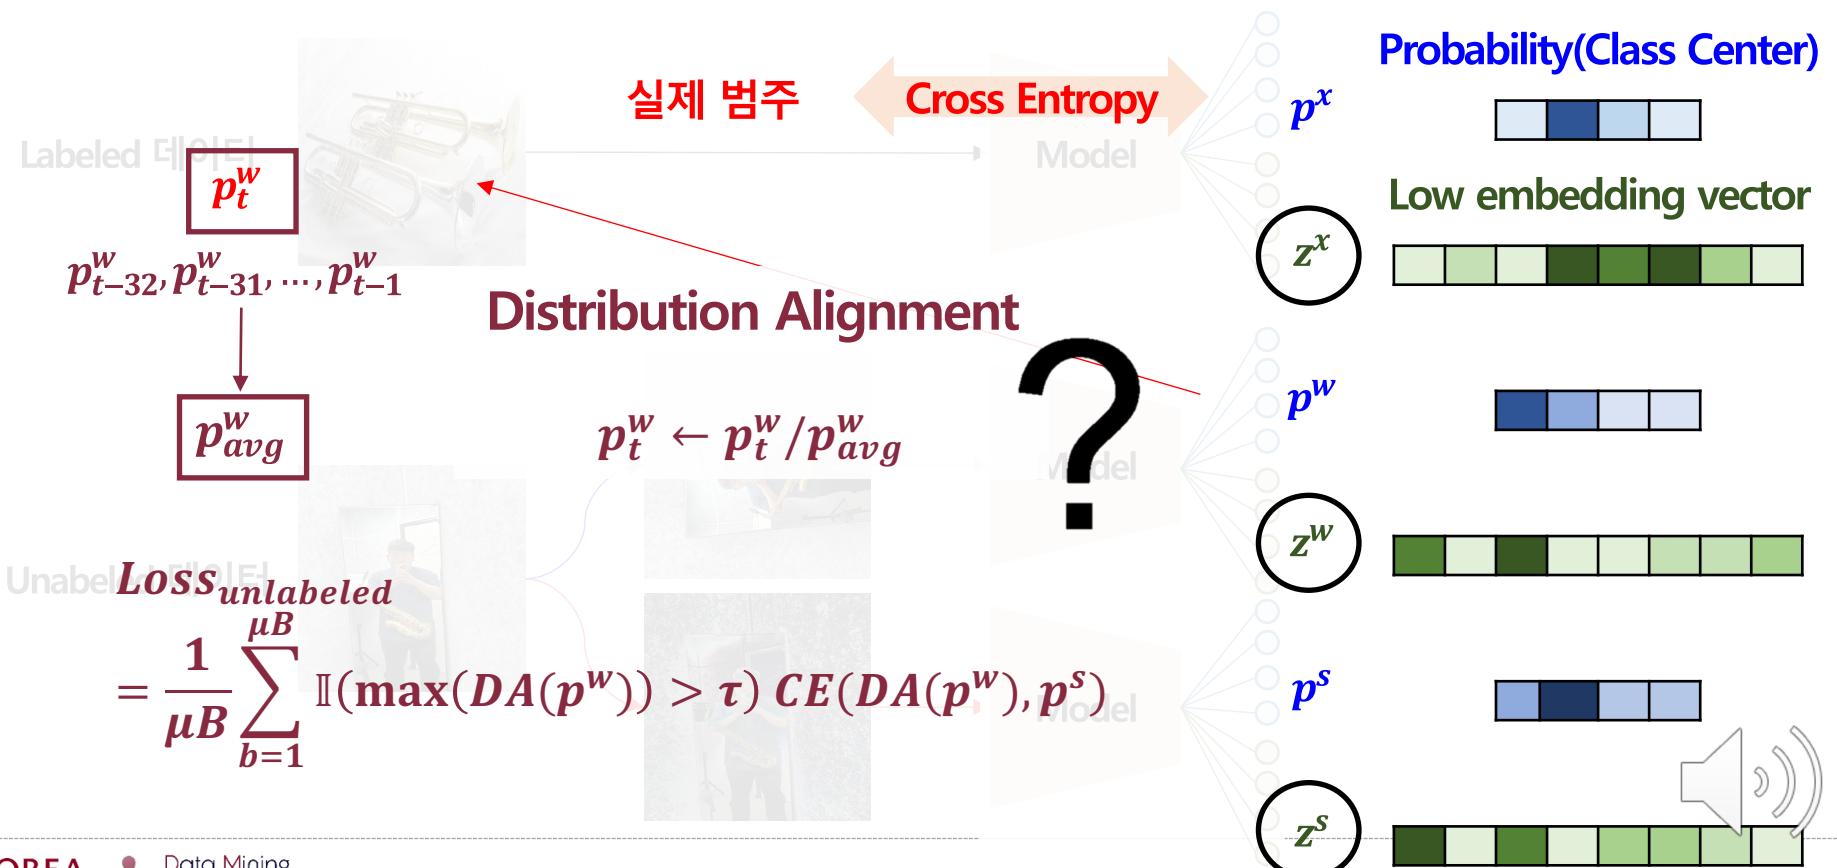


# 4. SimMatch

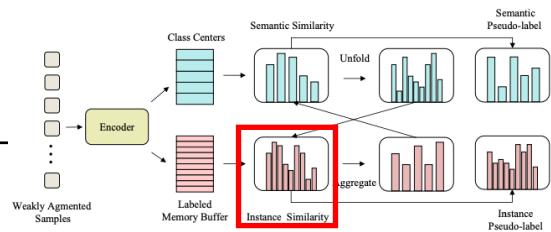


❖ SimMatch 내 Unlabeled 데이터에 대한 손실 함수(Distribution Alignment, DA)

- $p^w$  값을 보정해 분포를 안정화 한 후  $p^s$ 와  $p^w$  사이 Cross entropy 계산(Unlabeled 손실함수)

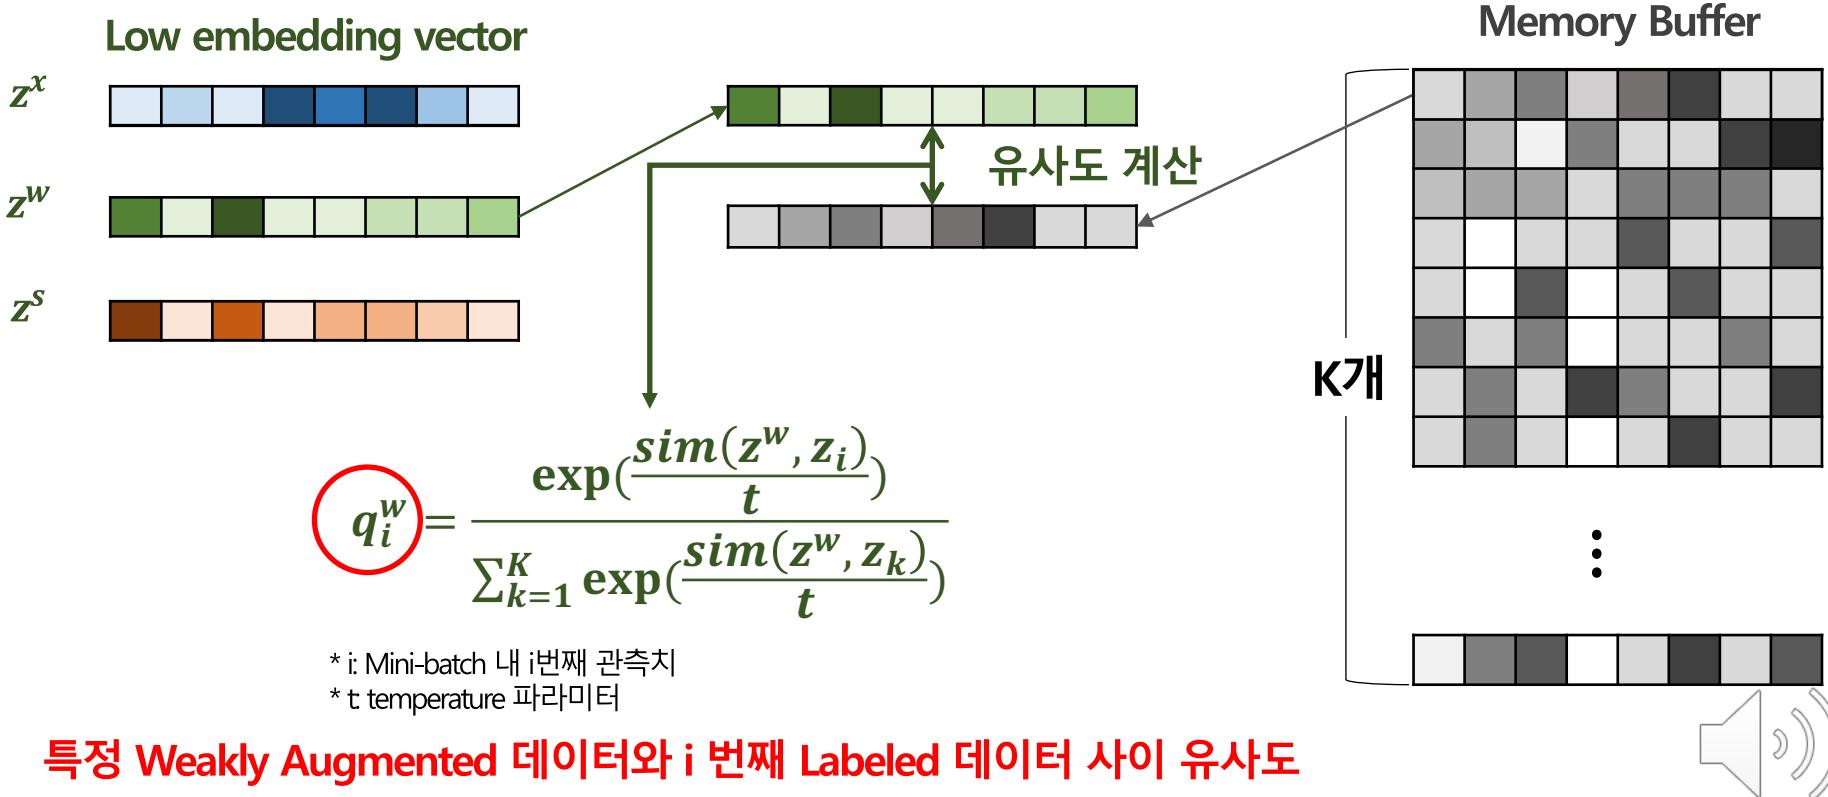


# 4. SimMatch



## ❖ Instance Similarity 정의

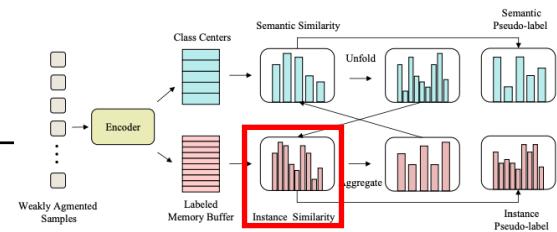
- Memory Buffer는 모든 Labeled 데이터에 대한 Embedding vector로 구성
- 특정 Embedding vector와 Memory Buffer 사이 유사도 계산 → **Instance Similarity( $q$ )** 분포



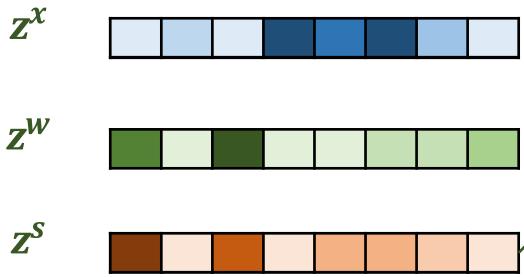
# 4. SimMatch

## ❖ Instance Similarity 정의

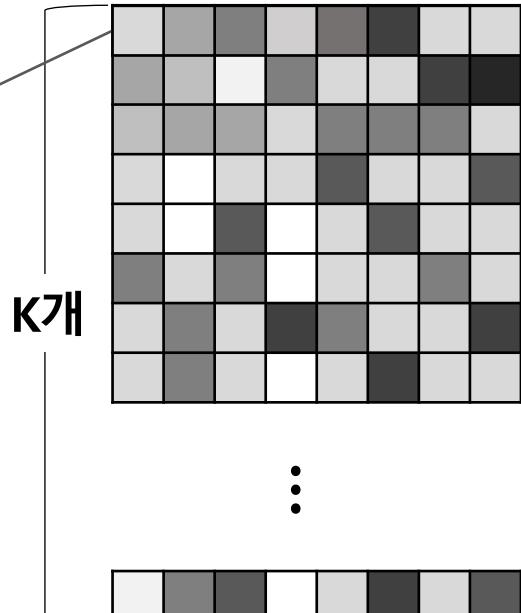
- Memory Buffer는 모든 Labeled 데이터에 대한 Embedding vector로 구성
- 특정 Embedding vector와 Memory Buffer 사이 유사도 계산 → **Instance Similarity( $q$ )** 분포



Low embedding vector



Memory Buffer



유사도 계산

$$q_i^s = \frac{\exp(\frac{sim(z^s, z_i)}{t})}{\sum_{k=1}^K \exp(\frac{sim(z^s, z_k)}{t})}$$

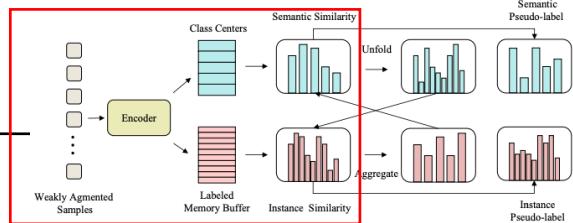
\* i: Mini-batch 내 i번째 관측치

\* t temperature 파라미터

특정 Strong Augmented 데이터와 i 번째 Labeled 데이터 사이 유사도



# 4. SimMatch

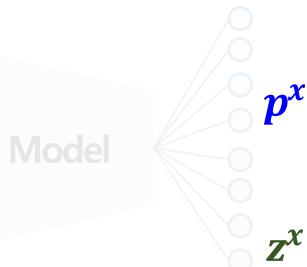


## ❖ Labeled 손실 함수 + Unlabeled 손실함수 + Instance Similarity 손실함수

- Instance Similarity 손실 함수는 유사도 분포 차이를 최소화
- 세 손실함수를 합하여 전체 손실 함수 정의 후 모델 학습

Labeled 데이터

$$\text{Loss}_{\text{labeled}} = \frac{1}{B} \sum_{b=1}^B \text{CE}(y, p^x)$$



Probability(Class Center)



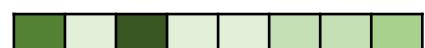
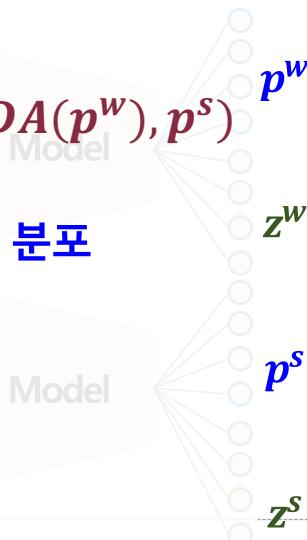
Low embedding vector



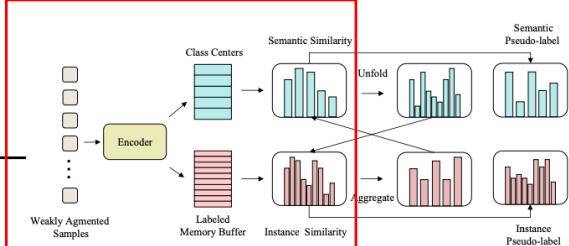
$$\text{Loss}_{\text{unlabeled}} = \frac{1}{\mu B} \sum_{b=1}^{\mu B} \mathbb{I}(\max(DA(p^w)) > \tau) \text{CE}(DA(p^w), p^s)$$

역할: (Weak↔Labeled) 분포 == (Strong↔Labeled) 분포

$$\text{Loss}_{\text{instance}} = \frac{1}{\mu B} \sum_{b=1}^{\mu B} \text{CE}(q^w, q^s)$$



# 4. SimMatch

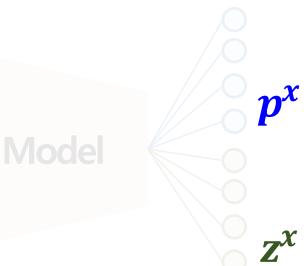


## ❖ Weakly Augmented 데이터 두 Similarity에 레이블 정보를 넣어보자!

- 두 유사도를 산출할 때 Label 정보가 사용되지 않음(단순한 모델 출력 값)
- Label 정보를 사용해  $p^w, q^w$  를 보정하여 더 정확한 Semantic/ Instance Similarity 산출해보자!

Labeled 데이터

$$\text{Loss}_{labeled} = \frac{1}{B} \sum_{b=1}^B CE(y, p^x)$$



Probability(Class Center)



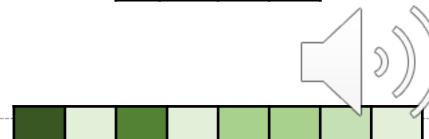
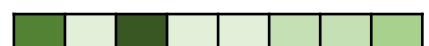
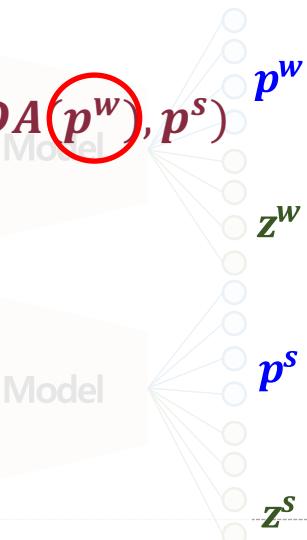
Low embedding vector



Unlabeled 데이터

$$\text{Loss}_{unlabeled} = \frac{1}{\mu B} \sum_{b=1}^{\mu B} \mathbb{I}(\max(DA(p^w)) > \tau) CE(DA(p^w), p^s)$$

$$\text{Loss}_{instance} = \frac{1}{\mu B} \sum_{b=1}^{\mu B} CE(q^w, q^s)$$



# 4. SimMatch

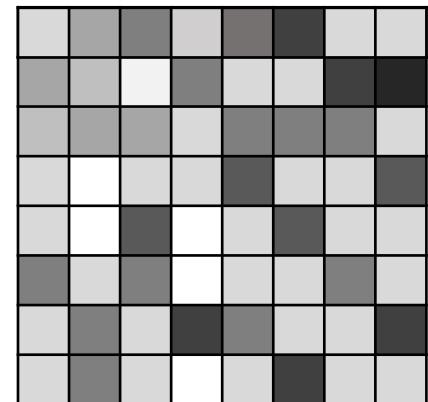


❖ Weakly Augmented 데이터에서 산출한 두 Similarity에 레이블 정보를 넣어보자!

- **Label Memory Buffer**는 모든 Label 값 자체가 포함된 벡터(Label 데이터 개수는 8개)

Label Memory Buffer      Memory Buffer(MB)

|   |
|---|
| 1 |
| 2 |
| 3 |
| 4 |
| 1 |
| 1 |
| 2 |
| 4 |



# 4. SimMatch

*p: Semantic similarity*

*q: Instance similarity*

## ❖ Label 정보를 활용해 Instance Similarity 보정(Unfolding)

- Label Memory Buffer는 모든 Label 값 자체가 포함된 벡터(Labeled 데이터 개수는 8개)
- Weakly Augmented 데이터에 대한 Instance similarity 분포를 보정

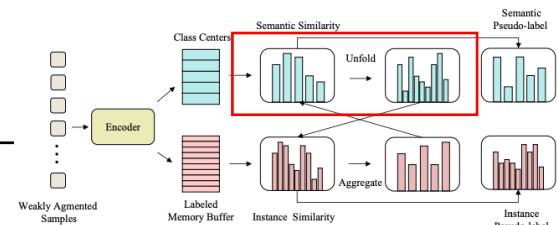
Weakly Augmented 데이터 예측 확률(Semantic Similarity)

| 범주      | Saxophone | Trumpet | Trombone | Tuba |
|---------|-----------|---------|----------|------|
| $p_i^w$ | 0.8       | 0.01    | 0.1      | 0.09 |

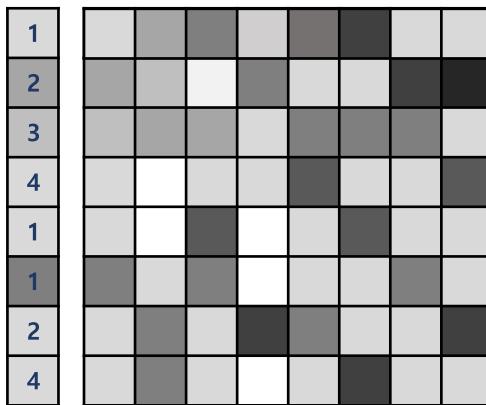
Weakly Augmented 데이터와 MB Vector( $j=1, 2, \dots, 8$ ) 사이 Similarity 분포

| MB      | 1   | 2    | 3    | 4    | 5   | 6    | 7    | 8    |
|---------|-----|------|------|------|-----|------|------|------|
| 범주      | 1   | 2    | 3    | 4    | 1   | 1    | 2    | 4    |
| $q_j^w$ | 0.2 | 0.05 | 0.01 | 0.04 | 0.3 | 0.25 | 0.05 | 0.01 |

| $p_i^{unfold}$ | 0.8 | 0.01 | 0.1 | 0.09 | 0.8 | 0.8 | 0.01 | 0.09 |
|----------------|-----|------|-----|------|-----|-----|------|------|
|----------------|-----|------|-----|------|-----|-----|------|------|



Memory Buffer(MB)



i번째 Labeled 데이터의 실제 범주  
Weakly Augmented 데이터 예측 확률

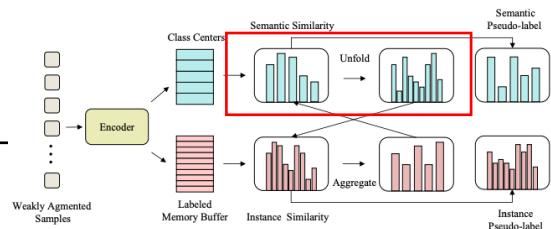
$$p_i^{unfold} = p_i^w, \text{ where } \text{class}(q_j^w) = \text{class}(y_i^w)$$



# 4. SimMatch

*p: Semantic similarity*

*q: Instance similarity*



## ❖ Label 정보를 활용해 Instance Similarity 보정(Unfolding)

- **Label Memory Buffer**는 모든 Label 값 자체가 포함된 벡터(Labeled 데이터 개수는 8개)
- Weakly Augmented 데이터에 대한 Instance similarity 분포를 보정

Weakly Augmented 데이터 예측 확률(Semantic Similarity)

| 범주      | Saxophone | Trumpet | Trombone | Tuba |
|---------|-----------|---------|----------|------|
| $p_i^w$ | 0.8       | 0.01    | 0.1      | 0.09 |

범주가 일치하는 경우, 유사도 ↑

범주가 일치하지 않는 경우, 유사도 ↓

Weakly Augmented 데이터와 MB Vector( $j=1, 2, \dots, 8$ ) 사이 Similarity 분포

| MB          | 1    | 2    | 3    | 4    | 5    | 6    | 7    | 8    |
|-------------|------|------|------|------|------|------|------|------|
| 범주          | 1    | 2    | 3    | 4    | 1    | 1    | 2    | 4    |
| $q_j^w$     | 0.2  | 0.05 | 0.01 | 0.04 | 0.3  | 0.25 | 0.05 | 0.01 |
| $\hat{q}_i$ | 0.26 | 0.00 | 0.00 | 0.01 | 0.40 | 0.33 | 0.00 | 0.00 |

| $p_i^{unfold}$ | 0.8 | 0.01 | 0.1 | 0.09 | 0.8 | 0.8 | 0.01 | 0.09 |
|----------------|-----|------|-----|------|-----|-----|------|------|
|----------------|-----|------|-----|------|-----|-----|------|------|

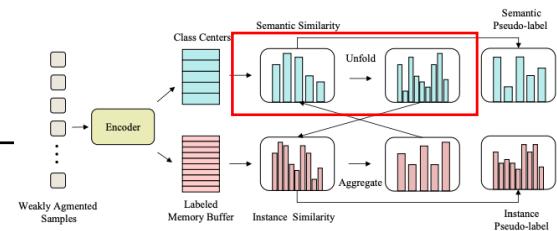
$$\hat{q}_i = \frac{q_i^w * p_i^{unfold}}{\sum_{k=1}^K q_k^w * p_k^{unfold}}$$



# 4. SimMatch

*p: Semantic similarity*

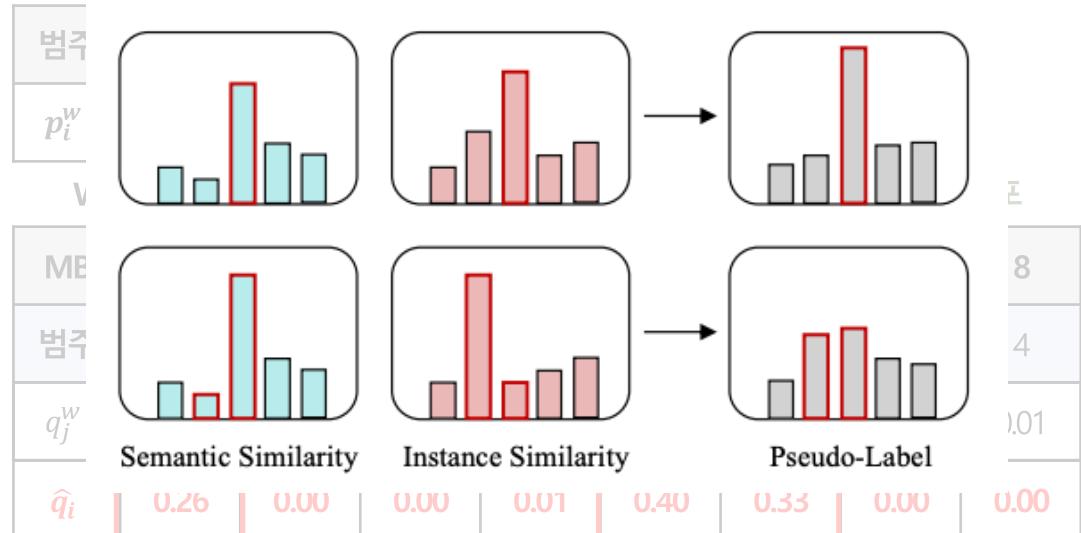
*q: Instance similarity*



## ❖ Label 정보를 활용해 Instance Similarity 보정(Unfolding)

- **Label Memory Buffer**는 모든 Label 값 자체가 포함된 벡터(Labeled 데이터 개수는 8개)
- Weakly Augmented 데이터에 대한 Instance similarity 분포를 보정

Weakly Augmented 데이터 예측 확률



Instance similarity 보정!

범주가 일치하는 경우, 유사도 ↑

범주가 일치하지 않는 경우, 유사도 ↓

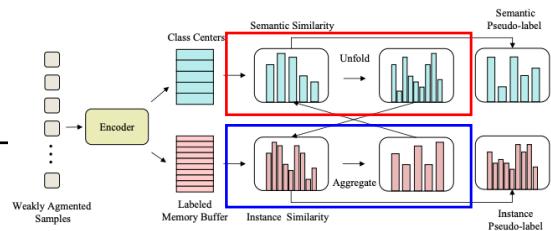
$$\hat{q}_i = \frac{q_i^w * p_i^{unfold}}{\sum_{k=1}^K q_k^w * p_k^{unfold}}$$



# 4. SimMatch

*p: Semantic similarity*

*q: Instance similarity*



## ❖ 보정된 Instance Similarity를 사용해 Semantic Similarity 보정(Aggregation)

- 보정된 Instance similarity( $\widehat{q}_i^w$ )를 바탕으로 Semantic Similarity 보정 진행

➤ 보정된 유사도 중 특정 범주에 속하는 유사도 합( $q_i^{agg}$ )을 산출하여 기존 Semantic Similarity와 가중합

Weakly Augmented 데이터 예측 확률

| 범주      | Saxophone | Trumpet | Trombone | Tuba |
|---------|-----------|---------|----------|------|
| $p_i^w$ | 0.8       | 0.01    | 0.1      | 0.09 |

| 범주          | Saxophone | Trumpet | Trombone | Tuba |
|-------------|-----------|---------|----------|------|
| $q_i^{agg}$ | 0.99      | 0.00    | 0.00     | 0.01 |

Weakly Augmented 데이터와 MB Vector(j=1,2,...,8) 사이 Instance Similarity

| MB                | 1    | 2    | 3    | 4    | 5    | 6    | 7    | 8    |
|-------------------|------|------|------|------|------|------|------|------|
| 범주                | 1    | 2    | 3    | 4    | 1    | 1    | 2    | 4    |
| $q_j^w$           | 0.2  | 0.05 | 0.01 | 0.04 | 0.3  | 0.25 | 0.05 | 0.01 |
| $\widehat{q}_i^w$ | 0.26 | 0.00 | 0.00 | 0.01 | 0.40 | 0.33 | 0.00 | 0.00 |

| $p_i^{unfold}$ | 0.8 | 0.01 | 0.1 | 0.09 | 0.8 | 0.8 | 0.01 | 0.09 |
|----------------|-----|------|-----|------|-----|-----|------|------|
|----------------|-----|------|-----|------|-----|-----|------|------|

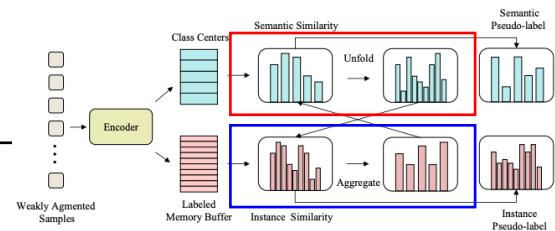
$$q_i^{agg} = \sum_{j=1}^K \mathbb{I}(class(p_i^w) = class(q_i^w)) \widehat{q}_j^w$$



# 4. SimMatch

*p: Semantic similarity*

*q: Instance similarity*



## ❖ 보정된 Instance Similarity를 사용해 Semantic Similarity 보정(Aggregation)

- 보정된 Instance similarity( $\widehat{q}_i^w$ )를 바탕으로 Semantic Similarity 보정 진행

➤ 보정된 유사도 중 특정 범주에 속하는 유사도 합( $q_i^{agg}$ )을 산출하여 기존 Semantic Similarity와 가중합

Weakly Augmented 데이터 예측 확률

| 범주      | Saxophone | Trumpet | Trombone | Tuba |
|---------|-----------|---------|----------|------|
| $p_i^w$ | 0.8       | 0.01    | 0.1      | 0.09 |

| 범주          | Saxophone | Trumpet | Trombone | Tuba |
|-------------|-----------|---------|----------|------|
| $q_i^{agg}$ | 0.99      | 0.00    | 0.00     | 0.01 |

$$\alpha = 0.9$$

$$1 - \alpha = 0.1$$

| 범주                | Saxophone | Trumpet | Trombone | Tuba |
|-------------------|-----------|---------|----------|------|
| $\widehat{p}_i^w$ | 0.82      | 0.01    | 0.09     | 0.08 |

Sematic similarity 보정!



# 4. SimMatch

*p: Semantic similarity*

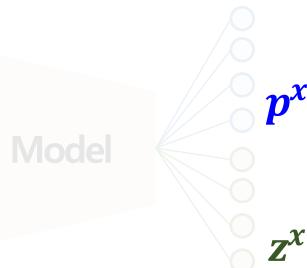
*q: Instance similarity*

## ❖ SimMatch 학습을 위한 최종 손실 함수 정의

- Unfolding, **Aggregation** 된 값을 사용해 Similarity 손실 함수 산출
- 즉, 레이블 데이터 정보를 반영해 Similarity 보정한 후 손실 함수 산출

Labeled 데이터

$$\textbf{Loss}_{labeled} = \frac{1}{B} \sum_{b=1}^B \textbf{CE}(y, p^x)$$



**Class center(Probability)**



**Low embedding vector**

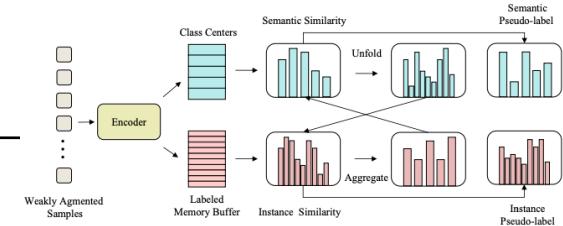
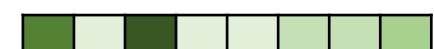
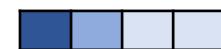
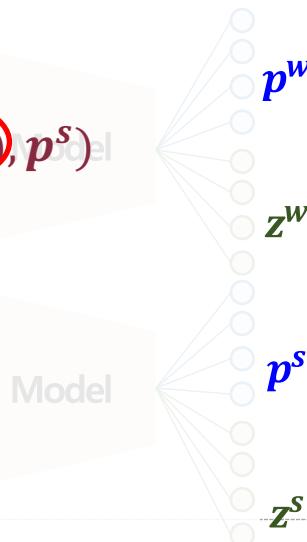


**Loss<sub>unlabeled</sub>**

$$= \frac{1}{\mu B} \sum_{b=1}^{\mu B} \mathbb{I}(\max(\widehat{DA(p^w)}) > \tau) \textbf{CE}(\widehat{DA(p^w)}, p^s)$$

Unlabeled 데이터

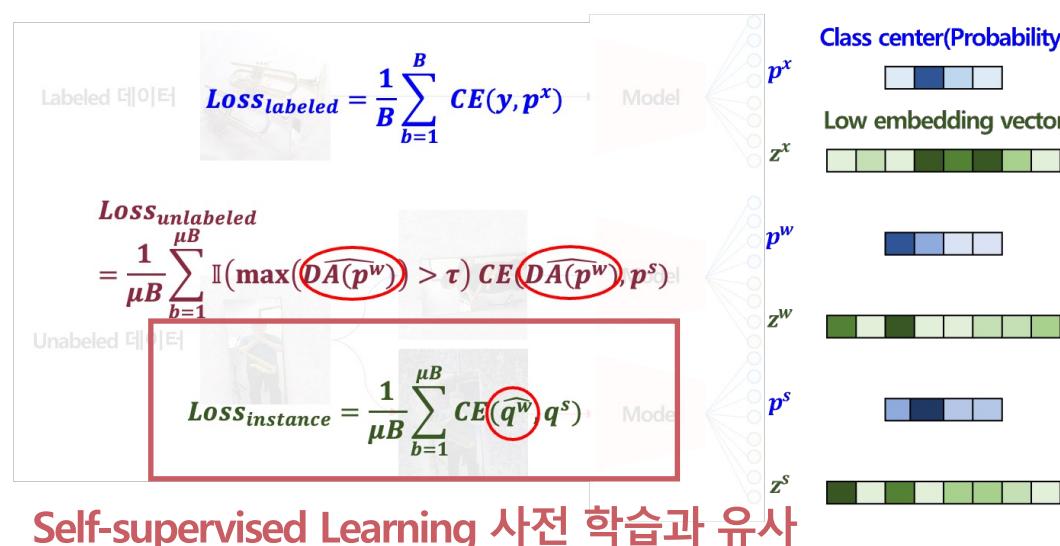
$$\textbf{Loss}_{instance} = \frac{1}{\mu B} \sum_{b=1}^{\mu B} \textbf{CE}(\widehat{q^w}, q^s)$$



# 4. SimMatch

## ❖ FixMatch vs SimMatch(FixMatch에서 추가된 내용)

- Unlabeled 손실 함수 산출 시, Distribution Alignment 후  $p^w$  산출
- Instance 관련 손실 함수 추가 (Semantic & Instance Similarity)
  - 기존 Consistency Regularization에 관측치 별 특징(Similarity)이 유사해지도록 학습
- Label 정보를 활용해 Weakly Augmented 데이터로 부터 생성하는 Pseudo Label 보정



# 4. SimMatch

## ❖ SimMatch 실험 결과 – 과거 방법론과 비교(CIFAR-10/ CIFAR-100)

- 과거 Semi-supervised 및 FixMatch 등과 비교 진행
- 학습 데이터 수가 적을 때(40 Labels, 400 Labels)에서 특히 성능 향상이 두드러짐

Table 1. Top-1 Accuracy comparison (mean and std over 5 runs) on CIFAR-10 and CIFAR-100 with varying labeled set sizes.

| Method               | CIFAR-10           |                    |                    | CIFAR-100          |                    |                    |
|----------------------|--------------------|--------------------|--------------------|--------------------|--------------------|--------------------|
|                      | 40 labels          | 250 labels         | 4000 labels        | 400 labels         | 2500 labels        | 10000 labels       |
| Π-Model [34]         | -                  | 45.74±3.97         | 58.99±0.38         | -                  | 42.75±0.48         | 62.12±0.11         |
| Pseudo-Labeling [35] | -                  | 50.22±0.43         | 83.91±0.28         | -                  | 42.62±0.46         | 63.79±0.19         |
| Mean Teacher [52]    | -                  | 67.68±2.30         | 90.81±0.19         | -                  | 46.09±0.57         | 64.17±0.24         |
| UDA [56]             | 70.95±5.93         | 91.18±1.08         | 95.12±0.18         | 40.72±0.88         | 66.87±0.22         | 75.50±0.25         |
| MixMatch [6]         | 52.46±11.50        | 88.95±0.86         | 93.58±0.10         | 32.39±1.32         | 60.06±0.37         | 71.69±0.33         |
| ReMixMatch [5]       | 80.90±9.64         | 94.56±0.05         | 95.28±0.13         | 55.72±2.06         | 72.57±0.31         | 76.97±0.56         |
| FixMatch(RA) [48]    | 86.19±3.37         | 94.93±0.65         | 95.74±0.05         | 51.15±1.75         | 71.71±0.11         | 77.40±0.12         |
| Dash [57]            | 86.78±3.75         | <b>95.44</b> ±0.13 | 95.92±0.06         | 55.24±0.96         | 72.82±0.21         | 78.03±0.14         |
| CoMatch [36]         | 93.09±1.39         | 95.09±0.33         | -                  | -                  | -                  | -                  |
| SimMatch(Ours)       | <b>94.40</b> ±1.37 | 95.16±0.39         | <b>96.04</b> ±0.01 | <b>62.19</b> ±2.21 | <b>74.93</b> ±0.32 | <b>79.42</b> ±0.11 |



# 4. SimMatch

## ❖ SimMatch 실험 결과 – 과거 방법론과 비교(ImageNet 1%, 10% 데이터)

- 적은 학습 Epoch 및 사전 학습 없이 최고 성능을 달성
- (MoCo V2 + CoMatch) 방식으로 많은 학습으로 Epoch 유사한 성능 달성

Table 2. Experimental results on ImageNet with 1% and 10% labeled examples.

| Self-supervised<br>Pre-training   | Method                    | Epochs        | Paramters<br>(train/test)      | Top-1<br>Label fraction<br>1% | Top-1<br>Label fraction<br>10% | Top-5<br>Label fraction<br>1% | Top-5<br>Label fraction<br>10% |
|---|---------------------------|---------------|--------------------------------|-------------------------------|--------------------------------|-------------------------------|--------------------------------|
| None  | Pseudo-label [35, 62]     | ~100          | 25.6M / 25.6M                  | -                             | -                              | 51.6                          | 82.4                           |
|   | VAT+EntMin. [24, 41, 62]  | -             | 25.6M / 25.6M                  | -                             | 68.8                           | -                             | 88.5                           |
|   | S4L-Rotation [62]         | ~200          | 25.6M / 25.6M                  | -                             | 53.4                           | -                             | 83.8                           |
|   | UDA [56]                  | -             | 25.6M / 25.6M                  | -                             | 68.8                           | -                             | 88.5                           |
|   | FixMatch [48]             | ~300          | 25.6M / 25.6M                  | -                             | 71.5                           | -                             | 89.1                           |
|   | CoMatch [36]              | ~400          | 30.0M / 25.6M                  | 66.0                          | 73.6                           | 86.4                          | <b>91.6</b>                    |
| PCL [37]<br>SimCLR [14]<br>SimCLR V2 [15]<br>BYOL [25]<br>SwAV [10]<br>WCL [65] | Fine-tune                 | ~200          | 25.8M / 25.6M                  | -                             | -                              | 75.3                          | 85.6                           |
|   |                           | ~1000         | 30.0M / 25.6M                  | 48.3                          | 65.6                           | 75.5                          | 87.8                           |
|   |                           | ~800          | 34.2M / 25.6M                  | 57.9                          | 68.4                           | 82.5                          | 89.2                           |
|   |                           | ~1000         | 37.1M / 25.6M                  | 53.2                          | 68.8                           | 78.4                          | 89.0                           |
|   |                           | ~800          | 30.4M / 25.6M                  | 53.9                          | 70.2                           | 78.5                          | 89.9                           |
|   |                           | ~800          | 34.2M / 25.6M                  | 65.0                          | 72.0                           | 86.3                          | 91.2                           |
|   | Fine-tune<br>CoMatch [36] | ~800<br>~1200 | 30.0M / 25.6M<br>30.0M / 25.6M | 49.8<br>67.1                  | 66.1<br>73.7                   | 77.2<br><b>87.1</b>           | 87.9<br>91.4                   |
| MoCo V2 [16]  | FixMatch-EMAN [8]         | ~1100         | 30.0M / 25.6M                  | 63.0                          | 74.0                           | 83.4                          | 90.9                           |
| None  | <b>SimMatch (Ours)</b>    | ~400          | 30.0M / 25.6M                  | <b>67.2</b>                   | <b>74.4</b>                    | <b>87.1</b>                   | <b>91.6</b>                    |

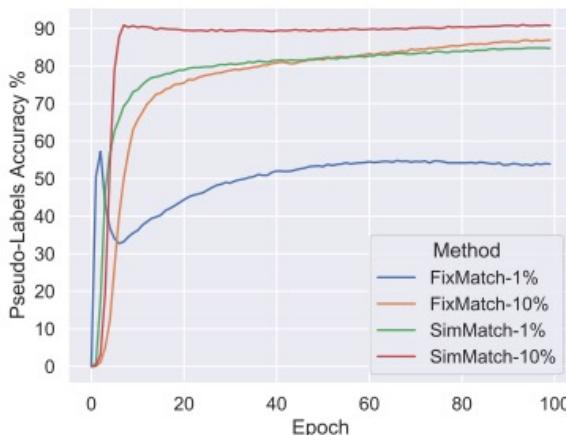


# 4. SimMatch

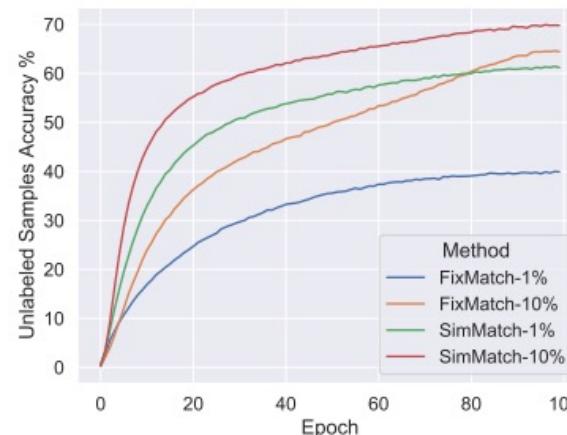
## ❖ FixMatch vs SimMatch

- ImageNet 학습 데이터 중 1%, 10%만 사용해 학습한 경우에 대한 세 가지 성능 표기
  - Pseudo-Labels: Weak Augmented 데이터에 대한 Pseudo-Label 이 얼마나 정확한지를 나타내는 그림
  - Unlabeled Samples: Weak/ Strong Augmented 데이터에 예측 범주와 실제 범주 사이 정확도 시계열 그림
  - Validation: 검증 데이터셋 정확도 시계열 그림

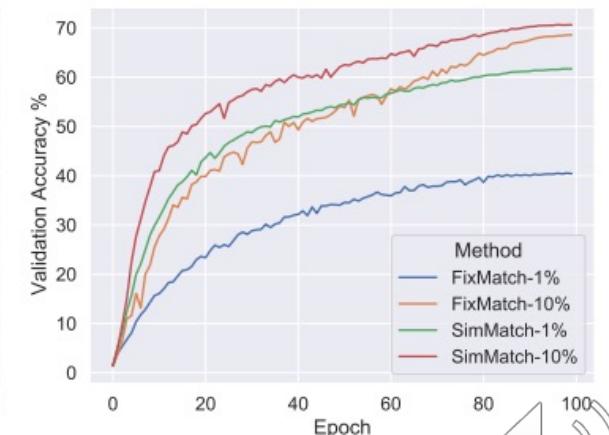
FixMatch 1%



FixMatch 10%



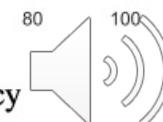
SimMatch 1%



(a) Pseudo-Labels Accuracy

(b) Unlabeled Samples Accuracy

(c) Validation Accuracy



# 목차

---

1. Introduction
2. FixMatch
3. SelfMatch
4. SimMatch
5. Conclusion



# 5. Conclusion

---

## ❖ Summary

- 실제 현장에서는 (입력-출력) 데이터를 수집하기 어려움
- 이를 위해 Self-supervised/ Semi-supervised Learning 연구가 이루어지는 상황
- 특히 이번 세미나에서는 Semi-supervised Learning에 집중
  - FixMatch: Unlabeled 데이터에 Weak/ Strong Augmentation을 진행해 예측 값이 유사해지도록 학습
  - SelfMatch: Self-supervised Learning 방식으로 모델 사전 학습 후 FixMatch 학습
  - SimMatch: Semantic & Instance similarity 정의 후 이들을 사용해 Unlabeled 데이터 활용
  - SimMatch는 Semi&Self supervised Learning 방법론 개념을 통합했다는 판단



# Reference

---

1. Sohn, K., Berthelot, D., Carlini, N., Zhang, Z., Zhang, H., Raffel, C. A., ... & Li, C. L. (2020). Fixmatch: Simplifying semi-supervised learning with consistency and confidence. *Advances in neural information processing systems*, 33, 596-608.
2. Kim, B., Choo, J., Kwon, Y. D., Joe, S., Min, S., & Gwon, Y. (2021). Selfmatch: Combining contrastive self-supervision and consistency for semi-supervised learning. *arXiv preprint arXiv:2101.06480*.
3. Zheng, M., You, S., Huang, L., Wang, F., Qian, C., & Xu, C. (2022). Simmatch: Semi-supervised learning with similarity matching. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 14471-14481).
4. 2022년 2학기 강필성 교수님 강의자료(Semi-supervised Learning: Holistic Methods)
5. Li, J., Xiong, C., & Hoi, S. C. (2021). Comatch: Semi-supervised learning with contrastive graph regularization. In *Proceedings of the IEEE/CVF international conference on computer vision* (pp. 9475-9484).
6. SimMatch Github(<https://github.com/kyle-1997/simmatch>)



---

# 감사합니다

