

논문 2024-13-31

# 이미지 분류 성능 향상을 위한 무작위성 적용 방법론

## (Methodology of Applying Randomness for Boosting Image Classification Performance)

박 주 용, 전 유 리, 김 미 영, 이 정 민, 현 윤 석\*

(Juyong Park, Yuri Jeon, Miyeong Kim, Jeongmin Lee, Yoonsuk Hyun)

Abstract : Securing various types of training data in image Classification is important for improving performance. However, increasing the amount of original data is cost-limited, so data diversity can be secured by transforming images through data augmentation.

Recently, a new deep learning approach using Generative AI models like GAN or Diffusion Based models has emerged in the Data Augmentation task, and reinforcement learning-based methods such as AutoAugment and Deep AutoAugment using existing basic Augmentation techniques are also showing good performance. However, this method has the disadvantage of having a complicated optimization procedure and high computational cost. This paper conducted various experiments with existing methods Cutmix, Mixup, RandAugment. By combining these techniques appropriately, we obtained higher performance than existing method without much effort. Additionally, our ablation experiment shows that additional hyper-parameter adjustments are needed for the basic augmentation types when we use RandAugment. Our code is available at [https://github.com/liel1/Randomness\\_Analysis](https://github.com/liel1/Randomness_Analysis).

Keywords : Data Augmentation, Randomness, Image classification, Deep Learning

### 1. 서 론

Computer Vision 연구에서 다양한 유형의 학습 데이터를 확보하는 것은 성능 향상에 필수적이다. 그러나 학습 데이터 확보에는 비용적인 한계가 있어 이를 극복하기 위해 다양한 데이터 증강 (Data Augmentation) 연구가 진행되었다. 특히 이미지 분류에서 데이터 증강은 원본 이미지의 변형을 통해 데이터의 다양성을 확보함으로써 과적합 문제를 해결하고 성능 향상에 도움을 준다. 최근 데이터 증강 분야에서는 ViT (Vision Transformer) [1]에 특화된 패치 기반 증강 기법인 TransMix [2], MixPro [3]이 제안되었다. Bounding Box Cutmix [4]는 Mosaic [5]의 단점을 개선하여 재촬영품 객체 탐지를 위한 증강 기법을 제시했다. 또한, GAN [6]과 Stable Diffusion [7] 등의 생성 모델을 활용하여 기존 데이터와 유사한 합성 데이터를 확보하는 방식 [8-10]과 비교적 단순한 증강 기법을 사용하여 목표 데이터에 최적화된 Policy를 찾아내는 AutoAugment [11], DeepAutoAugment [12] 같은 강화학습 기반 연구들도 진행되었다. 그러나 강화학습 기반의 기법들은 최적화 절차가 복잡하고 계산 비용이 크기 때문에 현실적인 문제에 적용하기에는 무리가 있다.

이러한 한계를 극복하기 위해 본 연구에서는 기존의 데이터 증강 기법들을 조합하고 활용하여 이미지 분류에서 상대적으로 적은 비용으로 성능 향상을 이뤄내기 위한 다양한 실험을 진행하였다.

Cutmix [13], Mixup [14], RandAugment [15] 증강 기법은 간단하면서도 주목할만한 성능 향상을 보여준 기법들로 알려져 있다. 우리는 Cutmix와 Mixup이 서로 다른 두 이미지를 활용해 새로운 데이터를 생성한다는 점에 주목하여, 각 기법으로 데이터를 생성할 때 무작위성을 부여한다면 기존 이미지의 의미를 잃지 않으면서 데이터의 다양성을 확보할 수 있을 것이라고 생각했다. 우리는 이러한 가설을 입증하기 위해 다양한 비교 실험을 진행하였다. 그 결과, 무작위성 부여 증강 기법과 Cutmix, Mixup을 조합했을 때 실험에 사용한 모든 모델과 데이터셋에서 주목할만한 성능 향상이 나타남을 확인하였다.

본 논문에서는 무작위성 부여를 위해 먼저 RandAugment 증강 기법을 사용하였다. 우리는 RandAugment를 위한 하이퍼파라미터를 조정하는 과정에서 기존 하이퍼파라미터인  $N$ ,  $M$ 뿐만 아니라, RandAugment에서 사용하는 기본 증강 기법 종류에 대한 추가적인 조정이 필요하다는 점을 비교 실험으로 입증하였다. 실험을 위해 ResNet [16], WideResNet [17], ViT 모델을 사용하였으며, Tiny ImageNet [18], CIFAR-100 [19] 데이터셋에서 각 증강 기법이 모델의 이미지 분류 성능에 미치는 영향을 확인하였다. 본 논문을 요약하면 다음과 같다.

- 이미지 분류 문제에서 비교적 단순한 증강 기법을 어

\*Corresponding Author (yshyun21@inha.ac.kr)

Received: Jun. 28, 2024, Revised: Jul. 26, 2024, Accepted: Sep. 7, 2024.

J. Y. Park: Inha University (M.S. Student)

Y. R. Jeon, M.Y. Kim, J.M. Lee: Inha University (B.S. Student)

Y. S. Hyun: Inha University (Assoc. Prof.)

\* 본 논문은 2022년, 2024년 정부 (과학기술정보통신부)의 지원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2022R1A4A5033271, No.RS-2024-00348476).

떻게 조합해야 성능 향상이 나타나는지 확인하였다.

- Cutmix (Mixup)을 무작위성 부여 증강 기법과 적절히 조합한 증강 기법을 제안하고, 비교 실험을 통해 기존 증강 기법보다 우수한 성능을 확인하였다.

- 데이터에 무작위성을 부여할 때, 데이터와 모델에 맞게 증강 기법 종류 또한 최적화할 필요성을 보여주었다.

## II. 관련 연구

### 1. 사용한 증강 기법 설명

#### 1.1 RandAugment

RandAugment는 한 이미지에 무작위로 다양한 증강 기법을 적용하는 방식의 증강 기법이다. 적용할 증강의 개수를 지정하는 하이퍼파라미터  $N$ 과 각 변환의 강도 (Magnitude)를 조절하는 하이퍼파라미터  $M$ 이 존재하며, 이들은 데이터와 모델에 맞춰 최적화해야 한다. RandAugment는 AutoAugment와 비교했을 때 복잡한 탐색 공간 없이 쉬운 구현과 효율성을 장점으로 가지고 있다. 본 논문에서는 RandAugment와 같은 무작위성을 부여하는 증강 기법을 활용했을 때 나타나는 이미지 분류 성능 변화를 살펴봤다. 다음은 RandAugment에서 사용하는 증강 기법들이다.

- Identity, AutoContrast, Equalize, Rotate, Solarize, Color, Posterize, Contrast, Brightness, Sharpness, Shear-x, Shear-y, Translate-x, Translate-y.

#### 1.2 Mixup, Cutmix

Mixup은 서로 다른 이미지를 선형적으로 합성하여 새로운 데이터를 생성하는 증강 기법으로, 간단한 구현을 통해 성능 향상을 보여주는 장점을 가지고 있다. 사용한 수식은 다음과 같다.

$$\begin{aligned}\tilde{x} &= \lambda x_i + (1-\lambda)x_j \\ \tilde{y} &= \lambda y_i + (1-\lambda)y_j\end{aligned}\quad (1)$$

$x_i$ 와  $x_j$ 는 서로 다른 이미지를 의미하고,  $y_i$ 와  $y_j$ 는 각 이미지에 대응되는 one-hot label encoding vector를 의미한다.

Cutmix는 서로 다른 이미지 A, B에 대해 A 이미지의 일정 영역을 잘라낸 후 그 영역에 B 이미지를 채워 넣어 새로운 데이터를 생성하는 증강 기법이다. 이는 Cutout [20]과 유사한 방식으로 작동한다. 구체적인 알고리즘은 다음과 같다. 1. 두 개의 이미지를 랜덤하게 선택한다. 2. 한 이미지의 일정 영역을 다른 이미지로 대체할 Bounding Box 위치를 결정한다. Bounding Box는 다음과 같은 수식을 통해 구해낸다.

##### 1.2.1. Bounding Box 중심 좌표 샘플링

$$\begin{aligned}r_x &\sim U(0, W) \\ r_y &\sim U(0, H)\end{aligned}\quad (2)$$

이때,  $W$ 와  $H$ 는 각각 원본 이미지의 너비와 높이를 의미하며,  $U$ 는 Uniform Distribution을 의미한다.




그림 1. 증강 기법 시각화 (1)

Fig. 1. Visualization of Augmentations (1)

##### 1.2.2. Bounding Box 좌표 샘플링

$$\begin{aligned}r_w &= W\sqrt{1-\lambda} \\ r_h &= H\sqrt{1-\lambda}\end{aligned}\quad (3)$$

위 수식을 통해 전체 영역 대비 잘라낼 영역의 비율이  $\frac{r_w r_h}{WH} = 1-\lambda$ 가 되도록 설정한다.  $\lambda \sim B(\alpha, \alpha)$ 에서 Sampling 한다.  $B$ 는 Beta Distribution을 의미한다. 수식 (2)에서 구한 중심 좌표와 수식 (3)의 Bounding Box의 너비와 높이를 이용하여 bounding box의 좌측 상단 좌표와 우측 하단 좌표를 구한다.

##### 1.2.3. 새로운 데이터 생성

$$\begin{aligned}\tilde{x} &= M \odot x_A + (1-M) \odot x_B \\ \tilde{y} &= \lambda y_A + (1-\lambda)y_B\end{aligned}\quad (4)$$

수식의  $M$ 은 Binary mask를 의미한다.  $M$ 은 Bounding box 위치에서 0을 가지며, 나머지 영역에서는 1을 가진다. 최종적으로 Binary Mask  $M$ 과 서로 다른 이미지  $x_A, x_B$ 를 수식 (4)에 대입하여 새로운 데이터를 생성한다. 수식을 통해 알 수 있듯이, Bounding Box 내부에서는 B 이미지가 나타나고, 그 외 영역에서는 A 이미지가 나타나게 된다.

RandAugment, Mixup, Cutmix는 이미지 분류 분야에서 강력한 성능 향상을 보였으며, 구현의 단순함 덕분에 딥러닝 분야에서 빈번하게 사용되고 있다. 그림 1은 각 증강 기법을 적용한 예시이다. 그림 1, 2의 예시를 위해 화질 점수 예측 분야 데이터셋인 KonIQ-10k [21]을 활용했다. 본 논문에서는 위에서 살펴본 세 가지 증강 기법의 활용 방안을 제안하기 위해 다양한 비교 실험을 진행한다.

## III. 본 론

### 1. 증강 기법 제안

#### 1.1 무작위성 부여 방법론




그림 2. 증강 기법 시각화 (2)  
Fig. 2. Visualization of Augmentations (2)

위에서 살펴본 증강 기법들은 각각의 방법으로 우수한 연구 결과를 도출하였다. 특히 Cutmix는 두 이미지를 통해 생성한 데이터에 대해서도 모델이 각각의 객체를 인식하고 있다는 것을 CAM (Class Activation Map) [22]를 이용한 시각화를 통해 보여주었다. 즉, Cutmix를 통해 생성된 데이터는 Bounding Box 내부와 외부의 영역에서 기존 클래스에 대한 정보를 잘 보유하고 있다. 또한, RandAugment는 기존 증강 기법들을 무작위로 부여하는 간단한 방식으로도 뛰어난 성능을 보여주었다. 이는 데이터에 무작위성을 부여하는 증강 기법이 이미지 분류 분야에서 데이터 다양성 확보에 도움을 줄 수 있음을 시사한다. 우리는 Cutmix로 분리된 영역에 각각 무작위성을 부여함으로써, 각 영역이 보유하고 있는 클래스 정보를 유지하면서도 데이터의 다양성을 기존보다 더 확보할 수 있을 것이라 생각했다. 따라서 다음과 같은 순서로 데이터를 생성하는 증강 기법을 제안한다.

- ① 서로 다른 이미지에 무작위성을 적용
- ② 무작위성이 적용된 이미지를 활용하여 Cutmix, Mixup 적용

위 방식을 통해서 서로 다른 영역에 각각 무작위 증강이 적용된 새로운 데이터가 생성된다. 제안된 증강 기법의 장점을 소개하면 다음과 같다. 첫째, Cutmix, Mixup뿐만 아니라 여러 이미지를 활용하는 다른 증강 기법으로도 쉽게 확장할 수 있다. 둘째, 단순한 구현으로 쉽게 사용할 수 있다. 셋째, Cutmix, Mixup, RandAugment에서 나타나지 않는 양질의 데이터를 생성할 수 있다. 우리는 다양한 비교 실험을 통해 제안한 증강 기법의 효과를 입증하고 무작위성 부여에 대한 시사점을 제시한다.

## 2. 실험

### 2.1 기본 실험 환경

RandAugment 논문에서의 실험처럼 기본 증강 기법으로 RandomCrop (padding=4)과 RandomHorizontalFLIP을 적용하였다. Batch\_size는 64를 사용하였으며 Optimizer로 SGD-momentum (0.9)를 이용하였다. Weight\_decay는 5e-4로 설정했고, 학습률은 0.1을 시작으로 LambdaLR을 이용하여 60, 120, 160 epoch마다 학습률에 0.2배를 해주었다. 모든 실험은 GeForce RTX 3080 Ti Single GPU에서 진행되었다.

### 2.2 데이터셋 설명

이미지 분류 데이터셋인 Tiny ImageNet과 CIFAR-100를 사용하였다. Tiny ImageNet은 200개의 클래스로 이루어진 이미지 분류 데이터셋으로, 64×64의 해상도를 가진다. CIFAR-100는 100개의 클래스로 이루어진 이미지 분류 데이터셋으로, 32×32의 해상도를 가진다. 우리는 ViT-B/16에서의 실험을 위해서 이미지를 224×224 해상도로 resize 하였고, 나머지 모든 실험에서는 원본 이미지의 해상도를 사용

표 1. 증강별 하이퍼파라미터

Table 1. Hyperparameters of each augmentation

Augmentation	Hyperparameter
Mixup	Lambda from Uniform distribution ( $\alpha = 1$ )
	Apply Probability: 0.5
Cutmix	Lambda from Uniform distribution ( $\alpha = 1$ )
	Apply Probability: 0.5
RandAugment	Num_ops: 2
	Magnitude: 9
	Apply Probability: 0.5

표 2. 실험 2.3에서 제안된 증강 기법 성능 비교

Table 2. Performance comparison of proposed augmentation in experiment 2.3

Model	Augmentation	Accuracy	
		Tiny ImageNet	CIFAR-100
WideResNet-28-10	Mixup	0.6889	0.8232
	Cutmix	0.7057	0.8237
	RandAugment → Mixup	0.7041	0.8325
	RandAugment → Cutmix	<b>0.7160</b>	<b>0.8358</b>
ResNet50	Mixup	0.5298	0.6262
	Cutmix	0.5768	0.6453
	RandAugment → Mixup	0.5871	0.6485
	RandAugment → Cutmix	<b>0.6390</b>	<b>0.6803</b>
ResNet101	Mixup	0.5789	0.6190
	Cutmix	0.5285	0.6382
	RandAugment → Mixup	0.5912	0.6431
	RandAugment → Cutmix	<b>0.6362</b>	<b>0.6596</b>
ViT-B/16	Mixup	0.8960	0.9307
	Cutmix	0.8994	0.9338
	RandAugment → Mixup	0.9018	<b>0.9370</b>
	RandAugment → Cutmix	<b>0.9060</b>	0.9366

하였다. 모든 실험에서 학습과 평가 데이터셋을 나누기 위해 공식 스플릿을 이용하였다.

2.3 RandAugment + Cutmix, Mixup

앞서 살펴본 것처럼 Cutmix, Mixup은 서로 다른 이미지를 이용하여 새로운 데이터를 생성하는 방식의 증강 기법이다. 우리는 이 부분에 주목하여, 데이터를 생성할 때 무작위성을 부여한다면 기존 이미지의 의미를 유지하면서도 데이터의 다양성을 확보할 수 있을 것으로 판단했다. 따라서 RandAugment를 이용하여 서로 다른 이미지에 무작위성을 부여하였고, 무작위성이 부여된 두 이미지에 Cutmix, Mixup을 적용하였다. 각 증강 기법을 사용할 때 필요한 하이퍼파라미터는 표 1에서 확인할 수 있으며, 표 2은 RandAugment와 Cutmix (Mixup)을 합쳐서 적용했을 때와 개별로 적용했을 경우의 성능을 보여준다. 진하게 처리된 성능은 각 모델에서 가장 좋은 성능을 나타낸다. 다양한 모델에서의 비교를 위해 WideResNet-28-10, ResNet50, ResNet101, ViT-B/16 모델을 사용했으며, 실험 결과 모든 경우에서 Cutmix와 Mixup만을 사용했을 때보다 성능이 개선되는 것을 확인할 수 있었다. 특히 Tiny ImageNet에서 ResNet50을 모델로 사용한 경우, Cutmix, Mixup으로 생성되는 각 영역에 다른 무작위성을 부여했을 때 기존 증강 기법 대비 약 10.8%의 성능 향상을 보여주었다.

2.4 증강 종류 최적화의 필요성

RandAugment는 데이터셋과 모델에 맞게 최적의 하이퍼

표 3. RandOur 리스트

Table 3. List of RandOur

RandOur
1. No augmentation
2. Autocontrast
3. Invert
4. Brightness : increases brightness by a factor of 2
5. Sharpness : increases sharpness by a factor of 2
6. Rotation : -180 to 180
7. ColorJitter :
- Brightness: Brightness factor from [0.5, 1.5]
- Contrast : Contrast factor from [0.5, 1.5]
- Saturation : Saturation factor from [0.5, 1.5]
- Hue : Hue factor from [-0.5, 0.5]
8. Translation_X : -0.2 to 0.2
9. Translation_Y : -0.2 to 0.2
10. Shear_X : -20 to 20
11. Shear_Y : -20 to 20

파라미터를 찾아야 한다. 우리는 이 과정에서 증강 기법 종류도 조정해야 할 하이퍼파라미터에 포함되어야 한다고 생각했다. 이를 위해 우리는 RandAugment에서 사용하는 증강 기법 중 일부를 제외한 RandOur라는 증강을 만들고 증강의 강도 역시 임의로 지정하였다. RandOur에 대한 정보는 표 3에서 확인할 수 있다. (RandOur를 위해 RandAugment에서

표 4. 실험 2.4, 2.5에서 제안된 증강 기법 성능 비교  
Table 4. Performance comparison of proposed augmentation in experiments 2.4 and 2.5

Model	Augmentation	Accuracy	
		Tiny ImageNet	CIFAR-100
WideResNet-28-10	RandAugment → Cutmix	0.7163	0.8358
	Cutmix → RandAugment	0.7015	0.8253
	RandOur → Cutmix	<b>0.7201</b>	<b>0.8432</b>
	Cutmix → RandOur	0.7173	0.8400
ResNet50	RandAugment → Cutmix	<b>0.6390</b>	<b>0.6850</b>
	Cutmix → RandAugment	0.5807	0.6141
	RandOur → Cutmix	0.5989	0.6536
	Cutmix → RandOur	0.5979	0.6516
ResNet101	RandAugment → Cutmix	<b>0.6362</b>	<b>0.6596</b>
	Cutmix → RandAugment	0.5835	0.6117
	RandOur → Cutmix	0.600	0.6517
	Cutmix → RandOur	0.5967	0.6438
ViT-B/16	RandAugment → Cutmix	<b>0.9060</b>	<b>0.9366</b>
	Cutmix → RandAugment	0.8992	0.9346
	RandOur → Cutmix	0.8995	0.9358
	Cutmix → RandOur	0.8986	0.9348

제외한 증강: Equalize, Solarize, Posterize)

표 4에서 확인할 수 있듯이, ResNet50과 ResNet101 모델에서는 RandAugment가 Tiny ImageNet과 CIFAR-100 데이터셋에서 더 좋은 성능을 보인다. 반대로, WideResNet-28-10 모델은 RandOur가 더 좋은 성능을 보인다. 이는 특정 모델과 데이터에서는 RandAugment에서 사용한 증강 종류가 무작위성 부여에 최적은 아니라는 것을 시사한다. 따라서 성능을 향상시키기 위해서 최적의 하이퍼 파라미터를 찾을 때는 증강 종류도 고려해야 한다.

### 2.5 무작위성 강도에 따른 성능 비교

실험 2.3를 통해 우리는 Cutmix와 Mixup에서 존재하는 두 영역에 각각 다른 무작위 증강을 적용하면 성능이 향상된다는 것을 확인하였다. 추가로, 무작위성 강도에 따른 비교 실험을 진행하기 위해 서로 다른 이미지가 있는 두 영역에 같은 무작위 증강을 적용하였다. 이를 위해 먼저 Cutmix를 사용하여 새로운 데이터를 생성하고, 생성된 데이터에 무작위성을 부여 (RandAugment, RandOur) 하는 방식으로 실험을 진행하였다. 이에 대한 예시는 그림 2의 (c)에서 확인할 수 있다. 표 4에서 확인할 수 있듯이, 각 이미지에 서로 다른 무작위성을 부여하고 Cutmix를 적용하는 방식이, 같은 무작위성을 부여하는 것보다 좋은 성능을 보이는 것을 확인했다. 이는 본 논문에서 제안한 방식이 각 영역에 동일한 무작위성을 부여하는 방식보다 무작위성의 강도가 강하지만, 기존 이미지의 의미를 해치지 않는 선에서 데이터의 다양성을 더 잘 확보할 수 있는 증강 기법임을 나타낸다.

### 2.6 증강 기법 시각화 및 데이터 규모

각 증강 기법별 데이터 샘플 시각화는 그림 2에서 확인할 수 있다. 그림 2에서 볼 수 있듯이, 각 영역에 다른 무작위성을 부여함으로써 Cutmix와 Mixup에서는 나타나지 않는 다양한 종류의 데이터를 확보할 수 있게 된다. 이때, 다른 데이터 증강 기법 연구들과 동일하게 증강 기법에 따라 데이터 규모에서 차이를 두지 않는다. 특히, CIFAR-100의 경우 모든 실험에서 학습을 위해 50,000장의 이미지를 사용하며, 평가를 위해 10,000장의 이미지를 사용한다. 이에 따라, 학습 시간에 차이가 거의 존재하지 않아 제안한 증강 기법은 효율적인 학습이 가능하다. 구체적으로, ViT-B/16을 사용한 실험에서 Cutmix의 경우 10시간 52분, RandAugment → Cutmix의 경우 10시간 53분이 학습에 소요된다.

## IV. 결론

본 논문에서는 이미지 분류에서 간단하게 사용할 수 있는 데이터 증강 기법의 다양한 조합에 대한 실험을 진행하였다. 특히 Cutmix, Mixup과 같은 데이터 증강 기법을 사용할 때 나타나는 두 가지 영역과 무작위성을 부여하는 RandAugment의 성공적인 성능에 주목하였고, 실험 2.3을 통해 단순히 두 증강을 조합하는 것만으로 우수한 성능을 얻을 수 있는 것을 보였다. 이는, 본 연구에서 제안한 서로 다른 두 영역에 각각 다른 무작위성을 부여하는 증강 기법이 기존 이미지가 가지는 의미를 해치지 않으면서 데이터의

다양성을 확보할 수 있는 증강 기법이라는 것을 시사한다. 또한, 실험 2.5에서 진행한 비교 실험을 통해 각 영역에 다른 무작위성을 부여한 경우, 같은 무작위성을 부여했을 때보다 성능 향상에 도움을 주는 것을 확인했다. 마지막으로, 표 4의 실험 결과를 통해 RandAugment를 활용하여 무작위성을 부여할 때 기존 하이퍼파라미터 최적화뿐만 아니라 증강 기법의 종류에서도 최적화가 필요함을 보여주었다. 본 논문에서 진행한 연구가 Cutmix, Mixup같이 여러 이미지를 활용해 새로운 데이터를 생성하는 후속 연구들에서 무작위성을 각각 부여하는 방식에 대한 실험의 기반이 되기를 기대한다.

## References

- [1] A. Dosovitskiy, L. Beyer, A. Kolesnikov, D. Weissenborn, X. Zhai, T. Unterthiner, M. Dehghani, M. Minderer, G. Heigold, S. Gelly, "An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale," International Conference on Learning Representations, 2021.
- [2] J. N. Chen, S. Sun, J. He, P. H. Torr, A. Yuille, S. Bai, "Transmix: Attend to Mix for Vision Transformers," Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 12135-12144, 2022.
- [3] Q. Zhao, Y. Huang, W. Hu, F. Zhang, J. Liu, "Mixpro: Data Augmentation with Maskmix and Progressive Attention Labeling for Vision Transformer," arXiv preprint arXiv:2304.12043, 2023.
- [4] H. Lee, H. Jung, "Recyclable Objects Detection Via Bounding Box CutMix and Standardized Distance-based IoU," IEMEK J. Embed. Sys. Appl., Vol. 17, No. 5, pp. 289 - 296, 2022.
- [5] A. Bochkovskiy, C. Wang, H. M. Liao, "Yolov4: Optimal Speed and Accuracy of Object Detection," arXiv preprint arXiv:2004.10934, 2020.
- [6] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, Y. Bengio, "Generative Adversarial Nets," Advances in Neural Information Processing Systems, 27, 2014.
- [7] R. Rombach, A. Blattmann, D. Lorenz, P. Esser, B. Ommer, "High-resolution Image Synthesis with Latent Diffusion Models," Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 10684-10695, 2022.
- [8] Y. Zhou, H. Sahak, J. Ba, "Training on Thin Air: Improve Image Classification with Generated Data," arXiv preprint arXiv:2305.15316, 2023.
- [9] S. Motamed, P. Rogalla, F. Khalvati, "Data Augmentation Using Generative Adversarial Networks (GANs) For GAN-Based Detection Of Pneumonia And COVID-19 In Chest X-Ray Images," Informatics in Medicine Unlocked, 27, 100779, 2021.
- [10] B. Trabucco, K. Doherty, M. Gurinas, R. Salakhutdinov, "Effective Data Augmentation with Diffusion Models," arXiv preprint arXiv:2302.07944, 2023.
- [11] E. D. Cubuk, B. Zoph, D. Mane, V. Vasudevan, Q. V. Le, "Autoaugment: Learning Augmentation Policies from Data," arXiv preprint arXiv:1805.09501, 2018.
- [12] Y. Zheng, Z. Zhang, S. Yan, M. Zhang, "Deep Autoaugment," arXiv preprint arXiv:2203.06172, 2022.
- [13] S. Yun, D. Han, S. J. Oh, S. Chun, J. Choe, Y. Yoo, "Cutmix: Regularization Strategy to Train Strong Classifiers with Localizable Features," Proceedings of the IEEE/CVF International Conference on Computer Vision, pp. 6023-6032, 2019.
- [14] H. Zhang, M. Cisse, Y. N. Dauphin, D. Lopez-Paz, "Mixup: Beyond Empirical Risk Minimization," arXiv preprint arXiv:1710.09412, 2017.
- [15] E. D. Cubuk, B. Zoph, J. Shlens, Q. V. Le, "Randaugment: Practical Automated Data Augmentation with a Reduced Search Space," Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, pp. 702-703, 2020.
- [16] K. He, X. Zhang, S. Ren, J. Sun, "Deep Residual Learning for Image Recognition," Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 770-778, 2016.
- [17] S. Zagoruyko, N. Komodakis, "Wide Residual Networks," arXiv preprint arXiv:1605.07146, 2016.
- [18] Y. Le, X. Yang, "Tiny Imagenet Visual Recognition Challenge," CS 231N, 7.7: 3, 2015.
- [19] A. Krizhevsky, G. Hinton, "Learning Multiple Layers of Features from Tiny Images," 2009.
- [20] T. DeVries, G. W. Taylor, "Improved Regularization of Convolutional Neural Networks with Cutout," arXiv preprint arXiv:1708.04552, 2017.
- [21] V. Hosu, H. Lin, T. Sziranyi, D. Saupe, "KonIQ-10k: An Ecologically Valid Database for Deep Learning of Blind Image Quality Assessment," IEEE Transactions on Image Processing, Vol. 29, pp. 4041-4056, 2020.
- [22] B. Zhou, A. Khosla, A. Lapedriza, A. Oliva, A. Torralba, "Learning Deep Features for Discriminative Localization," Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 2921-2929, 2016.

**Juyong Park (박주용)**



2023 Mathematics from Inha University (B.S.)  
2023~Mathematics from Inha University (M.S.)

Field of Interest: Artificial Intelligence, Computer Vision  
Email: lielie96096@gmail.com

**Jeongmin Lee (이정민)**



2024 Mathematics from Inha University (B.S.)

Field of Interest: Data Augmentation, Artificial Intelligence  
Email: ljm104022@gmail.com

**Yuri Jeon (전유리)**



2024 Mathematics from Inha University (B.S.)

Career:  
2024~Advanced Technology Inc. (AI Engineer)  
Field of Interest: Artificial Intelligence, Image Processing  
Email: yrjun@ati2000.co.kr

**Yoonsuk Hyun (현윤석)**



2005 Mathematics from Seoul National University, Seoul, Republic of Korea (B.S.)  
2011 Mathematics from Massachusetts Institute of Technology, Cambridge, MA (Ph.D.)

Career:  
2011~2015 Research Fellow, Korea Institute for Advanced Study (KIAS)  
2015~2020 Principal Researcher, Samsung Advanced Institute of Technology (SAIT)  
2020~Associate Professor, Department of Mathematics, Inha University, Incheon, Republic of Korea  
Field of Interests: Machine Learning, Computer Vision, Multi-modal Learning  
Email: yshyun21@inha.ac.kr

**Miyeong Kim (김미영)**



2024 Mathematics from Inha University (B.S.)  
2024~Mathematical Science from Seoul National University (M.S.)

Field of Interest: Artificial Intelligence, Data Science  
Email: aldud88278@naver.com