

<http://dx.doi.org/10.17703/JCCT.2024.10.2.465>

JCCT 2024-3-54

전이 학습 기반의 생성 이미지 판별 모델 설계

Transfer Learning-based Generated Synthetic Images Identification Model

김채원*, 윤성연**, 한명은***, 박민서****

Chaewon Kim*, Sungyeon Yoon**, Myeongeun Han***, Minseo Park****

요약 인공지능(Artificial Intelligence, AI) 기반 이미지 생성 기술의 발달로 다양한 이미지가 생성되고 있으며, 이를 정확하게 판별하는 기술이 필요하다. 생성된 이미지 데이터의 양에는 한계가 있으며, 한정된 데이터로 높은 성능을 내기 위해 본 연구에서는 전이 학습(Transfer Learning)을 활용한 생성 이미지를 판별하는 모델을 제안한다. ImageNet 데이터 셋으로 사전학습된 모델을 입력 데이터 셋인 CIFAKE 데이터 셋에 그대로 적용하여 학습의 시간 비용을 줄인 후, 3개의 은닉층과 1개의 출력층을 더해 모델을 튜닝한다. 모델링 결과, 최종 레이어를 조정된 모델의 성능이 높아짐을 확인하였다. 딥러닝에서 전이 학습을 통해 학습한 후 출력층과 가까운 레이어를 데이터의 특성에 맞게 추가 및 조정하는 과정을 통해 적은 이미지 데이터로 인한 학습 정확도 이슈를 줄이고 생성된 이미지 판별을 할 수 있다는 데 의의가 있다.

주요어 : 생성 이미지, 딥러닝, 전이 학습, 분류

Abstract The advancement of AI-based image generation technology has resulted in the creation of various images, emphasizing the need for technology capable of accurately discerning them. The amount of generated image data is limited, and to achieve high performance with a limited dataset, this study proposes a model for discriminating generated images using transfer learning. Applying pre-trained models from the ImageNet dataset directly to the CIFAKE input dataset, we reduce training time cost followed by adding three hidden layers and one output layer to fine-tune the model. The modeling results revealed an improvement in the performance of the model when adjusting the final layer. Using transfer learning and then adjusting layers close to the output layer, small image data-related accuracy issues can be reduced and generated images can be classified.

Key words : Generated Synthetic Images, Deep Learning, Transfer Learning, Classification

1. 서론

인공지능(Artificial Intelligence, AI) 기반의 이미지 생성 모델(Image Generative Model) 기술의 발달로 대량의 다양한 이미지가 생성되고 서비스로 제공되고 있다[1].

대량의 다양한 이미지의 생성은 AI 학습 시의 부족한 이미지를 보완하는 긍정적인 작용과 동시에 악의적으로도 사용될 수 있다. 대표적인 예로 딥페이크(Deep Fake)[2]는 정치적·사회적으로 혼란을 유발하거나, 특정 인물을 콘텐츠로 활용하는 등의 심각한 사회적 부작용을 초래하

*준회원, 서울여자대학교 데이터사이언스학과 학부생

**준회원, 서울여자대학교 데이터사이언스학과 대학원생

***준회원, 서울여자대학교 데이터과학전공 학부생

****정회원, 서울여자대학교 데이터사이언스학과 교수 (교신저자)

접수일: 2024년 1월 2일, 수정완료일: 2024년 2월 24일

게재확정일: 2024년 2월 27일

Received: January 2, 2024 / Revised: February 24, 2024

Accepted: February 27, 2024

****Corresponding Author: mpark@swu.ac.kr

Dept. of Data Science, Seoul Women's Univ, Korea

였다.

이러한 우려로 AI 기술로 만들어진 이미지를 정확하게 판별하려는 연구가 활발하게 이루어지고 있다[3-6]. Marra[3]은 GAN(Generative Adversarial Network)을 사용하여 만들어진 이미지가 소셜네트워크(Social Network Service, SNS)에서 확산되는 문제점에 주목하였다. 특히, SNS에 이미지가 압축되어서 업로드 됨에 따라 가짜 이미지의 판별이 더 어려워짐을 서술하였다. GAN을 통해 SNS에 업로드된 왜곡 및 훼손된 이미지를 정확하게 감지하기 위한 모델을 제안하였다. 김대희[4]은 바이오 인식 기술이 다양한 분야에 적용됨에 따라 AI 기술을 활용한 생성 이미지에 대한 판별이 중요해졌음을 강조하였다. GAN의 기법을 통해 생성된 이미지를 학습하고, 이진 분류를 통해 AI로 생성된 얼굴 이미지와 실제 얼굴 이미지를 구분하는 모델을 제안하였다. 김지연[5]은 StyleGAN을 통해 생성된 가짜 얼굴 이미지를 탐지하는 모델을 제안하였다. Hsu[6]는 CFFN(Common Fake Feature Network) 기반의 대조 학습(Contrastive Learning)을 통해 가짜 얼굴 및 이미지를 감지하는 방법을 제안하였다.

AI로 생성된 이미지를 정확하게 판별하기 위해서는 많은 이미지에 대한 학습이 필요하다. 또한, 충분한 양의 데이터가 존재한다 하더라도 이미지 판별을 위해 딥러닝 모델을 학습하기 위해서는 많은 시간과 비용이 필요하다. 이러한 한계를 해결하기 위해 학습의 전반부는 이미 학습된 모델을 활용하는 전이 학습(Transfer Learning)[10]을 수행하고, 모델의 후반부에서는 데이터 특성에 적합한 레이어 추가와 이에 맞는 가중치를 조절하는 방법을 제안한다. 본 연구에서는 실제 이미지와 AI로 생성한 이미지로 구성된 CIFAKE[7] 데이터 셋을 사용한다. 데이터 셋을 전처리(Pre-processing)한 후 사전학습(Pre-Trained)된 6개의 딥러닝 기반 모델을 활용하여 전이 학습(Transfer Learning)을 수행한다. 기존의 출력층 대신 3개의 은닉층과 1개의 출력층을 사용한 모델을 생성한다. 이를 검증하기 위해 K겹 교차 검증(K-Fold Cross Validation)를 수행하고 정량적 평가를 통해 모델을 채택한다.

본 논문의 구성은 다음과 같다. 2장에서는 전이 학습에 대해 설명한다. 3장에서 전이 학습을 활용한 AI 생성 이미지 판별 모델을 제시하며, 4장에서는 실험 결과를 서술한다. 마지막으로 5장에서 결론을 언급한다.

II. 전이 학습

딥러닝 기반의 모델을 학습시키기 위해서는 다량의 데이터가 필요하다. 그러나 충분한 양의 데이터를 수집하여 모델을 학습시키는 것이 어려운 경우가 다수 존재하며, 학습에 필요한 데이터를 충분히 수집하였다 하더라도 모델을 처음부터 학습시키기 위해서는 높은 시간적 비용이 필요하다는 한계가 존재한다. 전이 학습은 학습에 필요한 데이터가 부족하거나 학습 시간을 절감시키기 위해 제안되었다.

전이 학습은 이미지 분류 문제를 위해 사전학습(Pre-Trained)된 딥러닝 모델의 레이어 가중치를 다른 데이터 혹은 문제에 활용하는 학습 방법이다[10]. 사전학습된 모델의 가중치를 활용하기 때문에 대량의 훈련 데이터가 필요하지 않고, 출력층(Output Layer)과 가까운 깊은 레벨의 레이어 몇 개의 가중치만 최적화하면 되기 때문에 빠르게 새로운 데이터에 대한 모델의 최적화가 가능하다. 모델의 입력층(Input Layer)에 가까운 얇은 레벨의 레이어에서는 특정 데이터에 한정되지 않은 보편적인 패턴을, 출력층과 가까운 깊은 레벨의 레이어에서는 입력 데이터의 구체적인 고유의 특성을 추출한다. 즉, 사전학습된 딥러닝 모델의 얇은 레벨 레이어에서는 데이터의 일반적인 특성들이 학습되어 있기 때문에, 새로운 데이터를 이용하여 다시 학습한다고 해도, 얇은 레벨의 레이어 가중치는 크게 변동되지 않으므로 전이 학습이 가능하다.

전이 학습은 학습하기 원하는 새로운 데이터와 사전에 학습된 데이터가 유사할수록 그 결과가 좋다. 특히, ImageNet[11]와 같은 초거대 이미지 데이터 셋으로 사전학습된 딥러닝 모델을 사용하는 경우, 새로 학습하기를 원하는 데이터가 사전에 학습된 데이터와 유사할 가능성이 높기 때문에 효과적인 전이 학습이 가능하다.

III. 제안 방법

그림 1은 제안 방법의 전체 프로세스이다. 네트워크 입력 데이터를 전처리한 후 전이 학습을 활용한 생성 이미지 판별 모델 개발의 순서로 진행된다.

1. CIFAKE 데이터 셋

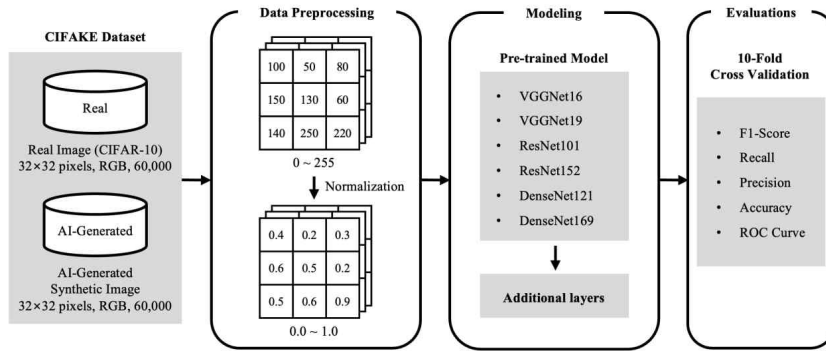


그림 1. 전이 학습 기반의 생성 이미지 판별 모델 개발 순서도
 Figure 1. Flow Chart of Transfer Learning-based Generated Synthetic Images Identification Model

본 연구에서는 120,000개의 비행기, 자동차, 새, 고양이, 사슴, 개, 개구리, 말, 배, 트럭 등 10개 카테고리로 구분된 해상도 32×32 픽셀(Pixels)의 RGB 3-채널(Channels) 컬러 이미지로 구성된 CIFAKE[7] 데이터 셋을 사용한다. CIFAKE 데이터 셋은 60,000개의 CIFAR(Canadian Institute for Advanced Research)-10[12] 실제 이미지와 이를 기반으로 생성된 60,000개의 AI 생성 이미지로 구성되어 있다.

2. 데이터 전처리

딥러닝 프레임워크(Framework)인 케라스(Keras)는 0에서 1 사이의 정규화(Normalization)된 값을 가지는 입력 데이터를 사용하는 경우 최적의 성능을 보인다[13]. 이에 각 픽셀이 0에서 255 사이의 밝기값을 가지는 CIFAKE 데이터 셋의 모든 이미지를 0에서 1 사이의 실수로 변환하기 위해 각 픽셀값을 255로 나누는 과정을 수행한다.

3. 전이 학습을 위한 사전학습 모델

본 연구에서는 VGGNet[14], ResNet[15], DenseNet[16]을 활용하여 전이 학습을 수행한다. VGGNet은 3×3 컨볼루션(Convolution) 레이어가 중첩된 단순한 구조를 가지는 딥러닝 모델이다. ResNet은 단순히 레이어를 깊게 쌓은 딥러닝 모델에서 발생할 수 있는 기울기 소실 문제를 해결하기 위해 몇 개의 레이어를 건너뛰고 정보를 전달하는 잔차 연결(Residual Connection)을 활용하여 잔차 연결 전, 후 레이어의 변화를 효과적으로 학습하는 모델이다. DenseNet은 이전 레이어의 정보를 모든 다음 레이어에 연결(Concatenate)하는 방식으로

기울기 소실 문제를 해결한 모델이다. 실험에는 ImageNet 데이터 셋을 활용해 사전학습 된 VGG16, VGG19, ResNet101, ResNet152, DenseNet121, DenseNet169 등의 6개 모델을 사용한다. 각 모델의 숫자는 레이어의 개수이다.

4. 모델링

사전학습 된 모델을 본 연구의 입력 데이터에 맞게 조정하기 위해 그림 2와 같이 6개의 모델의 마지막 출력층 대신 256, 128, 64개의 노드로 구성된 3개의 은닉층과 1개의 출력층을 사용한다. 각 은닉층의 활성화 함수(Activation Function)로 ReLU(Rectified Linear Unit)를 사용한다. 학습 시 훈련 데이터(Training Set)에 과적합(Over-Fitting)되는 것을 방지하기 위해 첫 번째, 두 번째 은닉층의 25%의 노드들을 랜덤으로 제외하고 각각 192, 96개의 노드의 정보만이 다음 층으로 전달되

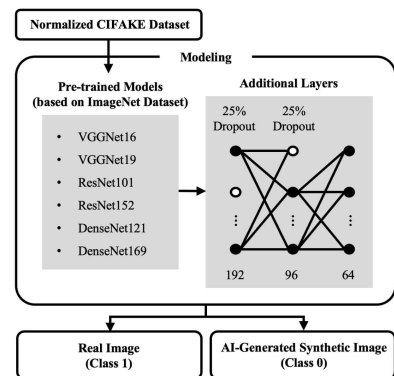


그림 2. 생성 이미지 판별 모델의 전이 학습 구조
 Figure 2. Transfer Learning Architecture of Generated Synthetic Images Identification Model

표 1. 생성 이미지 판별 모델에 사용한 하이퍼파라미터
Table 1. Hyper-parameter of Generated Synthetic Images Identification Model

Hyper-parameter	Value
Learning Rate	0.01 (Drops by a Factor of 0.95 Every Epochs)
Optimizer	Adam Optimizer
Loss Function	Binary Cross Entropy
Batch Size	32
Epoch	100

도록 드롭아웃(Dropout) 레이어를 추가한다. 출력층에서는 시그모이드(Sigmoid) 활성화 함수를 통해 예측 결과가 실제 이미지일 경우 클래스 1을, 예측 결과가 AI 생성 이미지일 경우 클래스 0을 출력한다.

실험을 위해 100,000개의 전처리 된 입력 데이터 셋을 훈련 데이터로, 나머지 20,000개의 입력 데이터 셋을 테스트 데이터(Test Set)로 활용한다.

표 1은 실험에 사용된 하이퍼파라미터(Hyper-parameter)이다. 제안 모델에 사용된 초기 학습

률(Initial Learning Rate)은 0.01로, 매 학습마다 0.95배씩 감소하도록 설정한다. 최적화 함수로는 Adam 옵티마이저(Adaptive Moment Estimation Optimizer)를 사용하고, 손실함수(Loss Function)는 이진 교차 엔트로피(Binary Cross Entropy, BCE), 배치(Batch) 크기는 32, 에폭(Epoch)은 100으로 지정한다. 분석 모델의 정확도를 검증하기 위해 10-Fold Cross Validation을 수행한다.

IV. 실험 및 결과

제안 방법의 성능은 F1-Score, 재현율(Recall), 정밀도(Precision), 정확도(Accuracy), ROC 곡선(Receiver Operating Characteristic Curve, ROC Curve)을 기준으로 평가하였다.

표 2는 사전학습 된 모델의 출력층을 그대로 사용

표 2. 생성 이미지 판별 모델의 정량적 평가
Table 2. Quantitative evaluation of Generated Synthetic Images Identification Model

Model	Datasets	Evaluation [%]				Model	Datasets	Evaluation [%]			
		F1-Score	Recall	Precision	Accuracy			F1-Score	Recall	Precision	Accuracy
VGG16	Training Set	83.75	83.63	83.87	83.77	VGG16 + Additional layers	Training Set	91.59	91.15	92.02	91.62
	10-Fold Cross Validation	83.71	83.62	83.79	83.74		10-Fold Cross Validation	91.19	90.75	91.64	91.24
	Test Set	83.47	83.65	83.29	83.43		Test Set	87.72	87.26	88.19	87.79
VGG19	Training Set	83.34	82.92	83.75	83.42	VGG19 + Additional layers	Training Set	89.53	88.42	90.67	89.66
	10-Fold Cross Validation	83.28	82.86	83.70	83.37		10-Fold Cross Validation	89.20	88.08	90.34	89.34
	Test Set	82.51	82.24	82.79	82.57		Test Set	86.25	85.46	87.05	86.37
ResNet101	Training Set	75.90	75.74	76.05	75.95	ResNet101 + Additional layers	Training Set	96.98	97.44	96.52	96.96
	10-Fold Cross Validation	75.85	75.74	75.96	75.90		10-Fold Cross Validation	94.97	95.51	94.45	94.95
	Test Set	75.07	75.15	74.99	75.04		Test Set	76.61	77.54	75.70	76.32
ResNet152	Training Set	75.32	75.90	74.76	75.14	ResNet152 + Additional layers	Training Set	95.80	95.71	95.90	95.81
	10-Fold Cross Validation	75.22	75.83	74.62	75.04		10-Fold Cross Validation	93.70	93.66	93.75	93.71
	Test Set	74.12	75.06	73.21	73.80		Test Set	75.51	75.93	75.09	75.37
DenseNet121	Training Set	88.29	88.71	87.87	88.23	DenseNet121 + Additional layers	Training Set	94.33	94.22	94.44	94.34
	10-Fold Cross Validation	88.25	88.71	87.80	88.19		10-Fold Cross Validation	93.82	93.70	93.95	93.94
	Test Set	87.83	88.44	87.23	87.74		Test Set	88.90	88.69	89.12	88.93
DenseNet169	Training Set	88.87	89.49	88.26	88.79	DenseNet169 + Additional layers	Training Set	97.08	97.73	96.44	97.06
	10-Fold Cross Validation	88.79	89.42	88.17	88.72		10-Fold Cross Validation	96.27	96.88	95.67	96.25
	Test Set	88.20	88.94	87.47	88.10		Test Set	88.62	88.88	88.35	88.59

했을 때와 3개의 은닉층과 1개의 출력층으로 수정하여 모델을 생성했을 때의 성능을 비교한 결과이다. 기존 모델의 출력층을 그대로 사용한 경우보다, 본 연구에서 제안하는 모델 후반부에 레이어를 추가하고 여러 실험을 통해 최종 레이어를 조정하는 방법을 통해 성능이 향상되었다.

사전학습 된 모델로 VGG16과 VGG19를 사용할 경우, 모든 데이터 셋에서 낮은 성능을 보이는 것을 확인하였다. 이는 단순히 레이어의 깊이를 깊게 쌓는 경우 입력 데이터의 정보가 출력층까지 제대로 전달되지 못하는 것을 의미한다. ResNet101과 ResNet152으로 사전학습을 할 경우 성능은 다소 개선되었으나 학습 데이터에 과적합(Over-Fitting)됨을 확인하였다. 레이어를 깊게 쌓은 딥러닝 모델에서 발생할 수 있는 기울기 소실로 인한 성능 하락을 잔차 연결 구조로 완화하고자 했으나, 그에 따른 모델의 복잡성이 증가하면서 과적합이 나타난 것으로 해석할 수 있다. 사전학습 모델로 DenseNet121과 DenseNet169의 사용이 가장 높은 성능 결과를 보였다. 이전 레이어의 정보를 손실 없이 활용할 수 있기 때문이다(표 2 참조). 공통적으로, 전이 학습을 위해 사용한 VGGNet, ResNet, DenseNet 모두 레이어의 개수가 많은, 깊은 네트워크에서 성능이 평균 1%p 정도 하락하였다. 이는 32×32 픽셀의 작은 크기를 가지는 입력 데이터의 특징이 많은 레이어를 거치며 손실되는 것으로 해석할 수 있다.

그림 3의 ROC Curve를 통해 제안 방법의 테스트 데이터 성능을 시각화하여 분석하였다. ROC Curve의

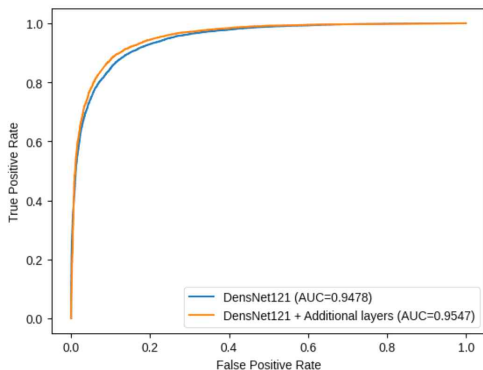


그림 3. 생성 이미지 판별 모델의 ROC 곡선
Figure 3. The ROC Curve of Generated Synthetic Images Identification Model

x축은 FPR(False Positive Rate)를, y축은 TPR(True Positive Rate)를 의미한다. 즉, 곡선이 그래프의 좌상단을 향할수록 좋은 성능의 모델로 해석한다. 그림 3을 통해 사전학습 모델인 DenseNet121 만을 사용한 경우(파란색 선)보다 본 연구에서 제안하는 DenseNet121과 추가 레이어를 사용한 모델(주황색 선)이 보다 좋은 성능을 보임을 알 수 있다.

V. 결론

본 논문에서는 사전학습(Pre-Trained) 된 모델에서 추출한 가중치를 활용해 인공지능(Artificial Intelligence, AI)로 생성한 이미지를 판별하는 모델을 제안하였다. 생성된 가짜 이미지를 판별하는 모델을 구현하기 위해 60,000개의 CIFAR-10 실제 이미지 데이터 셋과 이를 기반으로 생성한 60,000개의 AI 생성 데이터 셋이 포함된 120,000개의 CIFAKE 데이터 셋을 활용하였다. 딥러닝(Deep Learning) 기반의 프레임워크(Framework)인 케라스(Keras)의 최적의 성능을 위해 입력 데이터 셋을 0에서 1 사이의 실수로 정규화(Normalization)하였다. 정규화 한 입력 데이터 셋을 ImageNet 데이터 셋으로 사전학습 된 6개의 모델로 학습시켰다. 사전학습된 모델로 학습 후, 모델의 마지막 출력층(Output Layer) 대신 3개의 은닉층과 1개의 출력층을 사용하였다. 실험 결과, 본 연구가 제안하는 최종 레이어를 조정한 모델이 기존 모델보다 우수한 성능을 보였다. 특히, DenseNet121을 사전학습 모델과 추가 레이어를 사용하는 경우 테스트 데이터(Test Set)의 F1-Score가 88.90%로 가장 높은 성능을 보였다.

본 연구의 결과는 딥러닝에서 최적의 학습 모델을 만들기 위해서는 출력층과 가까운 레이어에서 입력 데이터에 맞게 조정하는 것이 중요함을 나타내고 있다. 결론적으로, 전이 학습을 활용할 경우 작은 이미지에 대해서도 우수한 성능을 얻을 수 있는 강점을 확인하였다.

그러나 연구에서 사용한 입력 데이터 셋의 크기가 32×32 픽셀(Pixels)로 매우 작아, 이미지의 어떤 부분을 기준으로 AI 생성 이미지와 실제 이미지를 판별하는지에 대한 분석에는 한계가 존재하였다. 따라서 향후 연구에서는 더 큰 이미지 데이터 셋을 활용하여 분석하는 연구와 함께 작은 이미지의 해상도를 개선[17]하여 감

별하는 연구를 하고자 한다.

References

- [1] S. Lee, "Deep Structured Learning: Architectures and Applications," *The International Journal of Advanced Culture Technology(IJACT)*, Vol. 6, No. 4, pp. 262-265, 2018. DOI:10.17703/IJACT2018.6.4.262
- [2] L. Verdoliva, "Media forensics and deepfakes: an overview," *IEEE Journal of Selected Topics in Signal Processing*, Vol. 14, No. 5, pp. 910-932, 2020. DOI:10.1109/JSTSP.2020.3002101
- [3] F. Marra, D. Gagnaniello, D. Cozzolino, and L. Verdoliva, "Detection of GAN-Generated Fake Images over Social Networks," *2018 IEEE Conference on Multimedia Information Processing and Retrieval(MIPR)*, pp. 384-389, 2018. DOI:10.1109/MIPR.2018.00084
- [4] D. Kim, S. Choi, and S. Kwak, "Deep Learning Based Fake Face Detection," *Journal of the Korea Industrial Information Systems Research*, Vol. 23, No. 5, pp. 9 - 17, Oct 2018. DOI:10.9723/JKSIS.2018.23.5.009
- [5] J. Kim, S. Hong, and H. Kim, "A StyleGAN Image Detection Model Based on Convolutional Neural Network," *Journal of Korea Multimedia Society*, Vol. 22, pp. 1447-1456, 2019. DOI:10.9717/kmms.2019.22.12.1447
- [6] C. C. Hsu, Y. X. Zhuang, and C. Y. Lee, "Deep Fake Image Detection Based on Pairwise Learning," *Applied Sciences*, Vol. 10, No. 1, pp. 370, 2020. DOI:10.3390/app10010370
- [7] J. J. Bird and A. Lotfi, "CIFAKE: Image Classification and Explainable Identification of AI-Generated Synthetic Images," *arXiv preprint arXiv:2303.14126*, Mar 2023. DOI:10.48550/arXiv.2303.14126
- [8] B. Recht, R. Roelofs, L. Schmidt, and V. Shankar, "Do imagenet classifiers generalize to imagenet?," *International conference on machine learning*, pp. 5389-5400, 2019.
- [9] S. J. Pan and Q. Yang, "A survey on transfer learning," *IEEE Transactions on knowledge and data engineering*, Vol. 22, No. 10, pp. 1345-1359, 2009. DOI:10.1109/TKDE.2009.191
- [10] S. Hong, Y. Lee, and C. Moon, "Transfer Learning-Based Vibration Fault Diagnosis for Ball Bearing," *The Journal of the Convergence on Culture Technology(JCCT)*, Vol. 9, No. 3, pp. 845-850, 2023. DOI:10.17703/JCCT.2023.9.3.845
- [11] J. Deng, W. Dong, R. Socher, L. J. Li, K. Li, and F. F. Li, "Imagenet: A large-scale hierarchical image database," *2009 IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, pp. 248-255, Jun 2009. DOI:10.1109/CVPR.2009.5206848
- [12] A. Krizhevsky, "Learning multiple layers of features from tiny images," *University of Toronto*, May 2009.
- [13] T. Jo, "Deep learning for everyone," *Gilbut INC.*, pp. 308, 2017.
- [14] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *International Conference on Learning Representations(ICLR)*, Sep 2014. DOI:10.48550/arXiv.1409.155
- [15] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," *2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, pp. 770-778, 2016. DOI:10.48550/arXiv.1512.03385
- [16] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," *2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, pp. 4700-4708, 2017. DOI:10.1109/CVPR.2017.243
- [17] C. Dong, C. C. Loy, K. He, and X. Tang, "Image super-resolution using deep convolutional networks," *IEEE transactions on pattern analysis and machine intelligence*, Vol. 38, No. 2, pp. 295-307, Jun 2015. DOI:10.1109/TPAMI.2015.2439281