

Triplet Loss 기반 딥러닝 모델을 통한 유사 아동 그림 선별 알고리즘⁺

(A deep learning model based on triplet losses for a similar child
drawing selection algorithm)

문 지 유¹⁾, 김 민 종²⁾, 이 성 옥³⁾, 유 용 균^{4)*}
(Jiyu Moon, Min-Jong Kim, Seong-Oak Lee, and Yonggyun Yu)

요 약 본 논문은 유사 아동 그림 선별 알고리즘 생성을 위한 Triplet Loss 기반 딥러닝 모델 설계를 목적으로 한다. 아동 그림들 사이 유사성 측정을 위해서는 동일 클래스에 속하는 그림 간 특징 벡터의 거리는 가까워야 하고 다른 클래스 간 특징 벡터의 거리는 멀어져야 한다. 따라서, 본 연구에서는 클래스 수가 많아지는 경우에 이미지 유사성 측정에 이점을 지닌 Triplet Loss와 잔여 네트워크(ResNet)를 결합한 딥러닝 모델을 구축하여 유사 아동 그림 선별 알고리즘을 생성하였다. 결론적으로 본 모델을 활용한 유사 아동 그림 선별 알고리즘을 통해 대상 아동 그림과 다른 그림 간의 유사성을 측정하고 유사성이 높은 그림을 선별할 수 있다.

핵심주제어: 이미지 유사성, Triplet Loss, 인공지능, 딥러닝, CNN, 아동 그림분석

Abstract The goal of this paper is to create a deep learning model based on triplet loss for generating similar child drawing selection algorithms. To assess the similarity of children's drawings, the distance between feature vectors belonging to the same class should be close, and the distance between feature vectors belonging to different classes should be greater. Therefore, a similar child drawing selection algorithm was developed in this study by building a deep learning model combining Triplet Loss and residual network(ResNet), which has an advantage in measuring image similarity regardless of the number of classes. Finally, using this model's similar child drawing selection algorithm, the similarity between the target child drawing and the other drawings can be measured and drawings with a high similarity can be chosen.

Keywords: Image Similarity, Triplet Loss, Artificial Intelligence, Deep Learning, CNN, Child drawing analysis

* Corresponding Author: ygyu@kaeri.re.kr

+ 이 논문은 연구개발특구진흥재단 기술사업화 역량강화사업(세부과제번호: 2021-DD-RD- 0472-01)과 2022년 한국원자력연구원의 주요사업 지원에 의해 연구되었음.

Manuscript received January 08, 2022 / revised February 09, 2022 / accepted February 17, 2022

1) 한국원자력연구원 인공지능융합연구소, 이화여자대학교, 제1저자
2) 한국원자력연구원 인공지능융합연구소, 공동저자
3) 주식회사 티엔에프에이아이, 공동저자
4) 한국원자력연구원 인공지능융합연구소, 교신저자

1. 서론

아동의 현재 심리상태와 내면세계를 파악할 수 있는 방법에는 대표적으로 그림을 통한 심리 분석이 있다. 아동 그림을 통한 심리분석은 대면상담의 형태로 심리 전문상담사에 의해 진행되어왔다. 하지만 이러한 오프라인 상담 방식은 전문가마다 해석의 차이가 있으며 많은 분석시간이 소요된다(Grishick R et al., 2014). 이에 따라 전문상담사를 직접 대면하지 않고 비대면으로 심리를 진단할 수 있는 프로세스의 필요성이 증가하고 있고 최근에는 심리분석의 과정을 인공지능을 활용하여 간편화시키는 연구가 시도되고 있다(Park et al. 2019; Yim, 2021).

현재 인공지능 기술을 활용한 방법으로는 객체 탐지를 통한 그림 심리분석 등이 있으며 이 방법은 그림의 색상정보, 객체 정보(크기, 위치, 종류) 등을 통해 아동의 심리가 분석된다. 본 연구는 대상이 되는 아동 그림과 유사성을 띠는 여러 아동 그림을 선별하여 폭넓은 아동 심리분석을 가능하게 하고자 유사 아동 그림 선별 알고리즘을 개발하는 것을 목적으로 한다. 연구 진행을 위해 (주)티엔에프에이아이에서 제공한 약 2000장의 5-7세 아동 그림 이미지 데이터를 활용하였다. 아동 그림에 그려진 인물과 사물의 객체정보(색상, 크기, 종류)를 활용하여 아동 그림을 크게 3가지 클래스로 구분 짓고 클래스별로 각 200장씩 총 600장의 그림을 직접 선별하였다. 추가로 학습 정확도를 높이기 위해 그림 영역 외의 불필요한 배경을 제거하는 전처리 과정을 진행하였다. 아동 그림 데이터는 Triplet Loss(F. Schroff et al. 2015) 기반 CNN(LeCun et al. 1989) 모델을 통해 학습하였으며, 이때의 CNN 모델은 ResNet(K. He et al., 2016) 중 가장 깊은 층을 지닌 ResNet-152를 사용하였다. 학습된 모델의 성능 평가를 위해서는 KNN과 XGBoost의 두 가지 머신러닝 방법론을 이용하였다. 최종적으로 새로운 아동 그림 이미지를 넣었을 때 이와 가장 유사도가 높은 상위 3개의 그림이 출력되도록 유사 아동 그림 선별 알고리

즘을 생성하였다. 본 논문은 다음과 같은 순서로 구성된다. 먼저, 2장에서는 CNN과 이미지 유사도 측정에 사용되는 손실함수들의 배경적 이론에 관해 설명한다. 3장에서는 본 연구에서 제안하는 딥러닝 모델의 전체 프로세스를 설명하며, 4장에서는 데이터에 대한 설명과 실험 수행 및 결과 해석으로 진행된다. 마지막 5장에서는 본 연구의 결론과 향후 시사점에 관해 이야기한다.

2. 관련 연구

2.1 CNN(Convolutional Neural Network)

CNN(Convolutional Neural Network)은 이미지 데이터 처리에 대표적으로 사용되는 방법 중 하나로 특징 추출 필터들에 의해 자동으로 학습되고 분류되도록 설계된 신경망이다. 합성곱 신경망(CNN)을 기반으로 생성된 딥러닝 모델들은 ILSVRC(ImageNet Large Scale Visual Recognition Challenge) 대회에서 그 성능을 검증받았으며, 특히 이미지와 관련된 연구에 CNN 기반 모델들이 많이 활용하고 있다. 2012년 ILSVRC에서 우승한 AlexNet(A. Krizhevsky et al., 2012)은 7개의 레이어와 2개의 GPU로 구성되어 있으며 LeNet과 비슷한 구조를 띤다. 2014년 우승한 GoogLeNet (Szegedy et al., 2015)은 독특한 구조인 인셉션(Inception) 모듈을 활용하였으며 총 22개의 레이어로 구성되어 있다. 반면, 같은 년도에 준우승한 VGGNet(K. Simonyan et al., 2014)은 GoogleNet보다 낮은 오류율을 기록했지만, 사용 편이성과 구조의 간결함으로 많은 주목을 받았다. 2015년 ILSVRC 대회에서 우승한 ResNet은 잔여 블록(Residual Block)을 사용하여 기존 CNN 모델들보다 더 깊은 구조의 모델들의 학습을 가능하게 하였다. 또한 컨볼루션 레이어 이후에 풀링 레이어 단을 추가시켜 계산량을 크게 감소시켰다. 결과적으로, ResNet은 오류율 3.57% 달성을 통해 사람 인식 오류율인 5%를 뛰어넘는 성과를 보였다.

2.2 이미지 유사도 측정을 위한 손실 함수

이미지 유사도 측정에 사용할 수 있는 손실 함수로 분류 모델에 대표적으로 사용되는 Cross Entropy 손실 함수가 있다. Cross Entropy 손실 함수는 데이터의 실제값과 예측값을 비교하며, 그 값이 일치할 경우에는 함수의 값이 0으로 수렴하게 되고 값이 일치하지 않는 경우에는 함수 값이 커지게 된다. 즉, Cross Entropy 함수는 두 확률분포의 차이가 어느 정도인지를 알려주는 정량적인 지표로써 활용된다.

아동 그림은 그림을 그린 대상에 따라 그림의 특성이 매우 다양하므로 특정 아동 그림에 대한 유사 그림 선별을 위해서는 서로 유사성을 지니지만 다양한 특징을 지닌 데이터를 인식해야 한다. 즉, 동일 클래스 내의 그림들의 특징 벡터는 서로 거리가 가까워야 하고 서로 다른 클래스 간 특징 벡터들의 거리는 멀어야 한다. 하지만 이는 분류 모델에서 주로 사용되는 Cross Entropy 함수로는 달성하기에 어려움이 있다.

반면, G. Koch(2015)가 제안한 삼 네트워크(Siamese Network)의 손실 함수인 Contrastive Loss(대조적 손실 함수)는 아동 그림 간 유사성을 측정하는데 이점을 지니고 있다. Contrastive Loss를 사용하는 네트워크는 Cross Entropy와 달리 두 개의 입력 이미지를 받으며 이미지 간 유사성 학습을 위해 동일 파라미터들을 공유한다. 학습에 Contrastive Loss를 사용할 시, 두 그림의 클래스가 같은 경우 특징 벡터 간 거리는 최소화되고 두 그림의 클래스가 서로 다른 경우

지정 길이 만큼 거리가 멀어지게 된다. 하지만 두 입력값이 임의로 선택되기 때문에 두 데이터가 같은 클래스인 경우보다 다른 클래스인 경우가 확률적으로 많다. 이는 클래스 수가 증가함에 따라 불균형을 일으키며 학습에 부정적인 영향을 미치게 된다.

Triplet Loss는 세 개의 입력을 받는 손실 함수로 Contrastive Loss의 학습 시 문제점을 해결하면서 더 안정적인 학습을 가능하게 한다. Triplet Loss를 사용하는 네트워크는 Fig. 1과 같이 기본 이미지인 Anchor, 기본 이미지와 동일 클래스에 속하는 Positive, 기본 이미지와 다른 클래스에 속하는 Negative의 세 입력값을 받는다. Triplet Loss를 손실 함수로 사용할 경우 Anchor와 Positive의 거리는 가까워지게, Anchor와 Negative의 거리는 멀어지게끔 학습이 진행된다. 즉, Triplet Loss를 이용할 시 클래스 개수와 관계없이 안정적이고 균형적인 학습이 가능하다.

3. Triplet loss 기반 딥러닝 모델

3.1 ResNet

딥러닝에서 모델의 층의 개수는 모델의 성능에 크게 영향을 미치는 요소 중 하나이다. 즉, 딥러닝 성능 향상을 위해 다양한 분야에서 점점 더 깊은 네트워크가 사용되고 있다. 하지만, 모델이 깊어짐에 따라 역전파(Back-propagation) 수행 시 초기 레이어의 학습 시 문제가 발생하였다. 이는 기울기 손실(Gradient Vanishing)의 문제로 레이어의 개수에 비례하여 모델의 성능이 떨어지는 한계를 보이게 하였다. 이러한 문제를 해결하고자 ResNet이 제안되었다.

ResNet은 모델의 깊이가 깊어짐에 따라 발생하는 학습 시 오류를 최소화하기 위해 잔여 블록(Residual Block)을 이용하였다. Fig. 2와 같이 잔여 블록에서는 항등 함수를 이용하여 본래의 특징을 다른 레이어로 쉽게 전파할 수 있다. 이는 기존 컨볼루션 신경망보다 깊은 모델을




Fig. 1 Triplet Loss Learning Process

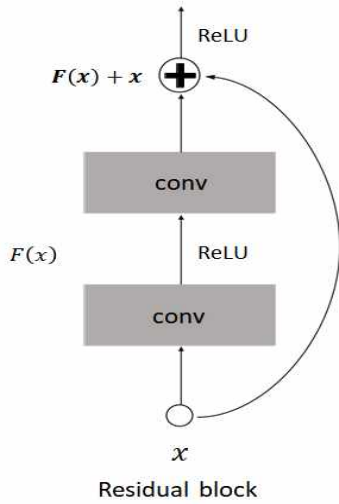


Fig. 2 Residual Block Structure

학습할 수 있게 하여 학습 효율성을 크게 증가시켰다.

본 연구에서는 Resnet 모델 중 가장 깊은 모델이며 총 152개의 layer를 지닌 ResNet-152을 이용하여 아동 그림의 특징 추출 과정을 거쳤다. 사용된 Resnet-152 구조는 Table 1과 같다.

3.2 Triplet loss(삼중항 손실)

Triplet loss를 이용한 딥러닝 모델에서는 Anchor, Positive, Negative 3개의 입력값이 필요하다. 먼저 Anchor, Positive, Negative가 입력되면, 세 이미지 각각이 같은 파라미터를 공유하는 CNN 모델을 거치게 되는데 이 과정을 통해 특징 벡터가 생성된다. 특징 추출단계 이후에는 학습이 진행되는데 이때 손실함수로 Triplet Loss가 사용된다. Triplet Loss는 특징 추출단계를 거쳐 생성된 Anchor, Positive, Negative의 특징 벡터들을 입력값으로 받는다. 학습은 Anchor와 Positive 특징 벡터 사이의 거리는 최소로, Anchor와 Negative 특징 벡터 사이 거리는 최대가 되는 방향으로 진행된다. Triplet Loss 손실함수는 식(1)과 같이 나타낼 수 있다.

$$L = \max(0, d(a, p) - d(a, n) + margin) \quad \text{식(1)}$$

Table 1 ResNet-152 Structure

layer name	152-layer	output size
conv1	7x7, 64, stride 2	112x112
conv2_x	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	56x56
conv3_x	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$	28x28
conv4_x	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$	14x14
conv5_x	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	7x7
GAP	Global Average Pooling layer	1x1

식(1)에서 $d(a, p)$ 는 Anchor와 Positive 특징 벡터 사이의 유클리드 거리를 $d(a, n)$ 은 Anchor와 Negative 특징 벡터 사이의 유클리드 거리를 의미한다. $margin$ 은 $d(a, p)$ 와 $d(a, n)$ 쌍 사이의 거리 차이를 의미하며 임의의 $margin$ 값을 지정 해주면 $d(a, p)$ 보다 $d(a, n)$ 가 임의의 값보다 크게 학습이 진행된다. 즉, 이를 통해 Anchor와 Positive 사이의 거리는 최소화되고 Anchor와 Negative 사이의 거리는 최대화된다.

Fig. 3은 본 연구에서 제안하는 아동 그림 유사 유형 선별 알고리즘을 위한 Triplet Loss 기반 딥러닝 모델을 시각화한 것이다. 모델은 ResNet-152로 구성된 잔여 네트워크와 Triplet loss를 합친 구조이다. 입력 이미지인 Anchor, Positive, Negative는 같은 가중치를 공유하고 있는 ResNet-152를 각각 거치게 되고 이 과정을 통해 입력값의 특징 벡터가 추출된다(1. Feature extraction). 이후 단계에서는 추출된 데이터의 특징 벡터를 이용하여 Triplet Loss를 이용한 학습이 진행된다(2. Learning). 최종적으로 전체 네트워크 구조는 ResNet-152를 통한 특징 추출단계와 Triplet Loss를 이용한 학습 단계로 이루어진다.

3.3 유사 아동 그림 선별 알고리즘

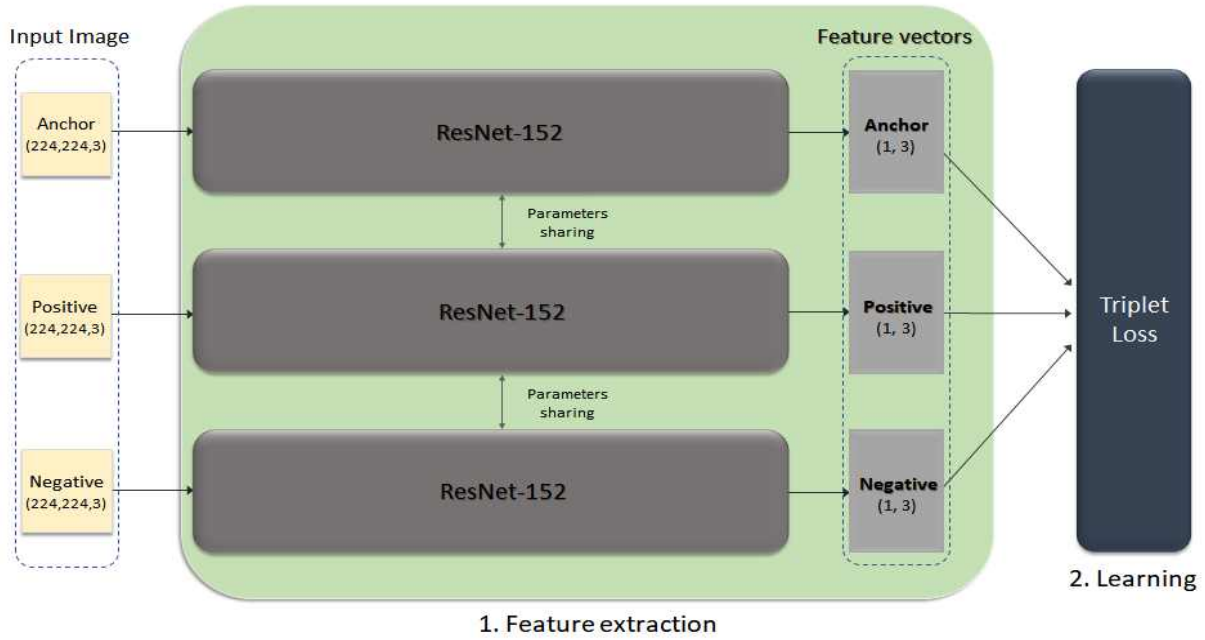


Fig. 3 Triplet Loss based Deep-learning Model Structure

학습된 Resnet-152 + Triplet Loss 모델을 통해 유사 아동 그림 선별 알고리즘을 생성하였다. 대상이 되는 아동 그림과 전체 아동 그림을 학습된 모델을 거쳐 특징 벡터를 전환 시키고 대상 그림의 특징 벡터와 전체 아동 그림의 특징 벡터 사이의 유클리디안 거리를 계산하여 대상 그림으로부터 거리가 가장 가까운 상위 3개의 아동 그림을 추출하였다. 유사 아동 그림 선별 알고리즘의 전체 과정은 Fig. 4와 같다. 유클리디안 거리는 n차원의 공간에서 두 점 사이의 거리를 의미하며, 벡터 간 거리를 기반으로 유사도를 측정할 때 주로 사용된다. 식(2)는 유클리디안 거리를 구하는 식이며, x 와 y 는 유클리디안 공간상 서로 다른 두 점을 의미한다.

$$D(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad \text{식(2)}$$

4. 실험

4.1 데이터 셋 & 모델 평가 방법

본 연구에서는 ㈜티엔에프에이아이에서 제공한 아동 그림 데이터로 실험을 진행하였다. 아동 그림 데이터는 그림들의 인물(갯수, 크기, 사용한 색상 등)정보, 객체(집, 나무, 없음 등)정보, 그림을 그린 아동의 나이, 특징 군(일반군, 격려군)을 활용하여 임의의 3개의 클래스를 생성하

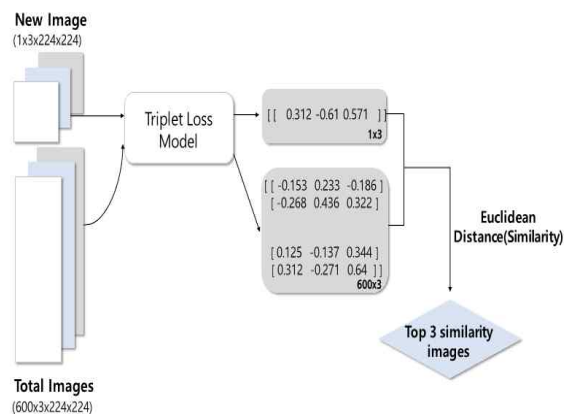


Fig. 4 Process of Similar Child Drawing Selection Algorithm




Fig. 5 Example of Images by Class

고 이에 적합한 그림들을 클래스별로 200장씩 직접 선별하였다. 각 클래스에 속하는 아동 이미지는 Fig. 5와 같다. (a)는 다양한 색상을 사용하여 한 명의 인물을 그린 그림으로 (a)와 비슷한 특징을 지닌 그림들은 0 클래스로 분류하였다. (b)는 (a)와 같이 한 명의 인물이 그려진 그림이지만 단조로운 색상 사용과 그림의 형태가 명확히 파악되지 않는 특징을 지니고 있다. (b)와 같은 특징을 지닌 그림들은 1 클래스로 분류하였다. (c)는 사람, 나무, 집 등의 객체를 다양한 색상을 이용하여 그린 그림이며 이 같은 특징을 지닌 그림들은 2 클래스로 분류하였다. 또한, 본 연구에서 제안한 Triplet Loss 기반 딥러닝 모델의 성능 평가를 위해 학습 전 데이터를 8:2의 비율로 훈련 데이터와 테스트 데이터로 분리하였다.

모델 평가 방법으로는 KNN (K-Nearest Neighbor)과 XGBoost 두 가지 머신러닝 방법론을 사용하였다. 테스트 데이터를 먼저 학습된


Triplet loss 기반 딥러닝 모델에 통과시켜 특징 벡터를 추출한다. 추출된 특징 벡터들은 KNN과 XGBoost의 입력이 되고 특징 벡터들의 정보를 이용하여 클래스를 예측한다.

KNN은 새로운 데이터가 들어오면 이로부터 가장 인접해있는 k개의 데이터를 찾고, 그 특성을 이용해 대상이 되는 데이터의 클래스를 예측하는 기법이다. 즉, 특정 데이터가 주어졌을 때 이와 가장 가까이 있는 k개의 표본을 찾고 함께 그룹 지어 그룹 안에 표본들의 빈도수가 많은 클래스로 해당 데이터를 예측한다. KNN 유사도 측정 방법에는 가장 대표적으로 사용하는 유클리디언 거리 방식을 이용하였으며, k 값은 적은 test 데이터 수와 클래스 개수를 고려하여 3으로 지정하였다.


XGBoost는 앙상블 학습 중 Boosting 방식의 대표적인 예로 앙상블 학습을 이용 시 과적합을 줄일 수 있으며 모델의 정확도를 향상시킬 수 있다는 장점이 있다. 또한, 기존의 머신러닝 부스팅 알고리즘과 비교했을 때, 내부적으로 결측치 처리가 자동화되어있고 병렬처리가 가능해 데이터의 크기와 관계없이 비교적 안정하고 빠른 훈련이 가능하다.

4.2 Implementation details

전체 데이터의 80% 비중을 차지하는 480장으로 학습을 진행하였으며 학습 시 배치 크기는



(a) Data Distribution Before Learning



(b) Data Distribution After Learning.

Fig. 6 Training Results Using Triplet Loss

데이터의 크기를 고려하여 10으로 지정하였다. 학습률(learning rate)은 0.005를 사용하였고 Adam optimizer로 최적화하였다. 또한 Triplet Loss 식의 margin은 5로 지정해주었다. 모델을 총 200회 학습하는데 대략 6시간의 시간이 소요되었고 학습은 Windows10 환경에서 NVIDIA GeForce RTX 3090 GPU를 사용하였다.

4.3 실험결과

Fig. 6의 (a)는 학습 전 유클리디안 공간상의 데이터를 시각화한 것이며 (b)는 Triplet Loss를 이용하여 학습한 후의 데이터의 위치를 시각화한 것이다. 이때의 x, y, z축은 각각 특징 벡터의 차원에서의 값을 의미한다. Triplet loss를 이용해 학습한 (b)의 경우 동일 클래스 내 거리는 가깝게, 클래스 간 거리는 멀어지게끔 학습이 이루어진 것을 확인할 수 있다.

Triplet Loss와 Contrastive Loss로 학습하여 생성된 모델을 KNN, XGBoost의 머신러닝 기법을 이용하여 모델의 성능을 평가하였다. Table 2는 두 머신러닝 방법으로 평가한 Triplet Loss, Contrastive Loss로 학습된 각각의 모델의 정확도를 나타낸다. KNN과 XGBoost 두 가지 방식으로 성능 평가한 결과, Triplet Loss를 사용한 모델의 정확도가 93.33%, 91.6%로 Contrastive Loss를 사용한 모델의 정확도인 86.67%, 83.33%보다 각 6.66%, 8.27% 더 높았다. 이는 Contrastive Loss보다 발전된 Triplet Loss를 사용함으로써 다양한 특성을 지닌 아동 그림에서 더욱 차별화된 특징이 추출되었기 때문이다. 또한, 손실함수와 관계없이 거리기반으

Table 2 Accuracy of Each Machine Learning Method

	KNN	XGBoost
ResNet-152 + Triplet Loss	93.33%	91.6%
ResNet-152 + Contrastive Loss	86.67%	83.33%

로 클래스를 분류하는 KNN에서의 정확도가 XGBoost의 정확도 보다 더 높았다. 이는 Triplet Loss를 사용한 모델이 유클리디안 공간에서 거리 정보를 이용, 변경하여 학습을 진행했기 때문이다.

아동 그림 이미지와 알고리즘을 통해 선별된 상위 3개 유사 아동 그림 이미지를 Fig. 7에 나타내었다. (a)는 0 클래스에 속하는 이미지로 이와 유사한 상위 3개 이미지는 모두 0 클래스에 속하는 것을 확인할 수 있다. 또한 각각 1과 2 클래스에 속하는 (b)와 (c)도 이와 유사한 상위 3개의 그림이 동일 클래스에서 선별된 것을 확인할 수 있다.

5. 결론

본 연구에서는 Triplet Loss 기반 딥러닝 모



Fig. 7 Example of Similarity Image extraction

델을 사용하여 아동 그림 유사유형을 선별할 수 있는 알고리즘을 개발하였다. 해당 딥러닝 모델은 ResNet과 Triplet Loss를 합한 구조로 다양한 특성을 보이는 아동 그림에서 더 차별화되고 세밀한 특징을 추출해 유사한 아동 그림을 선별하는 것을 가능하게 한다. ResNet 모델 중에서는 가장 많은 층을 지닌 ResNet-152를 사용하였으며 ResNet 모델의 잔여 블록을 이용해 깊은 모델을 효과적으로 학습할 수 있게 하였다. ResNet을 거치며 생성된 특징 벡터들은 이미지 유사성 측정에 주로 사용되는 Contrastive Loss와 이를 발전시킨 Triplet Loss를 이용하여 학습 및 모델성능 평가를 하였고 제안된 Triplet Loss기반 딥러닝 모델이 좋은 성능을 지니는 것을 확인하였다. 본 연구에서는 주관적인 근거에 의해 아동 그림을 3개의 클래스로 나누었지만, 심리 전문가의 보다 객관적인 근거에 의거하여 아동 그림의 유형이 세분화된 경우에도 적용될 수 있어 아동 그림을 통한 심리분석 발전에 이바지할 수 있다. 결과적으로 아동 그림과 유사한 여러 다른 아동 그림의 선별을 통해 사용자는 아동에 대한 심리를 이해하는 데 하나의 지표로 이를 활용할 수 있다.

References

- A. Krizhevsky, I. Sutskever, and G. E. Hinton. (2012). Imagenet classification with deep convolutional neural networks, In *Advances in neural information processing systems* (pp.1097-1105)
- F. Schroff, D. Kalenichenko, and J. Philbin. (2015). Facenet: A unified embedding for face recognition and clustering, *Proceedings of the IEEE conference on computer vision and pattern recognition*,
- G. Koch, R. Zemel, and R. Salakhutdinov. (2015). Siamese neural networks for one-shot image recognition, *ICML deep learning workshop*, vol. 2
- Grishick, R., Donahue, J., Darrell, T., & Malik, J.(2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 580-587)
- K. He, X. Zhang, S. Ren, and J. Sun. (2016). Deep residual learning for image recognition, In *Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE (pp. 770-778).
- K. Simonyan, and A. Zisserman. (2014). Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*
- Park, J., Shin, S., Kim, J. Y., Park, K. H., Lee, S., Jeon, M., Kim, S. (2019). Preliminary Research of HTP Sentiment Analysis Automation on Children's Drawings. *The HCI Society of Korea conference*, 867-871
- Szegedy, Christian, et al. (2015). Going deeper with convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*.
- Yim, J., Lee, S.-O., Kim, K.-P., & Yu, Y. (2021). Application of object detection algorithm for psychological analysis of children's drawing. *Journal of the Korea Industrial Information Systems Research*, 26(5), 1 - 9.



문 지 유 (Jiyu Moon)

- 이화여자대학교 자연과학대학 통계학과 학사과정
- (현재) 한국원자력연구원 인공지능응용연구실 정부훈련생
- 관심분야: 딥러닝, 인공지능, 데이터마이닝



김 민 종 (Min-Jong Kim)

- 과학기술연합대학원대학교 컴퓨터 소프트웨어 공학박사
- (현재) 한국원자력연구원 인공지능응용연구실 선임연구원
- 관심분야: 컴퓨터 비전, 딥러닝, 인공지능



이 성 옥 (Seong-Oak Lee)

- 대전대학교 보건의료대학원 예술치료학 석사
- (현재) (주)티엔에프에이아이 대표이사, 한국여성벤처협회 이사
- 관심분야: 아동, 여성, 양육, 인문, ICT융합기술



유 용 균 (Yonggyun Yu)

- 한국과학기술원 기계공학과 공학박사
- (현재) 한국원자력연구원 인공지능응용연구실 책임연구원
- 관심분야: 인공지능, 기계설계, 이상탐지