

Facial Emotion Recognition in Children Using Convolutional Neural Network with Data Augmentation

Hyora Lee*, Beom Kwon**

*Undergraduate, Coll. of Interdisciplinary Studies for Future Talent Development (Tax & Accounting), Dongduk Women's University, Seoul, Korea

**Assistant Professor, Div. of Interdisciplinary Studies in Cultural Intelligence (Data Science), Dongduk Women's University, Seoul, Korea

[Abstract]

In this study, we investigate how to recognize children's emotions from their face images. Children's face image datasets are fewer in number than adult face image datasets and are often not publicly available on the Internet due to child research ethics. In this study, we propose a new data augmentation technique to improve the emotion recognition accuracy of the convolutional neural network (CNN) model in a situation where the number of samples in the child face image dataset is limited. To demonstrate the effectiveness of the proposed data augmentation technique, we conducted experiments using the child face image dataset of the National Institute of Mental Health, which is publicly available on the Internet. The experimental results showed that the CNN model achieved the best performance in the emotion recognition task when the proposed data augmentation technique was applied.

▶ **Key words:** Child Abuse, Convolutional Neural Network, Data Augmentation, Deep Learning, Face Detection, Facial Emotion Recognition

[요 약]

본 연구에서는 아동의 얼굴 이미지(Face Image)로부터 아동의 감정을 인식하는 방법을 연구했다. 아동 얼굴 이미지 데이터 세트(Dataset)는 성인 얼굴 이미지 데이터 세트보다 개수도 적고, 아동 연구 윤리를 이유로 인터넷상에 공개되지 않는 경우가 많다. 이에 본 연구에서는 아동 얼굴 이미지 데이터 세트의 샘플(Sample) 수가 한정된 상황에서, 합성곱 신경망(Convolutional Neural Network, CNN) 모델의 감정인식 정확도를 높이기 위해서 새로운 데이터 증강 기법을 제안한다. 그리고 인터넷상에 공개된 미국 국립 정신건강 연구소의 아동 얼굴 이미지 데이터 세트를 활용하여 제안하는 데이터 증강 기법의 효용성을 입증하기 위한 실험을 수행했다. 실험 결과에 따르면, 제안하는 데이터 증강 기법을 적용했을 때 CNN 모델이 감정인식 작업에서 가장 우수한 성능을 달성하는 것을 입증했다.

▶ **주제어:** 아동학대, 합성곱 신경망, 데이터 증강, 딥러닝, 얼굴 검출, 얼굴 감정인식

- First Author: Hyora Lee, Corresponding Author: Beom Kwon
- *Hyora Lee (lhr06028@naver.com), Coll. of Interdisciplinary Studies for Future Talent Development (Tax & Accounting), Dongduk Women's University
- **Beom Kwon (bkwon@dongduk.ac.kr), Div. of Interdisciplinary Studies in Cultural Intelligence (Data Science), Dongduk Women's University
- Received: 2025. 01. 03, Revised: 2025. 01. 17, Accepted: 2025. 01. 24.

I. Introduction

아동학대란 보호자를 포함한 성인이 아동의 건강 또는 복지를 해치거나 정상적 발달을 저해할 수 있는 신체적·정신적·성적 폭력이나 가혹행위를 하는 것과 아동의 보호자가 아동을 유기하거나 방임하는 것을 말한다. 최근까지도, 인천 모텔 쌍둥이 영아 사망사건, 제부도 영아 시신 유기 사건, 여수 쌍둥이 영아 살해 사건, 청주 장애 아동 살인사건 등 아동학대와 관련된 사건 사고가 잇달고 있어, 학대받는 아동을 보호하기 위한 제도적 기반을 마련해야 한다는 주장이 나오고 있다[1-3].

이에 대한 일환으로, 아동학대 범죄에 대한 처벌 강화를 목적으로 하는 「아동학대범죄의 처벌 등에 관한 특례법(이하 아동학대처벌법이라 함)」이 2014년 9월 29일에 제정됐다. 이후 제도상의 미비점을 보완한 해당 법안의 개정안이 2021년 2월 26일에 국회 본회의에서 통과되어 2021년 3월 16일부터 시행되고 있다. 하지만 아동학대처벌법이 시행되고 있음에도 불구하고, 보건복지부에서 2024년 8월 30일에 공개한 ‘2023년 아동학대 주요통계’에 따르면, 2019년부터 2023년까지 최근 5년간 아동학대 신고접수건수는 지속해서 증가하는 추세인 것으로 나타났다[4].

대한민국에서는 아동학대를 예방하고 아동의 피해 사상을 조기에 발견해 피해를 최소화하기 위해서, 출생 후 4개월부터 생후 71개월까지 6세 미만을 대상으로 하는 영유아 건강검진 제도를 시행하고 있다. 하지만 영유아 건강검진은 의무 검진이 아니므로, 아동학대 정황이 발각되는 것을 회피하기 위해 영유아 건강검진을 의도적으로 받지 않더라도 부모에게 법적으로 가해지는 처벌이 없다. 또한, 6세 이상의 아동은 영유아 건강검진의 대상이 아니므로, 6세 이상 아동에게 가해지는 아동학대를 발견하는 것은 아동 본인 또는 주변 이웃의 신고에 의존할 수밖에 없는 상황이다.

E. K. Kim et al.은 [5]에서 서울 소재 초등학교 4~6학년 아동 737명을 대상으로 한 조사 결과로부터, 학대를 경험한 아동이 학대를 경험하지 않은 아동에 비해서 높은 우울과 공격성을 보인다는 것을 밝혔다. 본 연구에서는 [5]의 결과로부터, 아동학대 여부를 판단하는 데 아동의 감정 상태를 파악하는 것이 간접적으로 도움이 될 수 있다고 판단해, 아동의 감정을 인식하는 방법을 연구했다. 특히, 아동은 자신이 아동학대를 당하고 있음을 언어적으로 표현하는 것을 어려워하기 때문에[6], 본 연구에서는 표정이라는 비언어적인 요소에 주목했다. 구체적으로는, 아동의 얼굴 이미지(Face Image)로부터 아동의 감정 상태를 인식하는

방법에 관해 연구를 수행했다.

연구 수행을 위해서 아동 얼굴 이미지 데이터 세트(Dataset)의 종류를 조사하던 중, 현재까지 얼굴 감정인식 연구의 대부분은 성인을 대상으로 이뤄졌으며, 인터넷(Internet)상에 공개된 얼굴 이미지 데이터 세트도 성인이 피험자로 참여해 구축된 것이 대다수라는 것을 알게 됐다. 아동 얼굴 이미지 데이터 세트는 성인 얼굴 이미지 데이터 세트보다 개수도 적고, 아동 연구 윤리를 이유로 인터넷상에 공개되지 않은 데이터 세트도 있었다. 이에 본 논문에서는 아동 얼굴 이미지 데이터 세트의 샘플(Sample) 수가 한정된 상황에서, 합성곱 신경망(Convolutional Neural Network, CNN) 모델의 감정인식 정확도를 높이기 위해서 새로운 데이터 증강(Data Augmentation, DA) 기법을 개발 및 제안한다. 본 연구의 기여 포인트(Contribution Points)는 다음의 두 가지로 요약할 수 있다.

- 소규모 데이터 세트에서도 CNN 모델이 안정적으로 학습할 수 있도록 돕는 새로운 데이터 증강 기법을 제안한다. 제안하는 데이터 증강 기법은 증강 이미지를 생성하는 방식에 따라 네 가지로 분류된다.
- 제안하는 데이터 증강 기법의 효용성을 입증하기 위해서, 인터넷상에 공개된 아동 얼굴 이미지 데이터 세트를 이용해 실험을 수행했다. 실험 결과에 따르면, 기존 데이터 증강 기법과 비교해서, 제안하는 데이터 증강 기법을 이용했을 때 CNN 모델이 더 높은 감정인식 정확도를 달성했다.

본 논문의 구성은 다음과 같다. 2장에서는 아동 감정인식에 관련된 선행 연구 검토 내용을 소개한다. 3장에서는 아동 감정인식을 위해, 본 논문에서 제안하는 데이터 증강 기법을 소개한다. 4장에는 제안하는 데이터 증강 기법의 성능 평가를 위해 사용한 데이터 세트와 실험 결과가 기술되어 있다. 5장에는 본 논문의 결론이 기술되어 있다.

II. Related Work

지난 수십 년간, 아동의 얼굴 이미지로부터 아동의 감정을 인식할 수 있는 다양한 방법들이 꾸준히 연구됐다. 예를 들어, M. Rathod et al.은 [7]에서 온라인 교육 플랫폼(Platform)에서 교사와 학생 사이의 원활한 상호작용을 돕기 위해, 아동의 얼굴 이미지로부터 감정을 인식하는 방법에 관한 연구를 수행했다. 6세부터 12세까지 총 12명의 아동의 얼굴을 녹화해 구축한 LIRIS-CSE(LIRIS Children Spontaneous Facial Expression) 비디오 데이터베이스

(Video Database)[8]를 사용했으며, 일곱 가지의 서로 다른 구조를 갖는 CNN 모델에 대해 감정인식 성능을 평가 및 비교했다.

U. Laraib et al.은 [9]에서 VGG16, VGG19[10], ResNet50[11]을 특징 추출기(Feature Extractor)로, 서포트 벡터 머신 (Support Vector Machine, SVM)을 분류기(Classifier)로 사용해, 아동의 얼굴 이미지로부터 감정을 인식하는 방법을 제안했다. LIRIS-CSE 비디오 데이터베이스를 사용해 실험을 수행했으며, 실험 결과에 따르면 특징 추출기로 VGG19를 사용했을 때 SVM의 감정인식 정확도가 94%로 가장 높았다.

F. M. Talaat은 [12]에서 자폐 청소년을 대상으로, 감정인식 기술을 제안했다. 제안 기술에는 CNN 모델이 활용됐으며, CNN 모델을 평가하기 위해서 여섯 개의 감정 클래스(Class)로 구성되어 있는 자폐 어린이 얼굴 데이터 세트를 사용했다. 데이터 세트에는 감정별로, 화남(Anger) 70장, 두려움(Fear) 33장, 기쁨(Joy) 392장, 무표정(Neutral) 55장, 슬픔(Sadness) 214장, 놀람(Surprise) 69장으로 총 833장의 이미지가 포함됐다. 실험 결과에 따르면, CNN 모델은 자폐 청소년의 감정 상태를 99.99%의 정확도로 인식했다.

F. M. Talaat et al.은 [13]에서 아동기의 자폐 스펙트럼 장애를 조기에 진단하기 위해서, 얼굴 감정인식 기술을 제안했다. 인식하고자 했던 감정의 종류는 여섯 가지(화남, 두려움, 기쁨, 무표정, 슬픔, 놀람)였다. 오토인코더(Autoencoder)를 특징 추출기로 활용했으며, 추출한 특징을 사용해 주어진 아동 얼굴 이미지로부터 감정을 분류할 수 있도록, ResNet, MobileNet[14], Xception[15]을 학습시켰다. 실험 결과에 따르면, 세 가지 모델 중 Xception이 정확도 95.2%로 가장 높은 성능을 달성했다.

최근, 얼굴 감정인식 기술은 아동 관련 분야에 국한되지 않고 다양한 분야에 도입되고 있다. 예를 들어, S. Chu et al.은 [16]에서 자살 시도자 및 자살 고위험군이 보이는 자살 경고신호를 조기에 발견하기 위해서 얼굴 이미지에서 감정 상태를 인식할 수 있는 기술을 제안했다. 제안하는 기술은 얼굴 이미지에서 기하학적 특징과 경사지향 히스토그램(Histogram of Oriented Gradients, HOG) 특징을 추출하고, 이 특징을 머신러닝(Machine Learning, ML) 모델의 입력 벡터로 활용한다. 제안하는 특징의 효용성을 검증하기 위해서 네 가지 ML 모델을 대상으로 실험을 수행했다. 실험 결과에 따르면, 4가지 ML 모델 중에서 로지스틱 회귀(Logistic Regression) 모델이 가장 우수한 성능을 달성했다.

B. Kwon은 [17]에서 인터넷상에 공개된 얼굴 이미지 데이터 세트의 대부분이 모델을 훈련하기에는 부족한, 소규모 데이터 세트이며, 이는 인간-컴퓨터 상호작용(Human-Computer Interaction, HCI), 고객 서비스 등에서 얼굴 감정인식 기술을 활용하는 데 저해하는 요인이 된다고 언급했다. 그리고 B. Kwon은 이를 해결하기 위해서 합성곱 오토인코더(Convolutional Autoencoder, CAE)를 활용한 데이터 증강 기술을 제안했다. 실험 결과에 따르면, CAE 기반 데이터 증강 기술을 통해 생성된 증강 이미지를 포함해 LeNet-5 모델을 훈련한 경우, 포함하기 전과 비교해 감정인식 정확도가 21% 개선됨을 보였다.

III. Proposed Method

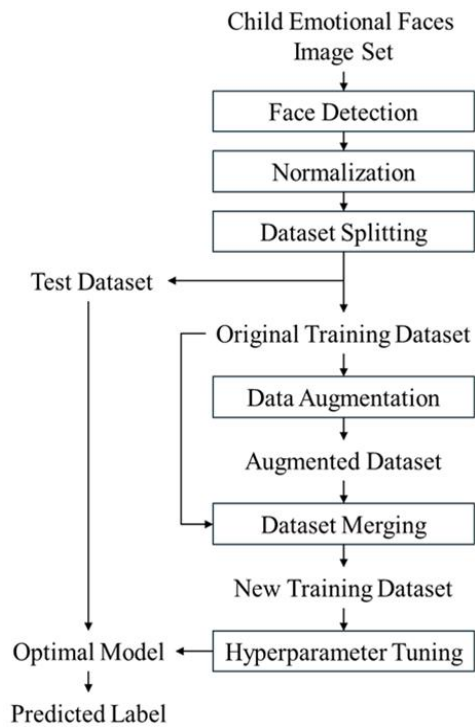


Fig. 1. Overall Process of the Facial Emotion Recognition Using the Proposed Data Augmentation Method.

그림 1은 본 연구에서 제안하는 데이터 증강 기법을 이용한 얼굴 감정인식의 전체 과정을 보여준다. 가장 먼저 원본 이미지에서 얼굴 영역을 검출하는데, 그 이유는 증강 이미지 생성 과정에서 원본 이미지를 사용할 경우, 생성된 증강 이미지에서 눈, 코, 입 등이 심하게 왜곡될 수 있기 때문이다. 왜곡을 완화하기 위해서 본 연구에서는 원본 이미지에서 검출해 낸 얼굴 이미지를 활용해 데이터 증강을

수행한다. 본 연구에서 제안하는 데이터 증강 기법은 증강 방식에 따라 네 가지로 분류된다. 표현의 간결성을 위해서 각 데이터 증강 방식을 DA1, DA2, DA3, DA4라고 표기하였다.

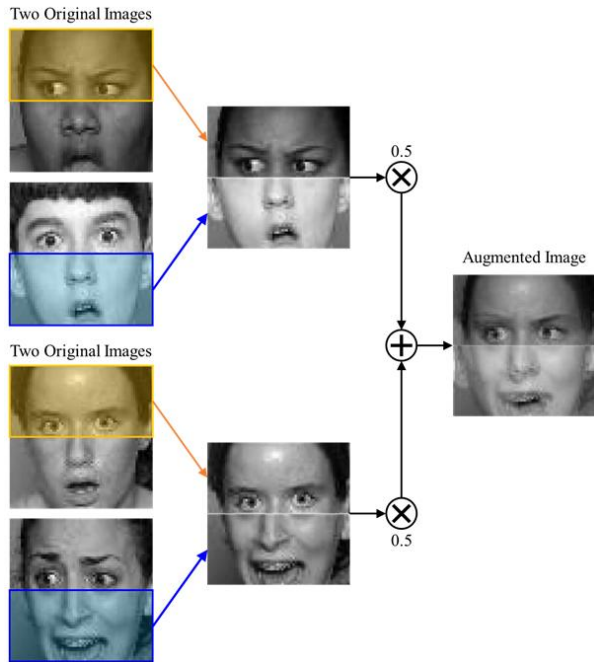


Fig. 2. Process of the Proposed DA1.

그림 2는 제안하는 DA1의 데이터 증강 절차를 보여준다. 가장 먼저, 학습 데이터 세트(Training Dataset)에서 같은 감정 클래스에 속한 4장의 아동 얼굴 이미지를 비복원 추출한다. 설명의 이해를 돕기 위해 랜덤으로 추출된 4장의 이미지를 각각 Img1, Img2, Img3, Img4라고 하자. 그러면, Img1의 상단 부분과 Img2의 하단 부분을 결합한다. 그다음 Img3의 상단 부분과 Img4의 하단 부분을 결합한다. 결합을 통해 얻은 2장의 이미지에 각각 0.5씩 곱한다. 다음, 두 이미지를 더함으로써 증강 이미지를 생성한다. 이때 0.5를 곱하는 이유는, 0.5를 곱하지 않고 두 이미지를 더하게 되면 값이 255인 픽셀(Pixel)의 수가 많아지게 되고, 그 결과 흰색의 증강 이미지가 생성될 수 있기 때문이다.

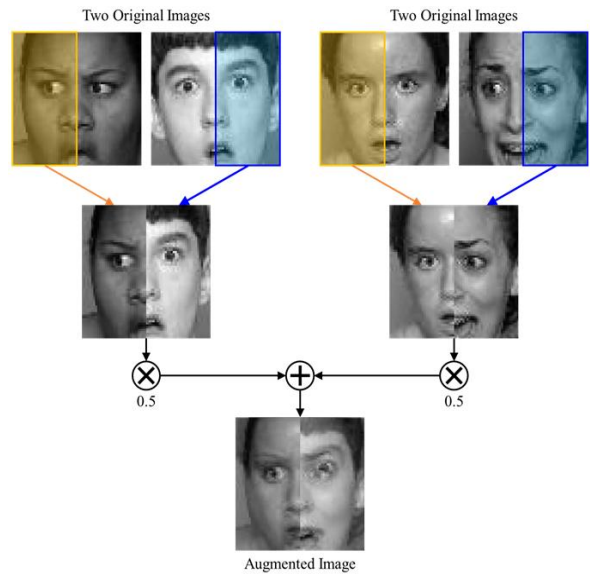


Fig. 3. Process of the Proposed DA2.

그림 3은 DA2의 데이터 증강 절차를 보여준다. 학습 데이터 세트에서 같은 감정 클래스에 속한 4장의 아동 얼굴 이미지를 비복원 추출하는 과정까지는 DA1과 같다. DA2에서는 Img1의 왼쪽 부분과 Img2의 오른쪽 부분을 결합한다. 그다음 Img3의 왼쪽 부분과 Img4의 오른쪽 부분을 결합한다. 결합을 통해 얻은 2장의 이미지에 각각 0.5씩 곱한 다음, 두 이미지를 더함으로써 증강 이미지를 생성한다.

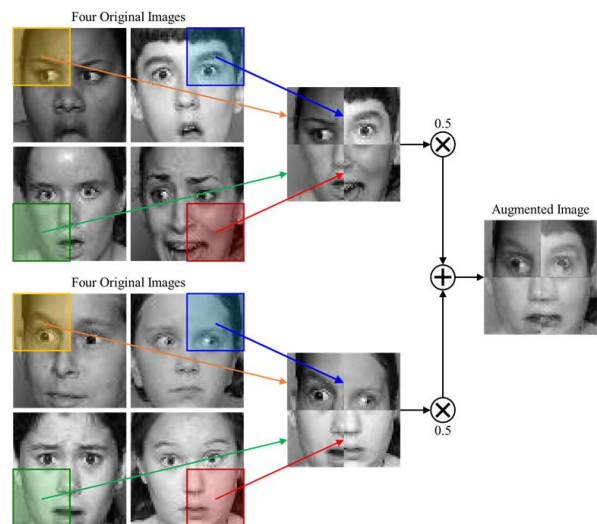


Fig. 4. Process of the Proposed DA3.

그림 4는 DA3의 데이터 증강 절차를 보여준다. 4장의 아동 얼굴 이미지를 추출해 데이터 증강에 활용했던 DA1, DA2와 달리, DA3에서는 학습 데이터 세트에서 같은 감정 클래스에 속한 8장의 아동 얼굴 이미지를 비복원 추출한다. 먼저, 추출한 8장의 이미지 중 4장의 이미지로부터,

Img1의 좌측 상단, Img2의 우측 상단, Img3의 좌측 하단, Img4의 우측 하단 부분을 각각 추출하고, 이를 결합한다. 나머지 4장의 이미지로부터, Img5의 좌측 상단, Img6의 우측 상단, Img7의 좌측 하단, Img8의 우측 하단 부분을 각각 추출하고, 이를 결합한다. 그다음 결합을 통해 얻은 2장의 이미지에 각각 0.5씩 곱한 다음, 두 이미지를 더함으로써 증강 이미지를 생성한다.

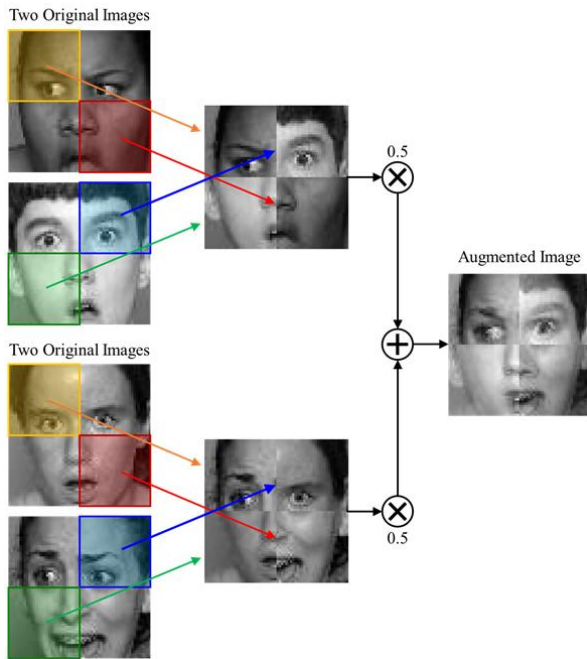


Fig. 5. Process of the Proposed DA4.

그림 5는 DA4의 데이터 증강 절차를 보여준다. 학습 데이터 세트에서 같은 감정 클래스에 속한 4장의 아동 얼굴 이미지를 비복원 추출한다. Img1의 좌측 상단과 우측 하단을 추출하고, Img2의 우측 상단과 좌측 하단을 추출해, 이를 결합한다. 그다음 Img3의 좌측 상단과 우측 하단을 추출하고, Img4의 우측 상단과 좌측 하단을 추출해, 이를 결합한다. 그다음 결합을 통해 얻은 2장의 이미지에 각각 0.5씩 곱한 다음, 두 이미지를 더함으로써 증강 이미지를 생성한다.

IV. Experimental Results

1. Dataset and Evaluation Protocol

본 연구에서는 제안하는 감정인식 기법의 성능을 평가하기 위해서, 미국 국립 정신건강 연구소(National Institute of Mental Health, NIMH)의 NIMH-ChEFS 데

이터 세트[18]를 이용했다.

Table 1. Summary of the NIMH-ChEFS Dataset

Item	Explanation
No. of Subjects	59
Age	10-17 (Mean: 13.6)
No. of Classes	5: Afraid(AF), Anger(AN), Happiness(HA), Neutral(NE), Sadness(SA)
No. of Images (Direct and Averted Gaze)	AF: 107 (52 + 55)
	AN: 104 (52 + 52)
	HA: 108 (52 + 56)
	NE: 111 (59 + 52)
	SA: 104 (51 + 53)
Resolution	1960×3008
Color/Grayscale	Color

표 1에서와 같이 59명의 아동이 NIMH-ChEFS 데이터 세트를 구축하는 과정에 피험자로 참여했으며, 참여 아동의 나이는 10세부터 17세까지로 평균 나이는 13.6세였다. 촬영이 진행되는 동안, 참여 아동은 다섯 가지의 감정을 표현해 달라는 요청을 받았으며, 감정별로 아동의 시선이 정면을 향할 때(Direct Gaze)와 측면을 향할 때(Averted Gaze)로 나누어, 얼굴 이미지를 1960×3008의 크기로 기록했다[19-28].

NIMH-ChEFS 데이터 세트가 제공하고 있는 이미지의 수를 감정별로 정리하면 다음과 같다. 먼저, 두려움(Afraid, AF) 클래스는 107장(정면: 52장, 측면: 55장), 화남(Anger, AN) 클래스는 104장(정면: 52장, 측면: 52장), 행복(Happiness, HA) 클래스는 108장(정면: 52장, 측면: 56장), 중립(Neutral, NE) 클래스는 111장(정면: 59장, 측면: 52장), 슬픔(Sadness, SA) 클래스는 104장(정면: 51장, 측면: 53장)이다. 따라서, 데이터 세트 내 이미지는 총 534장(정면: 266장, 측면: 268장)이며, 본 연구에서는 시선에 상관없이 CNN 모델이 아동의 감정을 인식할 수 있도록, 534장의 이미지 전부를 실험에 활용했다[29-45].

전처리 과정의 일환으로, 컬러(Color) 이미지를 그레이스케일(Grayscale) 이미지로 변환했다. 그다음 OpenCV 라이브러리(Library)의 캐스케이드 분류기(Cascade Classifier)를 활용해서, 원본 이미지에서 얼굴 영역을 검출했다. 이때, 캐스케이드 분류기가 검출해 반환하는 얼굴 영역은 정사각형인데, 그 크기는 원본 이미지마다 서로 다르다. 따라서, 534장의 원본 이미지로부터 검출한 얼굴 영역을 모두 64×64의 크기로 조정했다. 그다음 각 픽셀이 0과 1 사이의 값을 갖도록 정규화(Normalization)했다.

정규화까지 마친 534장의 얼굴 이미지를 8:2의 비율로 나눠, 학습 데이터 세트와 시험 데이터 세트(Test

Dataset)를 준비했다. 데이터 증강 기법은 학습 데이터 세트에만 적용했으며, 시험 데이터 세트에는 데이터 증강 기법을 적용하지 않았다. 데이터 증강 전 학습 데이터 세트에는 AF 클래스 85장, AN 클래스 81장, HA 클래스 86장, NE 클래스 88장, SA 클래스 81장의 이미지가 포함되어 있었으며, 클래스 사이의 불균형이 있었다.

이에 본 연구에서는 클래스 사이의 불균형이 없도록, 감정 클래스마다 이미지의 수가 160장이 되도록 데이터 증강을 수행했다. 데이터 증강 기법의 적용을 통해서, 감정 별로 AF 클래스 75장, AN 클래스 79장, HA 클래스 74장, NE 클래스 72장, SA 클래스 79장의 이미지를 생성했다. 최종적으로, 데이터 증강 기법이 적용된 학습 데이터 세트에는 총 800장(원본 421장, 생성: 379장)의 이미지가 포함됐다. 그림 6은 제안하는 데이터 증강 기법(DA1, DA2, DA3, DA4)으로 생성한 이미지의 예를 보여준다.

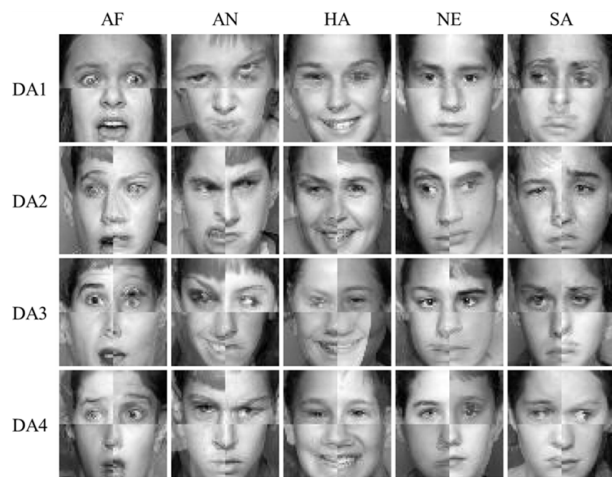


Fig. 6. Examples of Images Generated by the Proposed Four Data Augmentation Methods.

CNN 모델의 일반화 성능을 평가하기 위해, 5-겹 교차 검증(5-Fold Cross-Validation)을 수행했다. 각 교차 검증 평가에는 학습 데이터 세트의 20%가 검증 데이터 세트(Validation Dataset)로 사용됐다. 각 데이터 세트에서 감정 클래스별 샘플 비율을 유지하기 위해서, scikit-learn 라이브러리의 StratifiedKFold 클래스를 활용했다.

2. Baseline Model

제안하는 데이터 증강 기법의 효용성을 입증하기 위해서, 그림 7과 같은 구조를 갖는 CNN 모델을 베이스라인(Baseline) 모델로 활용했다.

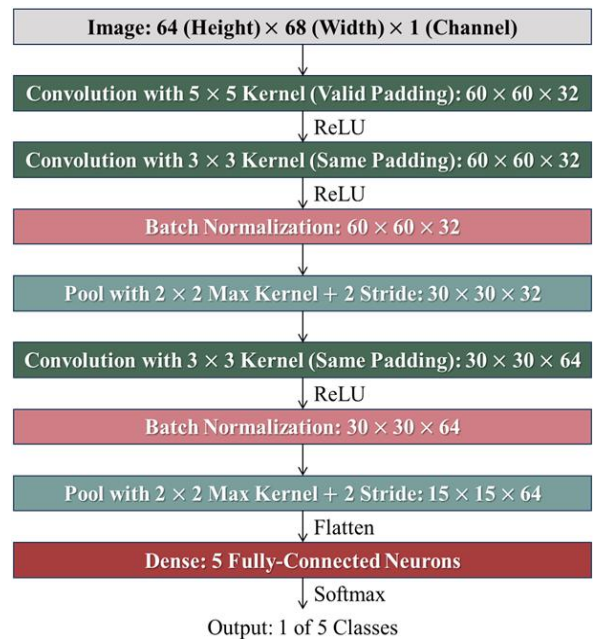


Fig. 7. Architecture of CNN Model Used in This Study.

그림 7에서와 같이, 먼저 CNN 모델의 입력층(Input Layer)에 64x64x1 크기의 입력 이미지가 전달된다. 그다음 입력 이미지는 5x5의 커널(Kernel)을 32개 갖는 첫 번째 합성곱 층(Convolutional Layer)과 3x3의 커널을 32개 갖는 두 번째 합성곱 층을 연달아 통과하면서, 특성 맵(Feature Map)으로 추상화된다. 이어서 특성 맵은 배치 정규화(Batch Normalization) 층과 최대 풀링(Max Pooling) 층을 통과한다. 그리고 3x3의 커널을 64개 갖는 세 번째 합성곱 층을 통과한 뒤, 배치 정규화 층과 최대 풀링 층을 다시 한번 더 통과한다.

최종적으로, 주어진 입력 이미지를 다섯 가지 감정 중 하나의 감정으로 분류하기 위해서, 플레튼(Flatten) 층을 통해 특성 맵의 모양(Shape)을 3차원 텐서(Tensor)에서 1차원 벡터(Vector)로 변환시키고, 5개의 유닛(Units)으로 구성된 완전 연결(Fully-Connected, FC) 층에 전달한다. 완전 연결 층에서는 활성화 함수(Activation Function)로 소프트맥스(Softmax) 함수를 사용해, 입력 이미지가 각 감정 클래스일 확률값을 계산할 수 있도록 했으며, 가장 높은 확률값을 갖는 감정 클래스가 CNN 모델의 최종 출력으로 결정된다.

3. Results

제안하는 데이터 증강 기법의 성능을 평가하기 위해서, 정확도(Accuracy, ACC), 매크로 평균(Macro-Average) Positive Predictive Value(PPV), 매크로 평균 True

Positive Rate(TPR), F_1 -Score(F1)을 평가 지표로 사용했다. 또한, 제안하는 기법의 효용성을 검증하기 위해서, 기존 데이터 증강 기법을 벤치마킹(Benchmarking)했다.

① 데이터 증강 미적용(Without Any DA): 데이터 증강 기법별로, 기법 적용 전후의 성능 개선 정도를 측정하기 위해서, 어떠한 데이터 증강 기법도 적용하지 않은 상태로 CNN 모델을 학습 및 평가한 실험이다.

② 좌우 반전(Horizontal Flipping, 이하 Flipping이라 함): 학습 데이터 세트 내 이미지들에 대해서 좌우 반전된 이미지를 생성하고, 생성한 이미지들을 학습 데이터 세트에 포함시킨 상태로 CNN 모델을 학습 및 평가한 실험이다. 본 연구에서는 PIL(Python Imaging Library)의 Image 모듈(Module) 내 Transpose.FLIP_LEFT_RIGHT 메소드(Method)를 사용해 좌우 반전 이미지를 생성했다.

③ 회전(Rotation): 학습 데이터 세트 내 이미지들에 대해서 회전시킨 이미지를 생성하고, 생성한 이미지들을 학습 데이터 세트에 포함시킨 상태로 CNN 모델을 학습 및 평가한 실험이다. 본 연구에서는 PIL의 Image 모듈 내에 있는 Rotate 메소드를 이용해 회전된 이미지를 생성했다. 이때, 이미지마다 회전시킬 각도는 [-5, 5] 범위 내 정수에 대해서 무작위로 선정된 값으로 결정했다.

④ 가우스 잡음(Gaussian Noise, 이하 Gaussian이라 함): 학습 데이터 세트 내 이미지들에 대해서 가우스 잡음이 포함된 이미지를 생성하고, 생성한 이미지들을 학습 데이터 세트에 포함시킨 상태로 CNN 모델을 학습 및 평가한 실험이다. 본 연구에서는 넘파이(Numpy) 라이브러리 내 Random 모듈에 있는 normal 함수를 이용해, 평균이 0이고 표준편차가 150인 정규 분포를 따르는 난수를 생성했다. 그리고 이렇게 생성한 난수를 이미지에 덧셈 연산을 통해 추가했다. 또한, 넘파이 라이브러리 내 clip 함수를 이용해 덧셈 연산 이후의 픽셀값이 0부터 255 사이의 값으로 제한되도록 했다.

⑤ 콘트라스트 조정(Contrast Adjustment, 이하 Contrast라 함): 학습 데이터 세트 내 이미지들에 대해서 콘트라스트를 조절한 이미지를 생성하고, 생성한 이미지들을 학습 데이터 세트에 포함시킨 상태로 CNN 모델을 학습 및 평가한 실험이다. 본 연구에서는 PIL 내 ImageEnhance 모듈의 Contrast 클래스를 이용해 이미지마다 콘트라스트를 조정했다. 또한, 클래스 내 배율 인자(factor)에 2.0을 지정해 콘트라스트를 최대 두 배까지 조정할 수 있도록 했다.

Table 2. Performance Comparison Between the Conventional and Proposed Data Augmentation Methods (The Best Records are Highlighted in Bold)

Method	Macro-Average			ACC
	PPV	TPR	F1	
Without Any DA	0.09	0.23	0.13	0.24
Flipping	0.15	0.33	0.21	0.34
Rotation	0.71	0.70	0.70	0.70
Gaussian	0.70	0.71	0.71	0.71
Contrast	0.75	0.75	0.75	0.75
Proposed DA1	0.78	0.76	0.77	0.76
Proposed DA2	0.75	0.74	0.74	0.74
Proposed DA3	0.81	0.81	0.81	0.81
Proposed DA4	0.75	0.73	0.74	0.74

표 2는 기존 데이터 증강 기법과 제안하는 네 가지 데이터 증강 기법(DA1부터 DA4까지)을 적용한 학습 데이터 세트로, CNN의 모델을 훈련하고, 시험 데이터 세트에서 모델의 성능을 평가한 결과를 보여준다. 실험 결과에 따르면, 전체 데이터 증강 기법 중에서 제안하는 DA3이 0.81의 정확도로 가장 우수한 성능을 보였다. 그다음으로 제안하는 DA1이 0.76, 제안하는 DA2와 DA4가 각각 0.74의 정확도로 우수한 성능을 달성했다. 기존 데이터 증강 기법 중에서는 콘트라스트 조정이, 0.75의 정확도로 가장 우수한 성능을 보였다. 반면, 좌우 반전이 0.34의 정확도로 가장 낮은 성능을 보였다. 데이터 증강 미적용 시 CNN 모델의 정확도는 0.24였으며, 제안하는 DA3를 적용하면 약 0.57(0.81-0.24)의 성능 개선 효과가 있음을 확인할 수 있었다.

표 3은 제안하는 데이터 증강 기법과 기존 데이터 증강 기법의 결합에 따른, CNN 모델의 감정인식 성능을 보여준다. 각 데이터 증강 기법을 통해 생성한, 두 학습 데이터 세트를 합쳐 하나의 학습 데이터 세트를 만들 때, 두 데이터 세트에 존재하는 중복 이미지는 모두 제거했다. 또한, 클래스 사이의 이미지 수의 불균형이 없도록 감정 클래스마다 이미지의 수가 200장이 되도록 했다. 따라서 표 3의 실험에서는, 총 1,000장의 이미지로 구성된 학습 데이터 세트가 CNN 모델 훈련에 사용됐다. 표 3의 실험 결과에 따르면, DA3와 Flipping 기법을 결합한 실험이 매크로 평균 PPV가 0.81로 가장 높게 확인됐으며, DA2와 Rotation 기법을 결합한 실험과 DA3와 Contrast 기법을 결합한 실험이 둘 다 매크로 평균 TPR이 0.79, 정확도가 0.79로 가장 우수했다. 표 2와 표 3의 결과를 함께 비교해 분석하면, 제안하는 데이터 증강 기법은, 기존 데이터 증강 기법과

결합해 적용하는 것보다 단독으로 사용될 때, CNN 모델이 우수한 성능을 달성했다.

Table 3. Performance Comparison Between the Different Combinations of Data Augmentation Methods (The Best Records are Highlighted in Bold)

Combination		Macro-Average			ACC
Prop.	Conv.	PPV	TPR	F1	
DA1	Flipping	0.76	0.74	0.75	0.75
	Rotation	0.70	0.57	0.63	0.57
	Gaussian	0.77	0.75	0.76	0.76
	Contrast	0.79	0.77	0.78	0.77
DA2	Flipping	0.68	0.62	0.65	0.61
	Rotation	0.80	0.79	0.79	0.79
	Gaussian	0.74	0.74	0.74	0.74
DA3	Flipping	0.81	0.78	0.80	0.78
	Rotation	0.79	0.78	0.78	0.78
	Contrast	0.80	0.79	0.80	0.79
DA4	Flipping	0.68	0.70	0.69	0.70
	Rotation	0.80	0.78	0.79	0.78
	Gaussian	0.77	0.77	0.77	0.77
	Contrast	0.75	0.73	0.74	0.74

그림 8은 표 3의 실험에서 훈련된 CNN 모델의 혼동행렬(Confusion Matrices) 결과를 보여준다. 제안하는 데이터 증강 기법 중에서, 표 3에서 세 가지 평가 지표에 대해서 가장 성능이 우수했던 제안하는 DA3 기법의 적용 전과 후에 관한 결과를 확인할 수 있다. 실험 결과에 따르면, 기존 데이터 증강 기법을 단독으로 적용하는 것과 비교해서, 제안하는 데이터 증강 기법 DA3를 함께 적용할 경우, 얼굴 감정인식 작업에서 CNN 모델의 인식 성능이 향상됐다. DA3 기법을 함께 적용했을 때, 좌우 반전(Flipping) 기법의 경우 정확도가 $0.44(=0.78-0.34)$, 회전(Rotation) 기법의 경우 정확도가 $0.08(=0.78-0.70)$, 가우스 잡음(Gaussian) 기법의 경우 정확도가 $0.07(=0.78-0.71)$, 콘트라스트 대조(Contrast) 기법의 경우 정확도가 $0.04(=0.79-0.75)$ 가 향상됐다. 기존 데이터 증강 기법 모두에 대해서 정확도 향상이 있었으며, 이를 토대로 제안하는 데이터 증강 기법의 효용성을 확인할 수 있다.

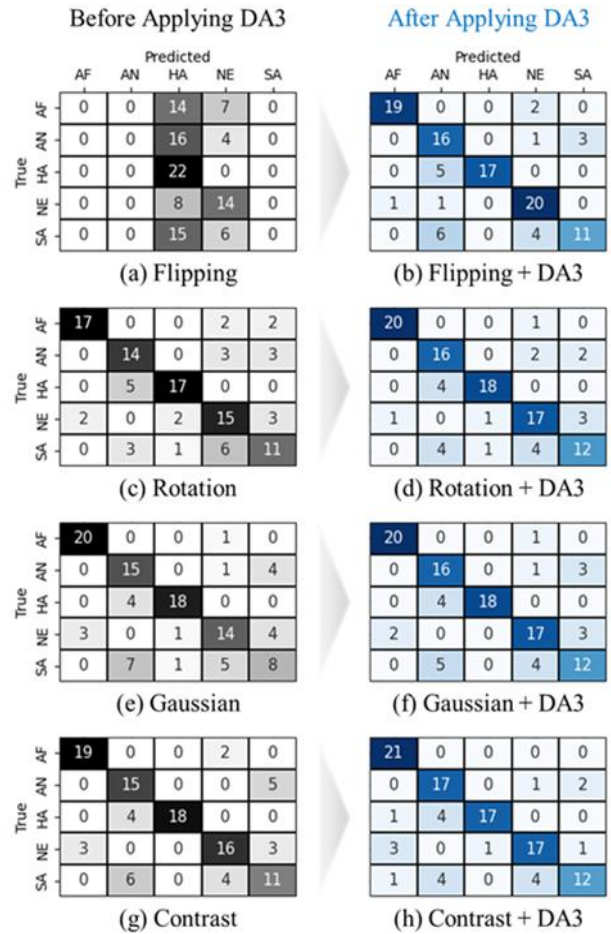


Fig. 8. Confusion Matrices of CNN Model According to the Data Augmentation Method.

V. Limitations and Future Challenges

본 연구의 실험에서 활용한 NIMH-ChEFS 데이터 세트는 아동의 정면 얼굴 이미지만 제공하고 있어, 실험 과정에서 CNN 모델은 아동의 정면 얼굴 이미지만으로 학습 및 평가됐다. 실제 환경을 고려하면, 아동의 얼굴 이미지는 다양한 각도에서 촬영될 수 있다. 따라서, 향후 연구에서는 먼저 피험자로 참여한 아동의 3차원 얼굴을 모델링하고자 한다. 그다음 피치(Pitch), 요(Yaw), 롤(Roll) 축을 회전축으로, 생성한 모델을 회전시켜 가며 다양한 각도에서 얼굴 모델을 촬영해, 아동 얼굴 이미지 데이터 세트를 구축하고자 한다[46]. 그리고 구축한 데이터 세트를 활용해 제안하는 데이터 증강 기법을 발전시켜 나가하고자 한다. 또한, 얼굴 촬영 각도뿐만 아니라 조명 변화, 얼굴 가림(Occlusion) 등에 의해서도 제안하는 기법의 성능 저하 가능성이 있을 수 있는 만큼, 향후 연구에서는 실제 상황에

서 발생할 수 있는 다양한 환경적 요소를 고려하고자 한다. 이를 통해, 제안하는 기법의 실효성과 활용성을 더욱 높일 수 있을 것으로 기대된다.

아동학대 여부를 파악하기 위해서 제안하는 기법을 실제 현장에서 활용할 경우, 법적 문제에 직면할 수 있다. 우선, 아동의 얼굴 이미지를 사용하려면, 보호자(예를 들어, 부모)의 동의를 받아야 한다. 아동에게 직접 동의받는 것은 제한되거나 법적으로 가능하지 않으므로, 아동의 보호자에게 명확한 설명과 동의를 받아야 한다. 또한, 동의를 받았다고 하더라도, 아동의 얼굴 이미지와 감정 상태를 수집, 분석, 저장, 공유하는 것에는 아동 보호와 관련된 법적 규제가 적용될 수 있다. 아동의 얼굴 이미지와 감정 상태를 수집하는 시스템이 악용되거나 불법적으로 사용될 경우, 법적 책임을 질 수 있으므로 기술이 오용되지 않도록 필요한 법적 보호 장치를 마련해야 할 것이다.

아동의 감정을 분석하는 것은 그 자체로 민감한 사안이므로, 법적 문제뿐만 아니라 윤리적 문제에도 직면할 수 있다. 아동의 감정 상태를 분석하고 이를 외부 시스템에 저장하거나 공유하는 것은 아동의 프라이버시(Privacy)를 침해할 수 있으므로 아동의 감정 상태와 관련된 정보는 반드시 신뢰할 수 있는 기관과 협력하여 처리해야 할 것이다. 또한, 아동학대 여부를 파악한 결과가 의심이 사게 될 경우, 이를 어떤 방식으로 다룰지에 대한 윤리적인 기준을 세워야 한다. 잘못된 결정을 내리거나 결과에 대해 의심받을 경우, 해당 결정을 어떻게 처리할지에 대한 명확한 프로세스가 필요하다. 예를 들어, 아동학대의 의심이 있는 경우, 전문가(예를 들어, 아동 심리학자, 사회복지사 등)의 개입이 필요할 수 있다.

VI. Conclusions

본 논문에서는 아동 얼굴 이미지 데이터 세트의 샘플 수가 한정된 상황에서, CNN 모델의 감정인식 정확도를 높이기 위해서 새로운 데이터 증강 기법 네 가지를 개발 및 제안했다. 제안하는 데이터 증강 기법의 효용성을 평가하기 위해서, 인터넷상에 공개된 미국 국립 정신건강 연구소의 NIMH-ChEFS 데이터 세트를 이용했다. 또한, 기존 데이터 증강 기법 네 가지를 벤치마킹해, 제안하는 데이터 증강 기법과 성능 평가 결과를 비교 및 분석했다. 실험 결과에 따르면, 제안하는 데이터 증강 기법 DA3이 데이터 증강 기법 중에서 정확도, 매크로 평균 PPV, 매크로 평균 TPR 모두에서 가장 우수한 성능을 달성했다. CNN 모델의

혼동행렬 결과에서도 기존 데이터 증강 기법만을 적용한 경우보다, 제안하는 DA3 기법을 함께 적용했을 때, 정확도가 개선되는 것을 보임으로써, 제안하는 데이터 증강 기법의 효용성을 입증했다.

ACKNOWLEDGEMENT

This work was supported by the National Research Foundation of Korea (NRF) grant funded by the Korea government (MSIT) (No. RS-2022-00165652).

REFERENCES

- [1] D. Russell *et al.*, "Preventing Child Sexual Abuse: A Systematic Review of Interventions and Their Efficacy in Developing Countries," *Child Abuse Negl.*, Vol. 102, pp. 1-14, April 2020. DOI: 10.1016/j.chiabu.2020.104395
- [2] A. Nyberg *et al.*, "School-Based Abuse Prevention Programs for Children: A Scoping Review," *Int. J. Disabil. Dev. Educ.*, Vol. 70, No. 2, pp. 137-155, January 2023. DOI: 10.1080/1034912X.2020.1865522
- [3] Y. Wu *et al.*, "Schools' Readiness for Child Sexual Abuse Prevention Education: Preliminary Scale Development Using a Delphi Method," *Child Abuse Negl.*, Vol. 154, pp. 1-11, August 2024. DOI: 10.1016/j.chiabu.2024.106884
- [4] K. Lee, "Child Abuse & Neglect Korea 2023," Ministry of Health and Welfare, August 2024.
- [5] E. Kim and J. Lee, "The Recognition of Facial Emotion and Attributional Bias Influenced on Depression and Aggression in Abused Children," *The Korean J. Dev. Psychol.*, Vol. 22, No. 3 pp. 1-18, January 2009.
- [6] E. Brennan and R. McElvaney, "What Helps Children Tell? A Qualitative Meta-Analysis of Child Sexual Abuse Disclosure," *Child Abus. Rev.*, Vol. 29, No. 2, pp. 97-113, April 2020. DOI: 10.1002/car.2617
- [7] M. Rathod *et al.*, "Kids' Emotion Recognition Using Various Deep-Learning Models with Explainable AI," *Sensors*, Vol. 22, No. 20, pp. 1-21, October 2022. DOI: 10.3390/s22208066
- [8] R. A. Khan *et al.*, "A Novel Database of Children's Spontaneous Facial Expressions (LIRIS-CSE)," *Image Vis. Comput.*, Vol. 83, pp. 61-69, March-April 2019. DOI: 10.1016/j.imavis.2019.02.004
- [9] U. Laraib *et al.*, "Recognition of Children's Facial Expressions Using Deep Learned Features," *Electronics*, Vol. 12, No. 11, pp. 1-16, May 2023. DOI: 10.3390/electronics12112416

- [10] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," 2014, arXiv: 1409.1556.
- [11] K. He *et al.*, "Deep Residual Learning for Image Recognition," in Proc. 29th IEEE Conf. Comput. Vis. Pattern Recognit., pp. 770-778, Las Vegas, NV, USA, June 2016. DOI: 10.1109/CVPR.2016.90
- [12] F. M. Talaat, "Real-Time Facial Emotion Recognition System among Children With Autism Based on Deep Learning and IoT," Neural Comput. Appl., Vol. 35, pp. 12717-12728, March 2023. DOI: 10.1007/s00521-023-08372-9
- [13] F. M. Talaat *et al.*, "Real-Time Facial Emotion Recognition Model Based on Kernel Autoencoder and Convolutional Neural Network for Autism Children," Soft Comput., Vol. 28, pp. 6695-6708, January 2024. DOI: 10.1007/s00500-023-09477-y
- [14] A. G. Howard *et al.*, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," 2017, arXiv:1704.04861.
- [15] F. Chollet, "Xception: Deep Learning With Depthwise Separable Convolutions," in Proc. 30th IEEE Conf. Comput. Vis. Pattern Recognit., pp. 1251-1258, Honolulu, HI, USA, July 2017. DOI: 10.1109/CVPR.2017.195
- [16] S. Chu and B. Kwon, "Facial Emotion Recognition Using Geometric and HOG Features," Journal of Korea Multimedia Society, Vol. 28, No. 1, pp. 112-125, January 2025. DOI: 10.9717/kmms.2025.28.1.112
- [17] B. Kwon, "Data Augmentation Using Convolutional Autoencoder for Facial Emotion Recognition," in Proc. 24th Int. Conf. Electron. Inf. Commun. (ICEIC), pp. 1-4, Osaka, Japan, January 2025.
- [18] H. L. Egger *et al.*, "The NIMH Child Emotional Faces Picture Set (NIMH-CHEPS): A New Set of Children's Facial Emotion Stimuli," Psychiatr. Res., Vol. 20, No. 3, pp. 145-156, August 2011. DOI: 10.1002/mpr.343
- [19] B. Kwon *et al.*, "Implementation of Human Action Recognition System Using Multiple Kinect Sensors," in Proc. 16th Pacific-Rim Conf. Multimed. (PCM), pp. 334-343, Gwangju, Republic of Korea, September 2015. DOI: 10.1007/978-3-319-24075-6_32
- [20] B. Kwon *et al.*, "An Enhanced Multi-View Human Action Recognition System for Virtual Training Simulator," in Proc. 8th Asia-Pacific Signal Inf. Process. Assoc. Annu. Summit Conf. (APSIPA ASC), pp. 1-4, Jeju, Republic of Korea, December 2016. DOI: 10.1109/APSIPA.2016.7820895
- [21] B. Kwon *et al.*, "Implementation of a Virtual Training Simulator Based on 360° Multi-View Human Action Recognition," IEEE Access, Vol. 5, pp. 12496-12511, July 2017. DOI: 10.1109/ACCESS.2017.2723039
- [22] B. Kwon and S. Lee, "Human Skeleton Data Augmentation for Person Identification over Deep Neural Network," Appl. Sci., Vol. 10, No. 14, pp. 1-22, July 2020. DOI: 10.3390/app10144849
- [23] B. Kwon and S. Lee, "Ensemble Learning for Skeleton-Based Body Mass Index Classification," Appl. Sci., Vol. 10, No. 21, pp. 1-23, November 2020. DOI: 10.3390/app10217812
- [24] B. Kwon and S. Lee, "Joint Swing Energy for Skeleton-Based Gender Classification," IEEE Access, Vol. 9, pp. 28334-28348, February 2021. DOI: 10.1109/ACCESS.2021.3058745
- [25] B. Kwon *et al.*, "Optimal Camera Point Selection Toward the Most Preferable View of 3-D Human Pose," IEEE Trans. Syst. Man Cybern.-Syst., Vol. 52, No. 1, pp. 533-553, January 2022. DOI: 10.1109/TSMC.2020.3004338
- [26] B. Kwon and T. Oh, "Multi-Time Window Feature Extraction Technique for Anger Detection in Gait Data," Journal of the Korea Society of Computer and Information, Vol. 28, No. 4, pp. 41-51, April 2023. DOI: 10.9708/jksci.2023.28.04.041
- [27] B. Kwon, "Gait-Based Gender Classification Using a Correlation-Based Feature Selection Technique," Journal of the Korea Society of Computer and Information, Vol. 29, No. 3, pp. 55-66, March 2024. DOI: 10.9708/jksci.2024.29.03.055
- [28] B. Kwon, "Improving BMI Classification Accuracy with Oversampling and 3-D Gait Analysis on Imbalanced Class Data," Journal of the Korea Society of Computer and Information, Vol. 29, No. 9, pp. 9-23, September 2024. DOI: 10.9708/jksci.2024.29.09.009
- [29] B. Kwon and Y. W. Chung, "An Improved Energy Saving Scheme in IEEE 802.16e," The Journal of Korean Institute of Information Technology, Vol. 10, No. 8, pp. 43-51, August 2012.
- [30] B. Kwon *et al.*, "A Target Position Decision Algorithm Based on Analysis of Path Departure for an Autonomous Path Keeping System," Wirel. Pers. Commun., Vol. 83, pp. 1843-1865, August 2015. DOI: 10.1007/s11277-015-2485-0
- [31] B. Kwon *et al.*, "A Downlink Power Control Algorithm for Long-Term Energy Efficiency of Small Cell Network," Wirel. Netw., Vol. 21, pp. 2223-2236, October 2015. DOI: 10.1007/s11276-015-0907-2
- [32] B. Kwon *et al.*, "Virtual MIMO Broadcasting Transceiver Design for Multi-Hop Relay Networks," Digit. Signal Prog., Vol. 46, pp. 97-107, November 2015. DOI: 10.1016/j.dsp.2015.08.003
- [33] B. Kwon *et al.*, "Framework Implementation of Image-Based Indoor Localization System Using Parallel Distributed Computing," The Journal of Korean Institute of Communications and Information Sciences, Vol. 41, No. 11, pp. 1490-1501, November 2016. DOI: 10.7840/kics.2016.41.11.1490
- [34] B. Kwon *et al.*, "Iterative Interference Cancellation and Channel Estimation in Evolved Multimedia Broadcast Multicast System Using Filter-Bank Multicarrier-Quadrature Amplitude Modulation," IEEE Trans. Broadcast., Vol. 62, No. 4, pp. 864-875, December 2016. DOI: 10.1109/TBC.2016.2617294

- [35] B. Kwon *et al.*, "Novel Error Detection Algorithm for LZSS Compressed Data," *IEEE Access*, Vol. 5, pp. 8940-8947, May 2017. DOI: 10.1109/ACCESS.2017.2704900
- [36] B. Kwon *et al.*, "Scattered Reference Symbol-Based Channel Estimation and Equalization for FBMC-QAM Systems," *IEEE Trans. Commun.*, Vol. 65, No. 8, pp. 3522-3537, August 2017. DOI: 10.1109/TCOMM.2017.2710310
- [37] B. Kwon and S. Lee, "Effective Interference Nulling Virtual MIMO Broadcasting Transceiver for Multiple Relaying," *IEEE Access*, Vol. 5, pp. 20695-20706, October 2017. DOI: 10.1109/ACCESS.2017.2752198
- [38] B. Kwon and S. Lee, "Cross-Antenna Interference Cancellation and Channel Estimation for MISO-FBMC/QAM-Based eMBMS," *Wirel. Netw.*, Vol. 24, pp. 3281-3293, November 2018. DOI: 10.1007/s11276-017-1531-0
- [39] B. Kwon and S. Lee, "Error Detection Algorithm for Lempel-Ziv-77 Compressed Data," *J. Commun. Netw.*, Vol. 21, No. 2, pp. 100-112, April 2019. DOI: 10.1109/JCN.2019.000021
- [40] B. Kwon *et al.*, "Accurate Blind Lempel-Ziv-77 Parameter Estimation via 1-D to 2-D Data Conversion Over Convolutional Neural Network," *IEEE Access*, Vol. 8, pp. 43965-43979, March 2020. DOI: 10.1109/ACCESS.2020.2977827
- [41] B. Kwon *et al.*, "EDA-78: A Novel Error Detection Algorithm for Lempel-Ziv-78 Compressed Data," *Wirel. Pers. Commun.*, Vol. 111, pp. 2177-2189, April 2020. DOI: 10.1007/s11277-019-06979-7
- [42] B. Kwon and T. Kim, "Toward an Online Continual Learning Architecture for Intrusion Detection of Video Surveillance," *IEEE Access*, Vol. 10, pp. 89732-89744, August 2022. DOI: 10.1109/ACCESS.2022.3201139
- [43] B. Kwon *et al.*, "Identification and Restoration of LZ77 Compressed Data Using a Machine Learning Approach," in *Proc. 10th Asia-Pacific Signal Inf. Process. Assoc. Annu. Summit Conf. (APSIPA ASC)*, pp. 1787-1790, Honolulu, HI, USA, November 2018. DOI: 10.23919/APSIPA.2018.8659755
- [44] B. Kwon and H. Son, "Accurate Path Loss Prediction Using a Neural Network Ensemble Method," *Sensors*, Vol. 24, No. 1, pp. 1-20, January 2024. DOI: 10.3390/s24010304
- [45] B. Kwon and E. Noh, "Path Loss Prediction Using an Ensemble Learning Approach," *Journal of the Korea Society of Computer and Information*, Vol. 29, No. 2, pp. 1-12, February 2024. DOI: 10.9708/jksci.2024.29.02.001
- [46] H. Song and B. Kwon, "Facial Animation Strategies for Improved Emotional Expression in Virtual Reality," *Electronics*, Vol. 13, No. 13, pp. 1-18, July 2024. DOI: 10.3390/electronics13132601

Authors



Hyora Lee received her B.S. degree in Taxation and Accounting from Dongduk Women's University, Seoul, Republic of Korea, in February 2025. From March 2018 to September 2022, she worked as an office

worker at Samsung Life Insurance, Seoul. Her research interests include artificial intelligence, healthcare, and computer vision. Since January 2025, she has been working as an intern at a research lab at the Samsung Advanced Institute for Health Sciences & Technology, Sungkyunkwan University, Seoul.



Beom Kwon received the B.S. degree in Electrical and Electronic Engineering from Soongsil University, Seoul, in 2012, and the M.S. and Ph.D. degrees in Electrical and Electronic Engineering from Yonsei

University, Seoul, in 2018. From March 2018 to September 2019, he was a Senior Researcher at the Agency for Defense Development (ADD), Daejeon, Republic of Korea. From October 2019 to August 2021, he was a Staff Engineer at Samsung Electronics Company, Ltd., Suwon City, Gyeonggi Province, Republic of Korea. From September 2021 to August 2023, he was an assistant professor in the Department of Artificial Intelligence at Dongyang Mirae University, Seoul. Since September 2023, he has been an assistant professor in the Division of Interdisciplinary Studies in Cultural Intelligence (Data Science) at Dongduk Women's University, Seoul. His research interests include artificial intelligence and its applications.