

논문 2022-59-11-9

# 딥러닝과 넛지 이론 기반의 위변조 방지 기술을 적용한 출석 인증 시스템

(Attendance Verification System by using Anti-spoofing Method based  
on Deep Learning and Nudge Theory)

라 이 언\*, 여 동 훈\*, 황 병 일\*, 김 동 주\*, 서 영 주\*, 황 도 경\*

(I Eon Na, Dong Hun Yeo, Byeong Il Hwang, Dong Ju Kim,  
Young Joo Suh, and Do Kyung Hwang<sup>©</sup>)

## 요 약

본 논문에서는 출석 인증 시 인물의 안면 위변조를 방지하기 위해 딥러닝과 Nudge 이론을 이용한 새로운 방법을 제안한다. 제안한 방법은 출석 인증 중 발생할 수 있는 안면 위변조 상황에서 딥러닝을 통하여 얼굴의 위변조 여부를 파악하고, Nudge 이론을 기반으로 사용자의 안면 인증 동기를 분석하여 최종적으로 출석 인증 중에 일어나는 안면 위변조 상황을 검출하고 예방한다. 기존의 통상적인 출석 인증 시스템은, 안면 위변조 기술이 적용되어 있지 않은 경우가 대부분이며 적용되어 있다고 하더라도 딥러닝만을 이용하여 인물 사진에서 추출한 특징을 기반으로 위변조 여부를 판단하기 때문에 화질 저하로 일어나는 분류 오류 혹은 학습 데이터량 부족으로 인한 오분류 발생 문제가 있다. 이러한 보안적인 문제들로 인하여 안면 인증 시스템의 수요가 높아짐에도 불구하고 AI 기반의 출석 인증 시스템의 보급에 현실적인 벽이 존재한다. 본 논문에서는 종래의 수동적인 안면 위변조 검출 기법을 개선하기 위해 기존 방식에 더불어 Nudge 이론과 딥러닝 기법을 활용한 인물의 동기 파악 알고리즘을 제안하였으며, 딥러닝 알고리즘의 결과 도출을 위해 신뢰성 있는 안면 데이터셋 활용에 더불어 제안된 시스템에서 필요한 데이터를 직접 수집하고 설계하였다. 그리고 학습된 모델에 새롭게 개발된 시선 분석 알고리즘을 추가하여 인물의 시선을 정확하고 효과적으로 검출하여 안면 위변조 여부를 검사한다. 제안된 방법은 실험을 통해 신뢰성 검증을 수행하였으며, 모델의 추정 결과를 활용하여, 최종적으로 출석 인증 시스템의 신뢰성 향상을 통한 시스템 보급의 가속화를 도모한다.

## Abstract

A novel, practical and universal method of face spoofing detection has been proposed to prevent face spoofing problems in the face identification attendance system by using deep learning and Nudge theory. The proposed method detects face spoofing event while the attendance system is running and figure out whether a person's purpose has a natural drive to get face identification or not by nudge theory and the new iris detection algorithm to detect and prevent face spoofing situations. Prior face identification attendance system does not have face anti-spoofing technology in their approach. Most systems use only deep learning to judge the situation by extracting features from the nearby network, even if they have. So the plan is feeble on blur situation or has poor performance with an insufficient dataset for network train. Because of this weakness in anti-spoofing, it can not adequately supply AI-based attendance. The proposed method uses Nudge theory and deep learning to upgrade the prior attendance system with a new practical way of a person's purpose judge system. It uses datasets that have reliability for deep learning network train to have enough performance on face spoofing detection. Our system evaluated various objectivity cases to get reliability and finally accelerated the popularity of AI-based face identification attendance systems for our society.

**Keywords** : Anti-spoofing, Face identification, Deep learning, Nudge effect, Eye tracking

\*비회원, 포항공과대학교 인공지능연구원 연구부(Research Division, POSTECH Institute of Artificial Intelligence)

© Corresponding Author(E-mail : dokyung@postech.ac.kr)

※ 본 과제는 행정안전부 지역맞춤형 재난안전 연구개발 사업의 지원을 받아 수행된 연구임(20015427), 이 논문은 2022년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No. 2022R1A6A1A03052954)

Received ; August 1, 2022

Revised ; September 2, 2022

Accepted ; September 22, 2022

## I. 서 론

안면 인증 기반의 출석 인증 시스템의 수요는 날이 갈수록 높아지고 있지만, 상용화 단계에 있어서 많은 문제들이 존재한다<sup>[1]</sup>. 아울러 인공지능으로 얼굴을 변조하는 기술을 이용한 피싱 범죄에 대한 경고의 목소리가 높아지고 있으며 이미 해외에서 유사한 사례가 나타나고 있다<sup>[2]</sup>. 국내의 범죄 현황도 비슷한 상황이고 안면 위변조 피싱이 발생하는 것은 시간문제라는 분석이 많다<sup>[2]</sup>. 또한 이러한 AI 기반의 출석 인증 시스템을 학교, 회사 등에 적용한다고 할 때 동료의 프로필 사진을 도용하여 출석 인증을 시도하려는 대리출석 문제가 일어나기 쉬운 상황이다. 이러한 현실적인 이유로 안면 인증 시스템을 많은 현업에 적용하는 데 어려움을 겪고 있으며, 이를 보완하고자 비교적 성능이 좋은 딥러닝 기반으로 얼굴 위변조를 감지하는 몇 가지의 기술들이 선행 연구되어 왔다<sup>[3~5]</sup>. 하지만 딥러닝은 학습 방식에 따라 성능이 좌우되기 때문에 충분한 양과 좋은 품질의 데이터셋을 제작하는데 있어서 위변조 상황을 연출해야 하고, 그를 위하여 설계해야 하는 위변조의 경우가 매우 다양하다. 때문에 모델을 구현하였음에도 불구하고 테스트 환경이 아닌 현업에 적용하기에 불안정한 면이 존재하며 이러한 딥러닝 기반의 시스템은 보통 화면에 출력되는 안면 혹은, 인쇄된 안면 사진을 직접 촬영한 이미지 위주로 학습을 시킨다. 그리고 딥러닝은 실제 인물의 얼굴과 화면에 픽셀로 구성된 안면을 구분하는 법을 학습하기 때문에, 출석 인증을 하는 카메라가 화면을 이루는 픽셀을 정확히 인식하기 힘든 화질을 가지고 있거나 안면이 픽셀로 이루어져 있는지의 여부를 판별하는데 방해가 되는 노이즈가 생길 시 안면 위변조 여부를 정확하게 파악하기 힘든 단점을 가지고 있다.

제안된 시스템은 두 개의 방법을 활용하여 이러한 문제점을 해결하였다. 실제 얼굴인지 아닌지를 감지하는 기술과, 안면 인증을 하려는 동기를 가지고 있는지를 감지하는 기술이다. 첫 번째로, 제안된 딥러닝 기반의 시스템이 외부 카메라로 입력된 안면 이미지가 실제 안면을 촬영한 이미지인지, 사진이나 액정 등에 출력되는 위변조 안면 이미지인지를 판별한다<sup>[6, 7]</sup>. 이를 위해 실제 사람의 안면 이미지와 변조된 이미지들을 대량으로 만들어서 이를 분별할 수 있도록 딥러닝 모델을 학습시키며, 변조된 이미지는 핸드폰, 태블릿, 모니터, TV 등의 화면에 출력된 안면 혹은 종이에 인쇄된 안면을 사용하였다. 일차적으로 실제 사람이라고 판별이 완료되

면, 두 번째로 Nudge 이론을 이용하여 현재 안면 인증을 시도하는 사람이 출석 인증을 하려는 동기가 있는지를 판단한다<sup>[8, 9]</sup>. Nudge 효과는 누군가의 강요가 아닌 자연스러운 상황을 만들어 사람이 의도된 선택을 할 수 있도록 이끌어 주는 이론이며, 제안된 방법은 본 이론을 적용하여 화면의 중앙을 기준으로 랜덤한 방향으로 안내 문구를 출력하여 사람의 시선이 자연스럽게 글씨가 있는 방향으로 이동하는지를 검증한다. 이는 딥러닝 기반 One Stage Detection 시선 인식 알고리즘을 사용하여 구현되며, 이를 통하여 안내 문구에 반응하지 않는 정교한 이미지, 동영상 혹은 모형으로 시도하는 안면 인증을 방지하게 된다. 두 검사를 모두 통과하면, 모델은 검사 대상을 실제 사람으로 판별하며 기존 방식인 dlib 기반의 딥러닝 안면 인증 모델을 활용하여 출석 인증 기술을 구현하게 된다<sup>[10, 11]</sup>. dlib는 이미지 프로세싱 프로젝트에서 다양하게 응용되는 메소드이며 신뢰성 있는 안면 인증 검사를 위한 데이터셋인 LFW (Labeld Faces in the Wild) 기준으로 99.35%의 정확도를 가지고 있다. 더불어 효과적인 머신러닝 기반 이미지 전처리 기술을 사용하여 시스템에 등록되어 있는 안면의 이미지와 외부 카메라로 입력된 안면의 이미지를 비교하는 데 있어서 여러 방해 요소를 제거하고 최적화를 시켜 준다<sup>[12~15]</sup>. 이렇게 기존 기술에 2가지 안면 위변조 기술을 추가함으로써 출석 인증 시스템의 신뢰성 향상에 더불어 안면 인식 기술의 수요가 높아지는 추세에 출석 인증 시스템의 보급을 촉진한다.

## II. 기존 방식

기존에 통용되던 안면 인증 기반의 출석 인증 모듈은 시스템 내부에 등록되어 있는 인물의 안면 사진을 기반으로 외부로 들어오는 안면 이미지를 분석하여 도출되는 일치도가 정해놓은 threshold를 충족하면 같은 인물이라고 판별하게 된다<sup>[16, 17]</sup>. 이 방식은 pre-trained 모델을 사용하며, 시스템 내에 등록된 사람들에 대해 별도의 추가 학습 없이 안면 이미지들의 신원 확인을 위해 특화된 특징들을 벡터로 자동 추출하여 두 안면의 일치도를 확률로 확인할 수 있다. 또한, 시스템에 등록되어 있는 인물의 프로필 사진과 밝기, 얼굴의 각도, 이미지 사이즈, 좌우 반전 여부가 다를 수 있는 외부 이미지를 효과적으로 비교하기 위하여 4가지 이미지 전처리 기법을 거친다. 외부로 들어온 안면 이미지를 머신러닝 기반의 안면 특징 추출 모델을 사용하여 양쪽 눈

의 위치에 눈의 좌표가 담긴 Landmark를 표기하고, 다른 두 눈의 높이를 같게 일치시켜주는 식을 삼각함수를 통하여 도출하여 이미지를 자동 회전시킨다. 회전된 안면 이미지는 시스템 내부의 안면 이미지들과 얼굴의 각도가 일치하게 되고 특징을 비교하기 용이하게 된다. 또한 시스템 내에 등록되어있는 안면 이미지들과 외부 안면 이미지의 밝기와 이미지 크기를 동기화 시키고, 안면 이미지의 좌우 반전을 통한 데이터 어그멘테이션을 거쳐서 촬영된 안면 이미지의 설정에 따라 좌우 반전이 달라도 특징 비교에 문제가 없도록 보완한다. 이러한 이미지 전처리 기법을 거쳐 안면 인증을 진행하고 이미지 전처리 과정을 거치지 않았을 경우와 비교하여 약 5%의 안면 인증 성능 향상을 보였다<sup>[10]</sup>.

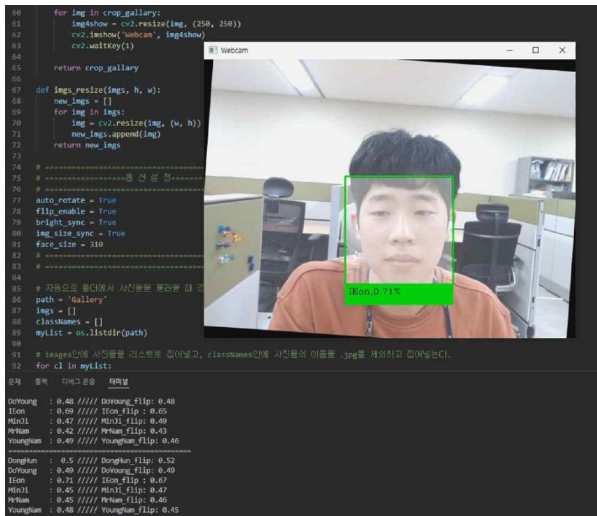


그림 1. 기존 출석 인증 시스템 구동 화면  
Fig. 1. Prior Face Identification Attendance check system.

하지만 기존 기술에서는 안면 위변조 기술이 없기 때문에 시스템 내에 등록되어있는 인물의 사진을 인쇄하거나 화면에 띄우면, 안면 인증 조작이 가능하다는 문제점이 있다. 이는 간단하게 모바일 기기에 본인이 아닌 다른 인물의 사진을 띄워 손쉽게 출석 인증이 가능함을 의미하고, 이는 대리출석 조작으로 이어진다. 이러한 단점들로 인하여 종래의 AI 기반 출석 인증 시스템의 효용성이 부족한 실정이다<sup>[18]</sup>.

### III. 제안된 방법

제안된 방법에서는 기존 방법인 안면 인증 기반의 출석 인증 시스템에 CNN 기반의 face spoofing detector와 Nudge 이론을 활용한 안면 위변조 감지 알

고리즘을 결합하여 기존의 문제점을 보완하고 향상된 기능의 출석 인증 모델을 제안하며 아래 그림 2는 제안된 방법의 순서도이다.




그림 2. 제안된 방법의 작업 순서도  
Fig. 2. Flow-Chart of proposed method.

#### 1. 딥러닝 기반 face spoofing detector

위변조 방지를 위한 첫 번째 방법은 딥러닝 기반의 Classifier를 사용하는 방법이다. 이를 통하여 실제 사람의 안면과 위변조된 인쇄 안면 혹은 화면에 출력된 안면의 특징을 자동으로 추출하여 분류한다. 딥러닝 모델로 사용된 YOLOv5 모델은 기존의 Object Detection 모델인 Faster R-CNN과 비교시 One Stage Detection 모델을 사용하여 분류 작업과 bounding box 작업을 동시에 수행하기 때문에 Faster R-CNN과 비슷한 정확도를 가짐과 동시에 6배 높은 모델 구동 속도로 실시간성을 가지고 있다<sup>[19]</sup>. Detector의 Backbone에서 위변조 여부를 감지할 때 안면보다 작은 커널이 이미지를 통과하면서 안면의 텍스처를 분석하게 된다. 이 분석된 텍스처를 기준으로 안면에서 픽셀의 특성이 검출되거나, 인쇄물의 특징이 보이는 경우를 위변조된 안면으로 판단한다<sup>[20]</sup>. 이후 Detector의 Head를 통하여 검출된 class의 위치를 찾고 face anti-spoofing을 구현하며 모델의 최종적인 분류는 'real'과 'fake'로 이루어진다<sup>[21]</sup>.



그림 3. LFW 데이터셋  
Fig 3. LFW(Labeled Faces in the Wild) dataset.

학습에 사용된 데이터셋은 LFW(Labeled Faces in the Wild)에서 인물의 안면 사진들을 사용하였고, 데이터셋 양 대비 학습 결과가 매우 우수하다고 알려진 1,000장을 각 class마다 사용하였다<sup>[22-24]</sup>. 본 데이터셋

은 wild 환경에서 수집된 안면 데이터들이기 때문에 조명과 노이즈등의 방해 환경에 robust한 성능을 보이는 강인한 이미지들로 구성되어 있다. 본 논문에서 제안하는 모든 딥러닝 모델들은 다양한 wild 환경에서의 안정적인 성능을 보이기 위하여 LFW 데이터셋으로 train data를 구성하였다. 다음의 그림 4과 같이 실제 안면 사진은 real 안면으로 라벨링 하였고, 원본 사진을 화면에 출력하여 카메라로 촬영한 사진과 종이에 인쇄하여 직접 촬영한 사진을 랜덤한 비율로 섞어서 fake 안면으로 라벨링 하였으며, 데이터 불균형 방지를 위하여 각 class별 데이터량이 동일하도록 fake 데이터에 언더샘플링을 하였다<sup>[25]</sup>. 다음의 그림 4과 같이 실제 안면 사진은 'real'로 라벨링 되었으며, 화면에 띄운 안면 혹은 종이에 인쇄한 안면은 변조된 안면으로 구분하여 'fake'로 라벨링 되었음을 알 수 있다. 학습에 사용된 원본 데이터는 총 2,000장이고 이를 어그멘테이션하여 10배로 늘려 총 20,000장을 train 70%, validation 20%로 나누어서 학습하였고 실험을 위하여 10%를 남겨두었다.




그림 4. 안면 위변조 분류 모델 학습 시 이미지 라벨링 예시: (a) real 안면 라벨링 예시; (b) 인쇄된 fake 안면 라벨링 예시; (c) 화면에 출력된 fake 안면 라벨링 예시

Fig. 4. Example of images labeling for model train: (a) real face labeling; (b) printed fake face labeling; (c) fake face on the screen labeling.

데이터의 라벨링과 증강은 Roboflow 사의 data processing 솔루션을 사용하였으며, 이미지 flip, crop, rotation, shear, saturation, brightness, exposure, blur, noise 총 9가지 기법을 사용하였다<sup>[26]</sup>. YOLOv5 학습 시 기존의 pre-trained된 모델 yolov5x6 로 트랜스퍼 러닝을 하였으며, 지정한 하이퍼 파라미터는 표 1과 같다.

표 1. YOLOv5 학습 시 하이퍼 파라미터

Table 1. YOLOv5 hyper parameters.

batch size	16
epochs	100
image size	1280 * 1280

batch size는 16으로 설정하였으며, 트랜스퍼 러닝에 사용될 coco-dataset 기준으로 pre-trained 된 weight file은 모델 구동 fps는 가장 느리지만 성능이 가장 우수하고 1280\*1280 이미지 사이즈를 지원하는 yolov5x6를 사용하였다<sup>[27]</sup>. 이미지 크기 640\*640을 지원하는 기존의 yolov5x를 사용하지 않은 이유는, 화면에 출력된 안면 혹은 인쇄된 안면이 모델에 입력되었을 경우 픽셀 혹은 인쇄된 종이의 미세한 특징을 추출해야 하고, 가능한 작은 크기의 픽셀을 검출하기 위함이다. 학습은 총 100 epochs를 진행하였다.

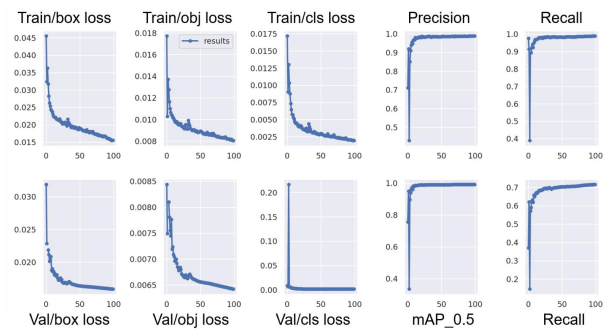


그림 5. CNN 기반 Object Detector 학습 그래프  
Fig. 5. CNN based Object Detector train graph.

그림 5의 학습 그래프를 보면, mAP\_0.5가 1로 수렴하도록 충분히 학습을 진행하였음을 알 수 있으며, 모델의 오버피팅을 방지하기 위하여 best model save 기법을 통해 자동으로 도출된 weight file을 사용하였다<sup>[28]</sup>.

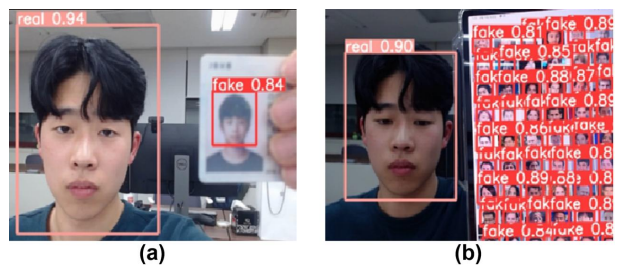


그림 6. real 안면과 fake 안면 검출 결과: (a) real 안면과 인쇄된 fake 안면을 detection한 결과; (b) real 안면과 화면에 출력된 fake 안면을 detection한 결과  
Fig. 6. Result of detection between real face and fake face: (a) result of detection between real face and printed fake face; (b) result of detection between real face and fake faces on the screen.

학습 결과 그림 6과 같이 real 안면과 fake 안면을 다양한 안면 위변조 상황에서 효과적으로 검출함을 알 수 있다. 신뢰성 있는 모델 평가를 위하여 실험에는 2

가지 데이터셋이 사용되었고, LFW에서 추출하여 제작한 데이터셋과, 랜덤한 피실험자를 실제로 촬영하여 제작한 데이터셋으로 구성하였다<sup>[22]</sup>.

첫 번째로, 신뢰성 있는 데이터셋을 바탕으로 모델의 성능을 검증하기 위하여 LFW 데이터셋 분류 실험을 하였다. 모델 학습 시 실험을 위하여 LFW 데이터셋에서 분리한 10%의 사진을 기준으로 2,000장의 평가 데이터셋을 구성하여 real-time으로 분류 실험을 진행하였다. 본 실험의 결과는 Confusion Matrix를 기반으로 평가되었으며, 식 (1)을 기준으로 정확도를 산출하였다<sup>[29]</sup>.

$$Acc. = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

위 식은 안면의 위변조 여부를 분류하는 분류 정확도인 Acc.를 구하는 공식이며 TP(True Positive)와 TN(True Negative)은 정상 사진과 위변조 사진을 옳게 분류한 경우이고, FP(False Positive)와 FN(False Negative)은 위변조 사진과 정상 사진을 오 분류한 경우이다.

표 2. LFW 기반 CNN 안면 위변조 분류 모델 평가표  
Table 2. Result of trained CNN face spoofing detector classification test by LFW dataset.

Confusion Matrix	Predicted (real face)	Predicted (fake face)
Ground Truth (real face)	TP: 986	FN: 14
Ground Truth (fake face)	FP: 23	TN: 977

표 2는 LFW로 구성된 2,000개의 real, fake 데이터셋을 학습된 CNN 모델로 분류한 Confusion Matrix이며, 표의 'Ground Truth'와 'Predicted' 항목은 사진의 대한 정답지와 예측 결과이다. 실험 결과는 정답지와 예측 결과의 일치 여부를 기준으로 도출되었고, TP 986개, TN 977개, FP 23개, FN 14개이다. Confusion Matrix와 식 (1)을 기반으로 안면 위변조 분류 모델은 0.98의 정확도를 산출한다.

두 번째로, 생활환경에서의 모델 성능을 검증하기 위하여 위의 그림 7과 같이 평가 데이터셋을 구성하였다. 랜덤하게 모집한 30명의 인원이 직접 안면 위변조 검사에 참가한 경우가 (a)이며, 참가된 안면을 (b), (c)와 같이 위변조 데이터로 제작하여 90개의 평가 데이터를 구축하고 동일한 방법으로 평가를 진행하였다.




그림 7. 모델 검증을 위한 생활환경에서의 데이터: (a) 인물의 실물; (b) 인쇄된 fake 사진; (c) 화면에 출력된 fake 사진

Fig. 7. Test dataset for model evaluation from living environment: (a) real person's face; (b) printed fake face; (c) fake face on the screen.

표 3. 실제 촬영 데이터 기반 CNN 안면 위변조 분류 모델 평가표

Table 3. Result of trained CNN face spoofing detector classification test by our own dataset.

Confusion Matrix	Predicted (real face)	Predicted (fake face)
Ground Truth (real face)	TP: 28	FN: 2
Ground Truth (fake face)	FP: 6	TN: 54

표 3은 해당 모델의 평가 결과이며 Confusion Matrix와 식 (1)을 기반으로 본 실험에서 0.98의 정확도가 산출되었다. 두 실험의 결론으로, 신뢰성과 실제 환경을 바탕으로 구성된 LFW 데이터셋과 커스텀 데이터셋을 활용한 실험들을 기준으로 진행된 테스트를 통해 98%와 91%의 분류 정확도를 확인하였다. 이를 통하여 제안된 CNN 모델의 성능을 검증 하였으며, 제안된 방법은 효과적으로 안면의 위변조 여부를 분류한다.

추가적으로 모델의 오 분류 케이스에 대하여 분석을 하였으며, LFW 데이터셋을 기반으로 한 실험에서 14건이 검출된 FN 케이스는 real 안면을 fake로 분류하기 때문에 출석 인증 시스템의 보안상 문제가 되지 않음을 확인하였다. 하지만 오 분류 케이스의 대부분을 차지하는 FP 케이스는 fake 인 안면을 real 로 감별하기 때문에 모델의 신뢰성에 악영향을 끼치며, 개선을 위하여 대표적인 사례들을 샘플링 하였다.

그림 8의 사진 (a), (b)는 모델의 오 분류 케이스중 FP를 샘플링한 결과의 예시이다. (a)와 같이 초점이 맞지 않거나 카메라, PC 등의 장비 문제를 이유로 화질 저하가 일어난 안면은 모델이 화면상의 안면과 인쇄된 안면의 특징을 파악할 수 없는 조건이기 때문에 화면에 출력된 fake 안면임에도 불구하고 real 안면으로 오 분




그림 8. FP 케이스 샘플링 예시: (a) 초점이 맞지 않는 ‘화면에 출력된 안면’; (b) 확대된 ‘인쇄된 안면’  
Fig. 8. Example of FP cases of our classification model: (a) fake face on the screen that is out of focus; (b) printed fake face that is zoomed in.

류하는 경우이다. 또한 (b)와 같이 인쇄된 fake 안면 사진 중 확대가 되어 인쇄 여부를 구분하기 어려운 경우 입에 동시에 종이 질감을 가려낼 수 없는 불충분한 해상도를 가지고 있는 경우도 real 안면으로 오 분류하는 현상을 보였다. 이를 보완하기 위하여 Nudge 이론 기반의 새로운 솔루션을 제안한다.

## 2. Nudge 이론 활용 시선 추적을 통한 사용자 동기 파악 모델

제안된 방법은 Nudge 이론을 기반으로 안면 인증을 수행하는 사람의 동공 움직임을 유도하여, 그 인물이 실제 사람이라면 움직여야 할 시선을 딥러닝 기반의 Iris Detection 모델로 파악하고, 이 결과를 바탕으로 검사 대상의 인물이 실제 사람임은 물론 안면 인증을 하려는 동기가 있는지 판단하여 안면 위변조 상황을 검출하고 방지하는 솔루션이다. Nudge는 ‘옆구리를 슬쩍 찌른다’는 뜻으로 강요에 의하지 않고 유연하게 개입함으로써 의도된 선택을 유도하는 방법을 말한다. 이 이론은 경계를 넘어 많은 분야에서 다양한 문제를 해결하기 위하여 폭넓게 활용되고 있으며 실생활에서 접할 수 있는 대표적인 Nudge 이론을 활용한 문제 해결의 예시는 소변기에 그려진 파리이다<sup>[8, 30]</sup>.

Nudge 효과가 적용된 그림 9의 소변기는 가운데 파리 그림이 있다. 따라서 사용자가 이 소변기를 이용할 때 파리에 집중하여 용변을 보게 되고 결과적으로 소변 튼 현상을 최소화하도록 인간의 행동을 유도한다. 이 소변기에서 사람의 행동을 유도하게 되는 파리와 같은 존재를 안면 인증을 하는데 있어서 ‘자연스럽게 읽게 되는 안내 문구’로 바꾸었다. 또한 이 문구의 위치를 랜덤하게 변경함으로써 문구를 읽기 위하여 따라가는 홍채 움직임을 감지하고, 동기에 맞게 움직이는지를 검사



그림 9. 생활환경에서 넛지 이론을 활용한 예시  
Fig. 9. Example of Nudge theory application in living environment.

하는 메커니즘이다. 사람의 홍채를 Detection하는 시스템은 face spoofing detection에 사용된 CNN 기반의 딥러닝 모델을 동일하게 사용하였으며, 추가 개발된 효과적인 알고리즘을 더하여 인물의 시선을 감지할 수 있도록 본 기술을 제안한다<sup>[31, 32]</sup>. 안면 인증 모듈이 구동되고 사용자가 안면 인증을 시도하기 시작하면, 화면의 중간을 기점으로 좌, 우, 위, 아래 방향으로 나눈다. 그 후 랜덤하게 지정된 안내 문구를 표시한다.

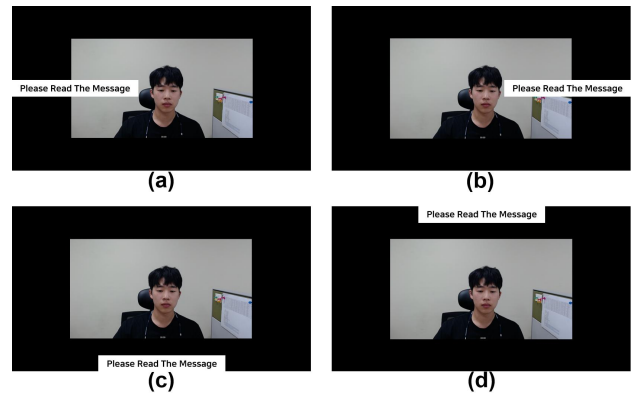


그림 10. 랜덤한 4가지 안내 문구 출력 예시: (a) 화면의 좌측; (b) 화면의 우측; (c) 화면의 아래; (d) 화면의 위  
Fig. 10. Examples for 4 directions of random message: (a) left side of the screen; (b) right side of the screen; (c) down side of the screen; (d) up side of the screen.

랜덤한 안내 문구가 4가지 방향으로 출력된 이후 CNN 기반의 Object Detection 모델을 활용하여 사람의 시선이 안내 문구의 방향대로 이동하는지를 검사한다. 시선 검출 모델의 학습은 LFW를 기준으로 랜덤하

게 추출한 1,000장을 사용하였으며, 동공의 다양한 움직임이 포함된 데이터가 부족하여 추가적으로 다양한 인물들이 동공을 여러 방향으로 움직이는 영상을 촬영하고, 촬영된 영상에서 필요한 frame 들만 추출하여 학습에 사용하였다<sup>[23, 24]</sup>. 동공의 움직임을 감지하기 위해서는 그림 11과 같이 가려진 동공의 위치와 중앙 좌표를 정확히 검출해 냄으로서 동공이 눈 기준으로 어느 위치에 있는지를 정확히 알 수 있어야 하며 이를 위해 학습된 class를 눈, 동공 2가지로 나누었다.

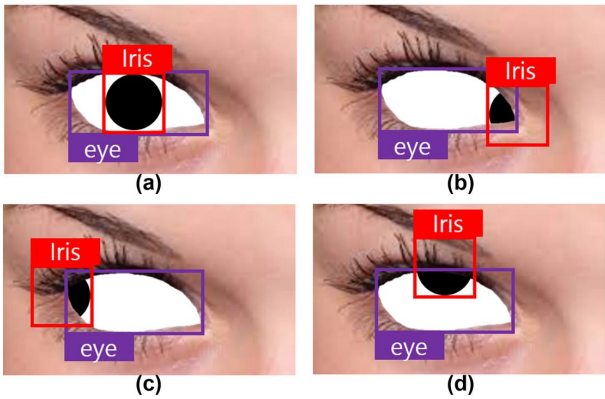


그림 11. 올바른 동공과 눈 검출 예시: (a) 눈동자가 모두 보일 때; (b) 눈동자가 우측으로 일부 가려져 있을 때; (c) 눈동자가 좌측으로 일부 가려져 있을 때; (d) 눈동자가 위로 일부 가려져 있을 때

Fig. 11. Correct example of iris and eye detection: (a) iris on the center position; (b) iris on the right side and hidden about a half; (c) iris on the left side and hidden about a half; (d) iris on the up side and hidden about a half.

가려진 동공의 위치를 포함한 동공의 윤곽을 정확히 검출하기 위해서, 기존과는 다른 라벨링 방법을 사용하였다. 기존의 Object Detection 모델 학습 시 사용하는 일반적인 이미지 라벨링 방법은 검출된 이미지의 영역만 bounding box로 표시한다. 그러나 아래 그림 12와 같이 동공 라벨링 시 가려진 눈동자의 위치를 사람이 직접 예측하여 실제 보이지 않는 범위까지의 동공을




그림 12. 동공과 눈 라벨링 예시  
Fig. 12. Example of iris and eye labeling.

bounding box로 라벨링 하였고, 눈의 윤곽 또한 환자의 경계선에 정확히 맞추었다.

그림 12는 Train을 위한 올바른 라벨링의 예시이며, 학습 결과 입력되는 인물의 눈과 동공을 정밀하게 검출하였다. 모든 Class에 대한 Bounding box의 좌표가 정확하여 사람의 시선을 추적하기에 용이했고, 아래의 그림 13은 모델에서 검출된 Bounding box의 좌표를 이용하여 시선 추적을 하는데 사용된 좌표이다.




그림 13. 계산을 위해 필요한 좌표 표기(좌측 눈)  
Fig. 13. Coordination for iris location detect(left eye).

좌측 눈에 필요한 좌표는 그림 13과 같이  $x1 \sim x4$ ,  $y1 \sim y4$ 이며, 우측 눈 또한  $x5 \sim x8$ ,  $y5 \sim y8$ 까지 동일한 방식으로 구성되어 있다. 이 좌표들을 기준으로 사람의 시선을 예측하는데 있어서 홍채의 위치가 눈의 중앙을 기준으로 얼마나 이동해야 시선을 바꾸었다고 인정할 것인지에 대한 threshold를  $x, y$  방향인  $tx, ty$ 로 정의하였으며 시선을 도출하는 식은 다음과 같다.

$$iris\ per_x = \frac{\left(\frac{x4 - x1}{x2 - x1}\right) + \left(\frac{x8 - x5}{x6 - x5}\right)}{2} - 0.5 - tx \tag{2}$$

$$iris\ per_y = \frac{\left(\frac{y4 - y1}{y2 - y1}\right) + \left(\frac{y8 - y5}{y6 - y5}\right)}{2} - 0.5 - ty \tag{3}$$

식 (2), (3)에서는 좌측 우측 눈의 좌표와 홍채의 좌표를 비교하여 홍채의 위치를 0 ~ 1 사이의 값으로 normalize 하여, 그 값을 평균 낸 후에 지정된 threshold 값에 따라서  $x$ 와  $y$ 의  $iris\ per$ 를 도출하고, 그 값에 따라 인물의 시선을 판단한다. 지정된 threshold 값은 30명의 인물을 통한 실험으로 얻었으며, 좌우 기준값을 나타내는  $tx$ 는 0.2, 위아래를 나타내는  $ty$ 는 0.25로 지정하였다.

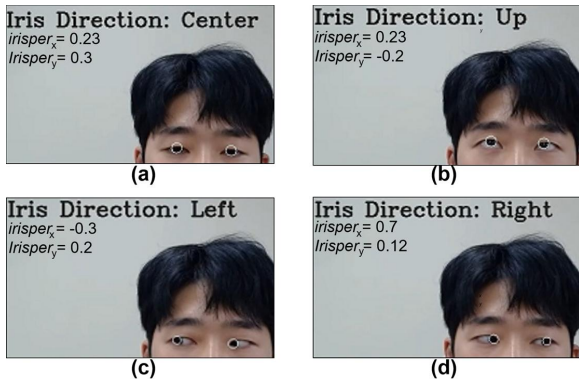


그림 14. 시선 감지 모듈을 활용한 상황별 tx, ty 측정 결과와 도출된 인물의 시선: (a) 시선이 정면으로 검출됨; (b) 시선이 위로 검출됨; (c) 시선이 좌측으로 검출됨; (d) 시선이 우측으로 검출됨

Fig. 14. Result of tx and ty measurement and direction of eye by iris analysis model test: (a) detected as looking forward; (b) detected as looking up; (c) detected as looking left; (d) detected as looking right.

그림 14는 시선 감지 모듈을 실제로 테스트한 결과이며, 홍채에 표시된 흰색 원은 bounding box를 원으로 표현한 것이다. 그리고 눈매 검출은 정상적으로 진행이 되지만 내부 알고리즘에서 계산으로만 사용하고 화면상에 표기하지 않으며 모델이 인물의 홍채 위치를 정확히 파악하고, 더불어 보고 있는 시선도 파악하여 도출해낼 수 있다. 제안된 방법은 CNN 기반 홍채 검출 결과와 Nudge 이론을 통합하여, 출석 인증 중 화면상에 랜덤한 방향으로 안내 문구를 띄워서 인증받는 사람이 그 안내 문구를 읽도록 유도하고, 그에 따른 시선 검사를 통하여 최종적으로 안면 위변조를 감지한다. 따라서 제안된 기술은 화면에 출력되는 안내 문구를 바라보아야 출석 인증을 통과할 수 있기 때문에, 한 장의 얼굴 사진만으로는 위변조가 힘든 장점을 가지고 있다. 하지만 사용자들이 화면 문구가 네 방향에서 출력된다는 것을 안다면 해당 방향들을 바라보는 4장의 이미지를 더 만들어서 손쉽게 위변조가 가능할 것으로 예상되기 때문에 이를 예방하기 위하여 첫 번째 제안된 딥러닝 기반의 face spoofing detector를 함께 사용하여 위변조 사진을 만들더라도 가짜 사진으로 판별할 수 있도록 두 시스템을 상호보완적 관계로 설계하였다.

## IV. 실험

### 1. Nudge 이론 활용 시선 추적을 통한 사용자 동기 파악 모델

제안된 시스템은 Nudge 이론과 딥러닝 기반의 시선 추적 알고리즘을 사용하여 사용자가 출석 체크를 원하는지의 동기를 파악한다. 따라서 사용자의 동기 파악 정확성을 모델 평가에 반영할 수 있도록 실험 환경을 구성하였다. 테스트 데이터셋은 랜덤한 30명의 피실험자를 기준으로 real과 fake 안면을 혼합하여 구성하고 제안된 방법이 안면 위변조 케이스를 얼마나 정확하게 판별하는지를 측정하였다. 인원 30명 중 15명은 실물로 안면 인증을 진행한 real 케이스이며, 나머지 15명은 인쇄된 사진과 화면에 출력된 얼굴을 혼합한 fake 케이스로 구성하였다. 평가 지표는 Confusion Matrix를 사용하였으며 TP와 TN은 real 안면이 출석 인증을 성공한 경우와, fake 안면이 출석 인증을 실패한 경우이다. FP와 FN은 fake 안면이 출석 인증을 성공한 경우와 real 안면이 출석 인증을 실패한 경우이다.

표 4. Nudge 이론 활용 시선 추적을 통한 사용자 동기 파악 모델 테스트 결과

Table 4. Result of Nudge Theory based user's purpose judge system test.

Confusion Matrix	Predicted (real face)	Predicted (fake face)
Ground Truth (real face)	TP: 14	FN: 1
Ground Truth (fake face)	FP: 0	TN: 15

표 4는 본 실험에 대한 평가 결과를 Confusion Matrix로 나타낸 표이며 real 인물이 출석 인증을 실패한 경우는 있었으나, fake 안면을 모두 검출했다. Nudge 이론을 기반으로 한 안면 위변조 판별 모델의 정확도는 식 (1)을 기준으로 도출하였으며, 계산된 정확도는 0.96이다. 실험에서의 오분류 케이스들은 fake 인물이 출석 인증을 통과한 경우가 아니기 때문에 출석 인증 시스템의 신뢰성에 악영향을 끼치지 않는다. 따라서 본 실험을 통해 제안한 Nudge 이론과 CNN 기반의 시선 추적 알고리즘을 활용한 사용자 동기 파악 모델이 안면 위변조를 효과적으로 방지함을 확인하였다.



2. 최종 제안된 시스템의 케이스별 성능 비교

본 논문에서는 기존의 출석 체크 시스템의 기능을 향상시키기 위하여 두 가지의 새로운 안면 위변조 방지 시스템을 제안하였다. 더불어 제안된 안면 위변조 방지 알고리즘들의 효용성을 다양한 실험을 통하여 개별적으로 검증하였다. 따라서 본 실험에서는 제안된 두 솔루션이 결합된 최종적인 출석 체크 시스템의 효용성을 검증하기 위하여 지금까지 제안된 모든 메소드들을 다양한 조합으로 구성하여 성능 비교실험을 하였다. 평가에 사용될 데이터셋은 정확도가 0.91로 분류 성능이 가장 낮게 기록된 생활환경에서 수집된 실험군과 동일한 방식으로 데이터셋을 구성하였고, 추가적으로 다양한 wild 환경에서의 안정적인 성능을 보이는지의 검증을 위하여 아래의 그림 15와 같이 조도 센서의 Lux값을 이용하여 국제조명위원회에서 명시한 어두운 환경인 LZ1과 높은 휘도 지역인 LZ4에 맞춘 실내와 실외 환경을 다양한 조명의 각도와 세기로 구성하였다<sup>[33~35]</sup>. 또한 안면과 카메라의 거리, 각도의 다양성, 노이즈를 더한 상황에서 모델의 평가가 가능하도록 모든 이미지를 모델에 투입하기 전에 Random Crop, Random Twist, Random Noise 기법을 사용하여 데이터 증강을 시행하였다<sup>[36]</sup>.

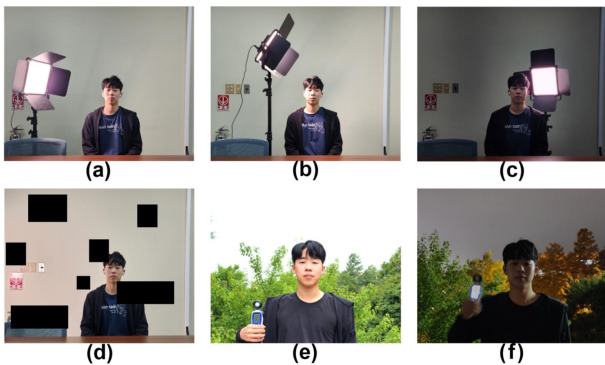


그림 15. wild 환경을 고려한 실험 데이터 제작 예시: (a) 실내에서 안면의 측면에 조명 설치; (b) 실내에서 안면의 상단부에 조명 설치; (c) 실내에서 안면의 후면에 조명 설치; (d) 안면에 랜덤한 노이즈 발생; (e) 밝은 실외 환경에 안면 노출 (LZ4); (f) 어두운 실외 환경에 안면 노출 (LZ1)

Fig. 15. Example of test dataset to evaluate our model on wild condition: (a) light on beside of the face in indoor; (b) light on up side of the face in indoor; (c) light on back side of the face in indoor; (d) random noise on the face; (e) face in bright condition at outdoor (LZ4); (f) face in dark condition at outdoor (LZ1).

위 방법을 기준으로 수집한 랜덤한 피실험자 30명의 안면 이미지를 그림 7와 같이 실제 얼굴과 위변조된 안면으로 구분하여 실험 데이터셋으로 90개의 평가 데이터를 구축하였으며, 이는 real 안면 30장과 fake 안면 60장으로 이루어져 있다. 각 케이스의 성능 평가 기준은 출석 체크 시스템이 안면 위변조 사진을 올바르게 판별하는지의 여부를 측정하여 Confusion Matrix로 나타내었고 식 (1)을 기준으로 최종 정확도를 산출하였다.

표 5. 여러 Method 조합별 안면 위변조 판별 실험 결과표

Table 5. Result of face anti-spoofing classification on various cases on proposed methods based.

	CNN	Nudge Theory	Acc.
Case 1	Not Applied	Not Applied	0.33
Case 2	Applied	Not Applied	0.91
Case 3	Not Applied	Applied	0.96
Case 4	Applied	Applied	<u>0.98</u>

표 5의 ‘CNN’은 CNN 기반의 안면 위변조 판별 시스템이며 ‘Nudge Theory’는 새롭게 제안된 Nudge 기반의 사용자 시선 추적을 통한 동기 파악 알고리즘이다. ‘Case 1’에서는 두 가지 안면 위변조 방지 메소드들을 모두 사용하지 않고 기존의 출석 체크 시스템만 사용하였기 때문에 모든 fake 안면들을 판별하지 못해서 정확도가 0.33이다. 나머지 ‘Case 2, 3’은 본 논문에서 제안된 두 안면 위변조 방지 솔루션을 개별적으로 적용하여 테스트가 진행되었고, 그 결과 두 경우 모두 안면 위변조 여부를 판별하는 성능은 우수하지만, Nudge 시스템을 사용한 ‘Case 3’이 비교적 우세함을 알 수 있다. 최종적으로 본 논문에서 제안한 시스템인 ‘Case 4’는 기존의 출석 체크 모델에 제안된 2가지의 안면 위변조 방지 솔루션을 모두 결합한 모델이며, 조명 세기 및 각도의 변화가 있는 다양한 wild 환경에서도 정확도 0.98로 가장 우세한 성능을 보였다.

V. 결 론

본 논문은 안면 인증 기반의 출석 인증 시스템을 사용하는 상황에서 안면 위변조 문제를 효과적으로 방지할 수 있는 방법을 새롭게 제안하였다. 제안된 방식은 CNN 기반의 딥러닝과 Nudge 이론을 활용하여 안면 위변조를 효과적으로 방지하고, 이를 통한 출석 인증


시스템의 고도화에 목적이 있다. 다양한 실험을 통하여 제안된 2가지 방식의 효과를 검증하였으며, 본 시스템을 적용한 출석 인증 시스템은 98%의 정확도로 안면 위변조 상황을 효과적으로 판별한다. 이 상호보완적인 두 메소드를 독립적으로 사용하였을 때 발생하는 기술적 한계를 극복하기 위한 모델의 고도화 작업이 향후의 연구계획이며, 지속적으로 발생하는 새로운 안면 위변조 기법들을 유연하게 탐지하는 방법론과 전체적인 모델의 정확도 향상이 앞으로의 연구의 목표이다. 본 시스템을 바탕으로 안면 인증의 수요가 증가하는 추세와 함께 나타나는 안면 위변조 문제에 있어서 관련 범죄를 예방하고, AI 기반의 안면 인증 시스템 보급의 가속화를 도모하는 방안을 제안한다.

## REFERENCES

- [1] W. Zhao, R. Chellappa, P. J. Phillips and A. Rosenfeld, "Face recognition: A literature survey," *ACM computing surveys (CSUR)*, vol. 35, no. 4, pp. 399-458, December 2003.
- [2] M. Caldwell, J. Andrews, T. Tanay and L. Griffin, "AI-enabled future crime," *Crime Science*, vol. 9, no. 1, pp. 1-13, August 2020.
- [3] J. Jung et al., "Development of Anti-Spoofing Equipment Architecture and Performance Evaluation Test System," *Journal of Positioning, Navigation and Timing*, vol. 7, no. 3, pp. 127-138, September 2018.
- [4] Z. Boulkenafet, J. Komulainen and A. Hadid, "Face anti-spoofing based on color texture analysis," in *Proc. of IEEE International Conf. on image processing (ICIP)*, pp. 2636-2640, Quebec City, Canada, September 2015.
- [5] W. Kim, "Face Anti-spoofing: A Comparative Review and Prospects," *IEIE Trans. on Smart Processing & Computing*, vol. 10, no. 6, pp. 455-463, July 2021.
- [6] X. Tu and Y. Fang, "Ultra-deep neural network for face anti-spoofing," *International Conf. on Neural Information Processing*, pp. 686-695, Long Beach, CA, USA, October 2017.
- [7] L. Li et al., "An original face anti-spoofing approach using partial convolutional neural network," *International Conf. on Image Processing Theory Tools and Applications (IPTA)*, pp. 1-6, Oulu, Finland, January 2017.
- [8] R. E. Thaler and C. R. Sunstein, *Nudge, Leader's Book*, pp. 50-300, June 2022.
- [9] D. Misawa, J. Fukuyoshi and S. Sengoku, "Cancer prevention using machine learning, nudge theory and social impact bond," *International Journal of Environmental Research and Public Health*, vol. 17, no. 3, January 2020.
- [10] I-E. Na, H. M. Ro and D. K. Hwang, "Improvement of face recognition attendance system by using machine learning image preprocessing," *Conf. on The Institute of Electronics and Information Engineers (IEIE)*, Jeju, South Korea, June 2022.
- [11] D. H. Yeo, H. M. Ro and B. I. Hwang, "Non-contact student concentration analysis algorithm using cnn-based facial condition detection model," *Conf. on The Institute of Electronics and Information Engineers (IEIE)*, Jeju, South Korea, June 2022.
- [12] B. Jun, H. S. Lee, J. Lee and D. Kimy, "Statistical face image preprocessing and non-statistical face representation for practical face recognition," in *Proc. of IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)*, pp. 392-397, Ajman, United Arab Emirates, February 2009.
- [13] D. Zhang, J. Li and Z. Shan, "Implementation of dlib deep learning face recognition technology," in *Proc. of IEEE Conf. on Robots & Intelligent System (ICRIS)*, pp. 88-91, Sanya, China, November 2020.
- [14] K. Amrutha, P. Prabu and J. Paulose, "Human Body Pose Estimation and Applications," in *Proc. of IEEE Innovations in Power and Advanced Computing Technologies (i-PACT)*, pp. 1-6, Kuala Lumpur, Malaysia, November 2021.
- [15] C. Lugaresi et al., "MediaPipe: A Framework for Building Perception Pipelines," *arXiv preprint arXiv:1906.08172*, June 2019.
- [16] S. Sharma, K. Shanmugasundaram and S. K. Ramasamy, "FAREC—CNN based efficient face recognition technique using Dlib," in *Proc. of IEEE International Conf. on Advanced Communication Control and Computing Technologies (ICACCCT)*, pp. 192-195, Ramanathapuram, India, May 2016.
- [17] M. Xu, D. Chen and G. Zhou, "Real-time

- face recognition based on Dlib," *Innovative Computing, Singapore*, pp. 1451-1459, September 2020.
- [18] J. Galbally, S. Marcel and J. Fierrez, "Biometric antispoofing methods: A survey in face recognition," *IEEE Access*, vol. 2, pp. 1530-1552, December 2014.
- [19] I. W. A. S. Darma, N. Suciati and D. Siahaan, "A performance comparison of balinese carving motif detection and recognition using YOLOv5 and mask R-CNN," in *Proc. of IEEE International Conf. on Informatics and Computational Sciences (ICICoS)*, pp. 52-57, Semarang, Indonesia, November 2021.
- [20] R. Azad et al., "On the texture bias for few-shot cnn segmentation," in *Proc. of the IEEE/CVF Winter Conf. on Applications of Computer Vision (WACV)*, pp. 2674-2683, Waikolora, USA, January 2021.
- [21] D. Thuan, "Evolution of Yolo algorithm and Yolov5: The State of the Art object detection algorithm," *THESEUS*, 2021.
- [22] G. B. Huang and E. Learned-Miller, "Labeled faces in the wild: Updates and new reporting procedures," *Dept. Comput. Sci. Univ. Massachusetts Amherst*, MA, USA, Tech. Rep, vol. 14, no. 003, 2014.
- [23] J. Cho, K. Lee, E. Shin, G. Choy and S. Do, "How much data is needed to train a medical image deep learning system to achieve necessary high accuracy," *arXiv preprint arXiv:1511.06348*, 2015.
- [24] S. Shahinfar, P. Meek and G. Falzon, "How many images do I need Understanding how sample size per class affects deep learning model performance metrics for balanced designs in autonomous wildlife monitoring," *Ecological Informatics*, vol. 57, May 2020.
- [25] C. Drummond and R. C. Holte, "C4.5 class imbalance and cost sensitivity: why under sampling beats over sampling," *Workshop on learning from imbalanced datasets II*, vol. 11, pp. 1-8, August 2003.
- [26] M. Kim and Y. Shin, "Development of a Web Browser-based Character in Video Metadata Generation Tool," *Journal of Korean Institute of Information Technology (KIIT)*, vol. 19, no. 11, pp. 143-153, November 2021.
- [27] M. Uzar, Ş. Öztürk, O. C. Bayrak, T. Arda and N. T. Öcalan, "Performance analysis of YOLO versions for automatic vehicle detection from UAV images," *Journal of Advanced Remote Sensing*, vol. 1, no. 1, pp. 16-30, March 2022.
- [28] L. Prechelt, "Early stopping-but when," *Neural Networks: Tricks of the trade Berlin Heidelberg*, vol. 1524, pp. 55-69, 1998.
- [29] K. C. McGwire and P. Fisher, "Spatially variable thematic accuracy: Beyond the confusion matrix," *Spatial uncertainty in ecology*, New York, USA, pp. 308-329, 2001.
- [30] P. G. Hansen and A. M. Jespersen, "Nudge and the manipulation of choice: A framework for the responsible use of the nudge approach to behaviour change in public policy," *European Journal of Risk Regulation*, vol. 4, no. 1, pp. 3-28, March 2013.
- [31] Z. Wei, X. Qiu, Z. Sun and T. Tan, "Counterfeit iris detection based on texture analysis," in *Proc. of IEEE International Conf. on Pattern Recognition*, pp. 1-4, Tampa, FL, USA, December 2008.
- [32] W. Huang, Q. Sun, C. P. Lam and J. K. Wu, "A robust approach to face and eyes detection from images with cluttered background," in *Proc. of IEEE International Conf. on Pattern Recognition*, vol. 1, pp. 110-113, Brisbane, Queensland, Australia, August 1998.
- [33] S.-N. Park, S.-J. Park and D.-H. Lee, "Standardization of LED measurement by the International Lighting Commission," in *Proc. of the Korean Institute of Illuminating and Electrical Installation Engineers*, vol. 26, no. 5, pp. 25-34, September 2012.
- [34] S.-H. An, "Foreign Light Pollution Management System and Evaluation Techniques," in *Proc. of the Korean Institute of Illuminating and Electrical Installation Engineers*, vol. 30, no. 3, pp. 4-12, May 2016.
- [35] J. Schanda, *Understanding the CIE System*, WILEY, pp. 25-443, July 2007.
- [36] C. Shorten and T. M. Khoshgoftaar, "A survey on image data augmentation for deep learning," *Journal of big data*, vol. 6, no. 1, pp. 1-48, July 2019.

저 자 소 개




라 이 언(비회원)  
2015년~2021년 HPS 산업용  
로봇 FA 엔지니어.  
2022년 한국공학대학교  
산업융합학과 학사 졸업.  
2022년~현재 포항공과대학교  
인공지능연구원  
연구부 연구원.

<주관심분야: ML/DL, Computer vision, Face  
recognition, Robotics>



여 동 훈(비회원)  
2021년 영남대학교 전자공학과  
학사 졸업.  
2021년~현재 포항공과대학교  
인공지능연구원  
연구부 연구원.

<주관심분야: Deep learning, Computer vision,  
Object detection, Face recognition>



황 병 일(비회원)  
2017년 경북대학교 컴퓨터학부  
석사 졸업.  
2022년~현재 포항공과대학교  
인공지능연구원  
연구부 연구원.

<주관심분야: Data analysis, Deep learning,  
Time series prediction>



김 동 주(비회원)  
2010년 성균관대학교 전기 전자  
컴퓨터공학 박사 졸업.  
2011년~2015년 대구 경북 과학  
기술원 IT 융합 연구부  
선임연구원.  
2015년~2016년 동서대학교 컴퓨터  
공학부 조교수.

2016년~현재 포항공과대학교 인공지능연구원  
연구부 연구부장.

<주관심분야: Computer vision, Face recognition,  
Deep learning>



서 영 주(비회원)  
1996년 Georgia Institute of  
Technology 컴퓨터공학  
박사 졸업.  
1998년~현재 포항공과대학교  
컴퓨터공학과 교수.  
2016년~2020년 포항공과대학교  
정보통신연구소 소장.

2020년~현재 포항공과대학교 인공지능연구원  
원장.

<주관심분야: AI, IoT, 행동인식, 실내 포지셔닝>



황 도 경(비회원)  
2020년~2020년 포항공과대학교  
PMC 연구실 연구원.  
2020년 부산대학교 전자공학과  
석사 졸업.  
2020년~현재 포항공과대학교  
인공지능연구원  
연구부 연구원

<주관심분야: Data restoration, DL/ML, Image  
processing, Signal processing>