

논문 2024-13-30

# 딥러닝 기반 저조도 향상 기술을 활용한 얼굴 인식 성능 개선

## (Deep Learning-Based Face Recognition through Low-Light Enhancement)

백 창우, 공 경보\*

(Changwoo Baek, Kyeongbo Kong)

**Abstract** : This study explores enhancing facial recognition performance in low-light environments using deep learning-based low-light enhancement techniques. Facial recognition technology is widely used in edge devices like smartphones, smart home devices, and security systems, but low-light conditions reduce accuracy due to degraded image quality and increased noise. We reviewed the latest techniques, including Zero-DCE, Zero-DCE++, and SCI (Self-Calibrated Illumination), and applied them as preprocessing steps in facial recognition on edge devices. Using the K-face dataset, experiments on the Qualcomm QRB5165 platform showed significant improvements in F1 SCORE from 0.57 to 0.833 with SCI. Processing times were 0.15ms for SCI, 0.4ms for Zero-DCE, and 0.7ms for Zero-DCE++, all much shorter than the facial recognition model MobileFaceNet's 5ms. These results indicate that these techniques can be effectively used in resource-limited edge devices, enhancing facial recognition in low-light conditions for various applications.

**Keywords** : Deep learning enhancement, Image preprocessing, Computer vision, Edge device

### I. 서론

얼굴 인식 기술은 다양한 응용 분야에서 활발하게 사용되고 있으며, 특히 스마트폰, 스마트홈 장치, 보안 시스템 등 엣지 디바이스에서 그 활용도가 더욱 주목받고 있다. 그러나 기존의 얼굴 인식 시스템은 이미지 획득 과정에서 발생하는 저조도로 인해 이미지 품질이 떨어지고 성능이 저하되는 여러 문제가 발생한다. 예를 들어, 이미지의 밝기와 대비가 낮아지면 얼굴의 중요한 특징들이 불분명해져 인식 시스템의 정확도가 크게 떨어진다. 또한, 이미지 획득 과정에서 충분한 빛이 없으면 카메라 센서가 노이즈를 증폭시키는 하드웨어적 문제도 존재한다. 이외에 저조도 환경에서 얻은 이미지는 동적 범위가 감소하고, 색상 왜곡이 발생하는 등 여러 문제들이 존재한다.

저조도 상황에서 얼굴 인식 성능을 향상시키기 위해서는 두 가지 주요 접근 방식이 사용된다. 첫 번째 접근 방식은 저조도 이미지의 품질을 개선하는 데이터 전처리 방법을 적용하여 이를 얼굴 인식 모델에 입력으로 제공하는 것이다. 두 번째 접근 방식은 저조도 이미지를 입력받더라도 조도 변화에 강한 모델을 개발하는 것이다.

본 논문에서는 두 가지 접근 방식 중 전자에 주목하여 최신의 딥러닝 기반 저조도 향상 기술인 Zero-DCE [1], Zero-DCE++ [2], SCI (Self-Calibrated Illumination) [3]에 대해

리뷰하고, 저조도 환경에서 해당 기술들의 효과를 검증한다.

### II. 본론

#### 1. 얼굴 인식 기술 개요

##### 1.1 얼굴 인식 (face recognition)

얼굴 인식 과정은 아래 그림 1과 같이 크게 얼굴 검출 (face detection)과 얼굴 식별 (face identification) 두 과정으로 구성된다. 얼굴 검출 과정은 주어진 이미지나 동영상 프레임에서 얼굴이 있는 위치를 찾는 과정이며 딥러닝 기반의 CNN 모델인 YOLO [4], RetinaFace [5], MTCNN [6] 등이 널리 사용된다.

얼굴 식별 과정은 검출된 얼굴 영역에 대해 ID를 식별하는 단계이다. 이 과정에서 얼굴 식별 모델은 얼굴 이미지에서 특징 (feature)을 추출하고, 이를 기존 데이터베이스에 저장된 얼굴 특징과 유사도를 recognition 비교하여 특정 임계점을 기준으로 동일 인물 여부를 판단한다. 유사도는 아래 수식 (1)과 같은 Cosine similarity를 주로 활용하며 이는 두 벡터  $A, B$ 에 대해 두 벡터의 내적을 벡터 각각의 크기를 구한 곱으로 나눈 값이다.

$$\cos(\theta) = \frac{A \cdot B}{\|A\| \|B\|} = \frac{\sum_{i=1}^n A_i \times B_i}{\sqrt{\sum_{i=1}^n (A_i)^2} \times \sqrt{\sum_{i=1}^n (B_i)^2}} \quad (1)$$

\*Corresponding Author (kbkong@pusan.ac.kr)

Received: Jun. 30, 2024, Revised: Jul. 26, 2024, Accepted: Aug. 28, 2024.

K. Kong: Pusan National University (Assist. Prof.)

C. Baek: Pusan National University (B.S. Student)

\* 이 과정은 부산대학교 기본연구지원사업 (2년)에 의하여 연구되었음.

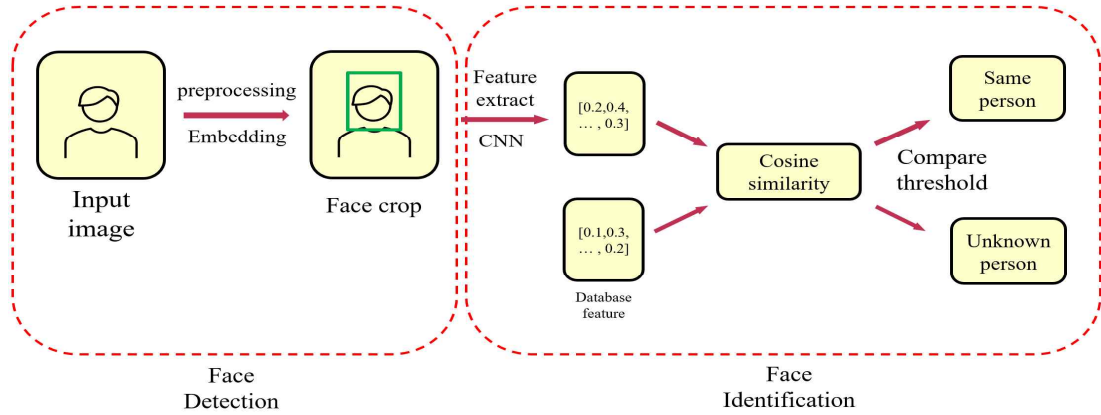


그림 1. 얼굴 인식 전체 프레임워크  
Fig. 1. The overall framework for face

1.2 얼굴 인식 학습을 위한 손실함수

기존 얼굴 인식은 두 가지 연구 방향이 존재한다. 첫 번째는 소프트맥스 손실 함수 [7]를 사용하여 다중 클래스 분류기를 훈련시키는 방법이다. 이 방법은 선형 변환 행렬의 크기가 클래스 수에 비례하여 선형적으로 증가하고, 학습된 특징이 개방 집합 (Open-set) 분류 문제에서 구분력이 떨어질 수 있다는 단점이 있다. 두 번째는 트리플렛 손실 함수 [8]를 사용하여 임베딩을 직접 학습하는 방법이다. 이 방법은 대규모 데이터 셋에서 얼굴 트리플렛의 수가 조합론적으로 급격히 증가하여 반복 단계 수가 상당히 증가하는 문제점이 있다.

ArcFace 손실 함수 [9]는 첫 번째 연구 방향인 소프트맥스 (Softmax) [7] 손실 함수에서 각도 마진 (Angular-margin)을 추가하여 특징 벡터 간의 구분력을 향상시킨다. 이를 통해 개방 집합 분류 문제에서의 구분력 저하 문제를 개선시킬 수 있다.

$$\theta_{y_i} = \arccos\left(\frac{W_j^T x_j}{\|W_j\| \|x_j\|}\right), \quad (2)$$

$$L = -\frac{1}{N} \sum_{i=1}^N \log \frac{e^{s(\cos(\theta_{y_i} + m))}}{e^{s(\cos(\theta_{y_i} + m))} + \sum_{j=1, j \neq y_i}^n e^{s \cos \theta_j}}. \quad (3)$$

식 (2)과 같이 이미지에서 추출한 특징 벡터  $x_i$ 와 Weight  $W_j$  간 각도  $\theta_{y_j}$ 를  $\arccos$  함수를 통해 구한다. 식 (3)과 같이 각도  $\theta_{y_j}$ 에 각도 마진  $m$ 을 두어 서로 다른 개인의 얼굴 특징 사이의 각도를 최대화하고, 동일 인물의 얼굴 특징 사이의 각도는 최소화하는 방식으로 학습된다. 각도를 통해 클래스 간 차이를 주어 더 큰 격차를 만드는 이 방식은 얼굴 특징을 더욱 명확하게 구분 짓게 해주어, 얼굴을 더 정확하고 효율적으로 식별할 수 있도록 한다.

그림 2에서 소프트맥스 손실 함수는 서로 다른 두 클래스 사이의 경계값이 모호한 반면 arcface 손실 함수에선 서로 다른 두 클래스 사이의 경계가 분명한 것을 볼 수 있다.




그림 2. 소프트맥스 함수와 Arcface 손실 함수가 2D 특징 공간에서 얼굴 특징의 분포의 미치는 영향 시각화 예시 [9]  
Fig. 2. Toy examples under the Norm-Softmax and ArcFace loss on 8 identities with 2D features [9]

2. 저조도 향상 기술 소개

저조도 향상 기술은 어두운 환경 조건에서 디지털 이미지나 영상을 획득하는 과정에서 발생하는 노이즈와 세부 정보의 손실을 보정하여 이미지의 시각적 품질을 향상시키는 기술이다. 저조도 향상 기술에는 하드웨어적 접근과 소프트웨어적 접근이 있으며 본 논문에서는 소프트웨어적 접근 중 딥러닝 기반 저조도 향상 기술을 중점적으로 다룬다.

전통적인 딥러닝 기반 저조도 향상 기술은 고조도와 저조도 상태의 이미지 쌍으로 구성된 대규모 이미지 데이터 셋을 이용하여 모델을 학습한다. 학습된 모델은 테스트 과정에서 저조도 상태의 이미지가 입력으로 들어왔을 때, 단순히 밝게 하는 것이 아니라 픽셀 간 대비를 개선하여 더욱 선명하고 자연스러운 저조도 향상 이미지를 출력한다. 대표적인 예로는 RetinexNet [10], KinD [11] 등이 있다. 그러나 이러한 기술들은 연산량이 많고 모델 구조가 무거워 저사양 옛지 디바이스 환경에서는 사용이 어렵다.

본 논문에서는 이러한 문제를 해결하기 위해 최근 제안된 딥러닝 기반 저조도 향상 기술인 Zero-DCE [1], Zero-DCE++ [2], SCI (Self-Calibrated Illumination) [3]에 대해 리뷰하고, 이 기술들이 실제 저조도 상황에서 얼굴 인식 성능에 미치는 영향을 검증한다.

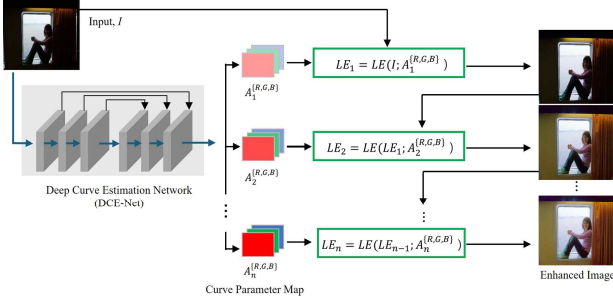


그림 3. Zero-DCE 모델 전체 Framework  
Fig. 3. Overall Framework of Zero-DCE




그림 4 DCE-Net이 추정한 파라미터 맵과 적용 이미지  
Fig. 4. An example of the pixel-wise curve parameter maps

### 2.1 Zero-DCE

처음 소개할 연구는 Zero-DCE [1] 모델로 그림 3에서 보듯이 픽셀마다 고차 커브를 재귀적으로 적용하여 이미지의 조도를 점진적으로 향상시키는 방법이다. 구체적으로, 저조도 이미지가 입력으로 들어오면 가벼운 합성곱 신경망인 DCE-Net을 통해 입력 이미지의 다이내믹 레인지를 조정하는 고차 커브를 예측한다.

$$LE(I(x); \alpha) = I(x) + \alpha I(x)(1 - I(x)), \alpha \in [-1, 1], \quad (4)$$

$$LE_n(x) = LE_{n-1}(x) + A_n(x)LE_{n-1}(x)(1 - LE_{n-1}(x)). \quad (5)$$

식 (4)과 같이 주어진 이미지  $I(x)$ 에 학습 가능한 파라미터인  $\alpha$ 로 이차 커브  $LE(I(x); \alpha)$ 를 구한다. 이차 커브는 단조성을 유지하고 미분 가능성을 만족하여 인접 픽셀 간의 대비를 보존하며, 역전과 과정에서 그라디언트를 쉽게 구할 수 있다. 이 이차 커브를 반복해서 재귀적으로 적용하면 식 (5)과 같이 고차 커브  $LE_n(x)$ 가 된다. 고차 커브 파라미터 맵  $A_n(x)$ 은 이미지의 세 가지 채널에 대해 각각 예측하여 조정하므로 원래의 색상을 더 잘 보존할 수 있고, 채도가 과도해지는 over-saturation의 위험성을 줄여준다. 이때의 파라미터 맵  $A_n(x)$ 은 반복할 때마다 다르다. 픽셀마다 다른 고차 커브  $LE_n(x)$ 를 적용하기에 인접 픽셀 간의 대비를 보존할 수 있다. 반복 횟수  $N=8$ 로 설정했으며, DCE-Net은 7개의 2D 컨볼루션 레이어로 구성된 CNN 구조만으로도 좋은 성능을 내어 기존의 저조도 향상 기술의 파라미터 수보다 더 가볍게 할 수 있다. 그림 4는 DCE-Net이 추정한 파라미터 맵과 적용 이미지를 보여준다.

논문에서 제안한 학습 방식은 공간적 일관성, 자연스러운 노출, 색상 일관성, 조명의 평활성을 고려한 4가지 비참조

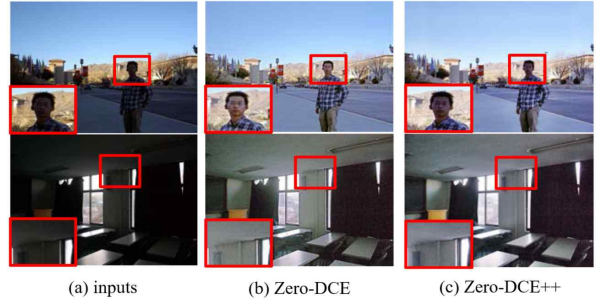


그림 5. Zero-DCE와 Zero-DCE++ 적용 결과 비교 이미지  
[2]

Fig. 5. Comparison of Images Using Zero-DCE and Zero-DCE++ [2]

손실 함수를 활용하여, 기존의 지도학습이 아닌 비지도학습 방식을 적용했다. 즉, 고조도와 저조도 상태의 이미지 쌍을 필요로 하지 않는다. 이를 통해 과적합의 위험을 방지하고 어두운 상황뿐만 아니라 다양한 조명 환경에서도 일반화되어 자연스러운 이미지 개선이 가능하도록 했다.

### 2.2 Zero-DCE++

후속 논문인 Zero-DCE++ [2] 모델은 기존 모델을 개선하여 DCE-Net 구조를 재설계하고, 고차 커브 예측 방식을 변경하며, 입력 이미지 크기를 조절함으로써 더욱 가속화 및 경량화하였다. Zero-DCE++는 기존 모델에 비해 파라미터 수는 약 8배 감소했다 (11K). 이는 합성곱 레이어를 깊이별 분리 합성곱 레이어 (Depthwise Separable Convolution Layer)로 대체함으로써 가능해졌다.

$$LE_n(x) = LE_{n-1}(x) + A_n(x)LE_{n-1}(x)(1 - LE_{n-1}(x)), \quad (6)$$

$$LE_n(x) = LE_{n-1}(x) + A(x)LE_{n-1}(x)(1 - LE_{n-1}(x)). \quad (7)$$

기존 모델은 식 (6)과 같이 고차 커브  $LE_n(x)$ 를 추정할 때, 반복적으로 고차 커브의 파라미터 맵  $A_n(x)$ 을 예측했다. 그러나 Zero-DCE++는 식 (7)과 같이 고차 커브  $LE_n(x)$ 추정 과정에서 하나의 파라미터 맵  $A(x)$ 을 사용하여 모든 반복 과정에서 동일한 파라미터 맵을 적용함으로써 연산량을 대폭 감소시켰다. 또한 Zero-DCE++는 로컬 영역의 픽셀들이 동일한 강도를 가진다는 가정에 기반하여 입력 이미지를 1/2로 다운샘플링하여 파라미터 맵을 예측한 후 이를 다시 업샘플링하는 방식을 사용한다. 이러한 극단적인 다운샘플링을 통해서도 여전히 효과적으로 좋은 성능을 유지할 수 있다. 이러한 가속화 및 경량화 과정을 통해 Zero-DCE++는 저사양 엣지 디바이스에서도 빠르게 저조도 이미지 개선이 가능하다. 그림 5는 Zero-DCE와 Zero-DCE++ 모델을 적용 결과를 비교한 이미지를 보여준다.

### 2.3 SCI

다른 최신 연구인 Self-Calibrated Illumination (SCI) [3] 모델은 기존 저조도 향상 기술들의 문제점을 개선하기 위해

더 빠르고 강인한 그림 6과 같은 SCI Learning Framework 를 제안한다.

$$y = z \otimes x. \tag{8}$$

식 (8)과 같이 관측된 이미지  $y$ 는 조명적 요소  $x$ 와 반사 요소  $z$ 의 곱으로 이루어져 있다는 Retinex [12] 이론에 기반한다. 조명 요소를 잘 추정하면 이를 픽셀 단위로 나누어 반사 요소, 즉 Clear 이미지를 얻을 수 있다.

$$F(x^t): \begin{cases} u^t = H_\theta(x^t), x^0 = y, \\ x^{t+1} = x^t + u^t, \end{cases} \tag{9}$$

논문에서 제안한 프레임워크는 자가 보정 모듈과 조명 추정 과정 두 가지로 나뉜다. 조명 추정 과정에서는 간단한 CNN 구조를 사용하여 점진적인 조명 추정을 한다. 식 (9)과 같이 조명 추정 과정  $F$ 에서 잔차 항  $u^t$ 를 넣어 더 일관성 있는 조명 추정이 가능하며, 모든 단계에서 가중치를 공유함으로써 계산 비용을 절감한다. 초기 입력을 저조도 이미지  $y$ 로 설정하고, 처음의 조명 요소를  $x^0$ 로 가정하여 최종적으로 조명 요소  $x^T$ 를 추정한다.  $u_t$ 는 3개의 3x3 합성곱 레이어로 구성된 간단한 CNN 구조로, 정확한 조도 추정을 가능하며 파라미터 수도 0.0619G로 매우 적다.

기존 Retinex 이론 기반 조명 추정과 달리 논문에선 자가 보정 모듈을 통해 얻은 값을 입력으로 넣어 초기 입력  $y$ 에 가까운 정보를 보존하고, 각 조명 추정 단계의 결과 값을 동일한 상태로 수렴하도록 했다.

$$G(x^t): \begin{cases} z^t = y \oslash x^t, \\ s^t = K_\theta(z^t), \\ v^t = y + s^t, \end{cases} \tag{10}$$

식 (10)과 같이 자가 보정 모듈 과정  $G$ 에선 반사 요소  $z^t$ 에 학습 가능한 간단한 CNN 구조 연산자  $K_\theta$ 에 입력하여 구한 출력  $s^t$ 를 이미지  $y$ 에 더해주어 조명 추정 입력을  $v^t$ 로 변환하여 각 단계에서 입력 간의 차이를 줄여 일관된 이미지 개선, 모델의 안정성 및 수렴 속도를 향상시킨다. 학습 시에만 자가 보정 모듈을 거치고 테스트 과정에서는 학습 시에 얻은 일관적 개선 능력을 바탕으로 자가 보정 모듈을 거치지 않고 조명 추정 블록만 활용해 계산 비용을 절감하였다. 공간적 일관성, 픽셀 수준의 일관성 두 일관성을 고려한 손실함수를 이용해 비지도학습 방식을 택했다.

Retinex 이론에 근거한 조명 추정 과정에 자가 보정 모듈을 도입하여 다양한 조명 조건에서도 더 강인하게 일관성 있는 조명 추정을 통해 이미지 개선을 할 수 있다. 그림 7은 최근 기법들과 SCI 기법의 적용 결과 비교를 보여준다.

### 3. 성능 평가

#### 3.1 실험 설계

딥러닝 기반 저조도 향상 기술을 실제 저조도 얼굴




그림 6. SCI의 전체 프레임워크, SCI는 조명 추정 및 자체 보정 모듈로 구성 [3]

Fig. 6. The entire framework of SCI [3]



그림 7. 최근 기법들과 SCI 기법 적용 결과 비교 [3]

Fig. 7. Comparison of SCI technology with other technologies [3]



그림 8. 한국인 안면 이미지 데이터셋 예시 [13]

Fig. 8. An example of a dataset for K-face [13]

이미지에 적용하여 얼굴 식별 과정에서 성능 향상이 얼마나 일어나는지 확인하기 위해 한국과학기술연구원과 한국지능정보사회진흥원 제공한 한국인 안면 이미지 (K-face) 데이터셋 [13]을 이용하였다. 그림 8은 이 데이터셋의 예시를 보여준다. 실험은 저사양 옛지 디바이스에서도 효과적인 성능을 발휘할 수 있는지 평가하기 위해 Qualcomm QRB5165를 사용하여 진행했다. Qualcomm QRB5165의 주요 사양은 표 1에 정리하였다.

표 1. Qualcomm QRB5165 주요 사양

Table 1. Specifications of Qualcomm QRB5165

Specifications of Qualcomm QRB5165	
Package	12.4 x 12.7mm LP4, 12.4 x 14mm LP5 MEP
CPU	Kryo 585 CPU, 64-bit, up to 2.84 GHz
ISP	Qualcomm Spectra 480 ISP with Dual 14-bit image signal processing
GPU	Adreno 650 GPU w/ support for Open GL ES & Open CL
Memory	LPDDR5 up to 2750 MHz, LPDDR4X up to 2133 MHz Memory Density: up to 16 GB



표 2. 실험 데이터셋 구성

Table 2. Composition of Experimental Dataset

	Illuminance	IDs	# images
Test Set	40 Lux	20	180
Database Set	200 Lux	20	180

얼굴 식별 모델로는 MS1MV3 데이터셋 [14]을 ArcFace [9] 손실 함수로 학습한 MobileFaceNet [15]을 활용하였다. MobileFaceNet은 얼굴인식을 위해 특별히 설계된 경량화된 딥러닝 모델로, 깊이별 분리 합성곱(Depthwise Separable Convolution)과 같은 경량화 기법을 사용하여 엣지 디바이스에서 효율적으로 작동할 수 있도록 최적화되어 있어 본 실험 모델로 선정하였다.

단순 픽셀 밝기 linear scaling 기법과 앞서 소개한 3가지 방법론인 Zero-DCE, Zero-DCE++, SCI 기술 총 4가지를 얼굴 검출 모델이 크롭한 후 이미지에 적용하여 얼굴 식별 과정에서의 성능을 비교하였다.

단순 픽셀 밝기 linear scaling 과정은 Min-Max 정규화를 통해 평균적인 조도의 이미지의 동적 범위와 강도를 갖게 하였다. 저조도 향상 기술은 3가지 방법론 모두 논문에서 제공한 pre-trained 모델을 활용하였다.

표 2와 같이 실험 데이터 셋은 한국인 안면 이미지 데이터 셋 중 전체 방향에서 40 Lux 저조도로 획득한 이미지를 테스트 이미지로 사용했다. 얼굴 검출 모델로는 YOLO [4] 모델 중 가장 가벼운 pre-trained YOLOv8n 모델을 사용하여 얼굴 이미지를 크롭하였고, 각 20명의 인원에 대해 정면을 포함한 다른 각도에서 찍은 9장의 이미지를 총 180장을 테스트 이미지로 사용하였다. 비교 데이터베이스 이미지로는 각각 인원별로 200 Lux에서 촬영된 9장의 이미지를 사용하였다.

그림 9과 같이 얼굴 식별 모델로 데이터베이스 이미지와 테스트 이미지 간의 유사도를 측정하여 어느 임계점보다 높

으면 같은 인원이라 판단, 낮을시 다른 인원이라 판단하여 이진 분류하였다. 이진 분류 문제기에 양성 클래스는 1명, 음성 클래스는 19명이 된다.

유사도를 비교할 때 먼저 한 테스트 이미지와 데이터 베이스 이미지 9장 중 유사도가 가장 높은 상위 5장의 이미지의 평균 feature를 구한다. 이후 구한 평균 feature와 테스트 이미지의 feature와 비교하여 최종 유사도를 구하여 동일 인물 여부를 판단하였다. 20명의 인원 모두를 대상으로 이 과정을 반복하였다.

본 실험에서 성능 측정 지표로 어느 임계점을 기준으로 구한 정확도가 아닌 정답 클래스와 오답 클래스의 분리도를 보고자 하였고 양성 클래스가 1명, 음성 클래스가 19명인 불균형 클래스를 고려하여 Roc-AUC, Max F1-Score를 활용하였다.

ROC-AUC는 분류기의 성능을 평가하는데 사용되는 지표로, 그림 10과 같이 민감도 (True Positive Rate)과 특이도 (False Positive Rate) 사이의 관계를 나타내는 ROC 곡선 아래의 면적을 의미한다.




그림 10. ROC 곡선 그래프 예시 [16]  
Fig 10. Example of ROC Curve Graph [16]

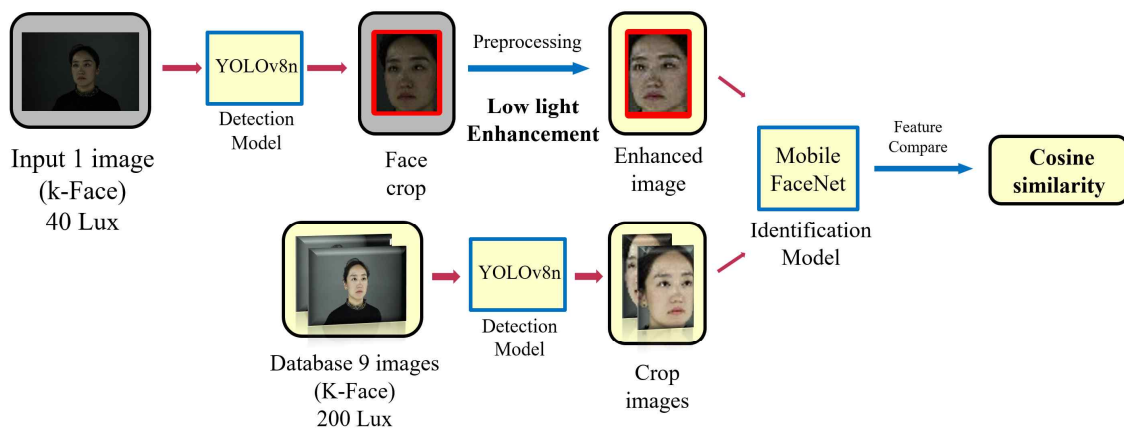


그림 9. 저조도 향상 얼굴 인식 성능 실험 전체 과정  
Fig. 9. The overall process of the experiment for evaluating facial recognition performance with low-light enhancement

$$TPR = \frac{TP}{TP + FN}, \quad (11)$$

$$FPR = \frac{FP}{TN + FP}. \quad (12)$$

민감도는 식 (11)과 같이 실제 양성 클래스 중 양성으로 올바르게 예측된 비율을 의미한다. 특이도는 식 (12)과 같이 실제 음성 클래스 중 잘못해서 양성으로 예측된 비율을 의미한다. 곡선 아래 면적인 ROC-AUC 값이 1에 가까울수록 모델의 성능이 좋다고 평가된다.

F1-Score는 식 (13)과 같이 정밀도 (Precision)와 재현율 (Recall)의 조화 평균이며 분류기의 성능을 평가하는데 사용되는 지표이다.

$$F1\ Score = \frac{2 \times Precision \times Recall}{Precision + Recall}, \quad (13)$$

$$Precision = \frac{TP}{TP + FP}, \quad (14)$$

$$Recall = \frac{TP}{TP + FN}. \quad (15)$$

정밀도 (Precision)는 식 (15)와 같이 양성으로 예측한 것 중 실제 양성인 것들의 비율을 의미하며, 재현율 (Recall)은 앞서 말한 민감도와 같다. Max F1-Score는 분류기 모델이 달성할 수 있는 최대 F1-Score이다. 정밀도와 재현율은 상호 Trade-off 관계에 있어 둘 사이의 균형이 최적일 때 F1-Score는 가장 높아진다. 이를 성능 지표로 이용하는 이유는 Max F1-Score가 불균형 클래스 분류 문제에서 단순 정확도 (Accuracy)보다 더 유의미한 지표이기 때문이다. 이는 분류 모델이 소수 클래스를 얼마나 잘 예측하는지를 더 잘 반영하기 때문이다. 본 실험에서는 앞서 말한 두 가지 성능 지표를 기준으로 저조도 향상 기법 적용 시 성능 변화를 측정하였다.

### 3.2 실험 결과 및 고찰

표 3은 ID 20개에 대한 각 지표의 지표들의 평균을 정리한 표이다. 표 3의 Parameters는 얼굴 식별 모델인 MobileFaceNet의 Parameter 수와 저조도 향상 모델의 Parameter 수를 더한 전체 Parameter 수를 의미한다. 그림 11을 보면 3가지 방법론 적용 후 시각적으로 조도가 향상된 것을 확인할 수 있다. Max F1-Score는 SCI, Zero-DCE++, Zero-DCE 순으로 적용 전보다 성능이 크게 향상 되었으며, ROC-AUC 세 알고리즘 모두 비슷하였으며 적용 전 보다 크게 향상 되었다. 그림 12는 대표 ID에 대한 ROC Curve 그래프와 Precision-Recall 그래프로 표 3과 유사하게 세 알고리즘 모두 성능이 향상되었으며 특히 SCI가 가장 높은 성능 커브를 보이는 것을 확인할 수 있다.

추가적으로 세 알고리즘의 Processing time은 SCI (0.15ms), Zero-DCE (0.4ms), Zero-DCE++ (0.7ms) 순으로 짧았으며 얼굴 인식 모델인 Mobilefacenet (Default)의 Processing time인 5ms보다 훨씬 짧다. 따라서 옛지 디바이스와 같은 제한된 환경에서도 Processing time, Parameter

표 3. 방법론 별 성능 지표 결과 및 Parameter, Processing Time (QRB 5165로 측정된 얼굴 인식에 필요한 전체 알고리즘 수행 처리시간)

Table 3. Performance Metrics, Parameters, and Processing Time by Method

	Default	Linear Scailing	Zero-DCE	Zero-DCE++	SCI
Max F1-Score	0.57	0.747	0.817	0.828	<b>0.833</b>
ROC-AUC	0.85	0.973	0.987	0.987	<b>0.986</b>
Parameters (K)	990	990	1069	1000	<b>993</b>
Processing time (ms)	5	5	5.7	5.4	<b>5.15</b>

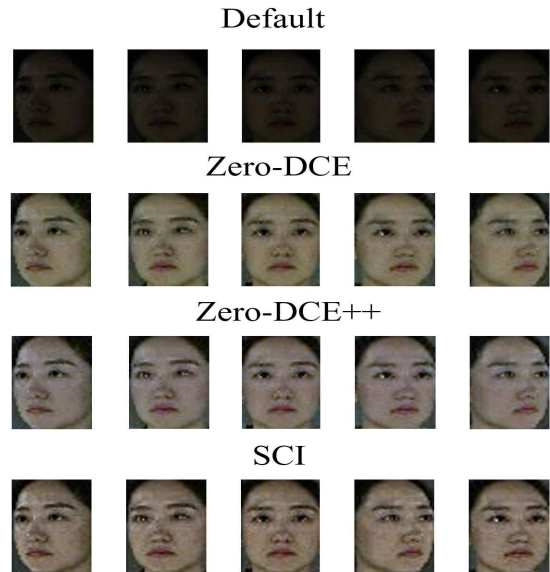


그림 11. 방법론 적용 이미지 (최상단행은 기본 이미지 (Default, 40Lux)이며, 그 아래 행은 차례대로 Zero-DCE, Zero-DCE++, SCI 방법이 적용된 이미지)

Fig. 11. Images with Applied Methods (The top row shows the default images, followed by rows with images processed using Zero-DCE, Zero-DCE++, and SCI, respectively)

측면에서 큰 부담없이 사용 가능하며 성능적인 측면에서 크게 효과적이라는 것을 확인할 수 있었다.

종합적으로 ROC-AUC, Max F1-Score, Processing time 실험 결과를 고려했을 때, 얼굴 인식 성능은 SCI가 근소하게 더 향상되었으며, Processing time에서도 다른 모델에 비해 약 2~4배 가량 짧아 SCI가 얼굴 인식 알고리즘에 가장 적합한 저조도 향상 모델임을 확인할 수 있다. 또한 저조도 상향 기술은 시각적으로 개선된 이미지를 목표로 하는 기술이지만, 얼굴 인식 모델에 전처리로 사용했을 때도 성능 개선이 있음을 확인하였다. 이는 저조도 환경에서 수집된 데이터의 품질 향상이 얼굴 인식 정확도에도 긍정적인 영향을 미칠 수 있음을 의미한다.

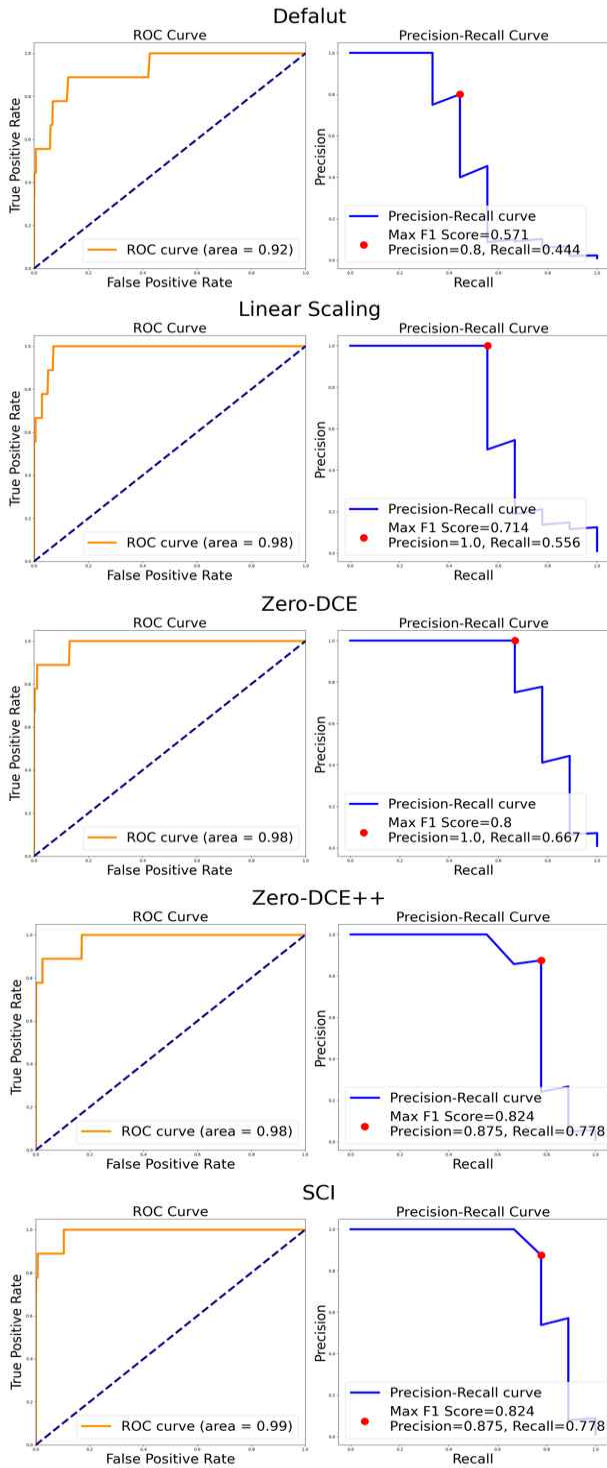


그림 12. 방법론 별 ROC 곡선 그래프 (좌) 및 Precision-Reacall 곡선 그래프 (우)

Fig. 12. ROC Curve graph (left) and Precision-Recall Curve graph (right) by Method

### III. 결론

본 연구를 통해 저조도 환경에서의 얼굴 인식 성능 개선을 위해 딥러닝 기반의 저조도 향상 기술을 데이터 전처리에 적용하는 접근 방식의 유효성을 확인하였다. 이와 더불어, 옛지 디바이스와 같은 저사양 환경에서도 큰 부담 없이 적용 가능함을 확인하였다. 이는 저조도 환경에서도 향상된 얼굴 인식 성능을 달성할 수 있는 중요한 단계로서, 기존의 얼굴 인식 시스템을 더욱 강인하게 만드는 데 기여할 수 있을 것이다.

향후 연구에서는 얼굴 인식에서의 손실 함수를 저조도 알고리즘에 함께 고려하여 End-to-End 모델 학습을 진행함으로써, 저조도 환경에서 더욱 우수한 얼굴 인식 성능을 달성할 수 있을 것으로 기대된다. 이는 저조도 환경과 같이 더욱 복잡하고 다양한 시나리오에서의 얼굴 인식 문제에 대한 이해를 깊게 하며, 실생활에서 얼굴 인식 기술의 적용 범위를 확대하는 데 기여할 것이다.

### References

- [1] C. Guo, C. Li, J. Guo, C. C. Loy, J. Hou, S. Kwong, R. Cong, "Zero-reference Deep Curve Estimation for Low-light Image Enhancement." Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 1780-1789, 2020.
- [2] C. Li, C. Guo, C. C. Loy, "Learning to Enhance Low-light Image Via Zero-reference Deep Curve Estimation." IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 44, No. 8, pp. 4225-4238, 2021.
- [3] L. Ma, T. Ma, R. Liu, X. Fan, Z. Luo, "Toward Fast, Flexible, and Robust Low-light Image Enhancement." Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 5637-5646, 2022.
- [4] J. Redmon, S. Divvala, R. Girshick, A. Farhadi, "You Only Look Once: Unified, Real-time Object Detection." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 779-788, 2016.
- [5] J. Deng, J. Guo, E. Ververas, I. Kotsia, S. Zafeiriou, "Retinaface: Single-shot Multi-level Face Localisation in the Wild." Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 5203-5212, 2020.
- [6] K. Zhang, Z. Zhang, Z. Li, Y. Qiao, "Joint Face Detection and Alignment Using Multitask Cascaded Convolutional Networks." IEEE Signal Processing Letters, Vol. 23, No. 10, pp. 1499- 1503, 2016.
- [7] W. Liu, Y. Wen, Z. Yu, M. Yang, "Large-margin Softmax Loss for Convolutional Neural Networks." arXiv preprint arXiv:1612.02295, 2016.
- [8] E. Hoffer, N. Ailon, "Deep Metric Learning Using Triplet Network." In: Similarity-Based Pattern Recognition: Third International Workshop, SIMBAD 2015, Copenhagen, Denmark,

- October 12–14, 2015. Proceedings 3. Springer International Publishing, pp. 84–92, 2015.
- [9] J. Deng, J. Guo, N. Xue, S. Zafeiriou, "Arcface: Additive Angular Margin Loss for Deep Face Recognition." Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 4690–4699, 2019.
- [10] C. Wei, W. Wang, W. Yang, J. Liu, "Deep Retinex Decomposition for Low-light Enhancement." arXiv preprint arXiv:1808.04560, 2018.
- [11] Y. Zhang, J. Zhang, X. Guo, "Kindling the Darkness: A Practical Low-light Image Enhancer." Proceedings of the 27th ACM International Conference on Multimedia, pp. 1635–1643, 2019.
- [12] E. H. Land, J. J. McCann, "Lightness and Retinex Theory." Journal of the Optical Society of America, Vol. 61, No. 1, pp. 1–11, 1971.
- [13] G. P. Nam, H. S. Choi, J. H. Cho, I. J. Kim, "Large-Scale Korean Face Database Construction," Proceedings of the IEIE Conference, pp. 62–63, 2017 (in Korean).
- [14] Y. Guo, L. Zhang, Y. Hu, X. He, J. Gao, "MS-Celeb-1M: A Dataset and Benchmark for Large-Scale Face Recognition." Computer Vision - ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part III 14. Springer International Publishing, pp. 87–102, 2016.
- [15] S. Chen, Y. Liu, X. Gao, Z. Han, "Mobilefacenet: Efficient cnns for Accurate Real-time Face Verification on Mobile Devices." Biometric Recognition: 13th Chinese Conference, CCBR 2018, Urumqi, China, August 11–12, 2018, Proceedings 13. Springer International Publishing, pp. 428–438, 2018.
- [16] [https://en.wikipedia.org/wiki/Receiver\\_operating\\_characteristic#Curves\\_in\\_ROC\\_space](https://en.wikipedia.org/wiki/Receiver_operating_characteristic#Curves_in_ROC_space)

### Changwoo Baek (백창우)



2019~Department of Electrical & Electronics Engineering at Pusan National University (B.S.)

**Field of Interests:** Computer Vision, On-Device AI, Generative AI

**Email:** hlgok18@pusan.ac.kr

### Kyeongbo Kong (공경보)



2015 Electronic Engineering from Sogang University (B.S.)

2017 Electrical Engineering from POSTECH (M.S.)

2020 Electrical Engineering from POSTECH (Ph.D.)

2023~Department of Electrical & Electronics Engineering at Pusan National University (Assistant Professor)

#### Career:

2020~2021 Postdoctoral Researcher, POSTECH

2021~2023 Assistant Professor, Pukyong National University

**Field of Interests:** Image Enhancement, Video Processing, Multimedia Signal Processing, 3D Vision, Generative Model.

**Email:** kbkong@pusan.ac.kr