

## Corneal Ulcer Discrimination using Double Decoded U-Net

Inhwan Kim\*, Daewon Kim\*\*

\*Graduate Student, Graduate School of Computer Science, Dankook University, Yongin, Korea

\*\*Professor, Department of Computer Engineering, Dankook University, Yongin, Korea

### [Abstract]

Corneal ulcers are caused by damage to the cornea through infection or shock by bacteria, viruses, or fungi. Bacterial corneal ulcers are an urgent disorder that causes symptoms such as pain, foreign body sensation, redness, and light sensitivity, and can even lead to blindness in severe cases. Therefore, a quick diagnosis of early corneal ulcers is necessary, and for this, professional tests such as slit lamp examination and culture test must be performed. In addition, continuous examination by medical staff is required, and patients may find it difficult to receive prompt diagnosis and treatment in the early stages. In this study, after performing pre-processing and post-processing using various image processing techniques, we designed and experimented with a Double Decoded U-Net (DBDU-Net) model that improved the structure of the U-Net model for corneal ulcer area segmentation. The DBDU-Net model is a structure in which one more expanding path is connected to the existing U-Net model, and the contracting path and the feature map extracted from the first expanding path are successively connected to the second expanding path. After learning the location information and object shape of the corneal ulcer area using DBDU-Net, the Dice similarity as an evaluation index showed an average accuracy of 93.32% and a maximum accuracy of 98.66%.

▶ **Key words:** Corneal Ulcer, Semantic Segmentation, Deep-Learning, Double Decoded U-Net

### [요 약]

각막 궤양은 세균, 바이러스, 곰팡이 등에 의한 감염이나 충격을 통한 각막 손상에 의해 발생한다. 세균성 각막 궤양의 경우 통증, 이물감, 충혈, 그리고 빛 과민성 등의 증상을 보이며 심할 경우 실명까지 이르게 되는 위급한 장애이다. 따라서 초기 각막 궤양에 대한 빠른 진단이 필요하고 이를 위해서는 세극등 검사와 배양검사 등의 전문적인 검사를 진행해야 한다. 또한 의료진의 지속적인 진찰을 필요로 하는데 환자들은 초기에 빠른 진단과 치료를 받기 어려운 상황이 발생할 수 있다. 본 연구에서는 다양한 영상처리 기법을 이용하여 전처리 및 후처리를 진행한 후 각막 궤양 영역 분할을 위해 U-Net 모델의 구조를 개선한 Double Decoded U-Net (DBDU-Net) 모델을 고안하고 실험을 진행하였다. DBDU-Net 모델은 기존 U-Net 모델에 확장경로를 하나 더 이어붙인 구조로 축소경로와 첫 번째 확장경로에서 추출되는 특징 맵을 두 번째 확장경로에 연속적으로 연결한 것이다. DBDU-Net을 이용하여 각막 궤양 영역의 위치 정보와 객체 형태를 학습한 후 평가 지표로서 Dice 유사도는 평균 93.32%, 최대 98.66%의 정확도를 보였다.

▶ **주제어:** 각막궤양, 의미론적 분할, 딥러닝, 이중 디코딩 유넷

- First Author: Inhwan Kim, Corresponding Author: Daewon Kim
- \*Inhwan Kim (peruson@naver.com), Graduate School of Computer Science, Dankook University
- \*\*Daewon Kim (drdwkim@dku.edu), Department of Computer Engineering, Dankook University
- Received: 2025. 07. 02, Revised: 2025. 08. 28, Accepted: 2025. 09. 01.

## I. Introduction

각막 궤양은 각막 영역에 발생하는 흔한 질환 중 하나이며 세균, 바이러스, 곰팡이 등에 의한 감염이나 직접적인 충격을 통한 각막 손상에 의해 발생할 수 있다[1]. 또한 각막 궤양은 최근 콘택트렌즈를 사용하는 사람들이 늘어남에 따라 발병 환자도 늘어나는 추세를 보이고 있다[2]. 각막 궤양은 신경 마비로 인해 발생하는 병증이며 특정 바이러스에 의한 궤양은 눈이 불편한 정도의 가벼운 증상을 보이나, 세균성 각막 궤양의 경우 통증, 이물감, 충혈, 그리고 빛 과민성 등의 증상을 보이고 심할 경우 실명까지 이를 수도 있다. 각막 궤양 발병을 신속히 인지하기 위해서는 의료진의 진찰과 의료 장비를 이용한 전문적인 검사가 동반 되어야 한다[3]. 각막 궤양이 심할 경우 특수한 형광 색소인 Fluorescein 염료를 통해 상피의 탈락 부위를 육안으로 식별할 수 있으며, 초기에는 육안으로 식별하기 어렵기 때문에 Slit-Lamp를 통한 상피세포 탈락 과정을 관찰할 수 있다[4-5]. 때때로 환자들은 초기 각막 궤양 질환 진행 시 신속한 치료 시기를 놓치며 의료진의 주관적인 견해와 판단을 통해 발병 여부를 확인할 수 밖에 없는 한계가 발생한다. 따라서 이에 대한 정확한 진단이 필요하며 영상처리 및 인공지능 기술의 발전을 통해 컴퓨터로 하여금 각막 궤양을 진단하고 해당 영역을 추출하게 하는 연구를 진행하였다. 덧붙여 단순한 각막 궤양의 발병 사실 여부 판단을 넘어 궤양의 위치 및 크기 정보를 확보한 후 신속하고 정확한 궤양 추출과 치료가 가능하게 하는 것은 매우 중요하다.

본 연구에서는 각막 궤양 진단과 관련정보 확보를 돕도록 Semantic Segmentation Model 중 하나인 U-Net 모델을 활용하였고 이를 고도화 작업을 통해 변형시킨 DBDU-Net 모델을 고안하여 각막 궤양 영역을 분할하는 연구를 진행하였다. 이를 위해 원본 안구 영상에 Gaussian Blurring과 Histogram Equalization, 그리고 Gamma Correction을 적용하여 궤양과 배경 영역의 대비를 증가시키는 특징을 추출하였고, U-Net 모델에 Decoding Path를 추가한 DBDU-Net 모델을 고안하여 실험을 진행하였다. Decoding Path를 추가함으로써 Contracting Path에서 얻어진 광역 정보와 첫 번째 Decoding path에서 추출된 공간 정보를 담은 특징 맵을 사슬처럼 이은 데이터를 사용하여 보다 향상된 결과 도출을 꾀하였다. 이후 기본 U-Net 모델 및 Transformer를 적용한 최신 모델들과의 성능 비교를 진행하였다. 원본 95장의 데이터셋을 증강하여 총 5700장의 안구 데이터를 생성하였으며 학습, 검증, 그리고 평가 데이터를 무작위로

섞어 총 10번의 실험을 진행하였다.

본 논문의 2장에서는 본 연구와 관련된 연구를 소개하였으며 3장에서는 객체 특징 추출 작업을 소개하였다. 4장에서는 본 연구를 통해 제안하는 DBDU-Net 모델과 여기서 추출되는 Feature map에 대하여 설명하였다. 5장에서는 실험 내용과 원본 및 증강 작업을 진행한 안구 데이터셋, 그리고 모델 성능 확인용 평가 지표를 설명하였다. 6장에서는 DBDU-Net과 타 기법들, 그리고 타 연구자들의 연구결과와의 성능평가 및 비교분석을 진행하였고 7장에서는 결론을 제시하였다.

## II. Related Works

컴퓨터 비전 분야에서 영상처리 기법과 다양한 최신 모델들을 이용하여 특정 객체를 추출 및 분할하는 작업은 활발하게 수행되어 왔다. 이러한 연구들은 공통적으로 Deep-Learning Model을 통해 분할 작업을 수행하기 전에 전처리를 수행하여 분할 할 객체의 특징을 추출한다. 본 연구에서는 안구 영상을 Grayscale로 변환한 후 Gaussian Blurring, Histogram Equalization, 그리고 Gamma Correction을 적용하였다.

Devi[6]는 급성 림프구성 백혈병 암 세포를 분할하고 분류하는 프로세스를 제안하였다. 이때 전처리 단계에서 Gaussian Blurring을 적용하여 이미지의 잡음과 반사를 흐리게 하고 암 세포의 객체를 원활하게 분할할 수 있도록 작업을 수행하였다. 또한 Liu[7]는 Gaussian Blurring을 이용하여 전체적인 해상도 저하를 감소시키는 작업을 수행하였고 Basar[8]는 2차원 영상에서 초점이 잡히지 않은 Blurring 이미지의 객체 탐지를 위해 DCT 계수와 PCNN 구조를 기반으로 한 초점 감지 방식을 제안하였다. Majeed[9]는 이미지 대비 향상을 위해 Histogram Equalization 기반 Adaptive Entropy Index Histogram Equalization (AEIHE)를 적용하여 전체적인 구조를 보존하면서 객체 이미지의 특징 성분을 높였다. Khan[10]은 Fuzzy Mapping 기술을 통해 전체 영상을 여러 조각으로 변환한 후 Histogram Equalization을 통하여 영상 대비를 높이고 다시 각 조각들을 정규화하여 조합한 영상을 통해 자연스러운 형상과 이미지 대비를 증가시킨 데이터셋을 얻었다. Pour[11]는 당뇨병성 망막병증을 발생시키는 손상된 망막을 추출하기 위해 Contrast Limited Adaptive Histogram Equalization (CLAHE) 방법을 사용하여 망막 영역의 대비를 증가시켰다. Histogram

Equalization 적용 후 각막 궤양 주변 영역의 화소값이 높아지는 현상이 발생할 수 있는데 이의 보안을 위해 Gamma Correction을 활용할 수 있다. Zhuang[12]은 흐릿하게 캡처된 이미지 각 구성 요소에 평균과 표준편차 값을 이용한 Adaptive Gamma Correction Transform (AGCT)을 도입하여 시각적으로 향상된 이미지를 만들었다. Choi[13]는 Logarithmic-Exponential Mixture (LEM) 함수를 적용한 Gamma Correction을 이용하여 의미론적 영상분할의 정확성과 이미지의 질을 향상시켰다. Singh[14]는 어두운 영상의 품질 향상과 강조를 위하여 Piecewise Gamma Correction (PGC)를 적용하였다.

이후 다양한 Deep-Learning Model을 통해 궤양 영역을 분할하는 연구가 진행되었다. Tingting[15]은 염료를 입힌 안구 영상에 Generative Adversarial Network (GAN) Model을 변형시킨 Semi Supervised Multi Scale Self Transformer Generative Adversarial Network (Semi-MsST-GAN)을 적용하여 각막궤양과 배경 사이의 경계를 뚜렷하게 하고, 노이즈 간섭을 해결하는 연구를 진행하였다. 안구 영상에서 진균성 각막궤양을 분할하기 위해 Mayya[16]는 Multi Scale Convolutional Neural Network (MS-CNN)을 이용하였고 Helano[17]는 U-Net 모델의 파라미터를 조정하였다. Wang[18]은 Fluorescein 염료를 사용한 데이터에 Adjacent Scale Fusion과 Position Embedding 기법을 적용하여 각막 궤양을 분할하였다.

본 연구에서 각막 궤양의 특징을 보다 원활하고 정교하게 추출하기 위해 U-Net 모델의 구조를 개선하여 실험을 진행한 것과 같이 연구의 신뢰성과 정확성 향상을 위해 U-Net의 파라미터 및 기본구조를 개선한 연구들도 있었다. Wang[19]은 고해상도 원격 감지 이미지에서 도로를 추출하기 위해 U-Net 모델의 구조를 개선한 Dual Decoder U-Net (DDU-Net)을 고안하였으며 Jia[20]는 U-Net 모델의 합성곱 계층 필터 크기를 키운 Large Kernel U-Net (LKU-Net) 모델을 통해 의료 영상 분할 분야에서 최신 모델과 성능 비교를 진행하였다.

### III. Corneal Ulcer Features Extraction with Image Processing

#### 1. Corneal Ulcer Dataset

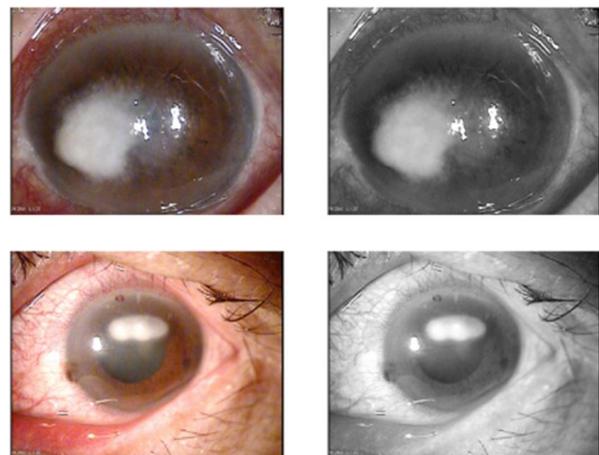
DBDU-Net 모델에 입력된 데이터 셋은 RGB 포맷의 원본 안구 영상이다. 각각의 안구 영상에는 크기, 형태, 그리

고 위치가 모두 다른 궤양 영역이 존재하며 그림 1에 안구 영상 데이터가 나타나 있다. 그림 1에 보이듯이 각 안구 영상의 평균 밝기나 명도의 표준 편차가 모두 다르며 장비의 촬영 각도에 따라 각막 궤양의 형태가 다양하게 나타난다.



Fig. 1. Dataset of Eye Images with Corneal Ulcer

또한 촬영 장비의 렌즈에 빛이 반사되어 높은 화소값을 갖는 빛 반사 영역들도 확인할 수 있다. 따라서 각막 궤양과 눈꺼풀 영역, 그리고 빛 반사 영역이 모두 포함되어 있는 원본 영상을 본 연구에서 고안한 DBDU-Net 모델의 입력 영상으로 사용하기 위해서는 적절한 영상 전처리를 통해 각막 궤양의 특징을 높이는 작업을 선행해야 한다.



(a)

(b)

Fig. 2. (a) Original Eye Image, (b) Grayscale Eye Image

전처리는 총 세 단계로 Gaussian Blurring을 통해 잡음을 최소화한 후, Histogram Equalization으로 명암대비를 최대화하였고, Gamma Correction으로 명도조정을 수행하는 순서로 진행 되었다. 전처리는 이미지의 질 향상이 목적이므로 전술한 세 단계의 순서를 지켜 수행하였다.

이 작업은 세 개의 채널을 갖는 RGB 형식의 원본 영상을 Grayscale로 변환한 후 한 개의 채널인 명도값만을 갖는 회색조 영상을 이용하여 수행하였다. 그림 2의 (a)결과 (b) 열은 각각 원본과 회색조로 변환된 안구 영상을 나타내고 있다.

2. Feature Extraction

회색조로 변환한 후 첫 번째 전처리인 Gaussian Blurring을 적용하여 안구 영상에서 화소값이 급격하게 변하는 부분을 감소시키거나 잡음 및 Hole 현상을 제거하였다. 이 과정을 통해 각막 궤양의 형태를 더 부드럽고 자연스럽게 하여 궤양 영역을 분할 할 때의 정확성을 향상시키고자 하였다. Gaussian Blurring에 사용된 Gaussian 필터는 수 식 (1)에 나타나 있다.

$$N(x|\mu, \sigma^2) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (1)$$

수 식 (1)에서  $x$ 와  $y$ 는 Gaussian 함수를 평면상에 위치 시키는 매개변수이며,  $\sigma$ 는 Gaussian 분포의 표준편차, 그리고  $e$ 는 자연 상수를 뜻한다. Gaussian Blurring 적용 이후 각막 궤양과 배경 영역의 경계를 뚜렷하게 하기 위해 Histogram Equalization을 적용하였다. 이 작업은 영상의 밝기 분포를 재분배하여 명암 대비를 최대화 하는 기법으로 각 명암의 빈도는 변경하지 않으면서 높은 화소값을 띄는 궤양 영역과 낮은 화소값의 배경 영역의 대비를 증가시킨다. Histogram Equalization은 그림 3에 나타난 바와 같이 총 세 단계의 절차를 통해 적용되었다.

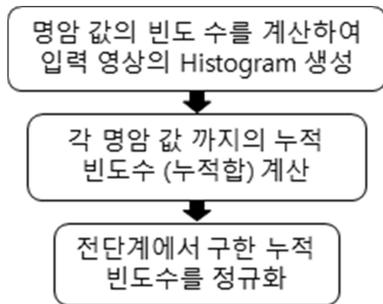


Fig. 3. Procedure of Histogram Equalization.

Histogram Equalization 적용 후 궤양 영역의 화소값을 증가시킨 영상을 생성하였다. 이 때 그림 4의 (b)와 같이 특정 영상 내에서 궤양 영역 주변에 흐릿하게 번져있는 부분들의 화소값도 동반하여 높아지는 효과가 나타나기도 하였다. 이 영역은 각막 궤양의 형태 파악이나 정확한 분

할에 영향을 줄 수 있기 때문에 밝기 보정을 위한 Gamma Correction을 진행하였다. 이 작업은 입력 및 출력값 사이의 비선형 변환과  $\gamma$ 값을 이용하여 밝기를 보정하는데 수 식 (2)에 공식이 나타나 있다. Gamma Correction을 통하여 전체적으로 어두운 방향으로 보정을 진행할 경우 상대적으로 어두운 영역들의 화소값이 밝은 영역의 화소값 보다 더 큰 폭으로 낮아진다.

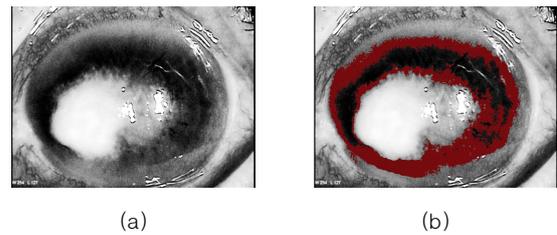


Fig. 4. (a) Result of Histogram Equalization, (b) Brightened area within the red background in (a)

$$O = \left(\frac{I}{255}\right)^{\frac{1}{\gamma}} \times 255 \quad (2)$$

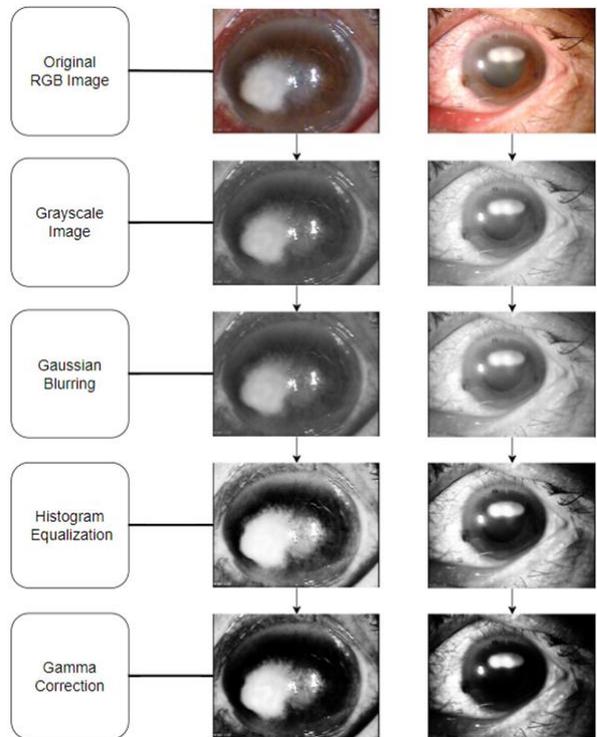


Fig. 5. Process of Corneal Ulcer Feature Extraction

이러한 특징을 이용하여 각막 궤양과 배경 영역의 대비를 증가시키며 궤양 주변에 번져있는 부분의 화소값 또한 낮출 수 있다. 지금까지 Gaussian Blurring, Histogram Equalization, 그리고 Gamma Correction을 통하여

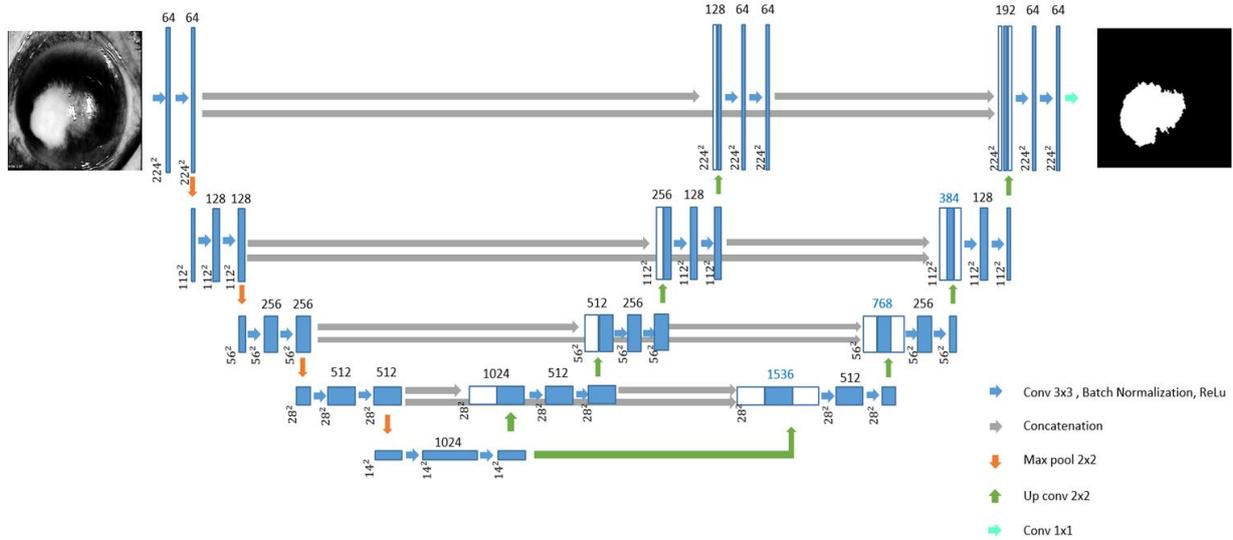


Fig. 6. Architecture of Double Decoded U-Net Model

DBDU-Net 모델이 원활하게 학습될 수 있도록 특징을 추출하는 작업을 진행하였다. 각막 궤양 특징을 추출하는 전체 과정이 그림 5에 나타나 있다. 한 개의 채널을 갖는 Grayscale 영상에 그림 5의 전체 과정을 적용한 결과 상대적으로 어두운 부분의 명도값은 0에 가까워졌으며 역으로 밝은 부분의 명도값에 해당하는 궤양 영역은 200 이상의 명도값을 갖게 되었다. 결과적으로 각막 궤양과 배경 영역의 대비를 증가시켰으며 이로 인해 두 영역의 경계는 더욱 뚜렷해졌고 각막 궤양의 특징을 원활하게 추출하게 되었다. 영상처리를 통해 각막 궤양 특징이 추출된 결과영상은 이후 DBDU-Net 모델의 입력 영상으로 사용되었으며 U-Net 모델에서의 원활한 학습을 위해 기존의  $640 \times 480$ 에서  $224 \times 224$ 의 크기로 조정된 후 실험이 진행되었다.

## IV. Double-Decoded U-Net Model

### 1. U-Net Model

U-Net은 의미론적 분할 모델의 하나로 바이오 메디컬 분야에서 이미지 분할을 목적으로 제안된 End-to-End 방식의 Fully Convolutional Network (FCN) 기반 모델이다. 전체적인 네트워크의 구조가 U자의 형태를 띠고 있으며 Encoder와 Decoder로 이루어져 있다. U-Net 모델의 Contracting Path에서는 입력 영상의 특징을 포착하는 작업을 수행하고 Expanding Path에서는 Upsampling을 통하여 원본 영상의 크기를 갖는 분할 결과 영상을 생성한다. 이 때 U-Net을 기존의 FCN 모델보다 효율적이고 정

확하게 만들어 주는 작업은 Concatenation 기법이다. U-Net의 Contracting Path와 같이 차원 축소를 거치는 단계에서는 이미지 객체의 상세한 위치 정보를 잃게 된다. 이를 통해 Expanding Path에서도 저차원의 정보만을 사용하기 때문에 위치 정보 손실을 만회하지 못한다. 따라서 Concatenation 기법을 이용하여 저차원과 고차원 정보를 모두 이용하는 작업을 수행한다. 결과적으로 Contracting Path에서 추출되는 국소적이고 세밀한 부분의 특징과 Expanding Path에서 생성되는 전반적이고 추상적인 특징을 이어 붙여서 전체 이미지의 특징을 추출함과 동시에 정확한 위치 파악도 가능하게 한다.

### 2. Double-Decoded U-Net Model

본 연구에서 제안하는 Double-Decoded U-Net 모델의 구조는 그림 6에 나타나 있다. 기존 U-Net 모델에 확장경로인 Decoding Path를 하나 더 붙여 축소경로와 첫 번째 확장경로에서 추출된 특징 맵을 참조하는 형식이다. 이는 저차원과 고차원 정보를 동시에 참조하여 세밀한 정보와 추상적인 정보를 모두 포함하고 추출된 특징 맵을 한번 더 참조하기 때문에 각막 궤양의 위치 정보 및 객체 특성에 대한 정보를 얻을 수 있다. DBDU-Net의 합성곱 필터 크기는  $3 \times 3$ 이며 U-Net 모델처럼 ReLU 활성화 함수를 사용한다. 축소경로에서는 Stride 값을 2로 갖는 Max pooling을 통해 Down-sampling을 진행하며 이를 통해 채널의 수는 두 배로 증가하고 차원의 수는 절반으로 감소하여 계산량 또한 감소하고 이미지의 전역적 문맥 정보 추출이 진행된다. 확장경로에서는 Up-sampling이 이루어지고 축소경로와는 반대로 채널의 수는 절반으로 감

소하며 차원의 수는 두 배로 증가하고 Encoder에서 추출한 추상화 된 특징 맵 정보를 활용하여 이미지 복원이 이루어져 원본영상의 크기와 같은 결과 영상이 생성된다. DBDU-Net 모델을 통해 학습을 진행하면서 첫 번째와 두 번째 Decoding Path의 결과를 비교한 영상이 그림 7에 나타나 있다. 그림 7의 (b)는 첫 번째 확장경로의 결과로 각막 궤양 정보를 확실하게 학습하지 못한 것을 알 수 있다. 하지만 그림 7의 (c) 영상인 두 번째 확장경로의 결과를 (a)와 비교해보면 각막 궤양의 위치 및 형태 정보를 원활하게 학습했다는 것을 추측할 수 있다.

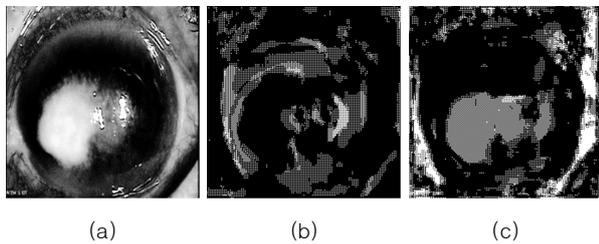


Fig. 7. (a) Pre-processed Input Image, (b) Result from the First Expanding Path, (c) Result from the Second Expanding Path.

### 3. Tensor Value Process

DBDU-Net 모델에 전처리 된 영상을 입력할 경우 화소 값들을 255로 나누어 정규화 된 Tensor로 입력한다. 이 때 각막 궤양과 같이 흰색 및 회색을 띠는 영역은 1에 가까운 높은 화소값을 나타내며 공막 영역과 같이 어두운 영역은 0에 가까운 낮은 화소값을 갖는다. 이러한 특징을 이용하여 Tensor로 변형된 영상에서 각 화소값들을 제공한다. 그림 8은 Tensor Value Process 작업 구조를 나타낸다.

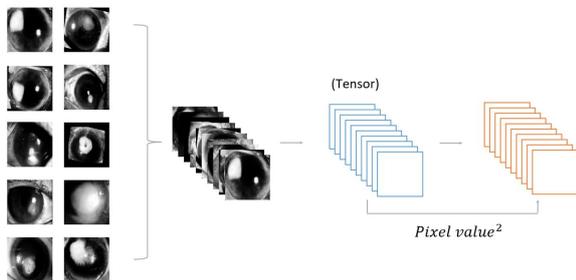


Fig. 8. Architecture of Tensor Value Process

그림 8에 나타난 과정을 통해 각막 궤양 영역의 화소값은 큰 변화가 없지만 어두운 영역의 화소값은 큰 폭으로 작아지기 때문에 궤양과 배경 영역에 해당하는 Tensor 값의 차이를 높이는 결과를 가져온다. 결과적으로 이 단계에서는 궤양과 배경 영역의 대비를 증가시키는 과정을 진행

하며 객체 정보를 원활하게 얻을 수 있게 한다.

### 4. Labeling

전처리 작업을 진행한 영상에서 빛 반사와 눈꺼풀 영역 등이 궤양 영역과 같이 높은 화소값을 갖기 때문에 DBDU-Net 모델 적용 후 각막 궤양으로 판단되고 분할된 배경 영역들이 존재하며 이로 인해 정확성이 낮아지는 약점이 있다. 따라서 Labeling 후처리 작업을 통하여 궤양 영역만을 분할하도록 실험을 진행하였다. Labeling은 서로 연결되어 있는 객체 픽셀에 고유한 번호 Label을 지정한다. 이 때 궤양에 해당하는 영역의 크기가 빛 반사 및 눈꺼풀 영역의 크기보다 일반적으로 크다는 점을 이용하여 각 Label의 빈도수를 계산한 후 가장 큰 Label에 해당하는 영역만 남기도록 하였다. 그림 9에 이 결과가 나타나 있다.

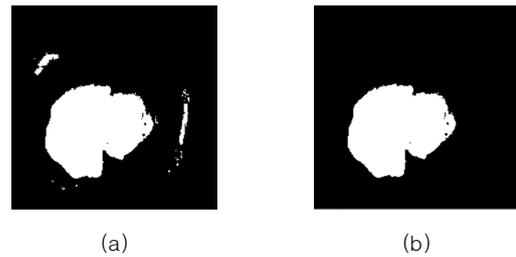


Fig. 9. (a) Result from DBDU-Net, (b) Result from Labeling Postprocessing on (a).

DBDU-Net 모델을 통한 분할 결과인 그림 9의 (a)에 Labeling 기법을 통하여 (b)의 결과 영상을 생성하였다. 그림 9의 (b)에서는 (a)의 궤양 주변의 잡음처럼 같이 분할된 배경 영역들이 제거된 것을 확인할 수 있으며 따라서 분할 결과의 정확성을 높이는 효과를 보인다.

## V. Experiment and Results

본 연구에서 사용한 안구 영상 데이터셋은 전체 95장이며 단국대학교 의과대학 병원 안과에서 의료 장비를 활용하여 촬영한 영상들이다. 원본인  $640 \times 480$  크기의 영상을  $224 \times 224$  크기로 축소하여 연구를 진행하였다. 딥러닝 모델을 이용하여 분할한 결과 영상의 정확도 측정을 위해 각 입력 안구 영상의 궤양 영역을 사전에 수동으로 추출한 Ground-Truth 영상을 구축하였으며 그림 10에 예시가 나타나 있다. 각 안구 영상에 대한 Ground-Truth를 별도로 생성한 후 증강 작업을 하기 전

데이터셋을 모델의 학습과 검증, 그리고 시험평가를 위해 각각 대략 8:1:1의 비율로 나누었다. 표 1은 증강 전후의 전체 데이터와 학습, 검증, 그리고 평가를 위하여 나누는 데이터의 수를 나타낸다. 전체 95장의 데이터를 비율에 맞추어 분배한 뒤 딥러닝 모델의 학습을 위하여 이미지 증강작업을 진행하였다. 상, 하, 좌, 우 반전과 시계방향 및 반시계방향 5도와 10도 회전, 그리고 확대 및 축소 작업을 통하여 총 5700장의 데이터를 생성하였다.

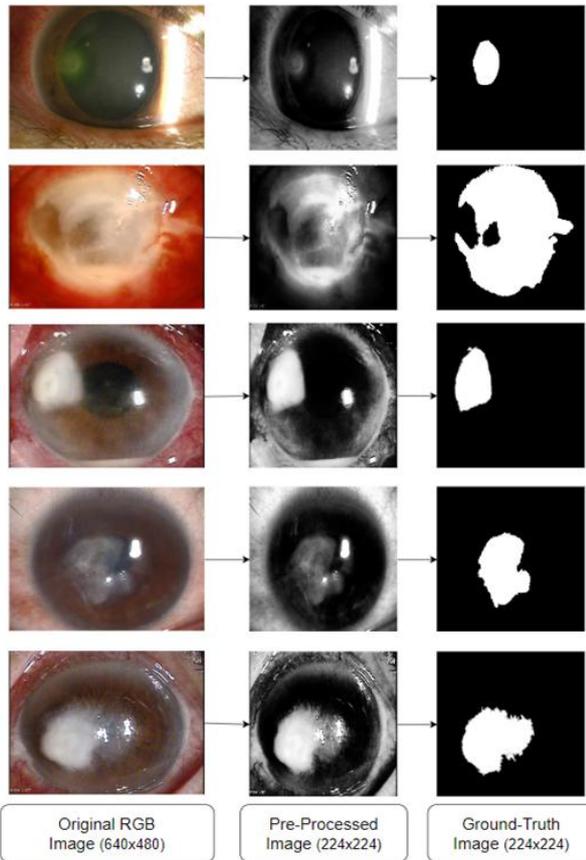


Fig. 10. Process of Generating Ground-Truth Images.

표 1에 제시된 바와 같이 나누는 데이터를 DBDU-Net 모델에 입력하여 학습을 진행하였다.

Table 1. Number of Dataset for Deep Learning.

	Total	Training	Validation	Test
Before A.	95	75	10	10
After A.	5700	4500	600	600

(A.:Augmentation)

4500장의 학습 데이터를 사용하였고 분할 정확도를 측정하기 위해 Dice와 Jaccard 계수를 사용하였다. 두 평가 지표 모두 영상의 정답과 실험 결과 간의 유사도를 측정한다.

두 평가 지표의 계산법이 수 식 (3)과 (4)에 제시되어 있다.

$$Dice\ Coefficient = \frac{2TP}{2TP+FP+FN} \quad (3)$$

$$Jaccard\ Coefficient = \frac{TP}{TP+FN+FP} \quad (4)$$

수 식 (3)과 (4)에서  $TP, FP, FN$ 은 혼동행렬의 True Positive, False Positive, 그리고 False Negative를 뜻한다. 두 평가지표 값의 범위는 0과 1 사이이며 값이 1에 가까울수록 두 영상이 많이 겹치는 것을 뜻한다. 딥러닝 모델인 DBDU-Net은 Pytorch와 TorchVision 라이브러리를 사용하여 설계되었으며 전처리 및 후처리 작업은 OpenCV 4.10 라이브러리를 사용하였다. 또한 Gaussian Filter 구현 및 Labeling 작업을 위하여 Scikit-learn 라이브러리를 활용하였다. 본 연구에서 딥러닝 모델의 학습에 사용된 PC의 개발 환경은 표 2와 같다.

Table 2. Experiment Environment for Deep Learning

OS	Windows 11
Graphics	NVIDIA GeForce RTX 3070
Memory	32GB
CPU	AMD Ryzen 5 5600X 6-Core Processor (3.70 GHz)

DBDU-Net 모델의 학습 시 Batch size는 100으로 하였고 전체 학습의 Epoch는 50회로 진행하였다. 매 Epoch 마다 600장의 검증 데이터를 통하여 Validation Loss를 측정하였으며 학습이 끝난 뒤 Validation Loss가 가장 낮은 지점의 가중치를 저장하는 Checkpoint Monitor 기법을 적용하여 평가를 진행하였다. 학습이 끝난 뒤 최적으로 저장된 가중치를 생성한 모델에 600장의 평가 데이터를 적용하여 분할 결과를 추출하였다. 또한 모델의 정확성과 지속적인 신뢰성, 그리고 교차 검증을 위해 전체 데이터를 무작위로 섞은 후 총 10번의 실험을 더 진행하여 평균 및 최대정확도를 기록하였다. 그림 11은 DBDU-Net 모델을 학습하는 동안 각 Path에서 추출되는 특징 맵을 나타낸다. 그림 11의 Expanding Path-1에서 추출되는 특징 맵은 기존 U-Net의 결과와 동일하며 각막 궤양에 대한 형태를 정확하게 분할하지 못하지만 Expanding Path-2에서 추출된 특징 맵에서는 각막 궤양에 대한 형태를 원활하게 분할할 것을 볼 수 있다. 이는 Contracting Path의 저차원 정보와 Expanding Path의 고차원 정보를 포함하는 특징 맵을 한 번 더 참조하였기

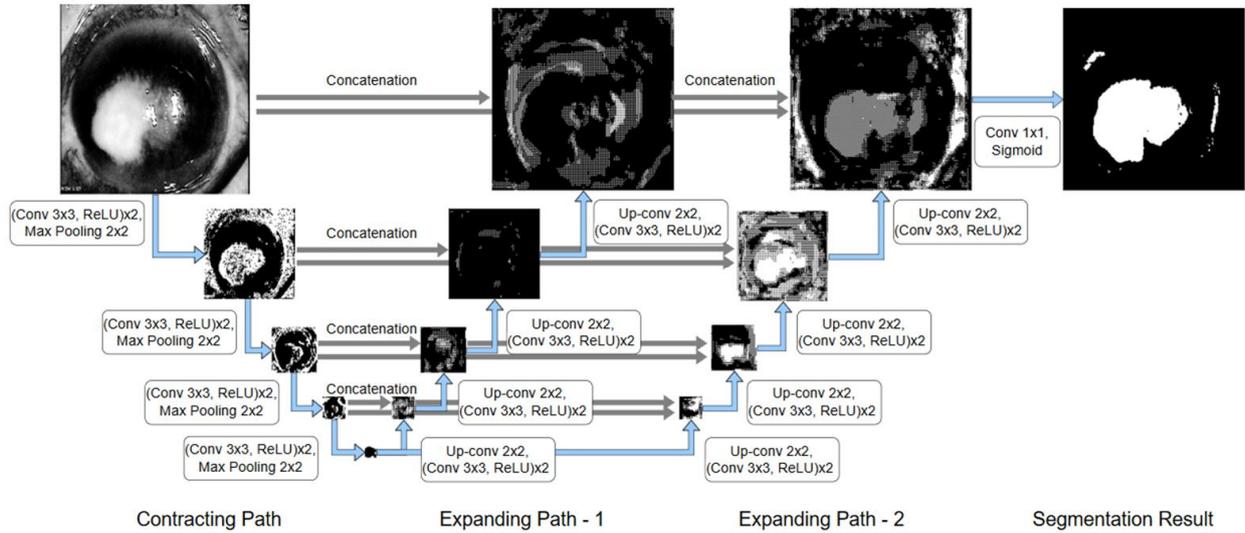


Fig. 11. Result of Extracted Feature map from Each Model's Path

Table 3. Result from Double Decoded U-Net Model.

Original	Pre-processed	Result from DBDU-Net	Result from Labeling	Ground Truth

때문이며 세부적인 특징과 추상적인 정보를 모두 포함하여 향상된 결과를 추출하는 것으로 보인다. 그림 11에 나타나 있듯 64개의 채널을 포함하는 마지막 단계의 영상을 Stride 값 1을 갖는 1×1 크기 필터의 Fully Convolutional Layer에 통과시켜 한 개의 채널을 갖는 최종 이미지를 추출한다. 표 3은 본 연구를 통해 제안하는 DBDU-Net 모델을 이용하여 순차적으로 적용된 결과 영상을 나타낸다. 이 때 추출된 결과 중 궤양이 아닌 배경이 같이 포함된 영역은 후처리 작업인 Labeling을 통해 제거

된 뒤 최종 영상이 생성되었으며 평가지표를 이용하여 Ground Truth와의 비교를 통해 정확도를 측정하였고 이를 표 4에 나타내었다. 표 4는 표 3의 결과영상과 Ground Truth를 비교하여 측정된 Dice와 Jaccard 계수를 나타낸다. 총 열 번의 실험을 진행하여 정확도를 측정하였으며 학습, 검증, 그리고 평가 데이터를 무작위로 섞은 데이터셋을 생성하여 각각 독립된 단계의 실험을 진행하였다. 평가 데이터에 대하여 최대 Average Dice Coefficient (ADC) 값인 98.66%를 보였으며 전체 데이터셋의 평균 ADC는 93.32%를 보였다. Jaccard 계수로는 최대 89.49%, 평균 87.35%의 수치를 보였다.

Table 4. Accuracy of DBDU-Net. (unit:%)

Number of Experiments	Dice Coefficient	Jaccard Coefficient
1	93.99	87.50
2	93.31	86.59
3	90.52	83.85
4	94.30	88.32
5	98.66	89.49
6	92.38	85.19
7	91.17	84.05
8	94.21	87.81
9	92.90	85.90
10	91.80	94.82
Average	93.32	87.35
Max	98.66	89.49

평가지표로서 유사도 측정방법의 상이함으로 인해 일반적으로 Dice 계수의 값이 더 높게 나오는데 이는 Ground-Truth와 일치된 결과에는 가중치를 부여하고 그렇지 않은 결과에는 영향을 줄이는 방법을 사용하기 때문이다.

## VI. Comparison and Discussion

본 연구에서 고안한 DBDU-Net 모델을 통한 각막 궤양 분할 실험결과 분석을 위해 타 기법들과의 성능 비교 평가를 진행하였다. 본 실험에서 사용한 데이터셋을 다른 모델에 적용했을 때의 결과와 비교 하였으며 각막 궤양 분할 연구를 진행해 온 다른 연구자들의 실험 결과와 또한 성능 비교를 진행하였다. 표 5는 본 연구에서 제안하는 DBDU-Net과 U-Net 모델 및 Transformer 기법을 사용하는 Semantic Segmentation 모델들과의 성능 비교 결과를 나타낸다.

Table 5. Comparison with various Semantic Segmentation Model's Performances. (unit:%)

Method	Dice Coefficient	Jaccard Coefficient
Original U-Net[21]	81.87	75.94
SegFormer[22]	76.16	69.83
TransU-Net[23]	83.73	77.90
DBDU-Net	98.66	89.49

기본 U-Net [21] 모델의 Dice와 Jaccard 계수는 각각 81.87%와 75.94%로 본 연구에서 제안하는 DBDU-Net 모델과는 약 14% ~ 16% 정도의 성능 정확도 차이를 보였다. 이러한 결과는 두 번째 Expanding Path를 도입하고 Contracting Path와 첫 번째 Expanding Path에서 추출되는 특징 맵을 참조하는 방법을 적용한 DBDU-Net 모델이 기존 U-Net 모델보다 각막 궤양의 위치 정보 및 형태 파악에 보다 유리하다는 것을 알 수 있다. SegFormer [22]의 경우 파라미터의 수가 가장 적은 SegFormer-B0 모델을 사용하였을 경우 76.16%의 Dice 계수를 도출하였으며 DBDU-Net 모델로부터의 결과와 비교하여 약 22.5%의 정확도 차이를 보였다. 이는 크기가 가장 작은 모델을 사용하여 충분한 객체 정보를 학습하지 못했을 가능성이 존재한다. DBDU-Net은 전처리 및 후처리 절차와 추가적인 Expanding Path를 이용하여 궤양 영역 특징을 더 뚜렷하게 추출한 것으로 사료된다. TransU-Net [23]은 U-Net 보다 높은 83.73%의 Dice 계수치를 보였고 DBDU-Net과 비교했을 때 약 14.93%의 성능 정확도 차이를 보였다. Transformer 적용 모델은 데이터의 양이 적을 경우 학습이 충분히 이루어지지 않는 한계가 있어 데이터셋이 상대적으로 적은 경우 더 가볍고 수행시간도 적게 소요되는 DBDU-Net 모델을 통한 분할 결과가 우위를 점한다는 것을 확인하였다. 이어서 각막 궤양 영역을 분할하는 작업을 진행해 온 다른 연구자들이 제안한 모델들과의

성능 비교를 진행하였다. 각 연구에서 사용한 평가 지표가 상이하여 효과적인 비교를 위해 Sensitivity와 Specificity를 추가로 측정하였고 표 6에 그 결과를 제시 하였다.

Table 6. Comparison with other Results. (unit:%)

Method	Dice Coeff.	Sensitivity	Specificity	Jaccard Coeff.
MS-CNN[16]	88.01	90.67	87.57	N/A
U-Net with Fine-Tuning [17]	82.30	88.90	99.40	N/A
Position Embedding [18]	80.73	N/A	N/A	71.63
DBDU-Net	98.66	90.73	98.28	89.49

표 6의 MS-CNN[16] 모델은 본 연구에서 사용한 데이터와 같이 RGB 상의 원본 안구 영상을 사용하였으며 Multi-Scale Convolutional Neural Network (MS-CNN) 모델을 통하여 진균성 각막 궤양 영역을 분할 하였다. 교차검증을 위하여 데이터를 무작위로 섞은 뒤 열 번의 실험을 실시하여 88.01%의 Dice 계수치를 보였다. 이 모델은 CNN을 활용하여 높은 정확도를 추출하였으나 2차원 영상에서 각막 궤양 위치 정보 확보를 위해 수동으로 박스로 표시한 뒤 잘라낸 데이터를 사용하였다. 본 연구에서는 전처리와 DBDU-Net 모델의 동작 그리고 후처리 과정이 모두 자동으로 이루어지며 Sensitivity 측면에서 MS-CNN 보다 우위를 보이는 것으로 나타났다. U-Net with Fine-Tuning[17] 모델은 DBDU-Net 모델과 마찬가지로 기존 U-Net 모델의 구조 및 파라미터를 변경하는 Fine-Tuning 작업을 통해 각막 궤양 영역을 분할하였다. 이는 Fluorescein 염료를 사용하여 상피의 탈락 부위를 더 쉽게 파악할 수 있는 안구 데이터를 이용하여 실험하였고 각막 영역을 수동으로 잘라 배경 영역의 개입을 줄이고 분할 작업을 진행하였다. Adjacent Scale Fusion과 Position Embedding[18] 기법을 통하여 각막 궤양을 분할한 연구 또한 Fluorescein 염료를 사용하였는데 DBDU-Net 모델이 Dice 계수치 평가지표에서 [17], [18]에 비해 각각 16.36%, 17.93%의 우위를 보였다. 이는 본 연구에서 DBDU-Net에 추가된 Expanding path로 인해 각막궤양의 광역 및 공간정보가 효과적으로 추출되었고 위치정보 또한 효율적으로 학습되었기 때문인 것으로 사료된다. 전술한 타 모델과의 성능 비교평가는 서로 상이한 데이터의 사용으로 인해 절대비교는 힘들다고 할 수 있다. 타 연구에서는 RGB 상의 원본 안구영상 또는

Fluorescein 염료를 사용하여 염색한 데이터를 사용한 경우도 있으므로 본 연구에서 사용한 데이터의 속성과는 다르지만 일반적인 각막궤양 분할의 연구범주 내에서 성능을 비교하는 것에 의미를 두었다.

## VII. Conclusion

각막 궤양은 각막 영역에 발생하는 흔한 질환 중 하나이며 세균, 바이러스, 곰팡이 등에 의한 감염이나 직접적인 충격을 통한 각막 손상에 의해 발생할 수 있다. 본 논문에서는 입력 원본 안구 영상에 다양한 영상 전처리 작업을 수행하고 Semantic Segmentation Model 중 하나인 U-Net 모델의 구조를 개선한 DBDU-Net을 고안하여 각막 궤양 분할 실험을 진행하였다. 궤양의 위치 정보와 특징에 대한 학습 효과를 증대시킨 DBDU-Net을 통하여 일차 분할한 뒤 후처리를 통해 최종적으로 각막 궤양 영역을 분할하는 절차를 제안하였다. 전처리 단계에서 한 개의 채널을 갖는 회색조 영상으로 변환한 뒤 Gaussian Filter를 사용하여 원본의 형상을 최대한 보존하면서 잡음 및 Hole 현상을 제거하였다. 이후 Histogram Equalization을 통해 각막 궤양과 배경 영역의 대비를 증가시킨 후 Gamma Correction을 통해 궤양 영역 주변의 높은 화소값을 지닌 영역들을 제거하였다. DBDU-Net 모델은 기존 U-Net 모델에 확장경로를 하나 더 이어 붙인 형식으로 축소경로에서 추출되는 특징 맵과 첫 번째 확장경로에서 추출되는 특징 맵을 두 번째 확장경로에 연속적으로 연결하여 각막 궤양의 위치 정보와 객체 형태 정보를 보다 원활하게 학습하게 한 것이다. 전처리 후 DBDU-Net에 입력된 영상은 0과 1 사이의 값을 갖는 Tensor로 변환되었으며 이후 Tensor Value Process를 적용하였다. 이어서 각막 궤양 주변의 빛 반사와 눈꺼풀 영역을 제거하기 위해 Labeling 후처리를 진행하였다. 총 열 번의 실험을 통해 최대 98.66%, 평균 93.32%의 ADC를 도출하였다. 이 결과와 일반 U-Net, SegFormer, 그리고 Transformer 기법을 사용한 ViT 모델 등으로부터의 결과와 비교하였을 때 약 14% ~ 22%의 Dice 계수 우위를 보였다. 또한 타 연구자들의 실험 결과와도 성능 비교를 진행하였으며, DBDU-Net이 성능면에서 뒤지지 않는 양호한 결과를 도출하는 것을 확인하였다. 기존 연구에서는 Fluorescein 염료를 사용하거나 수동으로 궤양의 위치를 잘라내어 사용한 경우도 있었다. 본 연구를 통해 고안된 DBDU-Net은 In-house 데이터를 사용하여 성능평가에 제약이 있을 수 있긴 하나 전체 자동작업

으로 진행되어 보다 신속하게 각막 궤양의 형태와 위치를 찾을 수 있으며 이를 통하여 의료진을 도와 초기 각막 궤양 환자에 대한 정확한 진단과 치료에 많은 도움을 줄 수 있을 것으로 사료된다. 향후 안과질환 의료영상 연구의 연속선 상에서 적절한 분량의 공공 안구 의료데이터를 확보하고 적용도구의 다양성 확보를 위해 트랜스포머를 이용한 자동판별 및 분할 프로세스를 고안할 예정이며 질환 연구 분야의 확장을 위해 항반변성 분류작업 또한 진행할 예정이다.

## REFERENCES

- [1] N. Tananuvat, P. Upaphong, C. Tangmonkongvoragul, M. Niparugs, W. Chaidaroon and M. Pongpom, "Fungal keratitis at a tertiary eye care in Northern Thailand: Etiology and prognostic factors for treatment outcomes," *Journal of Infection* Vol. 83, No. 1, pp. 112-118, DOI:10.1016/j.jinf.2021.05.016, May 2021.
- [2] A. Arora et al., "Targeting fungal keratitis: In vivo efficacy of corneal-targeting and non-targeting peptides against *Fusarium dimerum*," *European Journal of Pharmaceutics and Biopharmaceutics*, Vol. 214, DOI:10.1016/j.ejpb.2025.114793, 2025.
- [3] C. P. Pappas, "Corneal innervation and neurotisation: A review of current concepts," *JFO Open Ophthalmology*, Vol. 10, DOI:10.1016/j.jfop.2025.100163, 2025.
- [4] E. Faiella et al., "Digital twins in radiology: A systematic review of applications, challenges, and future perspectives," *European Journal of Radiology*, Vol. 189, DOI:10.1016/j.ejrad.2025.112166, 2025.
- [5] I. Cinar, Y. S. Taspinar, R. Kursun and M. Koklu, "Identification of Corneal Ulcers with Pre-Trained AlexNet Based on Transfer Learning," *11th Mediterranean Conference on Embedded Computing (MECO)*, Budva, Montenegro, pp. 1-4, DOI:10.1109/MECO55406.2022.9797218, June 2022.
- [6] T. G. Devi, N. Patil, S. Rai and C. S. Philipose, "Gaussian Blurring Technique for Detecting and Classifying Acute Lymphoblastic Leukemia Cancer Cells from Microscopic Biopsy Images," *Life (Basel, Switzerland)*, Vol. 13, No. 2, pp. 348, DOI:10.3390/life13020348, Jan 2023.
- [7] Y. Q. Liu, X. Du, H. L. Shen and S. J. Chen, "Estimating Generalized Gaussian Blur Kernels for Out-of-Focus Image Deblurring," *IEEE Transactions on Circuits and Systems for Video Technology*, Vol. 31, No. 3, pp. 829-843, DOI:10.1109/TCSVT.2020.2990623, March 2021.
- [8] S. Basar, M. Ali, A. Waheed, M. Ahmad and M. H. Miraz, "A Novel Defocus-Blur Region Detection Approach Based on DCT

- Feature and PCNN Structure,” *IEEE Access*, Vol. 11, pp. 94945-94961, DOI:10.1109/ACCESS.2023.3309820, August 2023.
- [9] S. H. Majeed and N. A. M. Isa, “Adaptive Entropy Index Histogram Equalization for Poor Contrast Images,” *IEEE Access*, Vol. 9, pp. 6402-6437, DOI:10.1109/ACCESS.2020.3048148, December 2021.
- [10] M. F. Khan, E. Khan, M. M. Nofal and M. Mursaleen, “Fuzzy Mapped Histogram Equalization Method for Contrast Enhancement of Remotely Sensed Images,” *IEEE Access*, Vol. 8, pp. 112454-112461, DOI:10.1109/ACCESS.2020.3001658, June 2020.
- [11] A. M. Pour, H. Seyedarabi, S. H. A. Jahromi and A. Javadzadeh, “Automatic Detection and Monitoring of Diabetic Retinopathy Using Efficient Convolutional Neural Networks and Contrast Limited Adaptive Histogram Equalization,” *IEEE Access*, Vol. 8, pp. 136668-136673, DOI:10.1109/ACCESS.2020.3005044, June 2020.
- [12] L. Zhuang, Y. Ma, Y. Zou and G. Wang, “A Novel Image Dehazing Algorithm via Adaptive Gamma-Correction and Modified AMEF,” *IEEE Access*, Vol. 8, pp. 207275-207286, DOI:10.1109/ACCESS.2020.3038239, November 2020.
- [13] J. Choi and B. Choi, “Highly Contrast Image Correction for Dim Boundary Separation of Image Semantic Segmentation,” *IEEE Access*, Vol. 9, pp. 64142-64152, DOI:10.1109/ACCESS.2021.3075084, April 2021.
- [14] H. Singh, A. Kumar, L. K. Balyan and H. N. Lee, “Fractional-Order Integration Based Fusion Model for Piecewise Gamma Correction Along With Textural Improvement for Satellite Images,” *IEEE Access*, Vol. 7, pp. 37192-37210, DOI:10.1109/ACCESS.2019.2901292, March 2019.
- [15] T. Wang, M. Wang, W. Zhu, L. Wang, Z. Chen, Y. Peng, F. Shi, Y. Zhou, C. Yao and X. Chen, “Semi-MsST-GAN: A Semi-Supervised Segmentation Method for Corneal Ulcer Segmentation in Slit-Lamp Images,” *Frontiers in neuroscience*, Vol. 15, pp. 793377, DOI:10.3389/fnins.2021.793377, January 2022.
- [16] V. Mayya, S. K. Shevgoor, U. Kulkarni, M. Hazarika, P. D. Barua and U. R. Acharya, “Multi-Scale Convolutional Neural Network for Accurate Corneal Segmentation in Early Detection of Fungal Keratitis,” *Journal of Fungi*, Vol. 7, No. 10, DOI:10.3390/jof7100850, October 2021.
- [17] H. M. B. F. Portela, R. de M. S. Veras, L. H. S. Vogado, D. Leite, P. E. Ambrósio, A. C. de Paiva and J. M. R. S. Tavares, “A corneal ulcer segmentation approach using U-Net and stepwise fine-tuning,” *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, Vol. 11, No. 7, DOI:10.1080/21681163.2023.2250476, August 2023.
- [18] Z. Wang, J. Lyu, W. Luo and X. Tang, “Adjacent Scale Fusion and Corneal Position Embedding for Corneal Ulcer Segmentation,” *Ophthalmic Medical Image Analysis, Lecture Notes in Computer Science*, Vol. 12970, DOI:10.1007/978-3-030-87000-3-1, September 2021.
- [19] Y. Wang, Y. Peng, W. Li, G. C. Alexandropoulos, J. Yu, D. Ge and W. Xiang, “DDU-Net: Dual-Decoder-U-Net for Road Extraction Using High-Resolution Remote Sensing Images,” *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 60, pp. 1-12, DOI:10.1109/TGRS.2022.3197546, January 2022.
- [20] X. Jia, J. Bartlett, T. Zhang, W. Lu, Z. Qiu, and J. Duan, “U-Net vs Transformer: Is U-Net Outdated in Medical Image Registration?,” *Machine Learning in Medical Imaging, Lecture Notes in Computer Science*, Springer, Vol. 13583, DOI:10.48550/arXiv.2208.04939, August 2022.
- [21] O. Ronneberger, P. Fischer and T. Brox, “U-Net: Convolutional Networks for Biomedical Image Segmentation,” *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, Springer, LNCS, Vol. 9351, pp. 234-241, DOI:10.48550/arXiv.1505.04597, 2015.
- [22] E. Xie, W. Wang, Z. Yu, A. Anandkumar, J. M. Alvarez and P. Luo, “SegFormer: Simple and efficient design for semantic segmentation with transformers,” *Advances in neural information processing systems*, Vol. 34, pp. 12077-12090, DOI:10.48550/arXiv.2105.15203, 2021.
- [23] J. Chen, Y. Lu, Q. Yu, X. Luo, E. Adeli, Y. Wang, L. Lu, A. L. Yuille and Y. Zhou, “Transunet: Transformers make strong encoders for medical image segmentation,” *arXiv:2102.04306*, DOI:10.48550/arXiv.2102.04306, 2021.

## Authors



Inhwan Kim received the B.S. (2022) from the Department of Computer Engineering, Dankook University, Yong-In, Kyunggi-Do, Republic of Korea. He worked as a graduate student researcher at Composite & Fusion

Media Processing Laboratory. His research interests include R-CNNs, U-Net, deep learning, and neural networks.



Daewon Kim received the Ph. D. (2002) in Electrical and Computer Engineering from Iowa State University, Ames, Iowa, USA. He is currently a professor in Department of Computer Engineering at Dankook University,

Republic of Korea. His research interests include image and signal processing, deep neural network, composite & fusion media processing, mobile applications and nondestructive evaluation.