

# 이중 부분 주의 기반 다중 합성곱 프레임워크를 이용한 피부암 탐지 개선 연구

무하마드 다니쉬 알리<sup>1</sup>, 한인철<sup>2</sup>, 김수균<sup>3\*</sup>

<sup>1</sup>제주대학교 전자공학전공 박사과정, <sup>2</sup>제주대학교 컴퓨터공학과 학생, <sup>3</sup>제주대학교 컴퓨터공학과 교수

## Advanced Skin Cancer Detection Using Dual Partial Attention Aware Multiple Convolutional Framework

Muhammad Danish Ali<sup>1</sup>, In-Chul Han<sup>2</sup>, Soo Kyun Kim<sup>3\*</sup>

<sup>1</sup>Ph.D. Student, Dept of Electronic Engineering, Jeju National University

<sup>2</sup>Student, Dept of Computer Engineering, Jeju National University

<sup>3</sup>Professor, Dept of Computer Engineering, Jeju National University

**요약** 흑색종과 비흑색종 피부암은 매년 전 세계적으로 수백만 건의 새로운 사례가 확인되는 가장 흔한 피부암의 두 형태이다. 피부암은 자외선 노출로 인한 DNA 손상에서 비롯한 피부 세포의 통제되지 않은 증식에서 발생한다. 조기 발견을 통한 치료는 높은 회복률을 보이지만, 늦은 발견은 악성 종양으로 성장할 수 있으며 치료를 어렵게 만든다. 본 연구는 ResNet-50과 VGG-19의 장점을 결합한 다중 합성곱 신경망 구조의 DV-PAC를 (Dual Vision Partial Attention Channel) 제안하여, 부분 주의 메커니즘을 통해 특징 표현을 강화하고 분류 정확도를 향상시킨다. 모델의 성능은 피부경 검사 영상 분석에서 주로 사용되는 HAM10000 데이터셋을 기반으로 평가한다. 실험 결과, 제안된 모델은 단일 구조의 모델을 뛰어넘는 정확도를 달성하며, 이중 백본 신경망과 주의 기반 융합의 결합 구조가 피부 병변 분류에서 높은 효과가 있음을 입증한다.

**주제어** : 인공지능, 개선된 이중 부분 신경망 구조, 합성곱 신경망, 컴퓨터 보조 진단, 이진 분류

**Abstract** Melanoma and non-melanoma skin cancers are among the most common types of skin cancer, with millions of new cases reported worldwide each year. Skin cancer arises from the uncontrolled proliferation of skin cells caused by DNA damage due to UV radiation exposure. Early detection enables high recovery rates, whereas late detection may lead to malignant tumor growth and make treatment more difficult. This study proposes the Dual Vision Partial Attention Channel (DV-PAC), a multi convolutional neural network framework that combines the strengths of ResNet-50 and VGG-19. The proposed model enhances feature representation and improves classification accuracy through a partial attention mechanism. The performance of the model is evaluated using the HAM10000 dataset, a widely used benchmark for dermoscopic image analysis.


**Key Words** : Artificial Intelligence (AI), Advanced Dual Partial Deep Learning Framework, Convolutional Neural Networks, Computer Aided Diagnosis, Binary Classification

## 1. 서론

피부암은 전 세계적으로 흔한 암 유형으로, 전체 암 진단 사례의 약 5.8%를 차지하며 매년 암 관련 사망의 약 0.6 ~0.7의 비중을 차지한다. 특히 자외선 방사 수치가 높은 호주와 뉴질랜드 같은 고위험 국가에서는 빠르게 피부암의 발병률이 증가하고 있다. 반면 자외선 노출이 낮은 노르웨이나 덴마크 같은 국가는 피부암 발병률이 낮게 기록된다. 피부암은 장시간 자외선에 노출되어 DNA가 손상될 때 발생하는 비정상적 증식으로 발병한다[1, 2]. 피부 조직의 복잡한 구조로 인해 고령 환자에게서 관찰되는 피부 병변은 조기 발견이 어렵다. 효과적인 치료를 위해서는 조기 진단이 필수적이며, 늦은 발견은 암의 전이 가능성을 높이고 치료를 복잡하게 만든다. 최근 몇 년간 전 세계적으로 수백만 건의 피부암 발견 사례가 보고되고 있기에, 더 효율적인 진단 방법의 필요성이 강조된다[3].

이러한 문제를 해결하기 위해 딥러닝 및 기계학습을 통한 여러 컴퓨터 보조 진단 시스템이 (Computer Aided Diagnosis, CAD) 연구되었다. SVM은 (Support Vector Machines) 회귀와 분류 문제에서 사용되는 지도학습 방법으로, 비선형 데이터에 대한 우수한 정확도 성능을 보인다. k-NN (k-Nearest Neighbors) 알고리즘은 가장 이웃하는 데이터들에 따라 분류를 수행하는 특징 유사성 기반 분류 기법으로 질병 분야에서 양성과 악성을 구분하는 데 널리 활용된다[4]. 의사결정트리 (Decision Trees) SVM과 같이 회귀와 분류 문제에서 사용할 수 있으며 결과를 쉽게 해석할 수 있다. 공분산 행렬은 (Grey Level Co-Occurrence Matrix, GLCM) 픽셀 밝기 간의 공간적 관계를 특성화하여 병변의 질감을 분석하는 강력한 텍스처 특징 추출 알고리즘이다. 이런 고전적인 알고리즘들은 소규모 데이터셋에서 유용한 결과를 도출하지만[5, 6], 고해상도 피부경 이미지 데이터셋의 패턴의 복잡성을 해결하지 못하고 모델 확장성이 낮은 한계가 있다. Fig. 1은 피부암 질환 중 가장 흔한 흑색종과 (Melanoma) 비흑색종 (Melanocytic Nevi) 두 가지 유형을 보여준다.

본 논문은 기존의 기계학습과 딥러닝 기법의 한계를 극복하기 위해 이중 비전 부분 주의 채널 (Dual Vision Partial Attention Channel, DV-PAC) 프레임워크를 제안한다. 우리는 ResNet-50과 VGG-19라는 두 가지 합성곱 신경망 백본의 강력한 표현 능력을 결합하여 특징 표현을 향상시킨다. 제안된 이중 경로 구조는 두 신경



[Fig. 1] Melanoma (Left) and Melanocytic Nevi: Non Melanoma (Right)

망에서 추출된 판별적 패턴을 특징연결 방식으로 결합함으로써, 병변 분류의 정확도를 효과적으로 개선하고 피부 병변의 세밀한 시각적 특징을 효율적으로 학습한다. 또한 모델의 성능을 평가하기 위해 피부 병변의 다양성과 복잡성으로 잘 알려진 HAM10000 벤치마크 데이터셋을 활용한다. 실험 결과 제안하는 DV-PAC는 96%의 높은 분류 정확도를 달성하였으며, 이는 앙상블 학습과 주의 메커니즘을 사용한 우리의 제안 방법이 피부 병변 분류 성능을 높이고, 조기 피부암 진단을 위한 유용한 도구가 될 수 있음을 입증한다.

본 연구의 주요 기여점은 다음과 같다.

- 다중 CNN 모델을 (ResNet-50, VGG-19) 개별적으로 학습 및 평가하고, 가장 성능이 우수한 모델을 앙상블 융합에 활용한다.
- ResNet-50과 VGG-19 모델에서 추출된 특징을 연결한 뒤, 부분 주의 채널 기법을 적용하여 피부암 병변의 중요한 패턴을 강조하고 정제한다.
- 기존의 기계학습 기반 모델과 개별 합성곱 신경망 모델보다 더 우수한 성능을 달성한다.

## 2. 관련 연구

Kadampur[1] 등은 피부과 진단을 더 효과적으로 수행할 수 있는 딥러닝 접근법을 제시하였다. 제시된 방법은 피부암 데이터를 분석하여 문제를 식별할 수 있는 컴퓨터 모델이며, 전문 기술 없이 신경망 모델을 구축할 수 있게 한다. 해당 모델은 테스트 데이터셋에서 약 98%의 평균 진단 정확도를 달성하였다. Karl[2] 등은 합성곱 신경망을 활용하여 피부암을 탐지하는 기법을 개발하였다. GoogleNet 신경망을 기반으로 개발한 모델은 HAM10000 테스트 데이터셋에서 94%의 정확도를 달성하였지만, GooleNet의 한계로 인하여 다른 CNN 모델보다 낮은 성능을 보인다. Darip[3] 등은 다양한 필터 크기를 갖는 (11×11, 5×5, 3×3) 합성곱 신경망에 잡음을 제거하기 위한 최대 풀링 연산을 결합하였다. 해당

모델은 AlexNet을 사용하여 이미지에서 다양한 특징을 추출하였으며, 인터넷에서 수집한 피부암 이미지에 적용한 결과 82%의 정확도를 얻었다. Adengun[7] 등의 논문에서는 피부암 분류 성능을 비교하기 위해 GoogleNet, AlexNet, ResNet을 포함한 다양한 CNN 모델 구조의 성능을 비교하였다. Lattoofi[5, 8] 등은 피부암 탐지 분류를 위해 딥러닝과 기계학습 방식을 비교하여 다양한 기계학습 알고리즘의 활용이 의료 분야에서 잠재적 영향력을 보여줄 수 있음을 보였다. 특히, ABCD 규칙은 비대칭, 경계, 색, 직경을 평가하여 흑색종 피부암 여부를 판단한다.

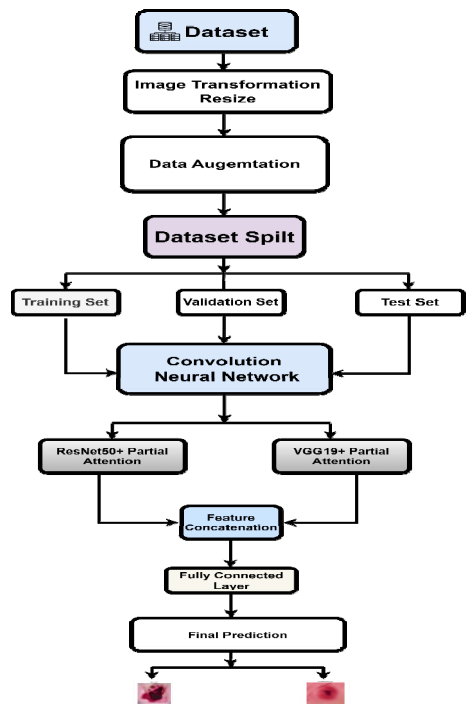
Ni Zhang[6, 9] 등은 WOA (Whale Optimization Algorithm) 라고 불리는 새로운 메타 휴리스틱 기법을 제안하였다. WOA는 다양한 수학적 및 구조적 설계 문제를 해결하며, 합성곱 신경망 구조를 최적화하여 최대 성능을 달성하였다. 다른 논문에서는 피부암을 조기에 탐지하기 위해 딥러닝 모델에 앙상블을 적용하는 방법을 제안하였다[10, 11, 12, 13]. 똑같은 분류 작업을 수행하는 여러 CNN 모델이 결합되는 스택킹 모델에 전이 학습 원칙을 적용하였다. 앙상블 학습 접근법의 효율성은 테스트 데이터셋에서 95%의 높은 정확도를 얻어 최상의 예측 결과를 얻었다. Kassani[14] 등은 ResNet-50을 사용하여 피부암을 분류할 수 있는 모델을 개발하여 피부암을 자동으로 분류하였다. 대규모 데이터셋을 처리하고 이미지에서 유용한 특징을 추출하는 데 가장 효율적인 ResNet-50 모델은 ISIC2019 테스트 데이터셋에서 92%의 정확도를 달성하였다. 본 연구는 CNN 모델을 이용하여 피부암을 자동으로 분류할 수 있도록 한다. 다수의 합성곱 필터층을 두며 마지막에는 완전 연결층으로 구성한다. 합성곱 층은 각 커널에서 평균값 풀링 방식으로 특징 차원을 줄이고, 필터를 통해 입력 이미지를 정제한다.

Shahi[15] 등은 GLCM을 이미지 텍스처 식별을 위한 특징 추출기법으로 활용하였다. GLCM은 의료 분야에서 손상된 피부 영역을 뚜렷하게 구별할 수 있는 장점을 갖고 있으며, 잡음이 포함된 대규모 데이터셋에서 더 잘 적용될 수 있다. 기존의 방법들은 부적절한 하이퍼파라미터 조정과 교차 검증으로 인한 과적합 문제를 겪고 있으며, 이를 해결해야 한다고 설명하였다. 본 연구에서 제안하는 DV-PAC는 새로운 관찰 학습의 효율성을 높이고 다양한 모델의 결과를 통합하여 예측에서 높은 정확도를 달성하는 것을 목표로 한다.

### 3. 제안 방법

#### 3.1 모델 프레임워크


CNN 기반 모델로 피부암을 검출하기 위해 Fig. 2와 같은 구조를 제안한다. 해당 구조는 ISIC 데이터셋의 피부경 검사 이미지를 입력 데이터로 사용한다. 판별적 특징을 추출하기 위해 ResNet-50과 VGG-19 신경망을 백본 모델로 활용한다. 최종 예측은 하위의 개별적 CNN 모델의 예측을 통합하여 얻을 수 있으며, 피부암 분류 성능을 크게 향상시킬 수 있다. 딥러닝 모델에서 부분 주의 채널 방식은 (PAC) 효율적인 필터링 메커니즘으로 사용된다. 입력 데이터에서 중요도가 낮은 특징의 영향을 줄이고, 높은 요소를 강조함으로써, 모델이 중요한 패턴을 식별하고 불필요한 정보를 배제할 수 있도록 학습시킨다. 이 방법은 의사 결정 능력을 향상시키고 계산 처리 자원을 절약하며, 완전한 주의 메커니즘이 필요하지 않은 상황에서 유용하다. PAC는 백본 신경망으로 사용하는 ResNet-50 및 VGG-19 모델에 통합될 때, 중요한 기능을 추출할 수 있게 하여 모델의 해석 가능성과 분류 정확도를 높인다.



[Fig. 2] Overview of Proposed Methodology

$$O = f\left(\frac{RT^U}{\sqrt{G_j}} * L\right)Z \quad (1)$$

수식(1)은 입력 특징 중 핵심 영역에 집중하기 위한 PAC 메커니즘을 의미한다.  $R$ ,  $T$ ,  $Z$ 는 특징 간의 관계를 정의하는 쿼리, 키, 값 행렬을 의미한다.  $L$ 은 관련 영역만 선택하게 만드는 주의 마스크를 의미하며, 출력  $O$ 는 이러한 특징들에 가중치를 부여하기 위해 활성화 함수  $f$ 를 통해 계산된다. Fig. 3은 CNN 모델에서 PAC 메커니즘을 활용하는 개요도를 보여준다.



[Fig. 3] Show the Partial Attention Mechanism in the CNN backbone model

### 3.2 데이터세트

다양한 분야에서 딥러닝 모델을 활용할 때 가장 중요한 요소는 데이터세트이지만, 모든 데이터세트에 접근하는 것은 불가능하며 특히나 고품질 데이터세트일수록 사용하기 더 어려워진다. 딥러닝 알고리즘은 데이터세트의 패턴과 특징을 분석한 다음 학습한 내용을 데이터에 적용하여 예측 결과를 생성한다. 따라서 최적화된 딥러닝 모델 학습을 위해서는 정렬된 데이터세트가 필수적이다. 본 연구는 과학계 연구 커뮤니티 Kaggle 웹페이지에서 사용되는 HAM10000 데이터세트를 활용한다. HAM10000 데이터세트는 크게 흑색종과 비흑색종 피부 병변으로 분류된다. 흑색종에는 악성 멜라닌 세포 종양을 의미하는 “mel” 약어가 표시된 이미지이다. 비흑색종은 피부섬유종(df), 광선각화증 또는 보웬병(akiec), 양성 각화증 유사 병변(bkl), 기저 세포 암종(bcc), 혈관 병변(vasc), 멜라닌 세포 모반(nv)과 같이 6가지 종류로 나뉘어 있다. 흑색종 피부암은 비흑색종과 다르게 전이와 사망 위험률이 높은 치명적인 피부암이기 때문에, 두 질병을 이진 분류하는 것은 임상적으로 중요한 목표로 설정된다.

#### 3.2.1 데이터 전처리

정규화 또는 대비 스트레칭이라 불리는 기법은 이미지의 색 변화를 대조하여 시각적 특성을 개선하는 간단한 기술이다. 의료 영상에서는 병변 반점과 같은 세부 사항에 더 집중할 수 있도록 사용된다. 이 과정은 출력 이미지의 가장 낮은 값과, 높은 값이 각각 최소, 최대 픽

셀 강도를 나타내도록 변경시킨다. 주목할 점은 이 과정이 선형과 비선형의 모든 방식으로 동작할 수 있다는 것이며, 대비 스트레칭의 다양성을 보여준다. 결과적으로 더 고품질의 시각적 특징을 갖는 고대비 이미지가 생성된다.

#### 3.2.2 데이터 증강

데이터 증강은 데이터세트에 더 많은 샘플을 추가하여 모델의 일반화 성능을 높이는 방법이다. 딥러닝 모델이 효과적으로 학습하기 위해서는 많은 양의 데이터가 필수적이며 분류마다 균일한 양의 데이터가 필요하다. 본 연구에서 사용하는 데이터세트는 특정 분류에 더 많은 표본이 있고, 다른 분류에는 더 적은 표본이 있기에, 각 분류의 균형을 맞추기 위해 업 샘플링 및 다운 샘플링을 활용한다. 데이터세트는 회전, 대칭 이동 및 잡음 추가 등의 다양한 증강 방법을 적용한다. 이미지의 크기는 변경하지 않으며, 이미지를 반전시키거나, 15도 및 45도, 시계 방향 및 시계 반대 방향으로 회전시킨다. 이러한 변화를 적용한 이미지 데이터는 다양한 시각적 조건을 갖게 되며, 모델의 식별 능력 향상에 도움을 준다.

#### 3.2.3 학습 데이터세트

CNN 모델 학습에는 데이터세트의 70%를 학습 데이터로 사용한다. 이 단계에서 신경망 모델은 이미지로부터 판별적 특징을 학습하고 매개변수를 정제하여 분류 오류를 최소화한다.

#### 3.2.4 검증 데이터세트

모델 성능을 검증할 때는 학습용 데이터로 사용하지 않는 데이터 중 전체 10%에 해당하는 데이터를 사용한다. 모델 훈련 중 관찰하지 못한 데이터에서 성능을 평가하는 것이 성능 개선, 매개변수 최적화 및 과적합 방지에 유용하다.

#### 3.2.5 테스트 데이터세트

모델 테스트에 사용되는 데이터는 학습과 검증 단계에서 사용하지 않는 나머지 데이터 20%를 모두 사용하며, 모델의 일반화 성능에 대한 객관적인 평가를 수행한다. 훈련된 모델은 정확도 (Accuracy), 정밀도 (Precision), 재현율 (Recall) 및 F1 점수와 (F1-Score) 같은 지표로 평가된다.

〈Table 1〉 Algorithms of Proposed Method

---

**Input:** Image datasets  $D$  with labeled samples

**Output:** Predicted class labels for test images

**Step 1:** Preprocess dataset  $D$

- 1: Resize images to  $224 \times 224$  pixels
- 2: Normalize and convert to tensors

**Step 2:** Split dataset  $D$

- 3: Training set (70%) : Validation set (10%) : Test set (20%)

**Step 3:** Partial Attention module

- 4: Apply Adaptive Average Pooling
- 5: Pass through Fully Connected layers (ReLU, Sigmoid)
- 6: Multiply attention weights with input feature maps

**Step 4:** Construct ResNet-50 & VGG-19 concatenation model

- 7: Extract features from pre-trained ResNet-50 and VGG-19
- 8: Apply Partial Attention to each feature set
- 9: Apply Adaptive Average Pooling and concatenate outputs
- 10: Apply fully connected layer for classification

**Step 5:** Initialize

- 11: Model  $M$ , optimizer (Adam), loss function (Cross Entropy Loss)

**Step 6:** Training & valid phase

- 12: **for**  $e = 1$  to  $N$  **do**
- 13: Forward pass input batch through  $M$
- 14: Compute loss and back propagate gradients
- 15: Update model weights
- 16: Record training accuracy and loss
- 17: Evaluate model on validation set
- 18: Record validation accuracy and loss
- 19: **end for**

**Step 7:** Evaluate model on test set

- 20: Compute Accuracy, Precision, Recall, F1-Score

---

### 3.3 학습 알고리즘

본 연구에서 제안하는 모델의 학습 알고리즘은 Table 1처럼 동작한다. 먼저 데이터셋을 입력받아 이미지 전처리 과정을 수행하고 학습, 검증, 테스트 데이터셋으로 나눈다. ResNet-50과 VGG-19를 백본으로 하는 이중 네트워크를 구성하고 각 특징 맵에 PAC 모듈을 적용하여 주요 병변 영역에 집중하도록 설계한다. 이어서 적응형 평균 풀링과 완전 연결층을 통해 최종 분류를 수행한다. 학습 단계에서는 Adam 최적화 알고리즘과 교차 엔트로피 손실 함수를 사용하고, 테스트 단계에서는 정확도, 정밀도, 재현율, F1 점수 지표를 사용하여 평가한다.

## 4. 실험

### 4.1 실험 설계

흑색종 및 비흑색종 피부암 분류를 위해 제안된 DV-PAC 모델의 성능을 평가하기 위해 여러 모델 구성에 대한 분석을 수행한다. 데이터셋은 학습, 검증, 테스트에 맞춰 70:10:20의 비율로 나눈다. 사용하는 데이터셋에 증강 기법을 적용하여 모델의 학습 효율성을 높이고 과적합을 줄이며, 불균형한 데이터 문제를 해결하고 일반화 성능을 향상시킨다. Table 2는 모델 학습에서 사용한 하이퍼파라미터 구성을 보여준다.

〈Table 2〉 Hyper parameter Configuration of the Proposed Model

Hyper-parameter	Value
Learning Rate	0.0001
Optimizer	Adam
Loss Function	Cross Entropy Loss
Attention Mechanism	Partial Attention
Activation Function	ReLU, Sigmoid
Range of rotation	$\pm 15^\circ$ , $\pm 45^\circ$
Shuffling	○
Flipping	Vertical
Noise Addition	random noise

## 4.2 평가 지표

제안하는 DV-PAC의 피부암 분류 성능은 정확도, 정밀도, 재현율, F1 점수 총 4개의 지표를 사용하여 평가한다. 모든 지표는 진양성 (True Positive, TP), 진음성 (True Negative, TN), 위양성 (False Positive, FP), 위음성의 (False Negative, FN) 값으로 계산된다. 진양성은 정확하게 참으로 분류된 값이며, 진음성은 정확하게 거짓으로 분류된 값을 의미한다. 반대로 위양성은 거짓을 참으로 잘못 분류된 값이며, 위음성은 참을 거짓으로 잘못 분류된 값을 의미한다.

### 4.2.1 정확도

$$Accuracy = \frac{TP + TN}{(TP + TN + FP + FN)} \quad (2)$$

수식(2)은 정확도를 나타내는 지표로, 모든 측정 결과 중에서 올바르게 분류된 결과의 비율을 의미한다.

### 4.2.2 정밀도

$$Precision = \frac{TP}{(TP + FP)} \quad (3)$$

수식(3)은 정밀도를 나타내는 지표로, 참과 거짓을 올바르게 분류한 결과 중에서 참으로만 올바르게 분류된 결과의 비율을 의미한다.

### 4.2.3 재현율

$$Recall = \frac{TP}{(TP + FN)} \quad (4)$$

수식(4)은 재현율을 나타내는 지표로, 참으로 분류된 모든 결과 중에서 올바르게 분류된 결과의 비율을 의미한다.

## 4.2.4 F1-Score


$$F1\ Score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} \quad (5)$$

수식(5)은 F1 점수를 나타내는 지표로, 재현율과 정밀도의 조화 평균을 나타낸다. 이는 모델 성능 평가에서 재현율과 정밀도의 중요성을 균형 있게 고려할 때 유용하다.

## 5. 결과

### 5.1 분류 결과 보고서


제안 모델의 분류 성능은 scikits-learn 라이브러리를 사용한 Fig. 4의 분류 결과 보고서에서 설명된다. 흑색종과 비흑색종 분류에서 정밀도, 재현율, F1 점수 모두 95% 이상의 결과를 얻으며, 정확도 또한 96%를 달성한다. 흑색종 피부암 분류는 98%의 높은 재현율을 보이며, 비흑색종의 경우에서도 98%의 높은 정밀도를 보인다. 평균적인 분류 성능을 비교하였을 때도 96%에서 97%로 비슷한 결과를 얻었는데, 이는 데이터 증강 기법이 불균형 문제를 완화하였음을 의미한다.



[Fig. 4] Classification Report of the Proposed Model

### 5.2 혼동 행렬

혼동 행렬은 (Confusion Matrix) 재현율과 정확도를 기준으로 모델의 성능을 평가하는 도구이다. 분류 모델로 얻은 예측 결과에 대한 상세한 정보를 제공하여 모델의 효과성을 명확하게 평가할 수 있다. Fig. 5처럼 제안된 모델은 230개의 데이터를 정확하게 비흑색종으로 분류하고, 나머지 10개의 데이터를 잘못 분류한다. 흑색종의 경우에는 1개의 데이터만을 잘못 분류하고, 나머지 239개의 데이터를 정확하게 흑색종으로 분류한다.



[Fig. 5] Confusion Matrix of the Proposed Model

### 5.3 정량 평가 비교

본 연구에서 제안하는 방법의 효용성을 확인하기 위해, Table 3과 같이 기존 연구 결과와 비교하여 평가한다. 기존의 모델들도 90% 이상의 높은 정확도를 보이고 있지만, 제안하는 모델이 96%로 가장 높은 정확도를 가진 것을 볼 수 있고, 앙상블 모델을 제시한 것보다 0.4% 더 높은 결과를 의미한다. 이는 CNN 모델 구조에 PAC 메커니즘의 결합이 병변 관련 영역에 초점을 맞추어 불필요한 정보를 배제하여 분류 정확도를 높이고 식별 능력을 개선한다고 할 수 있다.

<Table 3> Comparison of classification accuracy with existing methods.

Paper	Model	Accuracy
Lattoofi[5]	CNN Model	93.2%
Shorfuzzaman[10]	Ensemble Model	95.76%
Khan[12]	Deep CNN Model	90.0%
Khan[13]	Transfer Model	90.0%
Lattoofi[5]	Machine Learning	93.2%
<b>Proposed Model</b>	<b>DV-PAC</b>	<b>96.0%</b>

## 6. 결론

본 연구는 피부암을 효과적으로 분류하기 위해 DV-PAC 모델 구조를 제안하였으며, HAM10000 데이터세트에서 기존 모델보다 우수한 성능을 달성하였다. ResNet-50과 VGG-19로 구성된 이중 구조의 백본 신경망과 높은 분류 성능을 제공할 수 있는 주의 기반 융합 기술을 결합하여 피부암 검출에서 일반성과 진단 정확도를 개선하였음을 보였다. 향후 연구에서는 피부암 검출에서 일반성과 진단 정확도를 개선하기 위해 다른 학습 전략을 사용하는 방안을 고려한다. 더불어 모델 제약이 거의 없는 메타 학습 및 강화 학습과 같은 알고리즘을 탐구한다.

## REFERENCES

- [1] Kadampur M.A and Riyae S.A, "Skin cancer detection: Applying a deep learning-based model driven architecture in the cloud for classifying dermal cell images", Informatics in Medicine Unlocked, Vol.18, 2020.
- [2] Calin M.A, Parasca S.V, Savastru R, Calin M.R and Dontu S, "Optical techniques for the noninvasive diagnosis of skin cancer", Journal of Cancer Research and Clinical Oncology, Vol.139, pp.1083-1104, 2013.
- [3] Thurnhofer-Hemsi K and Dominguez E, "A Convolutional Neural Network Framework for Accurate Skin Cancer Detection", Neural Process Letters, vol.53, pp.3073-3093, 2021.
- [4] Dorj U.O, Lee K.K and Choi J.Y, "The skin cancer classification using deep convolutional neural network", Multimedia Tools and Applications, Vol.77, pp.9909-9924, 2018.
- [5] Lattoofi N.F, Al-sharuee I.F, Kamil M.Y, Obaid A.H, Mahidi A.A and Omar A.A, "Melanoma Skin Cancer Detection Based on ABCD Rule", 2019 First International Conference of Computer and Applied Sciences (CAS), pp.154-157, 2019.
- [6] Zhang N, Cai Y.X, Wang Y.Y, Tian Y.T, Wang X.L and Badami B, "Skin cancer diagnosis based on optimized convolutional neural network", Artificial Intelligence in Medicine, Vol.102, 2020.
- [7] Adengun A and Viriri S, "Deep learning techniques for skin lesion analysis and melanoma cancer detection: a survey of state-of-the-art", Artificial Intelligence Review, Vol.54, pp.811-841, 2021.
- [8] Ramlakhan K and Shang Y, "A Mobile Automated Skin Lesion Classification System", 2011 IEEE 23<sup>rd</sup> International Conference of Tools with Artificial Intelligence, pp.138-141, 2011.
- [9] Metha P and Shah B, "Review on Techniques and Steps of Computer Aided Skin Cancer Diagnosis", Procedia Computer Science, Vol.85, pp.309-316, 2016.
- [10] Shorfuzzanman M, "An explainable stacked ensemble of deep learning models for improved melanoma skin cancer detection", Multimedia Systems, Vol.28, pp.1309-1323, 2022.
- [11] Ali M.D, Saleem A, Elahi H, Khan M.A, Khan M.I, Yaqoob M.M, Farooq Khattak U and Al-Rasheed A, "Breast Cancer Classification through Meth-Learning Ensemble Technique Using Convolution Neural Networks", Machine Learning and Artificial Intelligence in Diagnostics, 2023.
- [12] Khan M.A, Mazhar T and Ali M.D, "Automatic melanoma and non-melanoma skin cancer diagnosis using advanced adaptive fine-tuned convolution neural networks", Discover Oncology, Vol.16, No.645, 2025.
- [13] Khan M.A, Ali M.D, Mazhar T, Shazad T, Rehman

W.U, Shahid M and Haman H, "An Advanced Deep Learning Framework for Skin Cancer Classification", The Review of Socionetwork Strategies, Vol.19, pp.111-130, 2025.

- [14] Kassani S.H and Kassani P.H, "A comparative study of deep learning architectures on melanoma detection", Tissue and Cell, Vol.58, pp.76-83, 2019.
- [15] Shahi P, Yadav S, Singh N and Singh N.P, "Melanoma Skin Cancer Detection Using Various Classifiers", 2018 5th IEEE Uttar Pradesh Section International Conference on Electrical, Electronics and Computer Engineering (UPCON), pp.1-5, 2018.

무하마드 다니쉬 알리(Muhammad Danish Ali)

[정회원]



- 2017년 12월 : Gomal university 컴퓨터공학과 (공학학사)
- 2023년 1월 : Comsats university 컴퓨터공학과 (공학석사)
- 2025년 3월 ~ 현재 : 제주대학교 에너지응용시스템학부 전자공학전공 박사과정

<관심분야>

기계학습, 딥러닝, 생물정보학, 이미지 전처리

한 인 철(Han In Chul)

[학생회원]



- 2025년 2월 : 제주대학교 컴퓨터공학과 (공학학사)
- 2025년 3월 ~ 현재 : 제주대학교 컴퓨터공학과 석사과정

<관심분야>

인공지능, 혼합현실, 컴퓨터 비전, 그래픽 상호작용

김 수 균(Kim Soo Kyun)

[정회원]



- 2006년 2월 : 고려대학교 컴퓨터학과 (이학박사)
- 2025년 3월 ~ 현재 : 제주대학교 컴퓨터공학과 교수

<관심분야>

멀티미디어, 패턴 인식, 이미지 전처리, 모바일 그래픽, 기하 모델링, 그래픽 상호작용