

다중 수용 영역 구조를 활용한 흑색종 분류 모델 연구

최지원, 김장겸*

세종대학교, *세종대학교

sotina13@gmail.com, *jk.kim@sejong.ac.kr

A Study on Melanoma Classification Using
Multi-Scale Receptive Field-Based Architecture

Choi Ji Won, Jangkyum Kim*

Sejong Univ., *Sejong Univ.

요 약

본 논문은 피부 병변 이미지로부터 흑색종을 분류하기 위한 딥러닝 기반 모델인 ASPP ResNet-50 을 제안한다. 흑색종은 빠른 전이와 높은 치사율로 인해 조기 진단이 중요한 피부암이다. 제안 모델은 ResNet-50 백본으로 Atrous Spatial Pyramid Pooling 구조를 통합하여 피부 병변 이미지를 분류한다. 성능 검증을 위해 ResNet-50, DenseNet-121, VGG-16 과 비교 실험을 수행한 결과, ASPP ResNet-50 모델이 92%로 가장 높은 분류 정확도를 보였다.

I. 서 론

흑색종은 멜라닌 세포 또는 모반 세포에서 기원하는 악성 종양으로, 피부에 주로 발생하며 전체 피부암 사망의 약 80%를 차지할 정도로 치명적인 질환이다 [1]. 2000 년대 이후 국내에서도 흑색종 발생률이 증가하고 있으며, 발생 원인은 명확하지 않지만 유전적 요인과 자외선 노출이 주요 위험 인자로 알려져 있다. 특히 전이 속도가 빨라 조기 발견 여부가 환자의 생존율에 결정적인 영향을 미친다. 따라서 정확하고 신속한 진단을 위한 보조 도구 개발이 요구된다 [1,2].

본 논문에서는 다양한 수용 영역을 활용하는 Atrous Spatial Pyramid Pooling 구조를 적용하여, 흑색종 조기 진단 성능을 향상시키기 위한 딥러닝 기반 분류 모델을 제안한다 [3]. ResNet-50 백본에 ASPP 구조를 통합한 ASPP ResNet-50 모델을 설계하고, 기존의 대표적인 합성곱 신경망 모델인 ResNet-50, DenseNet-121, VGG-16 과 성능을 비교하여 제안 모델의 유효성을 검증하고자 한다 [4-6].

II. 본론

2.1 Atrous Spatial Pyramid Pooling

Atrous Spatial Pyramid Pooling(ASPP)은 다양한 크기의 수용 영역을 갖는 복수의 팽창 합성곱을 병렬로 적용하여, 객체의 크기나 위치 변화에 강건한 특징을 효과적으로 추출할 수 있도록 고안된 다중 스케일 특징 추출 기법이다. ASPP 는 원래 DeepLab 계열의 semantic segmentation 모델에서 제안된 구조로, 공간 해상도를 유지한 채 넓은 문맥 정보를 포착하는 데 유리하다 [3].

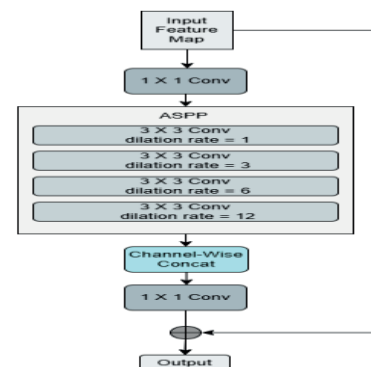


그림 1. ASPP Bottleneck 구조

2.2 ASPP ResNet-50

그림 1 은 ASPP Bottleneck 구조를 시각적으로 나타낸 것이다. 본 연구에서는 흑색종의 진단 성능 향상을 위해 ResNet-50 백본의 후반부에 ASPP 구조를 통합한 ASPP ResNet-50 모델을 제안한다. 기존 ResNet-50 의 Conv1, Conv2, Conv3 는 그대로 유지하되, Conv4 와 Conv5 블록은 각각 6 개와 3 개의 Bottleneck 블록 대신 3 개와 1 개의 ASPP Bottleneck 블록으로 대체하였다. 이는 ASPP 구조의 연산량 증가를 고려해 계산량을 줄이고 과적합을 방지하기 위함이다.

ASPP Bottleneck 은 입력 특징 맵에 먼저 1×1 convolution 을 적용한 후, dilation rate 가 각각 1, 3, 6, 12 인 네 개의 3×3 팽창 합성곱을 병렬로 수행한다. 이후 각 분기에서 추출된 특징을 채널 차원에서 병합하고, 다시 1×1 convolution 을 통해 통합한 다음, skip connection 을 통해 입력과 더해 최종 출력을 생성한다.

2.3 데이터 및 학습 환경 구축

흑색종 분류 모델 학습에는 Kaggle 의 피부 병변 이미지 데이터셋을 사용하였다. 해당 데이터셋은 양성(benign)과 흑색종(malignant) 두 클래스로 구성되어 있으며, 총 10,605 장의 이미지로 이루어져 있다. 이 중 학습용 데이터는 benign 5,000 장, malignant 4,605 장으로 총 9,605 장이며, 테스트 데이터는 각 클래스별 500 장씩 총 1,000 장이다. 학습 데이터는 모델의 일반화 성능 평가를 위해 8:2 비율로 훈련(7,684 장)과 검증(1,921 장) 데이터로 분할하여 사용하였다.

본 논문에서는 모델 학습의 최적화를 위해 AdamW Optimize 를 사용하였으며, 초기 학습률은 0.001, weight decay 는 0.0001 로 설정하였다. 학습 안정성 확보와 과적합 방지를 통해 모델의 일반화 성능을 높이고자 하였다. 손실 함수로는 분류 과제에 적합한 교차 엔트로피 손실을 적용하였으며, 학습률 조절을 위해 검증 손실을 기준으로 동작하는 schedule 를 사용하여 모델이 안정적인 수렴할 수 있도록 하였다. 이러한 학습 설정은 ASPP ResNet-50 뿐만 아니라 비교 대상인 ResNet-50, DenseNet-121, VGG-16 에도 동일하게 적용하였다. 모든 모델은 ImageNet 사전학습 가중치를 기반으로 전이 학습하였으며, 동일한 조건에서 30 epoch 동안 학습을 수행하였다.

2.4 실험 결과




그림 2. 모델별 학습 경향 비교: 왼쪽은 분류 정확도(accuracy), 오른쪽은 손실 값(loss)

모델	정확도(Accuracy)
ResNet-50	89.5%
DenseNet-121	89.8%
VGG-16	89.3%
ASPP ResNet-50	92.0%

표 1. 모델별 Test 분류 정확도

그림 2 의 학습 곡선을 통해 확인할 수 있듯이, ASPP ResNet-50 은 학습 초기에 빠르게 정확도가 향상되며 안정적으로 수렴하는 양상을 보였다. 특히, 훈련과 검증 정확도 간의 간극이 작아, 비교 모델에 비해 과적합을 최소화하는 효과가 있었으며, 최종적으로 약 93%의 높은 검증 정확도를 기록하였다. 반면, VGG-16 모델은

전체적으로 정확도의 변동 폭이 크고 수렴 안정성이 떨어지는 경향을 보였으며, 손실 값 또한 다른 모델에 비해 높고 불안정한 양상을 나타냈다. DenseNet-121 과 ResNet-50 은 비교적 안정적인 수렴 경향을 보였으나, ASPP 구조를 적용한 모델에 비해서는 정확도와 손실 측면에서 다소 열세를 보였다.

이러한 학습 경향은 표 1 에 제시된 최종 테스트 정확도와도 일치한다. 해당 표에서는 각 모델의 최종 테스트 데이터에 대한 분류 정확도를 비교하였다. 실험 결과, ASPP ResNet-50 은 92.0%의 정확도를 기록하며 가장 우수한 성능을 보였다. 그 뒤를 이어 DenseNet-121(89.8%), ResNet-50(89.5%), VGG-16(89.3%) 순으로 확인되었다.

성능 비교 결과 ASPP ResNet-50 이 검증 및 테스트 정확도 모두에서 가장 우수한 성능을 기록하였으며, 학습 안정성과 수렴 속도 면에서도 뛰어난 특성을 보였다. 그러나 학습 epoch 이 증가함에 따라 일부 과적합 경향이 관찰되었으며, 이는 모델의 구조적 복잡성과 관련된 한계로 해석될 수 있다.

III. 결론

본 논문에서는 흑색종 이미지 분류 성능 향상을 위해 다중 수용 영역 기반의 ASPP 구조를 ResNet-50 백본에 통합한 ASPP ResNet-50 모델을 제안하였고, 비교 모델 대비 성능이 우수하였음을 확인하였다.

ASPP 구조는 피부 병변의 공간적 특성을 효과적으로 반영할 수 있으며, 흑색종과 같은 고위험 질환의 조기 진단을 위한 보조 도구로 활용될 가능성을 시사한다. 향후 연구에서는 과적합 현상을 완화하고, ASPP ResNet-50 모델의 일반화 성능을 한층 더 향상시키는 방향으로 연구를 확장할 예정이다.

ACKNOWLEDGMENT

이 논문은 2024 년 대한민국 교육부와 한국연구재단의 인문사회분야 신진연구지원사업의 지원을 받아 수행된 연구임(NRF-2024S1A5A802363012)

참 고 문 헌

- [1] Park J.H., Lee H.S., Ham D.H., Kim J.R., "An analysis of the prognostic factors of malignant melanoma," *J. Korean Bone Joint Tumor Soc.*, vol. 15, pp. 122- 129, 2009.
- [2] 이석종, 이수정, "피부 흑색종," *Journal of the Korean Medical Association*, vol. 61, no. 11, pp. 662- 669, 2018.
- [3] Chen L.-C., Papandreou G., Kokkinos I., Murphy K., Yuille A.L., "DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs," *arXiv:1606.00915*, 2016.
- [4] He K., Zhang X., Ren S., Sun J., "Deep Residual Learning for Image Recognition," *Proc. CVPR*, 2016.
- [5] Huang G., Liu Z., van der Maaten L., Weinberger K.Q., "Densely Connected Convolutional Networks," *Proc. CVPR*, 2017.
- [6] Simonyan K., Zisserman A., "Very Deep Convolutional Networks for Large-Scale Image Recognition," *Proc. ICLR*, 2015.