

## Xception 모델링을 이용한 욕창이미지 크기별 비교분석

서진범<sup>0</sup>, 유하나<sup>\*\*</sup>, 조영복<sup>\*</sup>

<sup>0</sup>대전대학교 정보보안학과,

<sup>\*</sup>대전대학교 정보보안학과,

<sup>\*\*</sup>대전대학교 간호학과

e-mail: seojinbeom@naver.com<sup>0</sup>, ybcho@dju.kr<sup>\*</sup>

## Comparative analysis by pressure ulcer image size using Xception modeling

Jin-beom Seo<sup>0</sup>, Ha-na Yoo<sup>\*\*</sup>, Young-bok Cho<sup>\*</sup>

<sup>0</sup>Dept. of Information Security, Deajeon University,

<sup>\*</sup>Dept. of Information Security, Deajeon University,

<sup>\*\*</sup>Dept. of Nursing, Deajeon University

### ● 요약 ●

전이학습은 영상 분류를 진행한 모델을 사용하여 다른 종류의 영상 분류에 적용하여 문제를 푸는 것을 의미하며, 모델 설계부터 진행한 학습 모델보다 빠른 속도와 높은 정확도를 달성할 수 있다. 또한, 적은 데이터 셋에 대하여 학습을 진행하여 좋은 결과를 도출할 수 있는 장점이 존재한다. 본 논문에서는 전이학습으로 사용되는 모델 중 Xception 모델을 사용하며, 욕창 이미지의 모델 입력 크기를 256, 512, 1024의 크기로 설정하여 학습을 진행 후 욕창 이미지 크기별 성능을 비교분석을 진행하고자 한다.

**키워드:** 욕창(Pressure Sore), 딥러닝(Deep Learning), Xception

## I. 서론

딥러닝에서 컴퓨터 비전, 자연어 처리 분야에서 학습을 진행하기 위해 많은 양의 데이터가 필요하다. 또한, 컴퓨터 비전에서 의료 영상은 고해상도의 이미지가 대다수이며, 데이터의 수가 작은 경우가 많다. 이러한 의료 영상 이미지를 한정된 자원에서 딥러닝을 진행하기 위해 입력 이미지 크기를 다운사이징을 진행하게 되며, 이 과정에서 영상 정보가 손실되는 경우가 많으며, 이를 해결하기 위해 영상 손실이 최소한이 되는 이미지 크기를 선택하며, 다운사이징에서 생기는 노이즈를 최소화하는 과정으로 전처리를 진행한다[1].

모델의 구조가 복잡하고 큰 규모일수록 초기 학습시간에 많은 시간이 소요되는 어려움을 해결하기 위해 이미 학습된 모델을 통해 다른 데이터셋을 학습하는 전이학습이 사용된다. 전이학습의 경우 사전학습된 모델을 사용하기 규모가 작은 데이터셋을 학습하여 빠른 속도와 높은 정확도를 달성할 수 있다[2].

본 논문에서는 전이학습 모델 중 하나인 Xception 모델을 사용하며, 욕창 이미지의 크기를 256, 512, 1024 크기로 리사이징 후 각각 모델에 입력하여 각 크기별 욕창 이미지 분류 성능을 비교분석 하고자 한다.

## II. 관련 연구

### 1. Xception 모델

Xception 모델은 Inception 모델을 기반으로 설계된 모델이며, Cross Channel Correlations를 1번 진행한 후 해당 결과에 대해 Spatial correlations를 진행한다. Inceptions 모델과 비슷한 파라미터를 가지며, 상대적으로 높은 성능을 가지고 있다[3].

## III. Xception 모델링을 이용한 욕창 이미지 크기별 비교분석

Tensorflow, Keras Applications에서 사전학습된 모델 중 Xception 모델을 사용한다. Xception 모델을 불러올 때 최상위 계층인 FC 계층은 제외한 후 전 층이 동결되도록 설정하여 하위 계층을 구성한다. 하위 계층에 대해 Global Average Pooling Layer와 FC 계층을 추가하여 6개의 Output을 가지도록 구성하였다. 욕창 이미지의 경우 각각 크기가 다른 원본 이미지에 대해 1:1 비율의 크롭을 진행한 후 좌우, 상하 플립을 적용하여 데이터 증강을 진행하였다. 총 데이터셋의 크기는 382장이며, 클래스는 6으로 구성하였다.

이미지 크기별 성능 실험은 동일한 환경에서 실험을 진행하였으며, 이미지 크기의 경우 256, 512, 1024로 구분하였다. 각 분류 성능 비교의 경우 Accuracy와 Weight Average F-Score를 통해 비교하고자 한다. 학습 과정에서 Loss의 변화를 모니터링하여 조기 종료를 설정하였다.

Table 1. 256 size input result

Learning count	Accuracy	Weight Avg F-Score	Time (second)
1	0.67	0.63	186
2	0.71	0.71	237

Table 2. 512 size input result

Learning count	Accuracy	Weight Avg F-Score	Time (second)
1	0.75	0.77	486
2	0.78	0.8	894

Table 3. 1024 size input result

Learning count	Accuracy	Weight Avg F-Score	Time (second)
1	0.78	0.79	676
2	0.77	0.79	676

다음 표 1은 256 크기에 관한 결과를 나타낸 것이다. 2번의 학습 동안 Accuracy는 67%, 71%가 도출되었으며, F-Score는 0.63, 0.71이 도출되었다. 표 2는 512크기에 대한 결과를 나타낸 것이다. 2번의 학습동안 Accuracy는 75%, 80%, F-Score는 0.77, 0.79가 도출되었다. 표3은 1024크기에 대한 결과를 나타낸 것이다. 2번의 학습 동안 Accuracy는 78%, 77%, F-Score는 0.79가 도출되었다.

#### IV. Conclusions

본 논문에서는 옥창 이미지에 대하여 입력이미지를 256, 512, 1024로 리사이징하여 Xception전이학습 모델을 통한 분류 성능을 비교하였다. 256크기에서는 평균적으로 69%의 Accuracy가 도출되었으며, Weight Average F-Score는 0.67이 도출되었다. 512크기에서는 평균적으로 76.5%의 Accuracy, Weight Average F-Score는 0.785가 도출되었다. 1024크기에서는 평균적으로 77.5%의 Accuracy, Weight Average F-Score는 0.79가 도출되었다. 입력 이미지가 클수록 높은 정확도가 도출되며, 옥창이미지에서 512와 1024의 크기는 유사한 Accuracy, F-Score가 도출되나 1024 크기의 학습에서 학습 소요 시간과 컴퓨팅 자원이 필요하다. 차후 연구에서는 모델의 부분 동결을 통해 학습을 진행하여 Accuracy와 Weight Average F-Score를 높이고자 한다.

## ACKNOWLEDGEMENT

This research was supported by the Daejeon University Research Grants (2022)

## REFERENCES

- [1] Y. M. Seo, J. K. Han, “ Deep Learning Algorithm to Identify Cancer Pictures”, The Korean Institute of Broadcast and Media Engineers, Vol. 23, No. 5, pp. 669-681, Sep, 2018
- [2] G. Y. Hwang, H. B. Choi, H. S. Heo, Y. H. Han, “Performance Comparison of Transfer Learning Using InceptionV3 and Xception,”, KICS Summer Conference 2019, 2019
- [3] J. G. Park, J. H. Bang, B. Shazia, H. E. Sin, “A Study on the Semantic Segmentation of Fire Area Based on the Xception algorithm”, KIEE Summer Conference 2022, 2022