

소표본 의료 영상의 전이 학습을 위한 Feature Extractor 기법의 성능 비교 및 분석

이동호*, 홍대용*, 이연*, 신병석*

* 인하대학교 컴퓨터공학과

e-mail: dongholab13@gmail.com, ejddjfl67@gmail.com, 217019@inha.ac.kr,

bsshin@inha.ac.kr

Performance Analysis of Feature Extractor for Transfer Learning of a Small Sample of Medical Images

Dong-Ho Lee*, Dae-Yong Hong*, Yeon Lee*, Byeong-Seok Shin*

*Dept of Computer Engineering, In-Ha University

요 약

본 논문은 소표본 의료용 영상 분석의 정확도 향상을 위해 전이학습 모델을 feature extractor로 구축하여 학습시키는 방법을 연구하였으며 성능 평가를 위해 선학습모델로 AlexNet, ResNet, DenseNet을 사용하여 fine tuning 기법을 적용하였을 때와의 성능을 비교 분석하였다. 그 결과 실험에 사용된 3개의 모델에서 fine tuning 기법보다 향상된 정확도를 보임을 확인하였고, 또한 ImageNet으로 학습된 AlexNet, ResNet, DenseNet이 소표본 의료용 X-Ray 영상에 적용될 수 있음을 보였다.

1. 서론

딥러닝 기술의 급격한 발전과 함께 여러 분야에서 딥러닝을 응용하려는 움직임이 보이고 있다. 특히 의료분야에서는 CAD(Computer Aided Diagnosis)에 딥러닝을 적용하는 연구가 활발하게 진행되고 있으며, CNN을 기반으로 한 인체검출 (body detection), 병변분류 (diseases classification) 등에서 뚜렷한 성과를 거두고 있다.

그러나 딥러닝을 위해서는 막대한 양의 데이터셋이 필요하고 충분한 양의 데이터셋을 확보하지 못하는 경우 효과를 기대하기 어렵다. 의료영상은 환자의 프라이버시나 윤리적 논란 등으로 인해 대표본을 기대하기 어려운 경우가 많으며, 특히 희귀 질병의 경우 제한적인 소표본 수집이 불가피하다. 따라서 소표본 의료 영상 분석을 위한 효과적인 딥러닝 기법이 필요하다.

전이학습(transfer learning)은 데이터셋 학습에 널리 사용되는 방법으로 새로운 데이터셋의 학습을 위해 기존의 선학습 모델(pre-trained model)을 활용한다.[1] 실제로 데이터셋을 scratch로 학습시키는 일은 드물며 충분히 큰 데이터셋을 이용하여 학습된 모델을 특징(feature)의 초기화 과정에 사용함으로써 scratch로 학습할 때 보다 소표본 데이터를 더 효율적으로 학습할 수 있게 한다[2].

Shin[3]은 ImageNet으로 학습된 모델을 이용하여 Fine tuning 기법으로 전이학습 모델을 구현하였고, 이 모델이 의료용 데이터에 적용될 수 있음을 보였다. 그러나 해당 연구는 대표본 의료 데이터를 기반으로 하고 있어 소표본 의료 영상에는 부적합하다. 또한 표본의 크기가 작고, 미리 학습된 모델과 데이터셋의 속성이 크게 다를 때에는

Feature extractor 기법[2]을 사용하는 것이 일반적이므로 두 기법간의 비교가 필요하다.

소표본 의료 영상의 분석 정확도 향상을 위해 Feature extractor 기법을 적용한 전이학습 모델을 제안한다. 또한 Fine tuning 기법으로 구현된 전이학습 모델과 제안하는 모델을 비교하였고 ImageNet으로 학습된 AlexNet[4], ResNet[5], DenseNet[6] 모델에 제안 기법을 적용하여 소표본 의료 영상 분석 정확도가 향상됨을 확인하였다.

2. 연구 방법

우리의 전이학습 모델은 Fine tuning 기법과 Feature extractor 기법을 사용하여 구현되었다. 본 논문의 제안 기법인 Feature extractor 기법을 적용한 전이학습 모델은 ImageNet으로 학습된 선학습모델의 가중치를 그대로 사용하여 이미지의 특징들을 추출하고, 선학습모델의 마지막 fully connected layer만을 초기화하여 주어진 X-Ray 영상을 학습하도록 했다. 이때 선학습모델에 역전파(back-propagation)가 수행되지 않도록 함으로서 마지막 fully connected layer를 제외한 나머지 네트워크의 가중치는 초기화되지 않고 고정되어 특징을 추출하는 역할을 한다. 반면 Fine tuning 기법은 각 계층에서 역전파가 되도록 하여 선학습모델이 의료 영상에 맞추어 조절되도록 구축하였다.

전이학습 모델을 위한 선학습모델로는 세 개의 CNN 모델 AlexNet, ResNet-152, DenseNet-201을 선택하였으며 전체 네트워크의 구현은 Torch 프레임워크를 사용하였다. train epochs는 40회 수행하여 선학습모델별 전이학습 기법의 정확도를 비교하였고, 학습된 전이학습 모델을 test set에 적용하여 정확도를 측정하였다.

3. 연구 결과 및 분석

본 논문은 폐결핵 보유군과 비보유군의 흉부 X-Ray 영상을 대상으로 실험하였다. 영상은 총 662장으로 폐결핵 보유군 336장, 비보유군 326장으로 구성되었다. 전체 영상은 각기 다른 크기의 3-channel PNG 파일로 이루어졌으나 실험에 사용할 선학습모델의 입력으로 적용하기 위해 224×224로 변환하는 전처리 과정을 거쳤다. 전체 영상 중 training set은 486장, validation set은 44장, test set은 132장으로 구성되었다.

그림 1과 2는 전이학습 기법에 따른 선학습모델별 training loss의 변화를 보여준다. 초기 모델이라 할 수 있는 AlexNet은 Feature extractor로 훈련되었을 때 더 안정적으로 학습되는 모습을 보였고, 더 깊은 모델인 ResNet과 DenseNet은 두 기법에서 모두 안정적으로 학습되는 모습을 보이고 있다.

<표 1> 전이학습 기법에 따른 선학습모델별 test set classification 정확도 비교

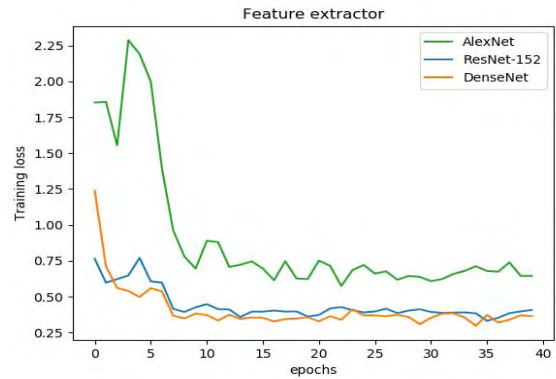
	AlexNet	ResNet-152	DenseNet
Feature Extractor	77%	85%	86%
Fine Tuning	75%	80%	83%

표 1은 학습된 모델들로 test set classification을 수행했을 때의 정확도를 나타낸다. Feature Extractor 기법이 Fine tuning 기법에 비해 2~5% 향상된 성능을 보이고 있으며, 전반적으로 일정수준 이상의 정확도를 확보했음을 알 수 있다.

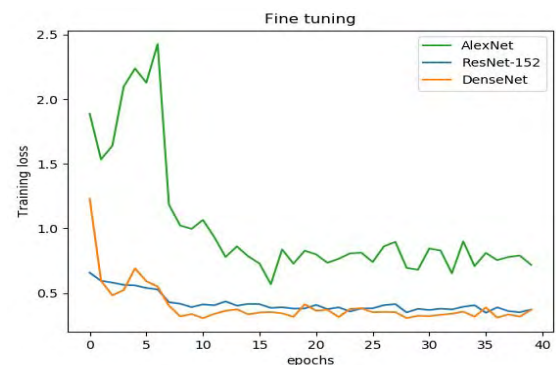
우리의 제안 기법인 Feature extractor는 전반적으로 안정적인 정확도를 확보했으며 이는 Fine tuning보다 높은 수치였다. 또한 네트워크가 비교적 얇은 모델에 대해 Fine tuning보다 더 안정적으로 학습됨을 보였다. 이를 통해 Feature extractor가 소표본 의료 영상에 대해 일정수준 이상의 정확도와 안정성을 보장함을 알 수 있고, 선학습모델에 따라 약간의 편차는 있으나 전체적으로 Fine tuning보다 정확하고 안정적인 기법임을 알 수 있다.

4. 결론

본 논문은 소표본 의료 영상의 분석 정확도 향상을 위해 Feature extractor 기법을 적용한 전이학습 모델을 제안한다. 이 방법의 성능 평가를 위해 AlexNet, ResNet-152, DenseNet-201 모델을 선학습모델로 선정하여 Feature extractor로 구성된 전이학습 모델의 성능을 실험하였고 제안 기법과 기존의 Fine tuning 기법으로 구현된 전이학습 모델의 결과와 비교하여 네 모델 모두에서 2~5% 이상의 성능 향상을 보였으며, 그에 따라 ImageNet로 학습된 모델이 소표본 의료용 X-Ray 영상에 적용될 수 있음을 확인하였다. 이 결과는 소표본의 제약이 있는 의료용 X-Ray 영상을 분석함에 있어 하나의 효율적인 대안이 될 수 있음을 보여준다.



(그림 1) Feature extractor 기법을 적용했을 때의 선학습모델 별 Training Loss 비교



(그림 2) Fine tuning 기법을 적용했을 때의 선학습모델 별 Training Loss 비교

참고문헌

[1] Ian Goodfellow, Yoshua Bengio, Aaron Courville "Deep Learning" MIT Press, 2016.
 [2] Transfer Learning. <http://cs231n.github.io/transfer-learning/>.
 [3] Hoo-Chang Shin, Holger R. Roth et al. "Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning" IEEE Transactions on Medical Imaging, vol. 35, no. 5, May 2016.
 [3] Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks", Advances in Neural Information Processing Systems 25 (NIPS 2012), 2012.
 [4] Kaiming He, Xiangyu Zhang, Shaoqing Ren et al. "Deep Residual Learning for Image Recognition", 2016 IEEE Conference on Computer Vision and Pattern Recognition, 2016.
 [5] Gao Huang, Zhuang Liu, Laurens van der Maaten, Kilian Q. Weinberger, "Densely Connected Convolutional Networks", arXiv:1608.06993, 2016.