

3차원 의료 영상의 영역 분할을 위한 효율적인 데이터 보강 방법

박 상 근*

한국교통대학교 기계공학

An Efficient Data Augmentation for 3D Medical Image Segmentation

Sangkun Park*

Department of Mechanical Engineering, Korea National University of Transportation, Daehak-ro 50,
Chungju-si, Chungbuk 27469, Korea

(Received 2021. 10. 13. / Accepted 2021. 10. 28.)

Abstract : Deep learning based methods achieve state-of-the-art accuracy, however, they typically rely on supervised training with large labeled datasets. It is known in many medical applications that labeling medical images requires significant expertise and much time, and typical hand-tuned approaches for data augmentation fail to capture the complex variations in such images. This paper proposes a 3D image augmentation method to overcome these difficulties. It allows us to enrich diversity of training data samples that is essential in medical image segmentation tasks, thus reducing the data overfitting problem caused by the fact the scale of medical image dataset is typically smaller. Our numerical experiments demonstrate that the proposed approach provides significant improvements over state-of-the-art methods for 3D medical image segmentation.

Key words : deep learning, data augmentation, medical image segmentation, deep neural networks

1. 서 론

최근에 컴퓨터 비전 분야에서 딥러닝 지도학습(supervised learning) 방식에 의한 영상 분할(image segmentation) 방법이 활발히 연구되고 있다. 이러한 흐름 속에 의료 분야에서도 큰 관심과 다양한 연구들이 시도되고 있다. 일반적으로 딥러닝 신경망을 구축하기 위해서는 충분한 데이터셋(라벨 데이터 포함)이 준비되어야 한다. 그런데 의료 분야의 경우엔 이것이 쉽지 않다. 즉 개인 정보 보호 측면에서 충분한 개수의 의료 영상 데이터 확보가 힘들며, 특히 라벨 데이터의 경우엔 전문가의 많은 시간과 비용이 요구되기 때문에 거의 찾아보기 힘들다. 설사 전문가에 의해 라벨 데이터가 만들어졌다 하더라도 전문가들 간의 차이가 존재하며, 또한 영상 측정 장치 간의 차이로 인해 동일

전문가에 의한 결과도 매번 다른 것이 사실이다.

본 연구는 의료 영상 분야에서 이러한 문제점을 극복하고 나아가 딥러닝 신경망의 성능을 높일 수 있는 데이터 증강 방법을 제시하고자 한다. 관련 논문을 살펴보면 다음과 같다. 대부분의 발표 논문들은 일반적인 2D 영상에 관한 것으로,

- 1) 강화학습(reinforcement learning) 방식을 사용하여 데이터 증강 정책(policy)를 탐색하는 기법^{1,2)},
- 2) GAN(generative adversarial networks) 기법을 사용하여 데이터 증강 영상을 직접 생성하는 방법³⁾,
- 3) 비지도학습(unsupervised learning) 방식을 이용하여 증강된 이미지를 생성하는 기법⁴⁾ 등이 있다.

본 연구 방식은 사전에 정의된 데이터 증강 함수를 사용하여, 3D 의료 영상 데이터의 고유 특징⁵⁾을 유지 하면서, 영상 데이터를 직접 수정하는 방식이다. 본 연

*Corresponding author, E-mail: skpark@ut.ac.kr.

구에서 수치 실험을 위해 사용한 딥러닝 라이브러리는 PyTorch⁶⁾이고, 신경망은 3D U-Net⁷⁾이며, 데이터 증강 함수 개발은 TorchIO⁸⁾ 라이브러리를 사용하였다. 본 연구 방식에 관한 자세한 설명은 2장에 있으며, 3장은 수치 실험 및 고찰에 관해 기술하며, 마지막으로 4장에 결론이 있다.

2. 데이터 증강 방법

본 연구에서 사용한 의료 영상 데이터는 IXI⁹⁾ 웹사이트에서 제공하는 의료 영상 데이터셋을 다운받아 사용하였다. IXI 데이터셋에는 T1, T2 및 PD 가중치 영상, MRA 영상 및 확산 가중치 영상 등을 포함하여, 정상적이고 건강한 사람 약 600개의 MR 영상이 포함되어 있다. 뇌 영상을 가지고 실험하기 때문에 NifTI 포맷을 지원하는 NiBabel¹⁰⁾ 라이브러리를 사용하였다.

다운 받은 3D 의료 영상 데이터는 딥러닝 신경망에서 학습을 위해 다음의 데이터 증강 함수들에 의해 변환되고 그 개수가 증가된다. 본 연구에서 개발한 데이터 증강 함수들은 Table 1과 같이 크게 3단계의 순서로 진행되며 각 단계별 증강 함수 세트가 존재한다.

1단계에서 기술한 증강 함수들의 적용 순서는 Table 1에서 기술한 순서와 같다. 3단계의 경우도 마찬가지이다. 그러나 2단계의 경우엔 무작위 순서로 증강 함수가 적용된다. 이는 데이터 분포의 다양성을 증가시키기 위함이다.

참고로 1단계 혹은 2단계의 경우에 무작위 순서로 의료 영상의 특징을 유지하면서 데이터의 다양성 향

상에 큰 효과를 볼 수 없다. 이는 수치 실험을 통해 경험적으로 확인하였다.

한편 본 연구에서 데이터 분포의 다양성 증가를 위해 D, P, M으로 표시한 3개의 파라미터를 설정하였고, 이 파라미터의 조정을 통해 데이터 분포의 다양성을 조정하였고, 또한 이 파라미터의 값이 어떤 상태일 때 계산 정확도가 증가하는지를 비교 평가하였다. 파라미터 D는 데이터셋의 크기를 나타내며, P는 증강 함수의 적용 여부를 판단하는 확률, M은 증강 함수를 통해 3D 영상의 변형 정도를 나타내기 위한 파라미터이다. 각 파라미터별 설정한 값의 의미는 다음과 같다.

- D1: 데이터셋의 크기 = 원본크기 x 1배
- D4: 데이터셋의 크기 = 원본크기 x 4배
- D8: 데이터셋의 크기 = 원본크기 x 8배
- P2: 적용 여부 판단 확률 = 0.2
- P5: 적용 여부 판단 확률 = 0.5
- P8: 적용 여부 판단 확률 = 0.8
- M1: 영상 변환 세기 = (2%, 5도, 0.1배)
- M2: 영상 변환 세기 = (4%, 10도, 0.2배)
- M3: 영상 변환 세기 = (8%, 30도, 0.5배)

여기서 2%, 4%, 8%는 원본 볼륨 크기의 최대 움직임 변화율, 5도, 10도, 30도는 최대 회전 변화량, 0.1배, 0.2배, 0.5배는 최대 배율 변화량을 나타낸다.

한편 본 연구에서 사용한 딥러닝 신경망은 3D U-Net⁷⁾이고, 손실 함수로 Dice Loss를 사용하였으며, 최적화 알고리즘은 AdamW¹²⁾을 사용하였다.

3. 수치 실험

2장에서 기술한 데이터 증강 파라미터 D, P, M을 사용하여 다음과 같은 3D U-Net 신경망 모델을 정의하였고, 각 모델에 MRI 영상과 라벨 영상 데이터셋을 입력하여 신경망을 학습시켰다. MRI 영상의 90%는 training-용도, 10%는 validation-용도로 사용하였다.

- D의 영향력 측정을 위한 신경망 모델
D1-P5-M2, D4-P5-M2, D8-P5-M2
- P의 영향력 측정을 위한 신경망 모델
D4-P2-M2, D4-P5-M2, D4-P8-M2
- M의 영향력 측정을 위한 신경망 모델
D4-P5-M1, D4-P5-M2, D4-P5-M3

Table 1 List of data augmentation functions proposed in this paper

Step	Function Name	Task
1	ToCanonical	RAS좌표계로 변환
	ReSample	같은 간격으로 변환
	CropOrPad	같은 크기로 변환
2	RandomMotion	영상 촬영 시 움직임 효과 추가
	RandomBias	낮은 주파수의 강도 변화 효과 추가
	RandomFlip	좌우/상하 뒤바꿈 변환
	RandomAffine	이동/회전/스케일 변환
	ElasticDeform	영상 왜곡 현상 추가
3	Normalization	강도의 정규 분포화 작업 수행
	Standarization ¹¹⁾	히스토그램 표준화 작업 수행
	RandomNoise	가우시안 노이즈 첨가

Fig. 1은 각 신경망 모델의 훈련 과정을 나타낸 것이다. X축은 반복회수에 해당하는 epoch 회수를, Y축은 손실 값에 해당하는 Dice Loss 값을 나타낸다. 이 그림으로부터 2장에서 기술한 본 연구 데이터 방식의 계산 수렴성에 대해 다음을 확인할 수 있다.

- D가 커질수록 손실 감소율이 크다.
- P의 변화는 수렴 속도에 영향을 주지 못한다.
- M의 변화는 손실 감소율에 큰 영향을 못준다.

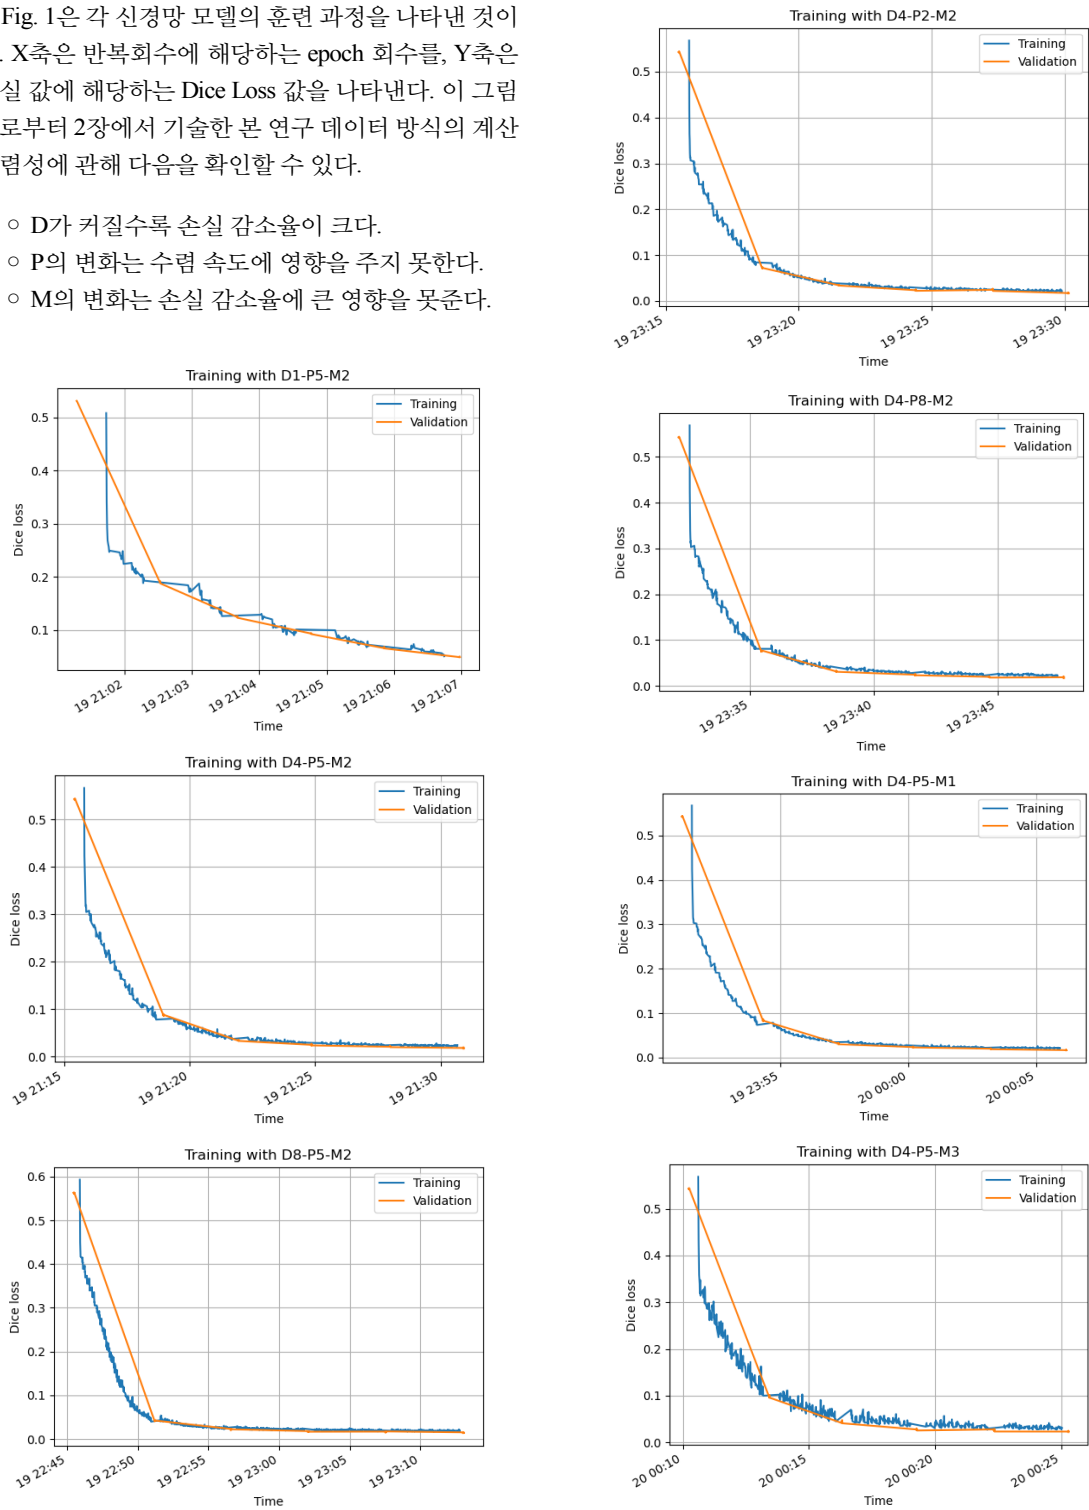


Fig. 1 Training history of deep learning model

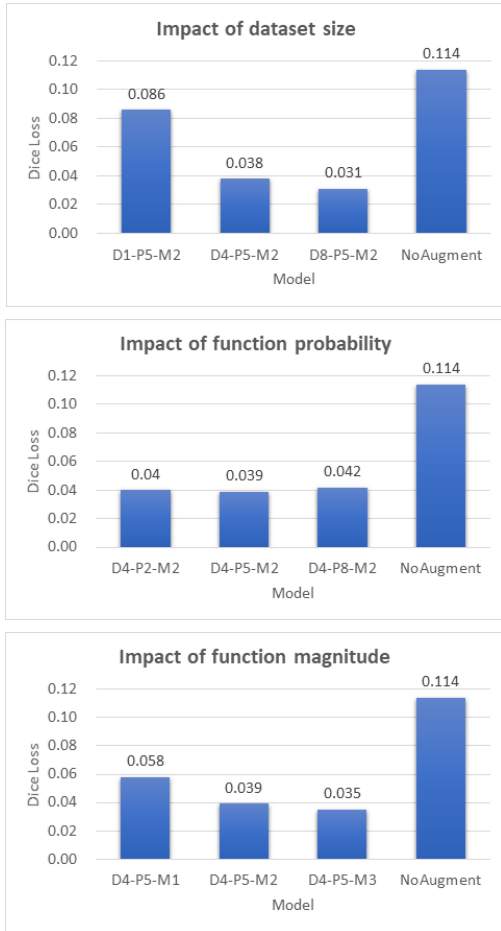


Fig. 2 Impact of augmentation parameters

Fig. 2 (a)는 D의 영향력, (b)는 P의 영향력, (c)는 M의 영향력을 비교한 그래프로서 계산 정확도 측면에서 다음을 확인할 수 있다.

- D의 크기가 클수록 계산 정확도는 증가한다. (D의 변화 시 데이터 다양성은 반드시 보장되어야 한다. D가 클수록 계산 시간은 크게 요구된다.)
- P의 변화가 계산 정확도에 미치는 영향은 작다.
- M의 변화 정도가 클수록 계산 정확도는 증가한다. (M의 변화에서 의료 영상의 특징은 유지되어야 한다. 만약 그렇지 않다면 오히려 학습을 방해하여 계산 정확도를 떨어뜨릴 수 있다.)

Fig. 3은 제시된 신경망 모델 중 계산 정확도가 가장 높은 D4-P5-M3 모델에 의한 예측 결과를 보여준다.

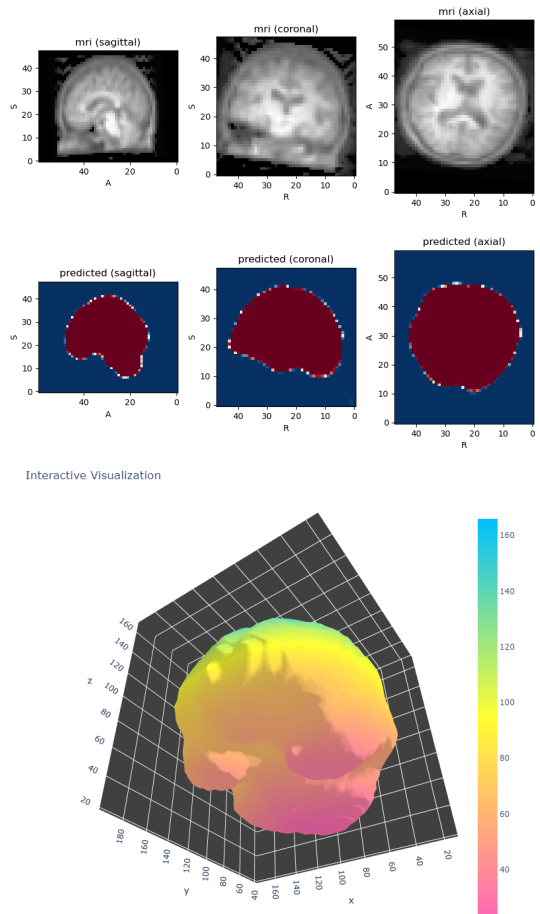


Fig. 3 Predictions of D4-P5-M3 model: (a) predicted slices (b) predicted iso-surface

(a)는 중앙 단면 영상을, (b)는 볼륨 영상으로부터 마칭 큐브 알고리즘에 의해 계산한 경계 곡면을 나타낸 것이다. 이 그림으로부터 본 연구에서 제시한 데이터 증강법의 가능성을 확인할 수 있고, 또한 본 연구에서 구현한 3D U-Net 신경망 모델에 의해 3차원 메시 곡면이 구해짐을 확인할 수 있다.

4. 결론

본 연구는 3D U-Net 신경망을 사용하여 3D 의료 영상 데이터로부터 3D 영상 분할을 수행할 수 있는 데이터 증강 방법을 제시하였다. 이 방법은 특수한 목적의 자료 구조를 사용하지 않으며, 또한 데이터 증강을 위한 추가적인 메모리 사용도 없다. 그리고 신경망 학습 과

정 중에 3D 의료 영상 데이터의 고유한 특징을 유지하면서 의료 영상 데이터를 수정하는 방식이다. 더불어 데이터의 다양성도 제공한다. 본 연구에서 수행한 수치 실험을 통해 얻은 경험을 요약하면 다음과 같다.

- D가 클수록 계산 정확도의 향상에 도움이 된다. 그러나 컴퓨터의 성능을 고려하여 적절한 값을 선택해야 한다.
- P의 변화는 계산 정확도의 개선에 큰 도움을 주지 못한다.
- M이 클수록 데이터 다양성이 증가하여 계산 정확도에 도움이 된다. 그러나 의료 영상 데이터에 내재한 고유 특징이 감소될 수 있음에 주의해야 한다.

Acknowledgement

이 논문은 2021년 한국교통대학교 지원을 받아 수행하였음.

References

- 1) E. D. Cubuk, B. Zoph, D. Mane, V. Vasudevan, and Q. V. Le, "Autoaugment: Learning augmentation strategies from data", In Proceedings of the IEEE conference on computer vision and pattern recognition, 2019.
- 2) S. Lim, I. Kim, T. Kim, C. Kim, and S. Kim, "Fast autoaugment", arXiv:1905.00397, 25 May 2019.
- 3) X. Yi, E. Walia, P. Babyn, "Generative adversarial network in medical imaging: A review", Medical Image Analysis, Vol. 58, 2018.
- 4) Q. Xie, Z. Dai, E. Hovy, M. Luong, Q. V. Le, "Unsupervised Data Augmentation", arXiv:1904.12848, 29 Apr 2019.
- 5) J. Xu, M. Li, and Z. Zhu, "Automatic Data Augmentation for 3D Medical Image Segmentation", arXiv:2010.11695 v2, 27 Dec 2020.
- 6) <https://pytorch.org/>
- 7) Ö. Çiçek, A. Abdulkadir, S. S. Lienkamp, T. Brox, O. Ronneberger, "3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation", arXiv:1606.06650, 21 Jun 2016.
- 8) F. Pérez-García, R. Sparks, S. Ourselin, "TorchIO: a Python library for efficient loading, preprocessing, augmentation and patch-based sampling of medical images in deep learning", arXiv: 2003.04696, 12 Jan 2021.
- 9) <https://brain-development.org/ixi-dataset/>
- 10) https://nipy.org/nibabel/coordinate_systems.html
- 11) L. G. Nyul, J. K. Udupa, X. Zhang, "New variants of a method of MRI scale standardization", IEEE Transactions on Medical Imaging, 19(2), 2000.
- 12) I. Loshchilov, F. Hutter, "Decoupled Weight Decay Regularization", arXiv:1711.05101v3, 4 Jan 2019.