

생성적 적대 신경망 기반 치주염 데이터 생성 및 소스 데이터 구성에 따른 데이터 생성 성능 비교 연구

주재한, 김석찬*

부산대학교, *부산대학교

jhjoo2018@pusan.ac.kr, *sckim@pusan.ac.kr

A Study on the Generation of Periodontitis Data based on Generative Adversarial Networks and Comparison of Performance according to the Composition of Source Data

Jaehan Joo, Suk Chan Kim*

Pusan National Univ., *Pusan National Univ.

요 약

본 논문은 식별자의 목적함수를 최적화한 생성적 적대 신경망 중 하나인 WGAP-GP 모델을 활용하여 직접 촬영한 중증 치주염 영상을 생성하고, 식별자 학습에 사용되는 소스 데이터 구성에 따른 영상 생성 성능을 비교 하였다. 사용한 데이터 셋은 양산부산대학교 치과병원으로부터 제공받은 313장의 데이터를 촬영 방향에 따라 분류하여 2개의 소스 데이터 셋을 구성하였다. 첫 번째 데이터 셋은 촬영 방향을 고려하지 않고 제공받은 모든 영상을 사용하였고, 두 번째 데이터 셋은 정면에서 촬영한 영상만으로 구성하였다. 데이터 수, 데이터 구성을 제외한 모든 학습 파라미터를 동일하게 하여 각 소스 데이터 셋에 대한 치주염 영상을 생성하였고, 정면 방향에서 촬영한 데이터로 식별자를 학습할 때 더 정교한 영상이 생성되는 것을 확인하였다.

I. 서 론

최근 다양한 의료 분야에서 딥러닝을 활용한 진단 방법이 연구되고 있다.[1] 선행된 딥러닝 기반 질병 진단 연구들은 컴퓨터단층촬영(Computed Tomography, CT), 자기공명영상(Magnetic Resonance Imaging, MRI)와 같은 정형화 된 의료 영상을 기반으로 연구가 진행되고 있다.[2 ~ 4] 하지만 질병을 미리 예방하는 문제에 딥러닝 기술을 활용할 경우 앞서 언급한 형태의 데이터는 일반인들이 촬영하기 어렵고, 전문 의료진의 소견이 필요하다는 점에서 한계가 있다. 예방 의학의 관점에서 이러한 문제를 극복하기 위해서는 적은 비용으로 간단하게 촬영할 수 있는 형태의 데이터를 기반의 시스템 설계가 필요하다. 따라서 본 논문에서는 디지털 카메라를 사용하여 직접 촬영한 치주 영상 데이터를 사용한다.

직접 촬영한 이미지 기반의 딥러닝 진단 시스템을 설계할 때 2가지 문제점이 존재한다.

첫 번째 문제점은 수집 가능한 데이터 수가 부족하여 과적합, 클래스 불균형 문제가 발생할 수 있다는 점이다. 딥러닝 모델 학습 및 테스트를 진행하기 위해서는 많은 데이터 수를 필요로 한다. 하지만 임상 환경에서는 수집 가능한 데이터 수에 한계가 있다. 특히 직접 촬영한 영상의 경우 정형화된 의료 영상 대비 개인 식별이 더 쉽기 때문에 개인정보 보호 법에 의해서 수집 가능한 데이터 수가 더 줄어든다.

두 번째 문제점은 직접 촬영한 영상은 정형화 된 의료 영상보다 임상적 유효성을 내포하고 있는 유의미한 특징 값을 추출하기가 어렵다는 점이다. 직접 촬영한 영상은 촬영 장치 및 방법이 표준화 되어 있지 않고, 촬영하는 사람에 따라서 데이터의 형태가 달라진다. 이러한 상황에서 많은 양의 데이터를 수집한다고 하더라도, 실제로 딥러닝 모델 훈련에 사용 가능한 데이터의 수는 매우 부족할 수 있으며, 사용가능한 데이터를 직접 선별해야 하는 과정이 수반된다.

본 논문에서는 이러한 임상 환경의 제약을 고려하여 직접 촬영한 치주

영상 데이터를 생성적 적대 신경망(Generative Adversarial Networks, GANs)을 활용하여 증식 시키고자 한다. 또한 GANs 모델의 식별자(Discriminator) 학습에 사용되는 소스 데이터셋의 구성에 따른 데이터 생성 성능을 비교한다.

II. 본론

본 논문에서는 생성적 적대 신경망 모델 중 하나인 WGAN-GP(Wasserstein GAN-Gradient Penalty) 모델을 기반으로 치주염 데이터 생성 기법에 대하여 연구하였다. 또한 WGAN-GP 모델의 식별자 학습을 위한 소스 데이터 셋의 구성을 2가지로 구분하여 생성 성능을 비교한다.

1. WGAN-GP

GANs은 모델 구조를 최적화 하는 방향과 목적함수를 최적화 하는 방향으로 발전해 왔다. 이 중에서 WGAN-GP는 목적함수를 최적화 한 GANs 모델 중 하나이며, 모델 훈련 과정 중 발생하는 근본적인 문제인 식별자의 경사도가 생성기(Generator)에게 주는 정보가 없다는 문제를 해결하였다. 식 1은 WGAN-GP의 목적함수를 나타낸다. 식 1에 나타난 목적함수는 EM 거리를 목적함수에 사용함으로써 모드붕괴(Mode Collapse) 문제를 완화하였고, 신경망 훈련 시 경사도 패널티를 적용하여 아주 큰 값을 가질 때 발생하는 경사도 손실 문제를 최소화 하였다.[5]

$$L = E_{\tilde{x} \sim P_g}[D(\tilde{x})] - E_{x \sim P_r}[D(x)] + \lambda E_{\tilde{x} \sim P_g}[(\|\nabla_x D(\tilde{x})\|_2 - 1)^2] \quad (\text{식 1})$$

2. 데이터 셋

본 논문에서는 양산부산대학교 치과병원에서 제공 받은 직접 촬영한 치주 영상 데이터를 사용한다. 제공 받은 데이터 셋은 정상 치주 영상, 경증 치주염 영상, 중증 치주염 영상으로 구분된다. 본 논문에서는 질환이 있는 데이터를 생성하기 위해 중증 치주염 영상 만 학습한다.




그림. 1. 촬영 방향에 따른 중증 치주염 영상
(왼쪽부터, 치주 내부, 측면, 정면 촬영)

중증 치주염 영상은 촬영 방향에 따라서 치주 내부 촬영 영상, 측면 촬영 영상, 정면 촬영 영상으로 클래스가 구분 된다. 각 클래스별 데이터 구성은 표 1 과 같고 그림 1은 각 클래스별 샘플 이미지를 나타낸다.

본 논문에서는 식별자 학습을 위한 소스 데이터 셋 구성에 따른 생성 성능을 비교하기 위해서 정면 촬영 영상만 사용한 데이터 셋과 촬영 방향을 고려하지 않은 데이터 셋을 구분하여 사용한다. 정면 촬영 영상만 사용한 데이터 셋은 총 119장의 치주 영상으로 구성되고, 촬영 방향을 고려하지 않은 데이터 셋은 313장의 치주 영상으로 구성된다. 2가지 데이터 셋 모두 324×216으로 영상을 리사이즈(Resize) 하였다.

3. 실험

본 논문에서는 중증 치주염 촬영 영상 데이터 생성을 위해서 2가지 소스 데이터 셋을 기반으로 실험을 진행하였다. 데이터 수와 촬영 방향에 따른 데이터 셋 구성을 제외한 모든 학습 조건은 동일하게 진행하였다. 표 2는 실험에서 사용한 학습 파라미터를 나타낸다.

III. 결론

그림 2는 각 소스 데이터 셋에 대한 에포크(Epoch) 별 생성된 치주 영상을 나타낸다. 좌측은 촬영 방향을 고려하지 않은 소스 데이터 셋으로 생성한 영상이고, 우측은 정면 영상만으로 구성된 소스 데이터 셋으로 생성한 영상이다. 촬영 방향을 고려하지 않은 경우는 에포크가 증가하여도 치주의 형상을 만들지 못하지만, 정면 촬영 영상만 사용한 경우에는 에포크가 증가할수록 정교한 치주 형상을 만드는 것을 확인할 수 있다. 두 가지 소스 데이터 셋에 대한 생성 영상 비교를 통해서 적은 소스 데이터 셋을 기반으로 영상을 생성할 때, 균일한 형태의 소스 데이터 구성이 생성 영상의 품질을 결정하는 것을 확인하였다. 하지만 만들어진 영상이 단순한 치주 영상인지, 치주염을 가지는 영상인지에 대한 추가적인 확인이 불가능하다. 또한 원본 영상 대비 영상의 선명도가 떨어지는 것을 확인할 수 있었다.

표 1. 중증 치주염 영상 데이터 셋
Table1. Severe Periodontitis Image Data set

Severe Periodontitis	Internal	lateral	Frontal
# Data	35	159	119

표 2. 실험 학습 파라미터
Table2. Training Parameter

Parameter	Epoch	Learning rate	batch size
value	800	0.0002	50

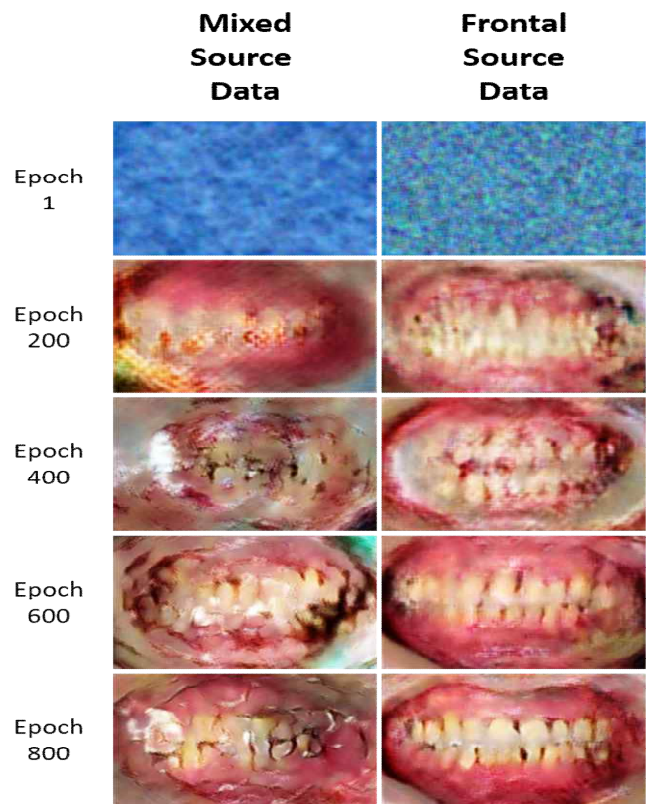


그림. 2. 생성된 중증 치주염 영상

ACKNOWLEDGMENT

본 연구는 2020년도 산업통상자원부의 재원으로 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제(No. 20204030200030)입니다.

이 논문은 국토교통부의 스마트시티 혁신인재육성사업으로 지원되었습니다.

참 고 문 헌

- [1] Shen, D., Wu, G., and H. L. "Deep Learning in medical image analysis," Annual review of biomedical engineering 19, (2017), pp. 221-248.
- [2] KER, Justin, et al. "Deep learning applications in medical image analysis," Ieee Access, June 2017, pp. 9375-9389.
- [3] Lundervol, Alexander S., and Arvid L. "An overview of deep learning in medical imaging focusing on MRI." Zeitschrift für Medizinische Physik 29.2 (2019), pp 102-127.
- [4] Cheng, Jie-Zhi, et al. "Computer-aided diagnosis with deep learning architecture: applications to breast lesions in US images and pulmonary nodules in CT scans," Scientific reports 6.1 (2016), pp. 1-13.
- [5] Gulrajani, Ishaan, et al. "Improved training of wasserstein gans." arXiv preprint arXiv:1704.00028 (2017).