

의료 데이터 복원을 위한 연합 기반 생성적 적대 신경망 설계

김민규¹, 한요섭^{1,2}

¹숭실대학교 정보통신공학과

²숭실대학교 지능형반도체학과

yiki9098@soongsil.ac.kr, yoseob.han@ssu.ac.kr

Collaborative Generative Adversarial Network for Medical Data Restoration

Min Kyu Kim¹, Yoseob Han^{1,2}

¹Department of Information and Telecommunication Engineering, Soongsil University

²Department of Intelligent Semiconductors, Soongsil University

요약

본 연구에서는 부족한 MRI 대비 영상을 생성 및 복원하기 위한 연합 기반 생성적 적대 신경망을 제안하고 최신 기법을 적용하여 복원 성능을 향상시키는 방법을 연구하였다. 제안된 모델은 보유 중인 대비 영상을 활용하여 부족한 대비 영상을 생성함으로써 추가적인 재촬영 없이 의료 데이터의 완전성을 보완한다. 이를 통해 의료 진단 및 분석의 신뢰성을 향상시키고 임상 환경에서의 효율성과 정확도를 높이는 데 기여할 수 있음을 확인하였다.

I. 서론

의료 영상은 질병 진단과 치료 계획 수립에 핵심적인 역할을 하며, 특히 자기공명영상(Magnetic Resonance Imaging, MRI)은 다양한 조직 특성을 비침습적으로 시각화할 수 있어 임상 현장에서 폭넓게 활용된다. MRI는 다양한 위상으로 구성된 다중 모달 영상을 제공하며 각 페이즈는 병변의 구조적·생리적 특성을 상호 보완적으로 나타낸다. 이러한 다중 페이즈를 종합적으로 분석하는 것은 뇌종양이나 척추 질환 등 복잡한 병변의 정확한 진단과 치료 방침 결정에 필수적이다.

그러나 실제 임상 환경에서는 모든 페이즈의 MRI 데이터를 확보하는 데 여러 제약이 존재한다. 긴 촬영 시간으로 인한 환자 불편, 조영제 사용의 제한, 병원 간 상이한 촬영 프로토콜 등으로 인해 특정 페이즈가 누락되는 경우가 빈번하다. 이러한 의료 영상 결손은 영상 기반 진단의 정확성을 저하시킬 수 있으며 분할 작업이나 병변 추적 등의 후속 분석에도 악영향을 미친다. 이를 해결하기 위한 직관적인 접근은 필요한 영상을 재촬영하는 것이지만 이는 시간적·경제적 부담이 크고 환자에게도 추가적인 부담을 초래한다.

이에 따라 최근에는 기존에 확보된 일부 페이즈 영상을 기반으로 누락된 페이즈를 생성하는 데이터 기반 복원 방법이 주목받고 있다. 본 연구에서는 여러 페이즈 간의 상호 관계를 활용하여 결측 MRI 영상을 생성하는 방법으로 다중 입력을 협력적으로 활용하는 생성적 적대 신경망(Collaborative Generative Adversarial Network, CollaGAN)[1] 기반 모델을 제안한다. 제안된 CollaGAN 구조는 최신 기법과 드롭아웃 기반 학습 전략을 도입하여 입력 부족 상황에서도 높은 복원 성능을 유지할 수 있도록 설계하였다.

본 연구의 주요 기여는 다음과 같다. 첫째, 다중 페이즈 입력을 활용한 CollaGAN 기반 구조로 누락된 MRI 페이즈를 효과적으로 복원함으로써

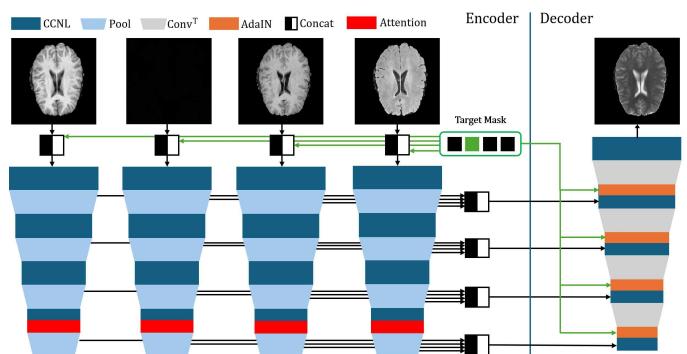


Figure 1 제안하는 모델 아키텍처

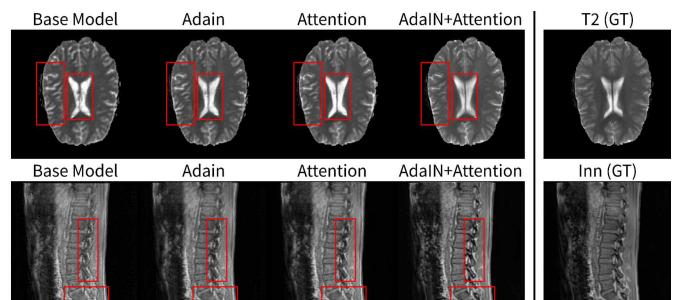


Figure 2 네 가지 모델(Base model, Adain model, Attention model, Adain + Attention model)의 복원 이미지 결과

의료 영상의 완전성을 확보하였다. 둘째, 다양한 페이즈 조합에서의 학습을 가능하게 하는 드롭아웃 기반 학습 전략을 도입하여 모델의 강건성을 향상시켰다. 셋째, AdaIN과 Attention 등 최신 기술을 통합함으로써 복원 성능과 안정성을 동시에 높였으며 임상 환경에서의 실질적 활용 가능성을 제시하였다.

Table 1: Evaluation on Brats2020 Dataset

	T1		T2		T1ce		Flair	
	NMSE↓	SSIM↑	NMSE↓	SSIM↑	NMSE↓	SSIM↑	NMSE↓	SSIM↑
Base Model	0.0431	0.9293	0.0914	0.9092	0.0747	0.9075	0.0628	0.8895
AdaIN	<u>0.0278</u>	0.9331	0.0890	0.9240	0.0712	0.9195	0.0408	0.9138
Attention	0.0295	0.9356	0.0903	0.9225	0.0680	0.9202	<u>0.0325</u>	0.9098
AdaIN + Attention	0.0301	<u>0.9405</u>	<u>0.0835</u>	<u>0.9243</u>	<u>0.0658</u>	<u>0.9240</u>	0.0389	<u>0.9280</u>

Table 2: Evaluation on IVDM3Seg Dataset

	Fat		Wat		Opp		Inn	
	NMSE↓	SSIM↑	NMSE↓	SSIM↑	NMSE↓	SSIM↑	NMSE↓	SSIM↑
Base Model	0.0295	0.8462	0.0764	0.8754	0.0943	0.8502	0.0943	0.8883
AdaIN	<u>0.0278</u>	<u>0.8600</u>	<u>0.0552</u>	<u>0.8843</u>	<u>0.0865</u>	<u>0.8663</u>	0.0902	<u>0.8968</u>
Attention	<u>0.0256</u>	0.8501	0.0608	0.8780	0.0901	0.8522	0.0879	0.8935
AdaIN + Attention	0.0288	0.8498	0.0602	0.8765	0.0865	0.8542	<u>0.0849</u>	0.8894

Figure 3 네 가지 모델(Base model, AdaIN model, Attention model, AdaIN + Attention)의 정량적 평가

II. 본론

기존 CollaGAN 구조에서는 생성기의 인코더 및 디코더에 CCNL(Convolution, Convolution, Normalization, Leaky-ReLU) 유닛을 적용하여 1×1 컨볼루션과 3×3 컨볼루션을 병렬적으로 배치함으로써 국소적 세부 정보와 전역적 구조 정보를 동시에 학습하였다.

또한 디코더 부분에 CCAM(Conditional Channel Attention Module)을 도입하여 입력 도메인 정보를 나타내는 마스크 벡터를 기반으로 각 채널의 가중치를 계산하여 도메인 조건에 적합한 정보만을 강조하고 불필요한 영향을 최소화한다.

$$AdaIN(x, y) = \sigma(y) \cdot \frac{x - \mu(x)}{\sigma(x)} + \mu(y)$$

Equation 1 AdaIN 기법 계산식

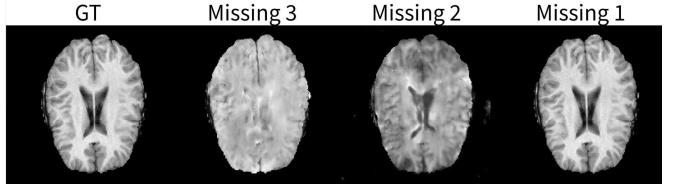
한편, Figure 1는 최신 기법을 적용한 모델 아키텍처를 보여주며 CCAM 대신 AdaIN(Adaptive Instance Normalization)[2]을 채널 어텐션 모듈로 대체하였다. Equation 1과 같은 계산을 통해 입력 특징의 평균과 분산을 조건 벡터의 통계값에 맞추어 정규화함으로써 각 도메인에 적합한 스타일 변환을 구현한다. 아울러 인코더에 Attention Layer[3]를 추가해서 입력 대비 영상 중에서 의미 있는 영역에 집중할 수 있도록 하여 병변과 같은 중요한 정보가 누락되지 않고 복원 과정에서 반영되며 다중 페이즈 간의 상관관계도 효과적으로 학습된다. 또한 드롭아웃 기반 학습 전략을 도입하여 견고성을 높였다. 학습 시 임의로 1개에서 최대 3개의 페이즈를 제거한 채 입력으로 활용하여 입력 부족 상황에서도 높은 복원 성능을 유지할 수 있도록 모델을 학습시켰다.

III. 데이터셋 & 실험

본 연구에서는 제안한 복원 모델의 성능을 평가하기 위해 두 가지 대표적인 의료 영상 데이터셋인 BraTS2020[4]과 IVDM3Seg[5]를 활용하였다. BraTS2020은 뇌종양 분할을 위한 대규모 공개 데이터셋이고 IVDM3Seg는 척추 디스크의 위치 및 분할을 목표로 구축된 비교적 소규모의 데이터셋이며 두 데이터셋 모두 3D 볼륨을 2D 슬라이스 형태로 변환하여 실험에 사용하였다.

제안된 기법의 성능 평가를 위해 기본 CollaGAN(Base model)과 세 가지 개선 모델(AdaIN, Attention, AdaIN+Attention)을 비교하였다. 각 모델은 CCAM을 AdaIN으로 대체하거나 Attention Layer를 추가하여 설계되었으며 두 기법을 결합한 모델도 함께 평가하였다. 또한, 드롭아웃 학습 전략의 적용 유무에 따른 강건성을 실험을 통해 검증하였다.

Drop out 적용 전



Drop out 적용 후



Figure 4 드롭아웃 적용 유무와 손실된 phase 수에 따른 복원 이미지 결과

IV. 결론

Figure 2는 BraTS2020과 IVDM3Seg 데이터셋에서 네 가지 모델(Base, AdaIN, Attention, AdaIN+Attention)의 복원 이미지를 비교한 결과를 보여준다. BraTS2020에서는 Base model이 디테일 재현에 한계를 보인 반면, 개선된 모델들은 GT에 근접한 고품질의 복원 결과를 나타냈으며, 특히 AdaIN + Attention 모델이 가장 우수한 성능을 보였다. IVDM3Seg에서도 모든 개선 모델이 Base model보다 향상된 결과를 보였으며, 정량적 비교는 Figure 3에 제시된 NMSE 및 SSIM 평가를 통해 이루어졌다. BraTS2020에서는 AdaIN과 Attention을 결합한 모델이 가장 뛰어난 성능을 보였으며, IVDM3Seg에서는 AdaIN 단독 모델이 가장 안정적인 결과를 나타냈다. 이는 데이터 규모에 따라 적합한 모델 구조가 달라질 수 있음을 시사한다.

Figure 4는 드롭아웃 적용 유무에 따른 페이즈 손실 상황에서의 복원 성능을 시각적으로 비교한 결과이다. 드롭아웃 미적용 시에는 손실 페이즈가 많을수록 복원 품질이 급격히 저하되었으나 드롭아웃 적용 모델은 손실 수에 관계없이 안정적인 복원을 보여주었다. 이는 다양한 입력 결손 상황에 대한 학습이 모델의 강건성을 높이는 데 효과적임을 입증한다. 종합적으로 제안한 기법들이 기존 CollaGAN 대비 전반적으로 우수한 복원 성능을 보였으며 데이터 특성에 따른 모델 선택과 드롭아웃 기반 학습 전략이 실질적인 효과를 발휘함을 확인할 수 있었다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원-대학ICT연구센터(ITRC)의 지원을 받아 수행된 연구임(IITP-2025-RS-2020-II201602)

참 고 문 헌

- [1] Lee, Dongwook, et al. "CollaGAN: Collaborative GAN for missing image data imputation." Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2019.
- [2] Huang, Xun, and Serge Belongie. "Arbitrary style transfer in real-time with adaptive instance normalization." Proceedings of the IEEE international conference on computer vision. 2017.
- [3] VASWANI, Ashish, et al. Attention is all you need. Advances in neural information processing systems. 2017, 30.
- [4] B. H. Menze, A. Jakab, S. Bauer, J. Kalpathy-Cramer, K. Farahani, J. Kirby, et al. "The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS)", IEEE Transactions on Medical Imaging 34(10), 1993-2024 (2015) DOI: 10.1109/TMI.2014.2377694
- [5] IVDM3Seg dataset. (n.d.). Retrieved from <https://ivdm3seg.weebly.com/>