

확산 모델 역확산 과정에서의 중간 예측 결과를 활용한 의료 영상 분할

한수호¹, 한요섭^{2,3}승실대학교 정보통신공학과¹승실대학교 전자정보공학부²승실대학교 지능형반도체학과³

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

Medical Image Segmentation via Augmentation of Intermediate Predictions from Reverse Process of Diffusion Model

Suho Han¹, Yoseob Han^{2,3}¹Department of Information and Telecommunication Engineering, Soongsil University²Department of Electronic Engineering, Soongsil University³Department of Intelligent Semiconductors, Soongsil University

요 약

이 연구는 확산 모델의 역확산 과정에서의 중간 예측 결과를 영상 분할에 활용한다. 기존 연구가 역확산 과정의 최종 결과만을 활용해 누적 오차와 긴 추론 시간을 초래하는 한계를 보완하기 위해, 단일 역확산 과정에서 얻은 중간 예측 결과를 선택하고 앙상블로 성능을 높였다. 제안하는 방법은 누적 오차를 줄이면서 추론 과정을 단축한다. MoNuSeg 데이터셋 실험에서 분할 성능이 기존 기법보다 향상되고, 추론 시간이 크게 감소해 임상 적용 가능성을 입증했다.

1. 서 론

의료 영상 분할은 의료 영상으로부터 병변이나 장기와 같은 관심 영역을 픽셀 단위로 분리하는 작업으로, 질병의 진단이나 치료 계획 수립에 사용된다. 그러나 대부분 전문의의 수작업에 의존해 시간·비용 부담이 크고, 수행자 간 편차가 크다는 한계가 보고되었다[1].

최근 딥러닝 모델을 활용한 의료 영상 분할에 대한 연구가 활발히 진행되고 있으며, 특히 다양한 분야에서 우수한 성능을 보이는 확산 모델(Diffusion Model)을 활용한 방법이 주목받고 있다. DDPM(Denoising Diffusion Probabilistic Model)[2]을 영상 분할에 적용한 SegDiff[3]는 모든 노이즈 제거 단계를 거친 최종 결과 x_0 만을 분할 마스크에 활용하므로, 순차적인 샘플링 과정에서 누적된 오차가 반영되어 있어 오차가 치명적인 의료 영상 분할에는 적합하지 않다. 또한 확산 모델의 특성상 역확산 과정을 수행하는 데에 긴 시간이 소요되는데, 역확산 과정을 여러 번 수행한 결과의 평균을 사용하는 SegDiff는 기존 연구들보다 수행 시간이 오래 걸린다는 단점을 가지고 있다.

이 연구에서는 역확산 과정 중간 단계에서 얻은 예측 결과 \hat{x}_0 를 활용하여 의료 영상 분할 성능을 높이고 수행 시간을 줄이고자 한

다. 역확산 과정의 모든 과정을 거친 최종 결과 x_0 와 달리 역확산 과정의 중간 과정으로부터 샘플링한 예측 결과 \hat{x}_0 는 무작위 노이즈에 의해 누적된 오차가 상대적으로 적기 때문에 실제 분할 마스크(Ground Truth)와의 차이가 줄어든다. 또한 여러 역확산 과정을 통해 얻은 최종 결과의 평균을 사용하지 않고 한 번의 역확산 과정에서의 중간 결과를 사용하여 분할 마스크를 예측하는 데 드는 시간을 줄였다. 대신에 역확산 과정의 t 회차 중간 결과 \hat{x}_0^t 를 활용한 앙상블 기법으로 분할 성능을 높였다.

여러 종류의 장기 조직을 현미경으로 촬영한 영상으로 구성되어 있는 MoNuSeg[4] 데이터셋을 통해 분할 성능을 검증한 결과, 기존 기법에 비해 높은 성능을 보여주었다.

Method	Dice	mIoU
U-Net	0.7943	0.6599
Res-UNet	0.7949	0.6604
SegDiff	0.8159	0.6900
Ours(Step-78)	0.8221	0.6989
Ours(Step-78~82)	0.8227	0.6998

표 1 MoNuSeg 데이터셋에 대한 분할 성능 비교

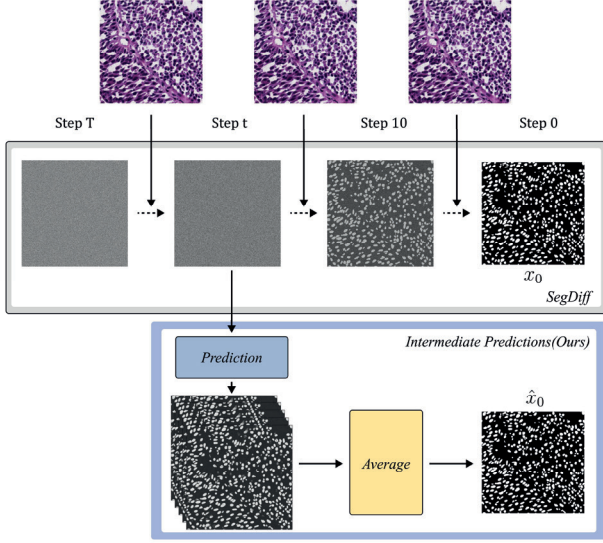


그림 1 확산 모델 역확산 과정 중간 예측 결과 활용 구조도

II. 본론

확산 모델(Diffusion Model)을 활용한 영상 분할

확산 모델은 마르코프 체인으로 정의된 확산 과정과 역확산 과정으로 구성된다. 확산 과정 $q(\cdot)$ 은 입력된 데이터에 대해 노이즈 스케줄 β_t ($1 \leq t \leq T$)를 활용하여 점진적으로 노이즈를 추가한다.

$$q(x_{1:T}|x_0) := \prod_{t=1}^T q(x_t|x_{t-1})$$

$$q(x_t|x_{t-1}) := N(x_t; \sqrt{1-\beta_t}x_{t-1}, \beta_t I)$$

역확산 과정 $p(\cdot)$ 은 확산 과정에서 학습한 노이즈에 대한 정보를 이용하여 노이즈를 목표하는 데이터 분포로 변환한다.

$$p(x_{0:T}) := p(x_T) \prod_{t=1}^T p(x_{t-1}|x_t)$$

$$p(x_{t-1}|x_t) := N(x_{t-1}; \mu_\theta(x_t, t))$$

확산 모델을 영상 분할에 활용하고자 확산 모델의 목표 분포를 분할 마스크로 두고, 분할하고자 하는 이미지 I 를 확산 과정과 역확산 과정의 중간 과정 출력과 결합하여 다음 과정으로 입력한다.

역확산 과정에서의 중간 예측 결과

확산 모델 역확산 과정의 중간 과정($1 \leq t \leq T-1$)에서 중간 예측 결과 \hat{x}_0^t 를 구하는 과정은 다음과 같으며, 전체적인 도출 과정을 그림 1에 정리하였다.

$$\hat{x}_0^t = \frac{x_t - \sqrt{1-\alpha_t}\epsilon_\theta^{(t)}(x_t, I, t)}{\sqrt{\alpha_t}}$$

결과 분석

우선 역확산 과정의 중간 결과 중 분할 성능이 높은 시점을 파악하고자 모든 중간 과정에서의 예측 결과에 대한 성능을 분석하였다. 그림 2는 전체 과정 중 10 개의 결과와 최종 결과를 보여주며, 초반 과정에서의 분할 마스크 예측 결과가 우수함을 알 수 있다.

제안하는 기법의 성능을 검증하기 위해 CNN 기반 모델, ViT 기

반 모델, 확산 모델(SegDiff)과의 분할 성능을 비교한 결과, 표 1에서 78 번째 중간 과정에서의 분할 마스크 예측 결과가 다른 모델 대비 Dice Coefficient와 mIoU(mean Intersection over IoU)가 소폭 증가한 것을 알 수 있다. 또한 78 번째부터 82 번째 중간 과정의 평균 예측 결과가 분할 성능을 소폭 향상시킨 것을 알 수 있다.




그림 2 중간 과정 시점에 따른 분할 마스크 예측 결과 비교

정성적인 분할 성능 분석을 위해 기존 기법과 제안 기법의 오차가 있는 픽셀을 비교한 결과, 기존 기법에 비해 False Positive(FP)의 비율이 현저히 줄어들었다.




그림 3 분할 성능 비교를 위한 오차 픽셀 비교
왼쪽부터 입력 이미지(Image), 정답 마스크(Mask), SegDiff의 예측 결과(SegDiff), 제안 기법의 예측 결과(Ours)
False Positive(초록색), False Negative(빨간색)

III. 결론

이 연구에서는 무작위 노이즈에 의해 누적된 오차가 상대적으로 적은 확산 모델 역확산 과정의 중간 예측 결과를 활용하여 영상 분할을 수행하였다. 기존 기법 대비 분할 성능 향상을 보였다. 추후 연구를 통해 개선된 기법과 다양한 데이터셋에 대한 특성을 반영할 예정이다.

ACKNOWLEDGMENT

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

참고 문헌

- [1] Schmidt A., "Probabilistic Modeling of Inter- and Intra-observer Variability in Medical Image Segmentation", Proceedings of the IEEE/CVF international conference on computer vision, pp. 21097-21106, 2023.
- [2] Jonathan H., "Denoising Diffusion Probabilistic Models", Advances in neural information processing systems 33, pp. 6840-6851, 2020.
- [3] Amit T., "Segdiff: Image segmentation with diffusion probabilistic models.", arXiv preprint arXiv:2112.00390, 2021.
- [4] Kumar, A. "A multi-organ nucleus segmentation challenge.", IEEE transactions on medical imaging 39.5, pp. 1380-1391, 2021.