

손실함수의 연산 도메인에 따른 희소뷰 CT 영상의 복원 품질에 관한 연구

김민규¹, 한요섭^{1,2}

¹ 숭실대학교 전자정보공학부

² 숭실대학교 지능형반도체학과

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

A Study on the Reconstruction Quality of Sparse-View CT According to the Computation Domain of the Loss Function

Min Kyu Kim¹, Yoseob Han^{1,2}

¹School of Electronic Engineering, Soongsil University

²Department of Intelligent Semiconductors, Soongsil University

요약

본 논문은 인공지능망을 활용하여 희소뷰 CT (sparse-view CT) 영상을 복원함에 있어, 일반적으로 사용되는 영상 도메인 (image domain) 에서 손실함수를 연산보다, 투영 도메인 (projection domain) 에서 손실함수를 연산하는 것이 복원된 CT 영상의 품질이 우수하다는 것을 검증하였다. 더 나아가, 동일한 데이터셋과 인공지능망 구조를 기반으로 학습이 되었음에도 불구하고, 손실함수의 연산 도메인을 영상 도메인에서 투영 도메인으로 변경하는 것만으로도 일반화 (generalization) 측면에서 더욱 우수한 성능을 보여주는 것을 확인하였다.

I. 서론

X 선 단층 촬영 영상 (X-ray computed tomography; X-ray CT) 은 고속 및 고해상도의 의료영상 촬영 장비 중 하나이다. 하지만, X 선을 활용하는 촬영 방식으로 인한 촬영을 하는 실험자 및 촬영을 받는 피실험자 에게 방사선 피폭 (radiation exposure) 을 일으킨다[1]. 이를 해결하기 위해, 많은 연구자들은 방사선 피폭량을 줄일 수 있는 다양한 X 선 단층 촬영 영상 시스템을 구축하였으며, 크게 3 가지로 구분된다[2]. (1) X-ray 소스가 방출하는 X 선의 강도를 감소시킨 저선량 CT (low-dose CT), (2) X 선 단층 촬영로 획득하는 데이터의 수를 감소시킨 희소뷰 CT (sparse-view CT), (3) X 선 단층 촬영을 수행하는 관심영역을 감소시킨 관심영역 CT (region-of-interest CT). 하지만, 방사선 피폭량을 줄이기 위해 고안된 X 선 단층 촬영 시스템에 의해 획득된 데이터를 해석적 복원 기법인 filtered backprojection (FBP) 기법을 통해 복원하면, 부족한 정보량으로 인해 심각한 영상의 열화가 발생하게 된다.

불완전한 획득 데이터로 인한 영상의 열화를 제거 또는 고품질의 영상을 복원하기 위해, 전통적으로 모델 기반 반복적 복원 기법 (Model-Based Iterative Reconstruction; MBIR) 이 활용되었다.

하지만, 반복적 복원 기법의 경우, X 선 단층 촬영 영상 시스템의 수학적 연산자인 투영 연산자 (projection operation) 와 역투영 연산자 (backprojection operation) 을 반복적으로 계산해야만 한다.

하지만, 투영 연산자와 역투영 연산자의 높은 연산량으로 인하여, 긴 복원 시간이 걸리지만 복원된 영상의 품질이 매우 뛰어나지 못했다.

최근 인공지능망 (artificial neural network) 기술은 많은 분야에서 우수한 성능으로 보여주고 있으며, 의료영상 복원 분야에서도 뛰어난 두각을 보이고 있다. 무엇보다, 인공지능망을 활용한 의료영상 복원 알고리즘은 복원 속도가 빠름에도 불구하고 우수한 복원 성능으로 인해 많은 연구가 활발히 진행되고 있다. 특히, 대부분의 인공지능망을 활용한 복원 연구는 영상 도메인에서의 수행되고 있으며, 인공지능망을 학습하기 위해 활용되는 손실 함수 (loss function, objective function) 또한 영상 도메인에서 L1 또는 L2 loss 를 대부분 활용하고 있다.




Figure 1 영상 도메인의 인공지능망.

본 연구는 동일한 데이터[3]와 인공지능망 구조[4]에서 손실함수의 연산 방식, 특히, 연산 도메인에 따른 복원 성능을 비교해 우수한 손실함수의 연산 방식을 제안한다.

II. 본론

Figure 2 은 고정된 영상 도메인 인공지능망 구조에서 파생된 다양한 학습 방식과 손실 함수의 계산 방식을 보여준다. 특히, Figure 2(a-b) 는 영상 도메인에서 손실 함수가 계산되지만, (a) 는 영상 자체를 학습하는 방식인 plain (or standard) 학습 방식이며, (b) 는 에러를 학습하는 방식인 residual 학습 방식을 보여준다. 반면, Figure 2(c-d) 는 투영 도메인에서 손실 함수를 계산하는 방식으로, 인공지능망 (Q_{img}) 에 의해 복원된 영상을 투영 연산자 (R) 과 필터 연산자 (F) 를 사용하여 투영 데이터로 변환하는 과정이 수행되며, 손실 함수는 해당 투영 도메인에서 계산된다. 여기서, (c) 는 투영 영상 자체에 대해 손실을 구하는 plain 학습 방식이며, (d) 는 획득된 원본 데이터를 치환하는 제약 조건인 consistency term 이 반영된 학습 방식이다. 아래의 수식 (1-4) 는 Figure 2(a-d) 에 명시된 인공지능망을 학습하기 위해 사용된 손실 함수를 나타낸다.

$$\mathcal{L}_{(img, plain)} = \operatorname{argmin}_{Q_{img}} \sum_i \|x - Q_{img}(x_s)\|^2$$

Equation 1 Image-domain loss with plain learning (see Figure 2(a))

$$\mathcal{L}_{(img, residual)} = \operatorname{argmin}_{Q_{img}} \sum_i \|x - (x_s - Q_{img}(x_s))\|^2$$

Equation 2 Image-domain loss with residual learning (see Figure 2(b))

$$\mathcal{L}_{(prj, plain)} = \operatorname{argmin}_{Q_{img}} \sum_i \|y - \mathcal{F}(\mathcal{R}(Q_{img}(x_s)))\|^2$$

Equation 3 Projection-domain loss with plain learning (see Figure 2(c))

$$\mathcal{L}_{(prj, consistency)} = \operatorname{argmin}_{Q_{img}} \sum_i \|y - (\mathcal{M}y_s + (1 - \mathcal{M})\mathcal{F}(\mathcal{R}(Q_{img}(x_s))))\|^2$$

Equation 4 Projection-domain loss with consistency learning (see Figure 2(d))

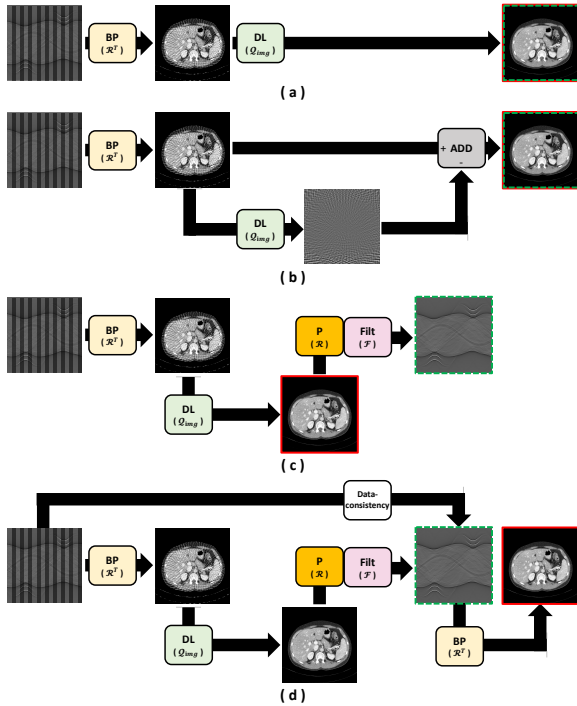


Figure 2 (a) plain 학습 또는 (b) residual 학습 기반 영상 도메인 인공지능망 구조. (c) plain 학습 또는 (d) consistency 학습 기반 투영 도메인 인공지능망 구조. 빨간 실선 박스는 복원된 영상이며, 초록 점선 박스는 손실함수 연산 시 사용된 데이터.

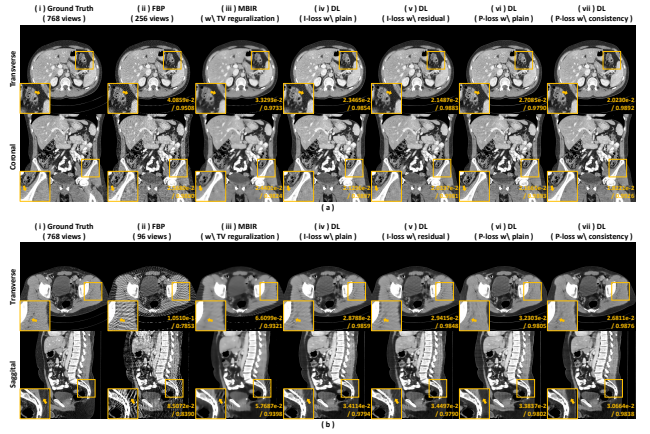


Figure 3 (a) DS = 3 또는 (b) DS = 6 인 최소부 CT 에 대해 다양한 손실함수에 의해 복원된 결과. 오른쪽 하단엔 NRMSE/SSIM 이 적혀 있음.

III. 결론

Figure 3 는 다양한 최소부 CT 에 따른 복원 결과를 보여준다. 반복적 복원 기법인 MBIR 기법은 최소하게 획득된 투영 영상에 의해 발생한 심각한 선형 잡음을 강하게 제거함으로 인해, X-ray CT 영상의 질감마저 제거하였다. Figure 3(iv-vii) 는 다양한 학습 기법과 손실 함수의 연산 도메인에 따른 결과를 보여준다. (iv-v) 는 영상 도메인에서 손실 함수를 연산한 인공지능망의 결과를 보여주며, 해당 복원 결과엔 선형 잡음이 남아 있다. 반면, (vi-vii) 는 (iv-v) 와 동일한 환경에서 손실 함수만을 투영 도메인에서 계산하여 학습한 인공지능망에 대한 결과이다. (v) 데이터 치환 제약을 활용한 투영 도메인 손실함수를 통해 학습된 인공지능망 구조가 다양한 최소부 CT 에서 우수하게 선형 잡음을 제거하며, peak signal to noise ratio (PSNR) 과 structural similarity index measure (SSIM) 과 같은 다양한 정량적 평가 지표 (Table 1 을 참고) 에 대해 다른 복원 기법들보다 뛰어난 성능을 보여준다.

Table 1 다양한 손실함수에 따른 (a) PSNR 및 (b) SSIM 기반 정량적 평가. I-loss 와 P-loss 는 각각 Image-domain loss 와 Projection-domain 를 의미함.

(a) PSNR [dB]	FBP (768 views)	MBIR (data-fidelity w/ TV reg.)	DL (I-loss w/ plain)	DL (I-loss w/ residual)	DL (P-loss w/ plain)	DL (P-loss w/ consistency)
DS = 2	43.8766	45.3438	45.1113	46.0363	41.9625	47.0810
DS = 3	37.5167	39.9657	43.3526	43.7071	41.2416	44.2701
DS = 4	33.9806	37.4422	41.9985	42.1607	40.6018	42.7751
DS = 6	29.9290	34.0616	40.2454	40.1494	39.4581	40.8848
DS = 8	27.5043	32.0263	38.9080	38.6853	38.6922	39.4378
(b) SSIM	FBP (768 views)	MBIR (data-fidelity w/ TV reg.)	DL (I-loss w/ plain)	DL (I-loss w/ residual)	DL (P-loss w/ plain)	DL (P-loss w/ consistency)
DS = 2	0.9866	0.9925	0.9934	0.9946	0.9846	0.9953
DS = 3	0.9442	0.9764	0.9901	0.9911	0.9811	0.9921
DS = 4	0.8884	0.9605	0.9867	0.9877	0.9785	0.9891
DS = 6	0.7873	0.9295	0.9815	0.9818	0.9751	0.9834
DS = 8	0.7113	0.9005	0.9768	0.9763	0.9717	0.9781

참고 문헌

- [1] Shah, N. B., "ALARA: is there a cause for alarm? Reducing radiation risks from computed tomography scanning in children," Current opinion in pediatrics, 2008.
- [2] Nuyts, J., "Modelling the physics in the iterative reconstruction for transmission computed tomography," Physics in Medicine & Biology, 2013.
- [3] C McCollough, "Overview of the low dose ct grand challenge," Medical physics, 2016.
- [4] Ronneberger, O., "U-net: Convolutional networks for biomedical image segmentation," In Medical Image Computing and Computer-Assisted Intervention- MICCAI 2015, 2015.