

전산화 단층 영상의 물리 함수 기반 크로스-도메인 인공지능망을 활용한 저선량 CT 영상의 복원에 관한 연구

이요셉^{2*}, 이건우^{1*}, 한요섭^{1,3}

¹ 숭실대학교 전자정보공학부

² 숭실대학교 정보통계보험수리학과

³ 숭실대학교 지능형반도체학과

dytpq0916@soongsil.ac.kr, woo5034@soongsil.ac.kr, yoseob.han@ssu.ac.kr

CT Physics-based Cross-domain Deep Learning for Low-dose CT Reconstruction

Joseph Lee^{2*}, Gun Woo Lee^{1*}, Yoseob Han^{1,3}

¹School of Electronic Engineering, Soongsil University

²Statistics and Actuarial Science, Soongsil University

³Department of Intelligent Semiconductors, Soongsil University

요약

본 논문은 펼쳐진 인공지능망 (unrolled network) 을 사용함에 있어 동일한 도메인의 인공지능망 만을 사용하는 것보다, 상이한 도메인의 인공지능망을 사용하는 것이 좋다는 것을 실험적으로 검증하였다. 더 나아가, 펼쳐진 인공지능망은 하나의 인공지능망으로 통합하기 위하여, 전산화 단층 영상의 물리 함수를 포함하는 새로운 형태의 인공지능망을 제안하였으며, 이는 저선량 CT 영상의 복원에서 펼쳐진 신경망보다 우수한 성능을 보임을 확인하였다.

I. 서론

X 선 단층 촬영 영상 (X-ray computed tomography; X-ray CT) 또는 자기 공명 영상 (Magnetic Resonance Imaging; MRI) 와 같은 의료 영상 장비는 획득 데이터 (measurements) 의 도메인과 영상 데이터 (images) 의 도메인이 서로 상이한 경우가 많다. X-ray CT 장비의 경우, 획득 데이터의 도메인이 투영 도메인 (projection-domain) 인 반면, MRI 장비는 주파수 도메인 (k-space, Fourier-domain) 에서 데이터를 획득한다. 이처럼, 영상 도메인에 존재하지 않는 획득 데이터는 의사가 분석 및 진단할 수 있는 영상 데이터로 전환하기 위하여 역변환 연산자 (Inverse operation) 를 사용한다. 특히, X-ray CT 의 획득 데이터인 투영 영상을 영상으로 변환하기 위해선 역투영 연산자 (Backprojection operator) 가 활용된다. 하지만, Figure 1 (b) 와 같이 획득 데이터가 잡음에 의해 변질된 경우, 역투영 연산자에 의해 복원된 영상은 심각한 영상 열화가 발생할 수 있으며, 이는 의사가 오진을 수행할 위험을 증가시킨다.

열화가 발생한 영상을 복원하기 위하여, 전통적으로 CT 시스템의 수학적 모델을 활용하여 최적화 문제를 해결하는 방식인 모델 기반 반복적 복원 (model-based iterative reconstruction; MBIR) 이 활용되었지만, 반복적인 CT 시스템 연산자를 활용한다는 점에서 느린 복원 속도를 갖는다는 단점이 있다.

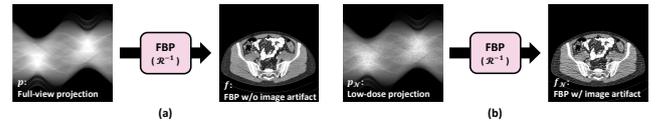


Figure 1 (a) 완전한 투영 영상 및 (b) 불완전한 투영 영상에 의해 복원된 영상.

최근 인공지능망은 의료 영상 복원 분야에도 도입이 되었으며 매우 우수한 영상의 복원 속도와 품질을 보여주었다. 무엇보다도, 인공지능망은 우수한 복원 성능을 보임에도 신경망 구축이 직관적이며 간편하여 현재까지도 많은 연구가 활발히 수행되고 있다. 최근, 의료영상의 복원 성능을 향상시키기 위한 연구 방향으로써, 펼쳐진 인공지능망을 활용하는 연구가 있다[1]. Figure 2 는 영상 도메인에서 펼쳐진 인공지능망을 보여준다. 연속된 인공지능망을 전통적인 반복적 복원 기법의 프로세스와 유사하게 점진적으로 영상의 복원 품질을 개선한다. 하지만, 동일한 도메인에서 펼쳐진 인공지능망을 DCF 이론의 행렬 계수 관점에서 유의미한 성능 향상을 기대하기 어렵다[2].

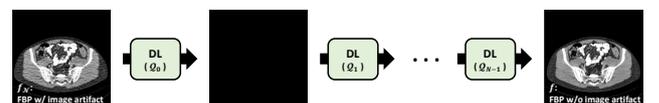


Figure 2 펼쳐진 영상 도메인 인공지능망 구조.

*These authors contributed equally to this work.

따라서, 본 연구는 단일 인공신경망에서 상이한 도메인에서의 펼쳐진 인공신경망을 구현하기 위해, 인공신경망 내부에 X-ray CT 시스템 연산자인 역투영 연산자를 배치시킴으로써 입력 데이터 도메인은 투영 도메인, 그리고 출력 데이터 도메인은 영상 도메인으로 설정된 단일 인공신경망을 제안한다.

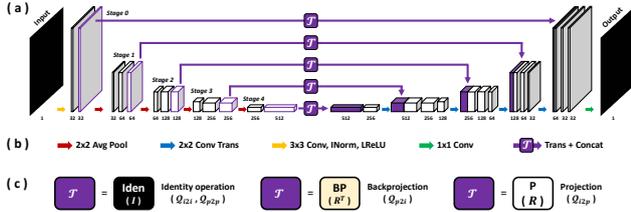


Figure 3 (a) 제안하는 인공신경망의 구조, (b) 인공신경망에서 사용된 모듈, (c) 입출력에 따른 변환함수 T 에 사용된 연산자.

II. 본론

Figure 3 은 제안된 인공신경망의 구조를 나타낸다. 인공신경망의 구조는 U-Net 의 구조[3] 의 일반화된 형태를 따르며, 입력과 출력 도메인에 따라 변환함수 T 의 연산자가 달리 정의된다. 기본적인 U-Net 을 사용하는 방식과 같이, 입출력 도메인이 동일하다면 변환함수 T 는 항등 함수 (identity function) 로 정의된다. 하지만, 제안하는 인공신경망은 입력 도메인은 투영 도메인이며 출력 도메인은 영상 도메인이기 때문에 변환함수 T 를 역투영 연산자로 정의하였다.

Figure. 4 은 전산화 단층 영상의 물리 함수가 적용된 인공신경망 Q_{p2i} 이 반영된 전체적인 모식도를 보여준다. 전체 투영 영상은 제안된 단일 크로스-도메인 인공신경망의 입력으로 전달되며, 인공 신경망의 출력으로 입력된 투영 영상과 상이한 도메인인 영상 도메인의 결과가 출력된다. 최종적인 복원 결과는 열화된 영상과 인공신경망의 차분으로 결정된다. 제안된 인공신경망 Q_{p2i} 는 아래의 목적함수를 최소화 시킴으로써 학습된다.

$$\mathcal{L}_{p2i} = \operatorname{argmin}_{Q_{p2i}} \sum_i \left\| f^i - (f_N^i - Q_{p2i}(p_N^i)) \right\|^2$$

이때, f 는 원본 영상 데이터이며 p_N 은 열화된 투영 데이터이다. 제안된 인공신경망을 학습하기 위해, 미국 의료 물리학회 (AAPM) [4] 에서 제공된 10 개의 환자 데이터를 활용했다. 특히, 9 명 중 8 명은 훈련, 1 명은 검증용을 위해 활용되었으며, 나머지 1 명은 테스트를 위해 활용되었다.

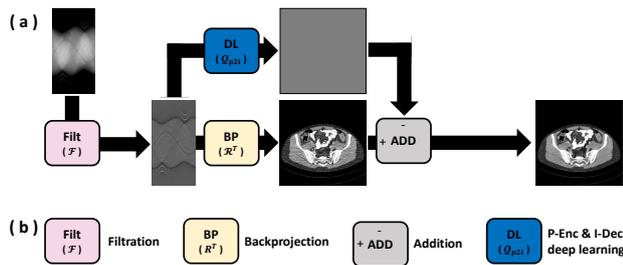


Figure 4 (a) 전산화 단층 영상의 물리함수 기반 인공신경망 구조, (b) 사용된 연산자.

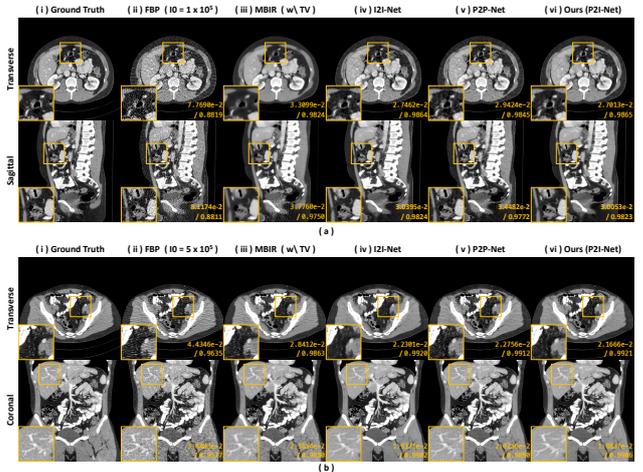


Figure 5 10 가 (a) 1×10^5 또는 (b) 5×10^5 인 저선량 CT 에 대해 다양한 기법에 의해 복원된 결과. 오른쪽 하단엔 NRMSE/SSIM 이 적혀 있음.

III. 결론

Figure 5 는 다양한 저선량 상황에 따른 복원 결과를 보여준다. 반복적 복원 기법인 MBIR 기법은 저선량 X-ray source 에 의해 발생한 영상 잡음을 강하게 제거함으로 인해, X-ray CT 영상의 질감마저 제거하였다. 하지만, 인공신경망 기반의 I2I-Net 과 P2P-Net 은 CT 영상의 질감은 남아있을 뿐만 아니라, 영상 잡음도 깨끗하게 제거하지 못했다. 하지만, 제안된 인공신경망의 경우, transverse 면 뿐만 아니라, sagittal 및 coronal 면에서도 가장 뛰어난 복원을 보여주었다. 아래의 Table 1 에서 알 수 있듯이, 제안한 인공신경망 구조인 P2I-Net 은 peak signal to noise ratio (PSNR) 과 structural similarity index measure (SSIM) 과 같은 다양한 정량적 평가 지표에 대하여 다른 복원 기법들보다 뛰어난 성능을 보여준다.

Table 1 다양한 저선량 상황에 따른 (a) PSNR 및 (b) SSIM 기반 정량적 평가.

(a) PSNR [dB]	FBP (768 views)	MBIR (w/ TV)	I2I-Net (I-dom.)	P2P-Net (P-dom.)	P2I-Net (Proposed)
1.0×10^5	32.4398	39.2765	41.8375	41.1701	42.1107
2.5×10^5	36.5052	40.9881	43.4600	43.0224	43.7103
5.0×10^5	39.6209	41.8857	44.7531	44.4914	44.9922
1.0×10^6	42.6685	42.4006	45.9404	46.0930	46.4105
(b) SSIM	FBP (768 views)	MBIR (w/ TV)	I2I-Net (I-dom.)	P2P-Net (P-dom.)	P2I-Net (Proposed)
1.0×10^5	0.8804	0.9803	0.9876	0.9854	0.9882
2.5×10^5	0.9448	0.9851	0.9907	0.9896	0.9912
5.0×10^5	0.9713	0.9857	0.9927	0.9921	0.9931
1.0×10^6	0.9854	0.9867	0.9945	0.9943	0.9948

참고 문헌

- [1] Eo, T., "KIKI-net: cross-domain convolutional neural networks for reconstructing undersampled magnetic resonance images," Magnetic resonance in medicine, 2018.
- [2] Ye, J. C., "Deep convolutional framelets: A general deep learning framework for inverse problems," SIAM Journal on Imaging Sciences, 2018.
- [3] Ronneberger, O., "U-net: Convolutional networks for biomedical image segmentation," In Medical Image Computing and Computer-Assisted Intervention- MICCAI 2015, 2015.
- [4] C McCollough, "Overview of the low dose ct grand challenge," Medical physics, 2016.