

# X-ray 영상에서 그리드 아티팩트 제거를 위한 복합형 기법

김혜원\*, 김경우\*\*, 김형규\*\*, 정중은\*\*, 박준혁\*, 김동현\*, 김호준\*

\*한동대학교 전산전자공학부

\*\*주식회사 제이피아이헬스케어

e-mail : 21700206@handong.edu

## A Hybrid Approach for Grid Artifacts Suppression in X-ray Image

Hyewon Kim\*, Kyongwoo Kim\*\*, Hyunggyu Kim\*\*, Joongeun Jung\*\*, Joonhyuk Park\*, Donghyun Kim\*, Hojoon Kim\*

\*Dept. of Computer Science and Electrical Engineering, Handong Global University

\*\*JPI Healthcare Co., Ltd

### 요약

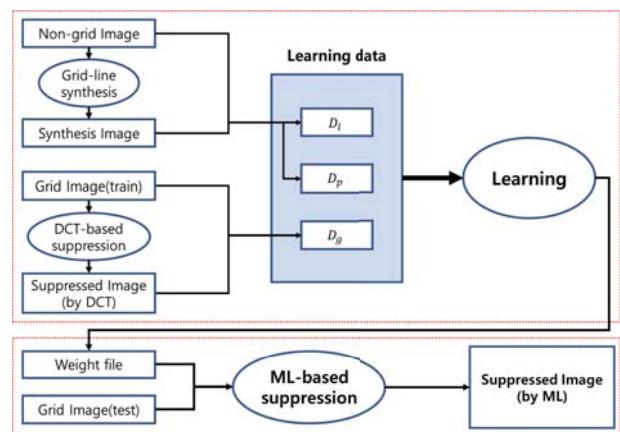
본 연구에서는 X-ray 영상에서 비산란 그리드 장치의 영향으로 인한 아티팩트를 제거하기 위하여 이산코사인변환(DCT: discrete cosine transform) 기반의 주파수 분석 기법과 딥러닝 네트워크의 학습 기법을 상호 보완적으로 결합하는 방법론을 제안한다. 피사체의 특성에 따라 다양하게 나타나는 그리드 라인의 억제 기능을 학습하기 위하여 서로 다른 특성을 반영하는 3 종류의 학습데이터를 생성한다. 학습에 사용되는 그리드 라인 영상의 타겟 데이터를 산출하기 위하여 DCT 기반의 밴드스톱 필터링 기법을 사용하였으며 학습데이터의 양적인 부족을 해결하기 위하여 폐치 기반의 학습 방법을 적용하였다. 제안된 방법에 대해 기존의 방법과 비교하여 피사체 경계선 영역에서 발생하는 성능저하 현상, 분할의 가장자리에서 발생하는 블로킹 현상, 배경 영상에서의 성능저하 현상 등을 상대적으로 개선할 수 있음을 실험적으로 평가하였다.

### 1. 서론

최근 들어 의료 영상처리 분야에서 딥러닝 기법을 활용하는 다양한 방법의 연구가 시도되고 있다[1-3]. 예로서, 컴퓨터 단층촬영 영상에서 특정 부위나 병변을 검출하는 문제를 위한 학습 모델 연구[1-2], 생물 의학 영상에서 영역 분할을 위한 딥러닝 네트워크 모델[3]이 연구되었으며, 영상의 노이즈를 제거하고 왜곡을 보정하는 문제에 대한 딥러닝 기법이 다양하게 제안되고 있다[4-5].

X-ray 진단 장비에 사용되는 그리드 장치는 산란선으로 인한 영상 왜곡을 보정할 수 있는 장점이 있는 반면, 영상에 반복되는 라인 형태의 아티팩트를 발생시키는 단점을 수반한다. 본 연구에서는 이러한 그리드 라인을 제거하기 위하여 주파수 분석 기반 기법과 딥러닝 기법을 상호 결합하는 방법을 고찰한다. X-ray 영상의 그리드 라인 제거를 위한 딥러닝 네트워크의 개발과정에서 어려운 점은 학습데이터의 구성 문제이다. 실제 촬영된 X-ray 영상만으로 일반화된 성능을 기대할만한 학습데이터를 구성하기가 어렵다는 점과 학습을 위하여 임의의 그리드 라인 영상에 대한 타겟 데이터를 정확하게 생성할 수 없다는 점이 문제점으로 지적된다. 이에 본 연구에서는 그리드 제품 모델의 규격과 연관하여 인위적 합성으로 학습데이터를

생성하는 방법과 이산코사인변환(DCT: discrete cosine transform) 기반의 영상 개선 과정을 적용하여 학습데이터를 생성하는 기법을 상호 결합하는 방안을 채택하였다. (그림 1)에 보인 바와 같이 인위적으로 그리드 라인을 생성한 두 종류의 학습데이터와 DCT 기반 기법을 적용한 학습데이터를 이용하여 학습이 이루어진다.

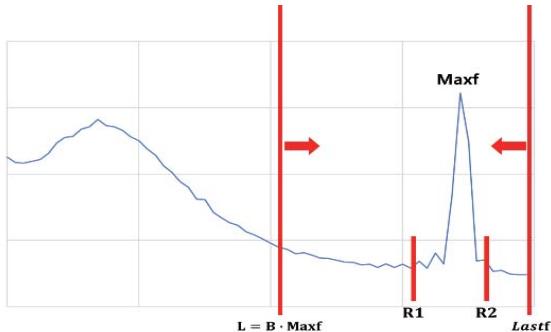


(그림 1) X-ray 영상의 그리드 라인 제거를 위한 딥러닝 기법

학습 네트워크로는 U-Net[3], DnCNN[6] 및 N<sup>3</sup>Net[7]을 사용하였으며, 학습데이터 구성의 조합 및 손실함수(loss function)의 설정은 다수의 실험을 통하여 최적화하였다. 제안된 기법의 성능 분석을 위하여 DCT 기반의 밴드스톱필터링 기법을 구현하고 결과를 비교 분석하였다.

## 2. 그리드 라인 제거를 위한 복합형 기법

X-ray 영상에서 전형적인 그리드 라인의 형태가 일정 주기로 반복된다는 점에서 DCT 변환을 이용한 밴드스톱필터링을 적용하였다. (그림 2)에 예시한 바와 같이 DCT 변환을 적용한 주파수 영역의 데이터에 대하여 그리드 라인에 해당하는 대역을 검출하고 필터링 후, 역변환을 적용함으로써 개선된 영상을 얻게 된다.



(그림 2) 그리드 라인의 주파수 대역 검출 과정

본 연구에서는 그리드 라인의 주파수 대역 검출을 위하여 다음과 같은 방법을 적용하였다. 산출된 DCT 데이터에서 그리드 라인에 해당하는 주파수의 후보 영역에 대한 하한(lower bound) L을 식(1)과 같이 산출한다. 식에서 Maxf는 고주파 영역에서 최댓값을 갖는 위치이며, B는 1.0 보다 작은 상수로서 실험에 의해서 설정하는 매개변수이다.

$$L = B \cdot \text{Maxf} \quad (1)$$

이어서, DCT 데이터에서 그리드 라인에 해당하는 범위, 즉 필터링 대상이 되는 범위를 찾기 위하여 다음 과정을 수행한다. 주파수 k의 위치에서 데이터의 변동량을 D(k)로 정의하면, 이는 식(2)와 같이 산출된다. 식에서 Dct()는 특정 행의 데이터를 1차원 배열로 고려한 것이다. 다시 말해서 위치 k에서의 변동량은 대상 위치의 데이터 값에 대상 범위 시작점 L로부터 (k-1)까지의 누적 평균값과의 편차를 의미한다.

$$D(k) = |Dct(k)| - \frac{1}{k-L} \cdot \sum_{i=L}^k |Dct(i)| \quad (2)$$

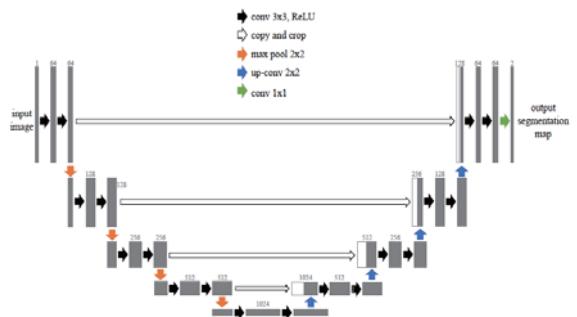
이로부터 D(k) 값이 임계치 M 보다 커지는 최초의 k 값과 Dct(R1) 보다 같거나 큰 마지막 위치를, 각각 추정 범위의 하한 값(R1)과 상한 값(R2)으로 결정한다.

제안한 DCT 기반 기법을 적용한 실험 결과, 피사체를 포함하지 않거나 피사체와 배경 영역의 명도 차이가 급격하지 않은 영상에서 대부분의 그리드 라인을 제거할 수 있었다. 그러나 급격한 명도 변화를 포함하는 영상에서 일부 성능의 미흡함을 보였다. 이에

본 논문에서는 이를 개선하기 위해 딥러닝 기법을 사용하는 방법을 고찰한다. 앞 절의 (그림 1)에 보인 바와 같이 DCT 기반의 결과 영상과 인위적으로 합성한 영상의 집합을 결합하여 학습데이터를 구성하고, U-Net, DnCNN, N<sup>3</sup>Net 총 3 가지의 네트워크를 활용하여 실험을 수행하였으며, 3 개의 모델을 적용한 실험 결과 상대적으로 성능이 일관되게 우수함을 보인 U-Net 모델 중심으로 기술하였다.

## 3. 학습데이터의 생성

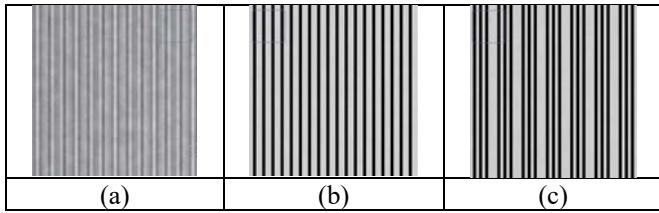
본 연구에서 사용한 영상 복원 네트워크의 구조는 (그림 3)에 보인 바와 같이 축소(contracting)와 확장(expanding)의 단계로 이루어 지는데, 각 확장 단계에서 하위 레벨의 출력 외에, 동일 레벨의 축소단계에서 생성한 특징 지도 데이터를 입력으로 받음으로써 특징 수의 축소 과정에서 발생하는 손실을 보완한다. 이는 기존 CNN에 비하여 특징에 대한 정교한 위치의 세분화를 가능하게 한다. 또한 적은 수의 영상을 이용하여 학습이 가능하기 때문에 본 연구의 응용분야와 같이 다양한 학습데이터 확보가 어려운 응용에 적합하다.



(그림 3) U-Net 기반의 영상 복원 네트워크

학습데이터는 총 3종류의 데이터 집합으로 구성하였다. 학습데이터 집합은 D<sub>g</sub>, D<sub>l</sub> 및 D<sub>p</sub>로 표기하였고, 각각의 의미는 다음과 같다.

- DCT 기반 기법으로 생성한 학습데이터(D<sub>g</sub>): (그림 4)의 (a)에 보인 것처럼 실제 그리드 라인 영상과 이에 대한 DCT 기반 개선 결과 영상으로 구성한 학습데이터
- 정형화된 라인을 인위적으로 합성한 데이터(D<sub>l</sub>): (그림 4)의 (b)에 보인 바와 같이 여러 종류의 X-ray 영상에 인위적으로 일정 주기의 선을 생성한 학습데이터, 이 때 라인의 간격은 그리드 제품의 사양에 따라 산출되는 간격으로 설정
- 패턴의 주기적 반복 형태를 생성한 데이터(D<sub>p</sub>): (그림 4)의 (c)에 보인 것처럼 전형적인 그리드 라인과 유사하게 3개의 선이 한 쌍을 이룬 형태가 반복되도록 생성한 데이터



(그림 4) 3 종류의 학습데이터: (a)  $D_g$ 에 사용된 자연 그리드 영상, (b) 인위적으로 일정 픽셀 간격의 선을 생성한 데이터  $D_l$ , (c) 인위적으로 세 선을 하나의 주기로 생성한 데이터  $D_p$

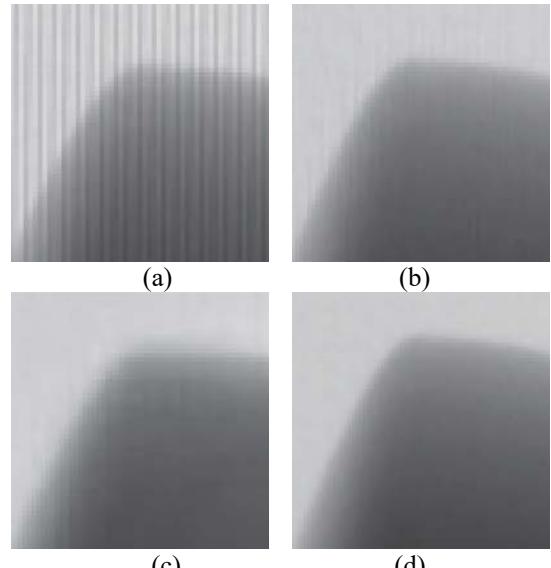
각 학습데이터 집합의 유용성을 검증하기 위해 개별 집합 및 다양한 조합을 선택하여 실험하고 결과를 비교하였다. 반복 실험의 결과, 인위적인 그리드 라인을 생성한  $D_l$ ,  $D_p$ 의 개별적 학습은 전체적으로 블러링 효과가 나타나거나, 평균 명도 값이 변하는 등의 단점을 수반하여 DCT 기반 그리드 제거 결과 영상에 비해 상대적으로 미흡한 성능을 보였다.  $D_g$ 의 개별적 학습은 DCT 기반 그리드 제거 영상과 유사하거나 조금 더 나은 성능을 보인 영상들이 일부 관찰되었다. 그러나 전반적으로 블러링 효과가 관찰되었고, 평균 명도 값이 높은 영상에서 전체적인 그리드 라인 제거 효과가 미흡하였다. 결론적으로 개별적인 학습데이터의 활용만으로는 DCT 기반 기법에 비하여 미흡한 성능을 보였다. 이에 세 종류의 학습데이터를 적절히 활용하는 방법을 고려하였고, 두 가지 방법론을 도출하였다.

첫번째 방법론은 상대적으로 두드러지는 특징이 있는 학습데이터를 순차적으로 학습시키는 방법이다.  $D_l$ - $D_g$  순서로 학습하는 실험과  $D_l$ - $D_p$ - $D_g$  순서로 학습하는 실험을 수행하였다. 실험의 결과로는 3 단계 학습이 2 단계 학습보다 나은 성능을 보였다.

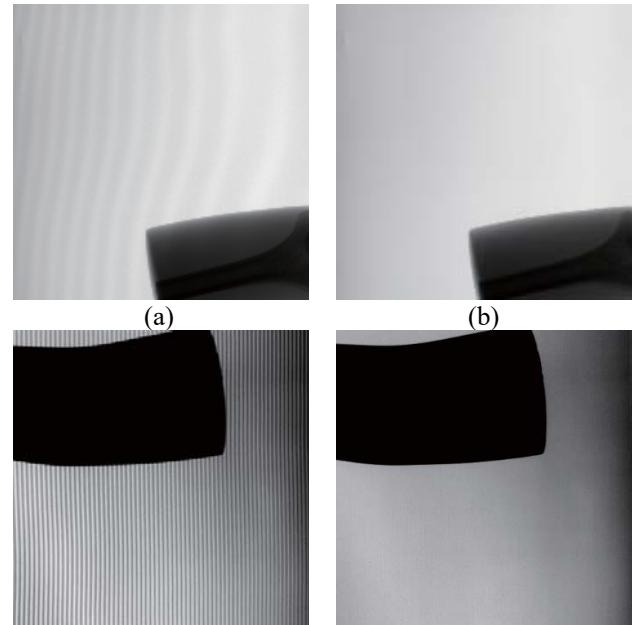
두 번째 방법은  $D_l$ ,  $D_p$ ,  $D_g$  세 가지의 학습데이터를 다양한 조합으로 혼합하여 학습하는 방법이다. 이에  $(D_l, D_p)$ ,  $(D_l, D_g)$ ,  $(D_p, D_g)$ ,  $(D_l, D_p, D_g)$  네 가지 조합에 대한 실험을 진행하였다. 실험 결과  $(D_l, D_p, D_g)$  즉, 세 가지의 학습데이터를 모두 결합하여 학습한 결과가 가장 나은 성능을 보였다. 이는 개별 학습데이터의 집합은 그 자체만으로 미흡한 성능을 갖고 있으나, 통합하여 학습함으로써 상호 보완적인 성능을 보일 수 있음을 시사한다.

#### 4. 실험 결과 및 고찰

앞 절에서 제안된 기법을 사용하여 생성한 학습데이터를 활용하여 실험한 결과를 관찰하였다. (그림 5)는 동일 입력 영상에 대해 각 모델을 적용한 결과를 비교한 것이다. 그림에 보인 바와 같이 딥러닝과 DCT 기반 기법을 결합한 복합형 기법이 DCT 기반 단일 기법에 비해 유사한 수준이거나 우수한 성능을 보였다. (그림 6)은 앞서 제시한 본 연구에서 제시한 복합형 기법을 사용한 실험 결과이다. 영상 전체에 나타난 그리드 라인의 제거뿐만 아니라 DCT 기반 기법의 약점으로 지적된 분할 경계선과 영상 가장자리의 그리드 라인이 개선됨을 보였다.



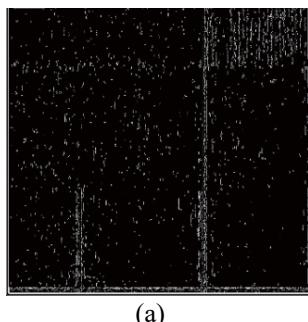
(그림 5) 그리드 라인 제거 실험 결과(예): (a) 입력 영상, (b) DCT 기반 기법, (c) DnCNN, (d) U-Net 기반 복합형 기법



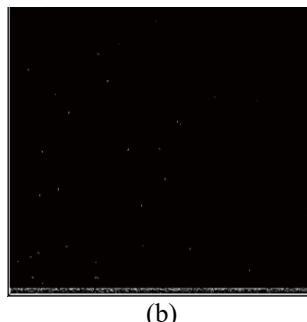
(그림 6) 제안된 기법을 사용한 실험 결과: (a), (c) 입력 영상, (b), (d) 결과 영상

(그림 7)은 DCT 기반 기법에서 나타나는 블로킹 현상의 개선 효과에 대한 실험 결과이다. 그림에 보인 바와 같이 영상 분할의 가장자리에서 나타나는 결함이 개선됨을 보인다.

(그림 8)은 영상 내 피사체 영역의 내부와 경계선 부분에 성능을 평가한 실험 결과이다. (그림 8)의 (a), (c) 와 (b), (d)는 각각 DCT 기반 기법 만을 적용했을 때와 본 연구에서 제시한 복합형 기법을 적용했을 때의 결과를 비교한 것이다. 그림에 보인 바와 같이 DCT 기반 기법 만을 적용했을 때, 피사체의 내부와 경계에 그리드 라인이 잔재하는 문제점을 개선할 수 있음을 보인다.



(a)

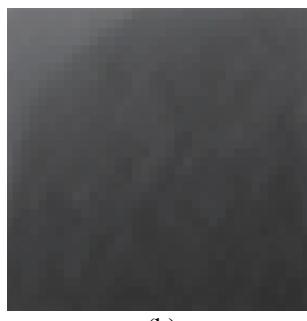


(b)

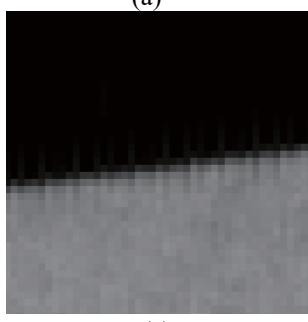
(그림 7) 블로킹 현상의 개선효과 실험: (a) DCT 기반 기법의 결과 (b) 제안된 기법의 결과



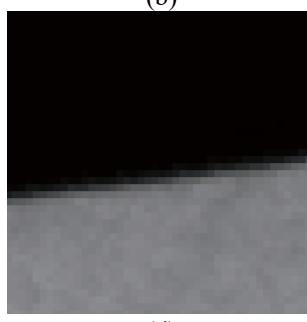
(a)



(b)

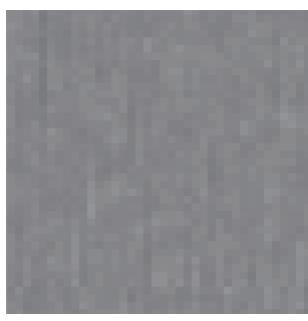


(c)



(d)

(그림 8) 영상 내 Object 의 내부(위) 및 경계 부분 (아래) 성능 비교: (a), (c) DCT 기반 기법 적용 결과 영상, (b), (d) 학습 기법 적용 결과 영상



(a)



(b)

(그림 9) 영상 배경 부분의 그리드 라인 제거 성능 비교: (a) DCT 기반 기법 적용 결과 영상, (b) 학습 기법 적용 결과 영상

이어서 영상에서 배경 부분의 그리드 라인 제거 성능을 비교하였다. (그림 9)는 DCT 기법만을 적용했을 때와 본 연구에서 제시한 복합형 기법을 적용했을 때의 결과를 비교한 것이다. (그림 9)의 (a)에서 볼 수 있듯이, DCT 기법은 배경에 잔재하는 그리드라인으로

인한 왜곡된 윤곽선이 나타나는 현상을 보였는데, 이러한 현상이 제안된 기법을 통해 개선될 수 있음을 알 수 있다.

## 5. 결론

X-ray 영상에서 그리드 라인을 개선하는 문제는 하나의 알고리듬으로 정확한 방법론을 결정하기 어려울 뿐만 아니라, 입력 영상에 대한 가장 이상적인 결과 영상을 제시하기 어렵다는 점이 실용적인 시스템을 구현하는데 난점으로 지적된다. 딥러닝을 이용한 영상 복원 기법에서 불완전한 학습데이터로 개선된 결과를 얻는 방법론은 이러한 문제에 적합한 접근으로 판단된다. 본 연구에서는 DCT 기반의 주파수 분석을 이용한 영상 개선 기법의 결과에 인위적으로 생성한 학습데이터를 포함하여 학습함으로써 성능이 개선될 수 있음을 실험적으로 보였다. 또한, 학습데이터를 구성하는 영상의 선택, 손실함수의 설정, 학습 횟수의 설정 등을 다수의 반복 실험을 통해 최적화하였다.

이러한 연구는 의료 영상에 포함되는 정보의 정확성을 향상시킴으로써 의료 진단의 신뢰도를 재고하고 하드웨어 그리드장치의 유용성을 증대시킬 수 있을 것으로 기대된다.

## 참고문헌

- [1] Hans Meine, Grzegorz Chlebus, Mohsen Ghafoorian, and Itaru Endo. "Comparison of U-net-based Convolutional Neural Networks for Liver Segmentation in CT," arXiv preprint arXiv:1810.04017, 2018
- [2] Adrien Motsch, Sébastien Motsch, and Thibaut Saguet. "Lesion segmentation using U-Net network," arXiv preprint arXiv:1807.08844, 2018
- [3] Jiawei Zhang, Yuzhen Jin, Jilan Xu, Xiaowei Xu, and Yanchun Zhang. "MDU-Net: Multi-scale Densely Connected U-Net for biomedical image segmentation," arXiv preprint arXiv:1812.00352, 2018
- [4] Weisheng Dong, Peiyao Wang, Wotao Yin, Guangming Shi, Fangfang Wu, and Xiaotong Lu., "Denoising Prior Driven Deep Neural Network for Image Restoration," arXiv preprint arXiv:1801.06756v1 [cs.CV], 2018
- [5] Jaakko Lehtinen, Jacob Munkberg, Jon Hasselgren, Samuli Laine, Tero Karras, Miika Aittala, and Timo Aila., "Noise2Noise: Learning Image Restoration without Clean Data," arXiv:1803.04189 [cs.CV], 2018
- [6] K. Zhang, W. Zuo, Y. Chen, D. Meng, and L. Zhang, "Beyond a gaussian denoiser: Residual learning of deep CNN for image denoising," IEEE Transaction of Image Processing, Vol.26, No.7, pp.3142-3155, 2017
- [7] Tobias Plotz and Stefan Roth, "Neural Nearest Neighbors Networks," arXiv preprint arXiv:1810.12575v1 [cs.CV], 2018