

X-ray 산란선 보정을 위한 신경망 학습 기법

윤혜린, 유현경, 이찬혁, 김호준
 한동대학교 전산전자공학부
 e-mail : hjkim@handong.edu

A Neural Network Training Method for Scattered X-ray Correction

Haelin Yoon, Hyunkyung Yoo, Chanhyeok Lee, Hojoon Kim
 School of Computer Science and Electrical Engineering, Handong Global University

요 약

본 연구에서는 X-ray 산란선 보정을 위한 신경망에서 학습기법의 세부 방법론을 고찰한다. 학습 데이터의 생성 과정과 데이터의 표현 과정에서 X-ray 영상의 특성을 반영하여 다양한 방법을 제시하고 실험적으로 고찰하였다. 학습을 위한 계산량의 문제와 유효하지 않은 학습데이터로 인한 성능 저하를 개선하기 위하여 샘플링과정을 수행하고 로컬영역을 고려하는 학습데이터 생성방법을 제시하였다. 실제 동일 피사체에 대하여 그리드 장비를 사용한 영상과 비교한 실험 결과를 통하여 제안된 방법의 유용성을 평가하였다.

1. 서론

신경망 기법을 사용하여 영상의 질을 개선하고자 하는 연구는 다양한 분야에서 시도되어 왔다. 측면 억제성 연결구조를 갖는 신경망을 사용하여 영상의 노이즈와 왜곡을 개선하는 연구가 수행되었으며[1], 의료영상 분야에서는 뇌 MRI 영상의 조영개선을 위하여 역전파 신경망을 적용한 연구가 발표되었다[2]. 또한 3 차원 의료영상의 자동 분할을 위하여 딥러닝 기반의 CNN(Convolutional Neural Network)모델을 사용하는 연구가 소개된 바 있다[3].

그리드 하드웨어를 사용하지 않은 X-ray 영상은 다량의 산란선과 노이즈를 포함하여 영상의 판독을 어렵게 한다. 그런데 산란선의 형태는 촬영환경과 피사체의 특성에 따라 다양한 변화를 갖기 때문에 촬영된 영상으로부터 픽셀 값 변화의 규칙을 찾아내어 원영상을 복원하는 것은 매우 어려운 문제이다. 이에 본 연구에서는 그리드를 사용한 영상(이하 grid 영상)과 사용하지 않은 영상(이하 non-grid 영상)으로부터 표본 추출된 학습 데이터를 생성하고 신경망을 사용하여 X-ray 영상을 개선하는 방법론을 고찰한다. 또한 대상 영상 데이터를 일반화된 의료영상 형식과 X-ray 신호의 원시 영상 형식으로 두 가지 경우에 모두 적용함으로써 X-ray 영상개선 응용시스템의 현장성과 사용자의 환경을 포괄적으로 고려하였다. 이 연구는 기존의 그리드 하드웨어 장치의 기능을 보완 또는 대체할 수 있는 소프트웨어 기반 연구로서 신경망이론의 적용가능성을 고찰하였다는 점에서 그 의미를 갖는다.

2. 신경망 학습을 위한 데이터의 표본 추출

X-ray 영상의 산란선 보정을 위하여 오류 역전파(BP) 알고리즘을 적용하는 다층 구조의 신경망을 구

현하였다. 산란선의 형태와 특성은 환경변수와 피사체의 특성 및 영상의 영역별 분류 등의 요인에 의하여 다양한 변이를 갖는다는 점을 고려하여 학습 데이터의 표현 방법과 대상 영역의 설정, 샘플링 방법 등의 방법론을 제시하고 실험적으로 검증하였다.

전형적인 X-ray 영상은 수백만 개의 픽셀로 이루어져 있어서 모든 픽셀 간의 변화를 학습 데이터로 활용하는 것은 그 조합의 수가 매우 방대할 뿐만 아니라 과도한 계산량이 요구된다. 게다가 영상 가장자리의 유효하지 않은 데이터를 포함함으로써 학습된 데이터를 생성함으로써 학습 효과를 저하시킬 수 있다. 따라서 본 연구에서는 식 (1)과 같이 원영상에서 일정 개수의 픽셀을 표본 추출함으로써 데이터의 양을 감소시키고 계산량을 개선하였으며, 영상에서 가장자리 영역의 여백을 제외시킴으로써 학습 데이터의 왜곡을 보완하였다.

$$y(i, j) = x(B_h + id_h, B_v + jd_v)$$

식 (1)에서 $y(i, j)$ 는 표본 추출된 픽셀 값이며, $x(i, j)$ 은 원영상의 픽셀 값이다. 상수 B_h 와 B_v 은 영상에서 가장자리 영역을 제거하기 위한 가로 및 세로 방향 여백 설정이며, d_h , d_v 는 샘플링하는 픽셀의 간격을 의미한다. 이렇게 추출한 픽셀의 개수는 식 (2)와 같이 감소한다.

$$N_s = ((S_h - 2B_h)/d_h) \cdot ((S_v - 2B_v)/d_v)$$

식 (2)의 N_s 는 샘플링된 픽셀 수이며, S_h 및 S_v 는 원영상의 가로 및 세로 픽셀 수이다. 다시 말해서 전체 픽셀 수는 $N_s/(S_h \cdot S_v)$ 의 비율로 감소하게 된다.

3. 신경망의 입력 및 출력 데이터 표현

산란선에 의한 픽셀 값의 변화는 피사체의 특성에 따라 다양하게 변화하는데 이는 영상에서 영역별로 구분되어 서로 다른 특성을 보인다. 그러므로 해당 픽셀의 값 뿐만 아니라 중심 픽셀을 기준으로 일정 범위 로컬 영역에 대한 픽셀 값의 분포를 학습에 포함시키는 것을 고려하였다.

로컬 영역 픽셀의 집합을 입력 데이터로 고려할 때 해당 위치의 픽셀 값의 영향이 가장 중요함이 직관적으로 예측 가능하다. 그러나 중심 픽셀 값에 대한 가중치가 학습 효과를 통해 반영되기 위해서는 방대한 양의 표본 영상이 필요한데 실제 환경에서는 다량의 표본 영상을 쌓으로 획득하기 어렵다. 이에 본 연구에서는 신경망의 입력 계층에서 중심 픽셀의 영향을 인위적으로 강화하는 방법을 채택하였다.

또한 X-ray 영상에서 부위 별 특성이 다르다는 점을 반영하여 각 영역을 별도로 구분하여 구현하였다. 예컨대 흉부 영상에서 척추를 기준으로 좌측과 우측의 폐 영역, 복부 부분으로 영역을 분할하였다.

신경망 출력 값의 의미를 단순히 정규화된 픽셀 값으로 고려하는 방법은 영상 복원의 응용에서 오차의 편차가 매우 심하게 나타날 수 있다. 이에 본 연구에서는 원영상과 관찰된 영상에서 픽셀 값의 편차를 정규화하는 방법을 고려하였다. 전체 픽셀의 편차 중 최소값과 최대값을 구하고, 출력 데이터로 사용할 픽셀의 값을 선형 매핑하여 변환한다. 신경망의 출력 값에 대하여 관찰된 데이터의 픽셀 값에 편차 범위의 비율을 보정함으로써 복원영상이 생성된다.

본 연구에서는 개발된 영상복원 신경망을 두가지 형식의 영상 표현에 적용하였다. 일반적으로 X-ray 진단 기기를 다루는 현장 사용자의 응용을 위하여 dicom 포맷의 영상을 사용하여 구현하였으며, 부수적으로 grid 생산 현장이나 장비 개발 현장에서 사용하는 경우를 고려하여 원시(raw) 데이터 형식의 X-ray 영상에도 적용하였다. 학습 데이터 형성을 위한 샘플링의 전반적인 과정은 두 경우 동일하게 적용하였으나 원시 데이터 영상에서는 샘플링 픽셀 수를 좀 더 확대하였다.


4. 실험 결과 및 고찰

실험 1 은 dicom 형식의 영상을 좌측 폐 영역, 우측 폐 영역, 복부 영역으로 분할하여 입력 데이터를 각각 생성한 경우로, 샘플링 과정에서 파라미터 값 B_h 와 B_v 는 동일하게 200 으로 하고, d_h 와 d_v 을 7 로 설정하였다. S_h 와 S_v 는 각 1994 및 2430 으로, 샘플링으로 인한 픽셀 수 감소 효과는 식 (3)과 같다.

$$((S_h - 2B_h)/d_h) \cdot ((S_v - 2B_v)/d_v) / (S_h \cdot S_v) \quad (3)$$


다시 말해서, 약 100 분의 1 로 감소하였다.

실험 결과는 (그림 1)에 보인 바와 같이 폐 영역과 어깨 부분에서 개선 효과가 확인되었으며, 그 외의 영역에서는 미미한 개선 효과를 보였다.




(그림 1) 실험 1 에서의 (a) 원본 non-grid 영상, (b) grid 영상, (c) 개선된 영상

실험 2 는 입력 노드를 해당 픽셀 주변 영역 25 개 픽셀로 설정하고, 출력 데이터를 grid 영상의 픽셀 값으로 생성하여 전체를 한 개의 신경망으로 학습한 경우이다. 그 결과 (그림 2)에 보인 바와 같이 전체적으로 영상이 개선되었으며, 폐 영역 등 일부 영역에서 다소의 왜곡현상이 발견되었다.



(그림 2) 실험 2 에서의 (a) 원본 non-grid 영상, (b) grid 영상, (c) 개선된 영상

실험 3 은 입력 데이터를 25 개 픽셀로 생성하고, 출력 데이터 형식은 grid 영상과 non-grid 영상의 차 값으로 생성하였다. 실험 결과 (그림 3)에서와 같이 산란선이 발생한 non-grid 영상이 grid 를 사용한 영상과 유사한 수준으로 개선된 것을 확인 할 수 있다.




(그림 3) 실험 3 에서의 (a) 원본 non-grid 영상, (b) grid 영상, (c) 개선된 영상

원시 데이터로 표현된 X-ray 영상의 산란선 보정 효과를 평가하기 위해서는 해당 grid 영상과의 차 값을 사용하였다. 모든 학습과 데이터 처리는 14bit 의 데이터 형식을 적용하였으며, 이미지를 시각화하기 위하여 8bit 로 resolution 을 낮춘 뒤 픽셀 값이 낮은 영역의 가시효과를 개선하기 위하여 흑백을 반전시켰다. 차영상에서도 14bit 영상을 8bit 형식으로 변환하여 시각적으로 확인할 수 있도록 하였다. 실험 결과


를 평가하기 위하여 기존의 non-grid 영상과 grid 를 사용한 영상, 두 영상의 차영상을 함께 비교하였다.

원시 데이터로 표현된 X-ray 영상의 학습 실험은 모든 경우에 학습 조건인 학습 데이터 별 오류 5% 미만을 만족시키고 비교적 짧은 횡수만으로 학습이 완료되었다. (그림 4)는 모든 원시 데이터 실험에 사용된 X-ray 영상이다.




(그림 4) 원시데이터 실험에서 공통으로 사용된 (a) 원본 non-grid 영상, (b) grid 영상, (c) a와 b의 차영상

실험 4 는 원시 데이터에 대한 실험으로 출력 데이터로는 grid 영상과 non-grid 영상의 차 값을 사용하였다. 매우 짧은 시간에 학습이 완료되었으며, (그림 5)에 보인 바와 같이 척추 영역에서 개선효과를 보였으며, 폐 영역에서는 약간의 왜곡이 발생하였다.




(그림 5) 실험 4 에서의 (a) 개선된 영상, (b) grid 영상과 개선된 영상의 차영상

실험 5 는 출력 데이터를 grid 영상의 픽셀 값 자체로 단일 신경망에 적용한 경우이다. 실험 4 보다 비교적 학습 시간이 길게 소요되었으며, 실험 결과 척추 영역에서는 실험 4 와 같은 수준의 결과를 얻지는 못했지만 어느 정도 개선이 있는 것으로 나타났다. 몸통의 바깥 부분에서 작은 왜곡이 발생하였으며 폐 영역에서는 왜곡이 발생하지 않았다.



(그림 6) 실험 5 에서의 (a) 개선된 영상, (b) grid 영상과 개선된 영상의 차영상

실험 6 은 위 실험에서 은닉 노드의 개수를 최적화한 경우이다. 학습 횡수는 실험 5 보다는 길었고, 실험 결과 (그림 7)에 보인 바와 같이 실험 5 에 비해 현저한 개선이 있었다.



(그림 7) 실험 6 에서의 (a) 개선된 영상, (b) grid 영상과 개선된 영상의 차영상

5. 결론

X-ray 산란선 보정을 위하여 신경망의 학습 데이터 표현, 입력 및 출력 데이터 형식 및 영상 표현 형식에 따른 특성의 변화를 실험적으로 고찰하였다. 전체를 한 개의 신경망으로 구현하는 방법은 영역별로 다소의 왜곡이 나타날 수 있으며, 영역별로 구분하는 신경망은 이러한 점을 개선할 수 있으나, 학습 데이터의 특성에 따라 성능의 편차를 보였다. 또한 출력 데이터의 차영상 표현은 학습 데이터가 충분하지 않을 때 일부의 왜곡현상이 나타날 수 있음이 확인되었다. 원시 데이터를 사용한 학습은 산란선의 작용이 원형 그대로 반영되기 때문에 조영효과 변형을 한 dicom 영상에 비해 상대적으로 변이가 적어 학습이 매우 빠른 특성을 보였다. 또한 동일한 구조와 데이터 형식을 적용한 실험에서도 은닉 노드의 수에 따라 성능 변화가 있음을 보였다.

※ 이 논문은 미래창조과학부의 소프트웨어중심대학사업 (2017-0-00130)의 지원을 받아 수행된 연구임

참고문헌

- [1] Haijiao Yun, Zhiyong Wu, Guanjun Wang, Gang Tong, Hua Yang, "Image enhancement algorithm based on improved lateral inhibition network," *Infrared Physics & Technology*, Vol.76, pp.308-314, 2016.
- [2] Kamil Dimililer, Ahmet Ilhan, "Effect of image enhancement on MRI brain images with neural networks," *Procedia Computer Science*, Vol.102, pp.39-44, 2016.
- [3] Qi Dou, Lequan Yu, Hao Chen, Yuerming Jin, Xin Yang, Jing Qin, Pheng-Ann Heng, "3D deeply supervised network for automated segmentation of volumetric medical images," *Medical Image Analysis*, Vol.41, pp.40-54, 2017.