

Original article

생성적 적대 신경망(GAN)을 활용한 PET/CT 영상 화질 개선에 관한 연구

정무진, 방사선사*, 박겸우, 방사선사, 광인석, 방사선사, 홍건철, 수석 방사선사
삼성서울병원 핵의학과

Evaluation of Improvement Strategies for PET/CT Image Quality Using Generative Adversarial Networks

Moo-Jin Jeong, Radiological Technologist*, Kyum-Woo Park, Radiological Technologist, In-Suk Kwak, Radiological Technologist, Gun-Chul Hong, Lead Radiological Technologist
Department of Nuclear Medicine, Samsung Medical Center, Seoul, Korea

*Corresponding Author: Moo-Jin Jeong, Department of Nuclear Medicine, Samsung Medical Center, 81, Irwon-ro, Gangnam-gu, Seoul, 06351, Republic of Korea. Tel: +82-2-3410-6285, E-mail: moojin0217@naver.com

Abstract

Purpose: This study aimed to evaluate the feasibility of noise control and quantitative restoration in low-dose Positron Emission Tomography/Computed Tomography (PET/CT) images using a Generative Adversarial Network (GAN)-based Pix2Pix model, thereby assessing its clinical applicability for radiation dose reduction. **Materials and Methods:** Image data were acquired using a SiPM-based PET/CT scanner (GE Discovery MI) and a NEMA IEC Body Phantom. Based on the reference activity (18.50 MBq), list-mode data were collected at five reduced dose levels (5%, 10%, 25%, 50%, and 75%) according to radiopharmaceutical decay time. A total of 10,000 paired low-dose and Ground Truth (GT) dataset pairs were constructed using bootstrapping and data augmentation. Three reconstruction algorithms were evaluated: VPHD-S, VPFX-S, and QCFX-S-400. Structural and quantitative metrics, including SSIM, PSNR, Recovery Coefficient (RC), CNR, SNR, and Background Variability (BV%), were evaluated. Statistical equivalence with GT was verified using Bland-Altman analysis, Intraclass Correlation Coefficient (ICC), and paired t-tests. Statistical significance was verified using paired t-tests. **Results:** The Pix2Pix model significantly enhanced image quality and quantitative accuracy across all low-dose conditions. SSIM and PSNR steadily increased with dose levels, with the BSREM-based QCFX-S-400 algorithm demonstrating the highest restoration performance (SSIM: 0.967, PSNR: 37.289 dB at 75% dose). RC analysis revealed that the VPFX-S and QCFX-S-400 algorithms fully satisfied the EANM EARL2 guideline standards across all dose levels (5%–75%). Furthermore, predicted CNR and SNR were significantly higher than those of GT (). At 50% and 75% dose levels, the BV% of predicted images was lower than that of GT, demonstrating superior noise suppression. **Conclusion:** The Pix2Pix model successfully restored high-quality synthetic PET images while maintaining quantitative reliability even under ultra-low-dose conditions (5%–75%). Combining the deep learning model with a high-resolution reconstruction algorithm (QCFX-S-400) maximized noise reduction and quantitative accuracy for small lesions. This approach substantially reduces patient radiation dose in accordance with ALARA principles while preserving the diagnostic efficacy and safety of low-dose PET/CT image.

Keywords: Radiation Dose Reduction, GAN, Pix2Pix, Low-dose PET

서론

양전자방출단층촬영(Positron Emission Tomography, PET)은 생체 내 유기적 대사 물질의 분포를 정량적으로 분석할 수 있는 대표적인 분자 영상 기법이다. 이는 체내 대사 변화를 정밀하게 추적할 수 있어 암의 조기 진단부터 치료 반응 평가, 재발 유무 확인에 이르기까지 종양학 분야에서 높은 임상적 가치를 인정받고 있다[1,2] 그러나 영상 획득 과정에서 발생하는 산란선(scattered radiation)과 무작위 계수(random counts)의 영향으로 인해 발생하는 잡음은 정밀한 진단을 저해할 수 있다. 이러한 물리적 제약을 극복하기 위해 최근 하드웨어의 감도 향상과 더불어 고도화된 재구성 알고리즘이 도입되면서 영상의 질과 정량적 정확도가 비약적으로 향상되었다. 특히 비행시간 선별 기술(Time-of-Flight, TOF) 및 점확산함수(Point Spread Function, PSF) 모델링의 발전은 기존의 영상 화질 저하 요인을 효과적으로 제어하며 임상적 유용성을 증대시키고 있다[3]. 이에 더해 최근 인공지능(AI) 기반 의료영상 기술이 핵심 중추로 자리 잡았으며, 특히 Motion Free와 같은 딥러닝 기법은 영상 잡음 제어 및 움직임 보정(motion correction)을 통해 영상의 화질 저하 요인을 정밀하게 개선하는 데 광범위하게 활용되고 있다[4].

이러한 기술적 진보는 단순히 영상의 질적 향상에 머무르지 않고, 핵의학 분야에서 환자 피폭 선량 저감(radiation dose reduction)으로 그 범위를 확장하고 있다. 하드웨어의 발전으로 인한 디지털 PET/CT의 감도 향상은 적은 양의 방사성 의약품 투여로도 진단에 적합한 영상을 확보할 수 있게 하였으며, 이는 환자가 받는 유효 선량을 근본적으로 낮추는 토대가 되었다. 그러나 과도한 투여량 감소나 검사 시간 단축은 영상 화질의 급격한 저하와 병변 검출력 약화를 초래하여 정량적 신뢰성을 감소시킬 수 있다[5]. 특히 저 투여량 환경에서는 잡음이 병변 신호를 압도하기 때문에, 이를 보완하기 위한 고도화된 영상 재구성 및 후처리 기법의 도입이 필수적이다[6]. 이러한 배경하에 생성적 적대 신경망(Generative Adversarial Networks, GAN) 기반 모델은 실제 영상과 통계적으로 매우 유사한 고품질 합성 영상을 생성할 수 있는 혁신적인 개선 방안으로 주목받고 있다[7]. 특히 GAN의 대표 구조인 Pix2Pix는 입력 영상과 출력 영상 간의 픽셀 단위 대응 관계를 정교하게 학습함으로써, 저 투여량 영상에서 발생하는 잡음 패턴을 효과적으로 제거하고 표준 투여량 영상에 근접한 화질을 재현할 수 있다. 이러한 AI 기반 모델은 소아 환자나 반복적인 추적 관찰이 필요한 암 환자의 누적 피폭 관리 측면에서 매우 높은 임상적 가치를 지닌다. 이에 따라 환자의 피폭 저감과 검사 효율성을 위해 방사성 의약품 투여량을 기존 대비 5%~50% 수준으로 경감시켜 영상을 획득하고, 이를 진단 가능한 수준으로 복원하려는 시도가 활발히 보고되고 있다[8-11]. 결과적으로 PET/CT의 하드웨어 발전과 AI 기술의 융합은 진단의 정확성을 높이는 동시에 피폭 저감에 크게 기여한다[12,13].

이에 본 연구는 Pix2Pix 모델을 활용하여 저 투여량 PET/CT 영상의 화질 개선 효과를 분석하고, 다양한 영상 재구성 알고리즘 환경에서의 성능을 다각도로 평가하고자 한다. 이를 통해 향후 비지도 학습(unsupervised learning) 기반 모델의 적용 기준을 마련하고, 저 투여량 PET-CT 검사의 임상 적용 가능성과 그 학술적 의의를 심도 있게 고찰하고자 한다.

대상 및 방법

1. 재구성 및 데이터 수집

연구를 위한 영상 획득은 LBS(Lutetium-based), SiPM(Silicon Photomultiplier) 기반 GE Discovery MI(GE Healthcare, USA)를 사용하였다. 해당 장비는 21cm의 축방향 시야각(Axial Field of View, AFOV)을 가지며, 380ps 미만의 뛰어난 시간 분해능을 바탕으로 TOF를 지원한다[14,15]. phantom은 NEMA IEC Body Phantom을 사용하였으며, 열소(sphere)와 배후방사능(background)의 방사능 농도 비를 4:1로 ^{18}F -FDG를 주입하였다(Fig. 1). 영상 획득시 CT 촬영 조건은 140kV에 Auto mA를 사용하였으며, PET 영상 획득 조건은 매트릭스 크기는 256×256 , cutoff filter 5.0mm, subset 16, iteration 4, Z-axis filter는 standard를 적용하여 획득하였다. PET 재구성 조건은 1. VPHD-S(VUE Point HD), 2. VPFX((VUE Point FX(TOF+PSF)) 3. QCFX-S-400(VUE Point FX+Q.Clear(β -strength 400)+PSF) 총 3가지로 하였다. 또한, 저 투여량 조건 설정을 위해 기준 농도인 18.50 MBq을 기준으로 방사성 동위원소의 붕괴 시간에 따라 5%, 10%, 25%, 50%, 75% 시점에서 각각 List-mode로 영상을 획득하였다.



Fig. 1. Description of equipment and phantom utilized for data acquisition and analysis

2. 데이터 셋 구축 및 전처리

20분 동안 획득한 List-mode 데이터는 1분/frame 단위로 분할 재구성하였으며, 이를 기반으로 통계적 신뢰성을 확보하기 위해 부트스트래핑(bootstrapping) 기법을 적용하였다. 재구성된 1분 단위 영상에서 무작위 비복원 추출(random sampling without replacement, $P=5$)을 수행하여, 최종적으로 저 투여량(low-dose) 영상 10,000장과 이에 대응하는 정답 영상(Ground Truth, GT) 10,000장을 생성하였다(Fig. 2-3). 이러한 부트스트래핑 방식은 제한된 팬텀 환경 내에서도 데이터의 다변화를 통해 영상 신뢰성을 최대화한다. 생성된 저 투여량 영상과 GT 영상은 1:1로 매칭하여 총 10,000쌍의 데이터셋을 구축하였다. 이후 모델의 일반화 성능을 극대화하고 학습의 안정성을 확보하기 위해 $\pm 15^\circ$ 범위 내의 임의 회전(rotation)과 ± 15 pixel 범위 내의 무작위 이동(translation)의 데이터 증강을 하였다. 이는 모델에 기하학적 변화를 주어 다양한 데이터 패턴을 학습하게 함으로써 과적합(overfitting)을 방지하고 학습 과정을 최적화하는 역할을 한다. 최종적으로 구성된 데이터 셋은 학습 80%, 검증 10%, 테스트 10%의 비율로 분할하여 학습을 진행하였다. 전체적인 모식도는 다음과 같다(Fig. 4).




Fig. 2. Constructing the dataset by pairing each low-dose image with its corresponding ground truth image




Fig. 3. An example of bootstrap sampling




Fig. 4. Workflow for generating and augmenting PET image pairs before splitting them into training, validation, and test sets.

3. Pix2Pix 모델 구조 및 학습

인공지능은 인간의 지적 행위를 모방하도록 설계된 기술을 의미하며, 데이터로부터 스스로 패턴을 학습하는 딥러닝 기법을 통해 다양한 의료영상 분야에 적용되고 있다. 학습 방식에 따라 지도 학습(supervised learning)과 비지도 학습(unsupervised learning)으로 구분되며, 본 연구에서 사용한 GAN은 생성기와 판별기가 상호 경쟁하는 적대적 학습 구조를 통해 이미지 전송 및 화질 변환 성능을 크게 향상시키는 지도학습의 대표적 모델이다. 이는 입력 이미지와 정답 이미지 간의 짝지어진 데이터를 바탕으로 학습하는 구조를 가진다[16,17].

이러한 GAN의 이미지 생성 능력을 활용하여 의료영상 분야에서는 CT 영상의 잡음 제거, MRI 영상의 대조도 강화 등 선량 최적화를 위한 다양한 연구가 진행되고 있다. 특히 핵의학 분야에서는 저 투여량 PET 영상의 화질을 개선하거나, 모달리티 변환을 통해 CT 데이터 없이 PET 데이터만으로 정확한 감쇠 보정(attenuation correction)을 수행하는 등 환자 피폭선량을 획득 단계에서 감축하기 위한 대안으로 주목받고 있다[18-20].

본 연구에서는 저 투여량 영상의 정량적 품질 저하를 보상하고 고품질의 합성 이미지를 생성하기 위해 Pix2Pix 모델을 활용하였다. Pix2Pix은 고유한 영상 구현 기능을 수행하는 생성기(generator)와 생성된 영상의 진위 여부를 판단하는 판별기(discriminator)로 구성되며, 두 네트워크 간의 적대적 학습을 통해 이미지의 세부 구조를 정교하게 복원한다. 생성기는 영상의 특징 추출과 복원을 위해 U-Net 구조를 가진다. 이는 연속적인 컨볼루션(convolution) 및 풀링(pooling) 과정을 통해 입력 영상의 추상적 특징을 추출하는 인코더(encoder), 업샘플링(up-sampling)을 통해 영상의 해상도를 본래의 크기로 복원하는 디코더(decoder)로 이루어진다. 이 과정에서 encoder의 특징 맵을 decoder로 직접 전달하는 스킵 커넥션(skip connection) 구조를 활용한다(Fig. 5). 이는 encoder 단계에서 보존된 고해상도의 세부 정보를 decoder에 결합함으로써, 의료 영상에서 필수적인 해부학적 경계선 및 미세 구조의 소실을 방지하고 구조적 정확성을 유지하는 데 기여한다[21-23]. discriminator는 작은 병변과 같은 국소적인 영역을 패치 단위로 분석하여 진위 여부를 가려내는 PatchGAN 구조를 적용하였다. PatchGAN은 전체 이미지를 일정 크기의 단위로 분할하여 각 영역 내의 패턴을 독립적으로 평가하므로, 영상의 세밀한 특징을 효과적으로 보존할 수 있어 저 투여량 영상 특유의 잡음을 억제하는 데 적합하다. 그러나 적대적 손실(adversarial loss)만으로는 생성된 영상의 픽셀 단위 정확도를 보장하기 어려우며, 영상의 윤곽선이 흐려지는 블러링(blurring) 현상이 발생할 수 있다. 이를 보완하기 위해 합성된 영상과 GT 사이의 물리적 절대 거리를 최소화하는 L_1 loss 함수를 추가로 도입하였다[24-26]. 결과적으로 Pix2Pix 모델은 adversarial loss와 L_1 loss를 결합하여 시각적 유사성과 정량적 정확성을 동시에 확보한다. adversarial loss는 판별기 (D)가 실제 영상과 생성된 가짜 영상을 구분하는 능력을 최대화하는 동시에, 생성기 (G)는 판별기를 완벽히 속이도록 설계된다. (x)는 입력된 저 투여량 영상, (y)는 GT 영상을 의미하며, (E)는 데이터 분포에 대한 기댓값이다. 최종 목적 함수는 다음과 같다(Eq. 1~2), [27].

$$L_{GAN}(G, D) = E_{x,y}[\log D(x, y)] + E_{x,z}[\log \{1 - D(x, G(x, z))\}] \quad \text{Eq. 1}$$

$$L_1(G) = E_{x,y,z}[||y - G(x, z)||] \quad \text{Eq. 2}$$

본 연구의 딥러닝 학습 시 프로그래밍 언어는 파이썬(Python 3.9.6)을 사용하였으며, 프레임워크는 파이토치(PyTorch v1.12.1)를 사용하였다. Intel Core i5-12400 CPU, 16GB DDR4 RAM, NVIDIA GeForce GTX 1060 3GB GPU 하드웨어 시스템 환경에서 수행되었다. 소프트웨어 환경으로는 최신 버전의 PyTorch 프레임워크와 CUDA 가속 환경을 구축하여 사용하였다. 모델의 최적화를 위한 학습 파라미터로 batch size는 8, epoch은 100으로 설정하였으며, learning rate은 0.001로 지정하여 학습을 진행하였다. 최적화 알고리즘으로는 Adam optimizer $\beta_1 = 0.5$, $\beta_2 = 0.999$ 를 적용하였으며, L_1 정밀한 이미지 복원을 위해 adversarial loss와 L_1 loss를 함께 구성하여 학습을 진행하였다.




Fig. 5. Schematic diagram of the U-Net architecture utilized in this study

4. 성능 평가 및 통계 분석

성능은 화질 지표(structural metrics)와 정량 지표(muantitative metrics)를 통해 분석하였다. 화질 지표는 최대 신호 대 잡음비(Peak Signal-to-Noise Ratio, PSNR)와 구조적 유사성 지표(Structural Similarity Index Measure, SSIM)를 사용하였다. PSNR은 영상의 최대 신호 대 잡음비를 의미하며, 복원 과정에서 발생하는 화질 손실을 로그 스케일(dB)로 측정한다(Eq. 3 ~ 4). 값이 높을수록 원본 영상에 가까운 고화질임을 나타낸다. SSIM은 인간의 시각적 인지 특성을 반영하여 영상의 휘도, 대조도, 구조의 유사성을 결합하여 평가하며, 1에 가까울수록 원본 영상의 해부학적 구조가 왜곡 없이 두 영상의 유사도가 높음을 의미한다[28]. 정량 지표는 회복계수(Recovery Coefficient, RC), 대조도 대 잡음비(Contrast-to-Noise Ratio, CNR), 신호 대 잡음비(Signal-to-Noise Ratio, SNR), 배경변동성(Background Variability, BV%)를 사용하였다(Eq. 5 ~ 7). RC는 실제 방사능 농도 대비 영상에서 측정된 농도의 비율로, 특히 sphere의 관심 영역 분석을 통해 부분 용적 효과(partial volume effect)의 보정 정도를 확인하는 정량적 지표이다. BV%는 배경 잡음의 변동성을 평가하는 핵심 지표로, 값이 낮을수록 잡음이 적고 영상 안정성이 높음을 의미한다. ROI 분석 및 정량 지표 산출은 의료 영상 분석 플랫폼인 3D Slicer를 활용하였다.

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad \text{Eq. 3}$$

$$PSNR = 10 \log_{10} \left(\frac{MAX_I^2}{MSE} \right) \quad \text{Eq. 4}$$

$$CNR = \left| \frac{Signal_{ROI, Sphere} - Signal_{ROI, Background}}{\sigma_{ROI, Background}} \right| \quad \text{Eq. 5}$$

$$SNR = \frac{Signal_{ROI, Sphere}}{\sigma_{ROI, Background}} \quad \text{Eq. 6}$$

$$SNR = \frac{\sigma_{ROI, Background}}{Signal_{ROI, Background}} \quad \text{Eq. 7}$$

Pix2Pix 모델의 저 투여량 조건별 정량 수치 보존 성능을 대용량 데이터 기반으로 검증하기 위해 5가지 저 투여량 조건으로 독립된 평가 세트를 구축하였다. 각 선량 레벨당 10,000개씩, 총 50,000개의 평가 세트를 활용하여 정량적 동등성 검증을 시행하였다. 모델이 복원한 영상과 GT 영상 간의 측정값 일치도 및 오차 범위를 평가하기 위해 급내상관계수(Intraclass Correlation Coefficient, ICC; Two-way random-effects model)와 Bland-Altman 분석(Mean Bias, 95% Limits of Agreement)을 수행하였다. 또한 ROI 크기(10 mm, 13 mm, 17 mm, 22 mm, 28 mm, 37 mm) 및 투여량 조건(5%, 10%, 25%, 50%, 75%)에 따른 GT와 예측 영상 간의 차이를 검증하기 위해 SPSS Statistics (v29.0, IBM Corp., Armonk, NY, USA)를 이용하여 대응표본 t-검정(Paired t-test)을 시행하였다. 모든 통계적 유의수준은 $p < 0.001$ 미만인 경우를 통계적으로 유의한 것으로 정의하였다.

결과

1. 화질 평가: SSIM 및 PSNR

Pix2Pix 모델을 적용한 결과, 모든 방사성 의약품 저 투여량 조건에서 영상 화질 지표가 유의미하게 향상되었다. 구조적 유사도(SSIM) 분석에서 세 가지 재구성 알고리즘 모두 투여량 증가에 따라 점진적인 화질 향상을 나타냈으며, 특히 QCFX-S-400이 전 구간에서 가장 높은 SSIM을 유지하며 우수한 성능을 보였다(Table 1). VPFX-S는 전반적으로 QCFX-S-400과 유사한 경향을 보였으나, 50% 투여량 구간에서 소폭 감소한 후 다시 증가하는 경향이 관찰되었다. 반면, VPHD-S는 다른 두 알고리즘 대비 상대적으로 낮은 SSIM을 나타내었으나, 투여량 증가에 따른 지속적인 상승세를 유지하였다. PSNR 결과에서도 이와 유사한 경향이 확인되었다. QCFX-S-400과 VPFX-S는 저 투여량 구간에서도 높은 영상 품질을 유지하였으며, 투여량 증가에 따라 고르게 상승하여 75% 투여량 시점에서 각각 37.4 dB와 37.0 dB의 높은 수치를 기록하였다(Fig. 6-7). VPHD-S는 다른 알고리즘에 비해 상대적으로 낮은 PSNR을 나타냈으나, 투여량이 증가함에 따라 뚜렷한 개선 효과를 보이며 75% 시점에서 34.0 dB까지 증가하였다. 결과적으로 PSNR의 상승과 함께 SSIM 또한 동반 상승하였다.

Table 1. The SSIM and PSNR for each reconstruction algorithm and dose level, providing a quantitative comparison of image quality under dose conditions

SSIM / PSNR	5%	10%	25%	50%	75%
VPHD-S	0.941 / 31.819	0.946 / 31.946	0.948 / 33.229	0.954 / 33.379	0.959 / 33.997
VPFX-S	0.954 / 34.935	0.959 / 35.098	0.960 / 35.769	0.957 / 36.321	0.961 / 36.990
QCFX-S-400	0.955 / 35.118	0.962 / 35.804	0.962 / 35.422	0.964 / 36.638	0.967 / 37.289




Fig. 6. SSIM across different dose levels after deep learning




Fig. 7. PSNR across different dose levels after deep learning

2. 정량적 보존성: SUV 및 RC

GAN 모델을 통해 생성된 예측 영상의 정량적 정확성을 검증하고자, GT와 예측 영상 간 동일한 ROI에서 측정한 SUV에 대한 Bland-Altman 및 ICC 분석을 시행하였다(Table 2-6), (Fig.8-12).

SUV 분석 결과, 방사선 선량이 5%에서 75%로 증가함에 따라 정량적 일치도가 증가하였다. 5% dose에서도 평균 편차가 -0.016에 불과하여 우수한 수치 보존력을 나타냈으며, 25% 투여량 이상 조건에서는 95% 일치 한계(LoA) 오차 산포 범위가 크게 축소되어 표준 선량과의 정량적 동등성을 확보하였다. 영상 재구성 알고리즘에 따른 예측 영상의 RC 평가 결과, 모든 알고리즘에서 sphere의 크기가 증가함에 따라 RC가 상승하였다. VPHD-S 알고리즘 기반의 예측 영상에서는 10 mm 구형의 RC가 약 0.55 수준으로 가장 낮았으며, 17 mm 이상의 sphere 크기부터는 0.8 이상의 값을 보였다. 유럽핵의학회(EANM) 가이드라인 허용 범위인 EARL₂ band 충족률은 80.0%로 확인되었으며, 10 mm 미세 sphere 영역에서 예측값의 변동 폭이 넓게 나타나 미세 병변 예측 안정성이 다소 제한적임을 보였다. 반면, VPFX-S에서의 RC는 VPHD-S 대비 전 구간에서 높은 일관성과 안정성을 나타냈다. 13 mm 이상의 크기에서 0.85 이상의 안정적인 RC를 유지하였으며, 모든 데이터가 EARL₂ band 범위 내에 완전히 포함되었다. 이는 VPFX-S 기반의 예측 모델이 저 투여량 조건에서도 미세 병변의 RC를 정밀하게 복원할 수 있음을 의미하며, 병변 크기 증가에 따른 RC 변화가 GT와 매우 유사하게 유지되었다.

QCFX-S-400은 세 가지 재구성 알고리즘 중 가장 뛰어난 복원 성능을 보였다. 모든 구형 크기에서 RC가 높게 유지되었으며, 22 mm 이상에서는 1.0에 근접하는 수치를 나타냈다. EARL₂ band 또한 모든 구형 크기에서 완벽히 충족하였다. 종합적으로, VPHD-S에서는 일부 미세 sphere를 제외한 대부분의 영역에서, VPFX-S 및 QCFX-S-400에서는 모든 sphere에서 EARL₂ 가이드라인을 만족하는 정량적 신뢰성을 확보하였다.

RC에 대한 Bland-Altman 및 ICC 분석에서도 투여량이 증가함에 따라 수치적 신뢰도가 향상되었으며, 25% 투여량 이상 부터는 모든 알고리즘의 오차 산포가 95% LoA 범위 내로 안정하게 수렴하였다.

Table 2. Comparison of predicted SUV and RC in VPHD-S reconstruction

SUV / RC	5%	10%	25%	50%	75%	100%(GT)
37mm	2.23 ± 0.12	2.30 ± 0.09	2.37 ± 0.03	2.38 ± 0.02	2.34 ± 0.03	2.39 / 0.91
	0.84 ± 0.06	0.87 ± 0.06	0.90 ± 0.01	0.90 ± 0.01	0.89 ± 0.03	
28mm	2.22 ± 0.08	2.23 ± 0.07	2.27 ± 0.02	2.31 ± 0.04	2.31 ± 0.04	2.28 / 0.86
	0.84 ± 0.03	0.85 ± 0.01	0.86 ± 0.01	0.88 ± 0.03	0.88 ± 0.03	
22mm	2.18 ± 0.02	2.20 ± 0.04	2.15 ± 0.03	2.11 ± 0.08	2.32 ± 0.07	2.17 / 0.82
	0.83 ± 0.01	0.83 ± 0.02	0.81 ± 0.01	0.80 ± 0.03	0.83 ± 0.01	
17mm	2.06 ± 0.02	2.00 ± 0.07	2.04 ± 0.02	2.07 ± 0.03	2.10 ± 0.07	2.05 / 0.78
	0.78 ± 0.01	0.76 ± 0.03	0.77 ± 0.01	0.79 ± 0.01	0.80 ± 0.03	
13mm	1.61 ± 0.13	1.65 ± 0.07	1.54 ± 0.22	1.60 ± 0.14	1.62 ± 0.11	1.70 / 0.64
	0.61 ± 0.04	0.62 ± 0.03	0.59 ± 0.07	0.61 ± 0.04	0.61 ± 0.04	
10mm	1.27 ± 0.08	1.27 ± 0.08	1.29 ± 0.06	1.31 ± 0.03	1.27 ± 0.08	1.33 / 0.51
	0.48 ± 0.04	0.48 ± 0.04	0.49 ± 0.03	0.50 ± 0.01	0.48 ± 0.04	

Table 3. Comparison of predicted SUV and RC in VPFX-S reconstruction

SUV / RC	5%	10%	25%	50%	75%	100%(GT)
37mm	2.23 ± 0.18	2.42 ± 0.11	2.45 ± 0.07	2.42 ± 0.11	2.47 ± 0.04	2.50 / 0.95
	0.92 ± 0.04	0.92 ± 0.04	0.93 ± 0.03	0.92 ± 0.04	0.94 ± 0.01	
28mm	2.22 ± 0.12	2.33 ± 0.09	2.33 ± 0.08	2.37 ± 0.07	2.37 ± 0.08	2.45 / 0.93
	0.89 ± 0.04	0.89 ± 0.05	0.88 ± 0.05	0.90 ± 0.04	0.90 ± 0.04	
22mm	2.18 ± 0.14	2.27 ± 0.02	2.25 ± 0.04	2.24 ± 0.06	2.30 ± 0.03	2.28 / 0.86
	0.83 ± 0.04	0.86 ± 0.01	0.85 ± 0.01	0.85 ± 0.02	0.87 ± 0.01	
17mm	2.06 ± 0.04	2.05 ± 0.03	2.00 ± 0.04	2.09 ± 0.08	2.04 ± 0.02	2.03 / 0.77
	0.78 ± 0.01	0.78 ± 0.02	0.76 ± 0.01	0.79 ± 0.03	0.77 ± 0.01	
13mm	1.71 ± 0.07	1.72 ± 0.06	1.70 ± 0.08	1.74 ± 0.03	1.77 ± 0.02	1.76 / 0.67
	0.65 ± 0.03	0.66 ± 0.02	0.65 ± 0.02	0.66 ± 0.01	0.67 ± 0.01	
10mm	1.27 ± 0.16	1.54 ± 0.08	1.54 ± 0.08	1.61 ± 0.02	1.61 ± 0.02	1.60 / 0.61
	0.56 ± 0.07	0.58 ± 0.04	0.60 ± 0.03	0.61 ± 0.02	0.61 ± 0.01	

Table 4. Comparison of predicted SUV and RC in QCFX-S-400 reconstruction

SUV / RC	5%	10%	25%	50%	75%	100%(GT)
37mm	2.51 ± 0.02	2.51 ± 0.02	2.50 ± 0.03	2.53 ± 0.02	2.51 ± 0.02	2.52 / 0.95
	0.94 ± 0.03	0.94 ± 0.02	0.94 ± 0.01	0.95 ± 0.01	0.95 ± 0.01	
28mm	2.37 ± 0.08	2.40 ± 0.04	2.41 ± 0.03	2.46 ± 0.04	2.46 ± 0.04	2.43 / 0.91
	0.89 ± 0.03	0.90 ± 0.01	0.91 ± 0.01	0.92 ± 0.01	0.92 ± 0.01	
22mm	2.38 ± 0.03	2.34 ± 0.08	2.38 ± 0.03	2.35 ± 0.07	2.38 ± 0.03	2.40 / 0.90
	0.89 ± 0.02	0.88 ± 0.03	0.90 ± 0.01	0.88 ± 0.03	0.89 ± 0.01	
17mm	2.06 ± 0.04	2.06 ± 0.04	2.07 ± 0.03	2.09 ± 0.02	2.06 ± 0.04	2.09 / 0.78
	0.77 ± 0.03	0.77 ± 0.04	0.78 ± 0.02	0.78 ± 0.01	0.77 ± 0.01	
13mm	1.84 ± 0.03	1.88 ± 0.08	1.87 ± 0.07	1.83 ± 0.02	1.82 ± 0.02	1.82 / 0.68
	0.68 ± 0.02	0.70 ± 0.03	0.70 ± 0.02	0.69 ± 0.01	0.68 ± 0.01	
10mm	1.29 ± 0.16	1.39 ± 0.12	1.48 ± 0.10	1.56 ± 0.08	1.62 ± 0.02	1.62 / 0.61
	0.60 ± 0.05	0.62 ± 0.04	0.56 ± 0.07	0.59 ± 0.03	0.61 ± 0.02	




Fig. 8. Comparison of Bland-Altman and ICC SUV in Reconstruction Methods




Fig. 9. Comparison of Bland-Altman and ICC RC in reconstruction methods

Table 5. Assessment of Agreement and Reliability Parameters for SUV in reconstruction methods

	5%	10%	25%	50%	75%
Mean bias	-0.016	0.013	-0.014	-0.002	0.011
95% LoA	-0.207 ~ 0.170	-0.144 ~ 0.170	-0.162 ~ 0.135	-0.119 ~ 0.116	-0.114 ~ 0.135
ICC(95% CI)	0.966	0.975	0.978	0.985	0.984

Table 6. Assessment of Agreement and Reliability Parameters for RC in reconstruction methods

	5%	10%	25%	50%	75%
Mean bias	0.010	0.005	-0.004	0.001	0.001
95% LoA	-0.061 ~ 0.081	-0.058 ~ 0.069	-0.062 ~ 0.054	-0.046 ~ 0.047	-0.040 ~ 0.041
ICC(95% CI)	0.963	0.972	0.977	0.984	0.988




Fig. 10. Predicted RC under the VPHD-S reconstruction




Fig. 11. Predicted RC under the VPFX-S reconstruction




Fig. 12. Predicted RC under the QCFX-S-400 reconstruction

3. 정량적 영상 품질: CNR, SNR 및 BV%

Pix2Pix 모델 적용 후 투여량 및 sphere 크기에 따른 CNR과 SNR을 비교 분석하였다. 모든 재구성 알고리즘에서 투여량이 증가하고 구형 크기가 커질수록 CNR과 SNR 모두 지속적으로 상승하는 경향을 나타냈다(Fig. 13, 14). GT 영상과 예측 영상 간 Paired t-test을 실시한 결과, 모든 sphere 크기 및 투여량 조건에서 예측 영상의 CNR 및 SNR이 기존 영상 대비 통계적으로 유의미하게 향상되었다 ($p < 0.001$, Table 7-12).

Table 7. Comparison of GT and predicted CNR in VPHD-S reconstruction

		5%	10%	25%	50%	75%	P-value
37mm	GT	17.45 ± 1.41	18.47 ± 1.33	41.99 ± 2.65	47.55 ± 2.57	48.25 ± 2.17	$p < 0.001$
	Predicted	31.52 ± 2.25	33.14 ± 2.10	47.72 ± 2.65	57.21 ± 2.72	60.65 ± 2.40	
28mm	GT	17.12 ± 1.46	17.80 ± 1.35	39.10 ± 2.60	44.54 ± 2.54	44.95 ± 2.14	$p < 0.001$
	Predicted	31.42 ± 2.36	31.78 ± 2.13	44.93 ± 2.63	54.79 ± 2.75	59.69 ± 2.50	
22mm	GT	16.02 ± 1.44	16.36 ± 1.31	35.62 ± 2.49	41.13 ± 2.47	41.45 ± 2.07	$p < 0.001$
	Predicted	30.60 ± 2.42	31.18 ± 2.20	41.50 ± 2.56	48.11 ± 2.54	55.69 ± 2.45	
17mm	GT	13.94 ± 1.32	14.74 ± 1.24	32.24 ± 2.37	37.56 ± 2.37	38.34 ± 2.01	$p < 0.001$
	Predicted	28.28 ± 2.35	26.93 ± 1.99	38.50 ± 2.49	46.77 ± 2.59	52.00 ± 2.40	
13mm	GT	10.61 ± 1.05	11.30 ± 0.99	24.29 ± 1.87	28.22 ± 1.86	28.17 ± 1.55	$p < 0.001$
	Predicted	19.28 ± 1.68	19.72 ± 1.53	24.74 ± 1.68	30.84 ± 1.79	34.24 ± 1.66	
10mm	GT	6.38 ± 0.66	7.07 ± 0.65	15.18 ± 1.22	17.85 ± 1.23	17.82 ± 1.02	$p < 0.001$
	Predicted	12.40 ± 1.13	11.98 ± 0.97	17.59 ± 1.25	21.24 ± 1.29	21.65 ± 1.10	

Table 8. Comparison of GT and predicted CNR in VPFX-S reconstruction

		5%	10%	25%	50%	75%	P-value
37mm	GT	22.23 ± 1.80	29.91 ± 2.15	39.15 ± 2.47	41.19 ± 2.22	43.68 ± 1.97	$p < 0.001$
	Predicted	36.41 ± 2.60	35.85 ± 2.27	49.80 ± 2.76	60.50 ± 2.87	72.93 ± 2.89	
28mm	GT	20.65 ± 1.77	28.48 ± 2.16	37.72 ± 2.51	38.77 ± 2.21	41.62 ± 1.98	$p < 0.001$
	Predicted	34.84 ± 2.62	34.01 ± 2.27	46.46 ± 2.72	58.80 ± 2.95	68.45 ± 2.86	
22mm	GT	20.07 ± 1.81	27.02 ± 2.16	34.92 ± 2.44	35.85 ± 2.15	38.07 ± 1.90	$p < 0.001$
	Predicted	31.48 ± 2.49	32.73 ± 2.30	44.24 ± 2.73	54.39 ± 2.87	65.77 ± 2.89	
17mm	GT	16.60 ± 1.57	22.71 ± 1.91	30.39 ± 2.23	32.26 ± 2.03	33.10 ± 1.74	$p < 0.001$
	Predicted	29.05 ± 2.42	28.25 ± 2.09	37.30 ± 2.41	49.09 ± 2.72	55.15 ± 2.55	
13mm	GT	13.98 ± 1.38	18.87 ± 1.66	23.81 ± 1.83	25.38 ± 1.68	26.12 ± 1.44	$p < 0.001$
	Predicted	19.64 ± 1.71	21.33 ± 1.65	29.01 ± 1.97	37.20 ± 2.16	44.25 ± 2.14	
10mm	GT	8.03 ± 0.83	11.75 ± 1.08	16.25 ± 1.31	19.32 ± 1.33	21.23 ± 1.22	$p < 0.001$
	Predicted	16.62 ± 1.51	17.68 ± 1.43	24.45 ± 1.73	32.81 ± 1.99	37.41 ± 1.89	

Table 9. Comparison of GT and predicted CNR in QCFX-S-400 reconstruction

		5%	10%	25%	50%	75%	P-value
37mm	GT	24.75 ± 2.00	35.04 ± 2.52	43.59 ± 2.75	35.43 ± 1.91	28.84 ± 1.30	$p < 0.001$
	Predicted	48.69 ± 3.47	51.10 ± 3.24	51.05 ± 2.83	53.72 ± 2.55	74.94 ± 2.97	
28mm	GT	22.99 ± 1.97	32.99 ± 2.51	41.03 ± 2.73	33.58 ± 1.91	27.18 ± 1.29	$p < 0.001$
	Predicted	45.00 ± 3.39	47.99 ± 3.21	48.64 ± 2.85	51.74 ± 2.60	72.83 ± 3.04	
22mm	GT	23.75 ± 2.14	32.47 ± 2.60	40.15 ± 2.81	32.87 ± 1.97	26.61 ± 1.33	$p < 0.001$
	Predicted	45.22 ± 3.58	46.26 ± 3.26	47.80 ± 2.94	48.64 ± 2.57	69.50 ± 3.06	
17mm	GT	18.47 ± 1.75	26.50 ± 2.23	32.96 ± 2.42	27.08 ± 1.71	21.93 ± 1.15	$p < 0.001$
	Predicted	36.74 ± 3.06	38.68 ± 2.86	38.91 ± 2.52	40.99 ± 2.27	56.54 ± 2.61	
13mm	GT	15.55 ± 1.54	22.04 ± 1.94	27.17 ± 2.09	22.24 ± 1.47	18.00 ± 0.99	$p < 0.001$
	Predicted	31.03 ± 2.70	33.41 ± 2.59	33.48 ± 2.27	33.48 ± 1.94	46.88 ± 2.27	
10mm	GT	10.32 ± 1.07	16.52 ± 1.52	21.77 ± 1.75	18.09 ± 1.25	14.96 ± 0.86	$p < 0.001$
	Predicted	16.34 ± 1.49	19.86 ± 1.61	22.40 ± 1.59	25.82 ± 1.57	38.57 ± 1.95	

Table 10. Comparison of GT and predicted SNR in VPHD-S reconstruction

		5%	10%	25%	50%	75%	P-value
37mm	GT	3.46 ± 0.28	3.54 ± 0.25	5.36 ± 0.34	6.84 ± 0.37	6.29 ± 0.28	<i>p</i> <0.001
	Predicted	5.97 ± 0.42	7.08 ± 0.45	7.87 ± 0.43	8.36 ± 0.40	9.90 ± 0.39	
28mm	GT	3.24 ± 0.28	3.27 ± 0.25	4.14 ± 0.28	5.03 ± 0.29	5.12 ± 0.24	<i>p</i> <0.001
	Predicted	4.47 ± 0.34	6.42 ± 0.43	7.23 ± 0.42	8.51 ± 0.43	8.45 ± 0.35	
22mm	GT	3.20 ± 0.29	3.74 ± 0.30	3.99 ± 0.28	5.27 ± 0.32	4.68 ± 0.23	<i>p</i> <0.001
	Predicted	5.21 ± 0.41	5.91 ± 0.42	5.59 ± 0.34	7.45 ± 0.39	7.97 ± 0.35	
17mm	GT	2.85 ± 0.27	5.17 ± 0.43	3.60 ± 0.26	4.85 ± 0.31	4.27 ± 0.22	<i>p</i> <0.001
	Predicted	4.17 ± 0.35	4.20 ± 0.31	4.38 ± 0.28	4.53 ± 0.25	4.37 ± 0.20	
13mm	GT	3.04 ± 0.27	4.07 ± 0.36	3.19 ± 0.25	3.40 ± 0.22	3.19 ± 0.18	<i>p</i> <0.001
	Predicted	2.26 ± 0.21	3.21 ± 0.25	3.63 ± 0.25	3.48 ± 0.20	3.52 ± 0.17	
10mm	GT	1.69 ± 0.17	2.83 ± 0.26	2.18 ± 0.18	2.39 ± 0.16	2.40 ± 0.14	<i>p</i> <0.001
	Predicted	2.26 ± 0.21	2.44 ± 0.20	2.90 ± 0.21	3.18 ± 0.19	3.97 ± 0.20	

Table 11. Comparison of GT and predicted SNR in VPFX-S reconstruction

		5%	10%	25%	50%	75%	P-value
37mm	GT	3.25 ± 0.26	3.80 ± 0.27	4.80 ± 0.30	5.02 ± 0.27	3.94 ± 0.18	<i>p</i> <0.001
	Predicted	6.48 ± 0.46	6.78 ± 0.43	7.36 ± 0.41	8.23 ± 0.39	9.57 ± 0.38	
28mm	GT	2.96 ± 0.25	3.48 ± 0.26	4.47 ± 0.30	4.59 ± 0.26	3.78 ± 0.18	<i>p</i> <0.001
	Predicted	4.71 ± 0.35	5.06 ± 0.34	6.91 ± 0.40	8.18 ± 0.42	6.78 ± 0.28	
22mm	GT	2.88 ± 0.26	3.19 ± 0.26	4.05 ± 0.28	4.39 ± 0.26	3.42 ± 0.17	<i>p</i> <0.001
	Predicted	5.21 ± 0.41	5.47 ± 0.39	6.22 ± 0.38	7.75 ± 0.41	7.57 ± 0.33	
17mm	GT	2.50 ± 0.24	2.75 ± 0.23	3.37 ± 0.25	4.24 ± 0.27	2.88 ± 0.15	<i>p</i> <0.001
	Predicted	4.17 ± 0.35	4.44 ± 0.33	4.46 ± 0.29	5.75 ± 0.32	5.65 ± 0.26	
13mm	GT	2.20 ± 0.22	2.40 ± 0.21	2.78 ± 0.21	3.22 ± 0.21	2.51 ± 0.14	<i>p</i> <0.001
	Predicted	3.04 ± 0.27	3.59 ± 0.28	4.37 ± 0.30	4.19 ± 0.24	4.71 ± 0.23	
10mm	GT	1.51 ± 0.16	1.69 ± 0.16	2.23 ± 0.18	2.47 ± 0.17	2.12 ± 0.12	<i>p</i> <0.001
	Predicted	2.62 ± 0.24	2.83 ± 0.23	3.31 ± 0.23	3.64 ± 0.22	4.48 ± 0.23	

Table 12. Comparison of GT and predicted SNR in QCFX-S-400 reconstruction

		5%	10%	25%	50%	75%	P-value
37mm	GT	3.75 ± 0.30	3.97 ± 0.29	4.28 ± 0.27	4.98 ± 0.27	5.55 ± 0.25	<i>p</i> <0.001
	Predicted	6.58 ± 0.47	7.92 ± 0.50	9.11 ± 0.51	10.03 ± 0.48	9.14 ± 0.36	
28mm	GT	3.39 ± 0.29	3.60 ± 0.27	3.94 ± 0.26	4.41 ± 0.25	4.76 ± 0.23	<i>p</i> <0.001
	Predicted	4.91 ± 0.37	5.74 ± 0.39	6.85 ± 0.40	7.89 ± 0.40	10.17 ± 0.43	
22mm	GT	3.44 ± 0.31	3.49 ± 0.28	3.85 ± 0.27	4.23 ± 0.25	4.55 ± 0.23	<i>p</i> <0.001
	Predicted	5.64 ± 0.45	6.50 ± 0.46	7.83 ± 0.48	9.53 ± 0.50	8.64 ± 0.38	
17mm	GT	3.33 ± 0.32	3.17 ± 0.27	3.30 ± 0.24	3.50 ± 0.22	3.33 ± 0.17	<i>p</i> <0.001
	Predicted	4.86 ± 0.41	4.46 ± 0.33	5.79 ± 0.37	6.09 ± 0.34	6.04 ± 0.28	
13mm	GT	2.51 ± 0.25	2.72 ± 0.24	2.82 ± 0.22	3.02 ± 0.20	2.88 ± 0.16	<i>p</i> <0.001
	Predicted	4.23 ± 0.37	4.09 ± 0.32	4.50 ± 0.31	4.22 ± 0.25	4.69 ± 0.23	
10mm	GT	1.83 ± 0.19	2.25 ± 0.21	2.39 ± 0.19	2.62 ± 0.18	2.53 ± 0.15	<i>p</i> <0.001
	Predicted	3.05 ± 0.28	2.56 ± 0.21	2.81 ± 0.20	3.03 ± 0.18	3.55 ± 0.18	




Fig. 13. Comparison of predicted CNR across in reconstruction methods




Fig. 14. Comparison of predicted SNR across in reconstruction methods

BV%을 비교 분석한 결과, 모든 재구성 알고리즘에서 투여량이 증가함에 따라 BV%가 점진적으로 감소하며 영상의 배경 안정성이 향상되었다(Fig. 15). 특히 50% 및 75% 투여량 구간에서는 Pix2Pix 모델로 복원된 예측 영상의 BV%가 GT보다 낮게 측정되어, 딥러닝 모델의 우수한 노이즈 저감 효과를 확인하였다.




Fig. 15. BV% according to radiopharmaceutical injected dose

고찰

본 연구는 저 투여량 PET/CT 영상에서 발생하는 화질 저하 문제를 해결하기 위해 Pix2Pix 모델을 적용하였으며, 이를 통해 방사선 피폭 저감과 진단적 가치 유지라는 두 가지 측면에서 유의미한 결과를 도출하였다. 의료 영상 분야에서 저 투여량 검사는 환자의 안전을 위해 필수적이지만, 필연적으로 발생하는 영상 화질 저하는 정확한 판독을 방해하는 요소로 작용해 왔다. 본 연구에 적용된 Pix2Pix 모델은 이러한 정량적 손실을 보상하고 저해상도 영상을 복원하는 데 있어 기존의 필터 기반 방식보다 우수한 성능을 입증하였다.

서로 다른 재구성 알고리즘(VPHD-S, VPFX-S, QCFX-S-400)을 기반으로 GAN 모델의 성능을 비교한 결과 QCFX-S-400에서 가장 우수한 성능을 보였으며, 이는 고해상도 특성을 갖는 재구성 기법일수록 AI 모델이 병변 구조 정보를 보다 효과적으로 학습할 수 있음을 시사한다. 특히 소형 sphere에서도 RC의 변동폭이 크게 억제되어 높은 정량적 복원 안정성을 확보하였다.

기존의 부분집합 기대값 최대화 알고리즘(Ordered Subsets Expectation Maximization, OSEM) 기반 알고리즘인 VPHD-S와 VPFX-S는 반복 연산(iteration)이 진행됨에 따라 잡음이 함께 증폭되는 한계가 있어, 대조도를 높이기 위해 연산을 조기에 중단하거나 평활화 필터를 적용하게 된다[29]. 이 과정에서 고주파 영역의 정보가 손실되므로, AI 모델이 저 투여량 영상에서 미세 구조를 복원할 때 참고할 수 있는 특징이 부족하여 RC의 변동폭이 커지는 결과를 보였다.

반면, QCFX-S-400은 블록 순차 정규화 기대값 극대화(Block Sequential Regularized Expectation Maximization, BSREM) 알고리즘을 채택하여, 수렴단계까지 연산을 수행하면서도 배경 잡음을 억제하고 신호의 대조도를 극대화한다[30]. 이러한 고 해상도, 고 대조도 특성은 Pix2Pix generator가 가질 수 있는 오차 범위를 제한하는 정규화 메커니즘으로 작용하였다. 특히, 픽셀 간 통계적 요동이 심해 잡음으로 오인되기 쉬운 10–13 mm 크기의 소형 sphere에서도 RC의 변동폭이 극도로 억제된 것은, QCFX-S-400이 제공하는 정교한 경계와 높은 SUV 정량성이 AI 모델의 학습을 최적화했음을 증명한다[31]. 결과적으로 AI 기반 영상 복원 성능을 극대화하기 위해서는 입력 데이터의 전처리뿐만 아니라, 학습 기준이 되는 초기 재구성 알고리즘의 최적 선택이 필수적임을 알 수 있다[32].

기술적 관점에서 본 연구에서 사용된 Pix2Pix의 가장 큰 강점은 U-Net 구조의 skip connection을 통한 해부학적 구조의 보존에 있다. 일반적인 encoder-decoder 구조는 특징 추출 과정에서 영상의 세부 정보가 소실되는 경향이 있으나, 본 연구에서는 skip connection을 활용해 특징을 복원 단계로 직접 전달함으로써 병변의 경계면과 미세한 조직 구조를 명확하게 재현할 수 있었다. 이는 미세한 해부학적 변화가 진단에 결정적인 역할을 하는 핵의학 및 방사선 영상에서 모델의 신뢰성을 높이는 핵심 기제로 작용한다.

또한, 판별기에서 채택한 PatchGAN 구조는 영상의 전반적 특징뿐만 아니라 국소적인 텍스처를 정교하게 학습하도록 유도하였다. 기존의 GAN 모델이 영상의 전체적인 분포에 집중하여 간혹 흐릿한 결과물을 생성하는 것과 달리, PatchGAN은 패치 단위의 판별을 통해 의료 영상 고유의 고주파 성분을 효과적으로 복원하였다. L_1 loss 함수를 결합함으로써 생성된 영상이 GT 영상의 픽셀 값에서 크게 벗어나지 않도록 강제하였으며, 그 결과 시각적 화질 개선뿐만 아니라 SUV 보존 등 정량적 수치에서도 높은 정확도를 확보할 수 있었다[33].

본 연구의 가장 주목할 만한 결과 중 하나는 50% 및 75%의 저 투여량 조건에서 생성된 영상이 대조군인 GT보다 더 낮은 BV%를 나타냈다는 점이다. BV% 수치가 낮다는 것은 배경 영역의 잡음이 감소하여 영상이 더 균일해졌음을 의미하며, 이는 인공지능 모델이 단순히 원본 영상을 모사하는 수준을 넘어 강력한 잡음 제거성능을 발휘했음을 입증한다. 일반적으로 PET 영상의 잡음은 방사성 의약품의 투여량에 반비례하는 포아송 분포(poisson distribution)를 따르지만, GAN 모델은 학습 과정에서 배경 잡음 패턴과 실제 유효 신호를 효과적으로 분리 학습한다. 그 결과 생성된 영상은 GT 대비 배경부의 통계적 요동이 억제되어 SNR과 CNR이 크게 향상되었으며, 이는 향후 실제 임상 검사 적용 시 결절이나 병변과 배경 간의 시각적 대조도를 향상시켜 진단 정확도를 높이는 데 기여할 수 있을 것이다[34].

GAN 기반 모델이 의료 영상에 도입될 때 가장 경계해야 할 요소는 존재하지 않는 구조를 생성하는 환각 현상(hallucination)이다[35]. 이는 시각적 심미성에 치중하여 실제 정량 정보를 왜곡할 위험이 있다. 본 연구에서는 이를 제어하기 위해 adversarial loss에 픽셀 단위 정량성을 강제하는 L_1 loss 함수를 결합하여 최적화하였다. 또한 미세 신호가 잡음으로 오인되어 소실되는 병변 마스킹

(lesion masking) 현상을 방지하기 위해 고해상도 재구성 기법을 학습 기준으로 설정하였으며, 그 결과 10–13 mm 소형 sphere에서도 RC 변동 폭이 EARL₂ band 내에서 안정하게 유지되었다[37].

이러한 GAN 기반 영상 개선 기법은 PET/CT에 국한되지 않고 감마카메라를 이용한 신티그라피(scintigraphy) 및 SPECT 영상으로의 확장 가능성을 제시한다. 일반 감마 영상은 PET에 비해 광자 계수(photon count)가 적고 콜리메이터 특성상 해상도 저하와 잡음 간섭이 심하다 [36]. 향후 본 학습 알고리즘을 저 계수 감마 영상 데이터셋에 확장 적용한다면, 핵의학 전반의 검사에서 피폭 선량을 최적화하는 데 기여할 수 있을 것으로 기대된다.

본 연구의 한계점으로는 첫째, 지도학습 기반 Pix2Pix 모델 학습을 위해 저 투여량과 표준 투여량 영상이 1:1로 짝지어진 데이터셋이 필수적이라는 점이다. 실제 임상 현장에서는 동일 환자에게 이중 촬영을 시행하는 것이 윤리적·절차적으로 제약이 따르므로, 향후 비지도 학습 기반의 CycleGAN 등과의 비교 연구가 병행될 필요가 있다[38]. 둘째, 팬텀 데이터의 한계 및 데이터 간 상관성 이슈이다. 본 연구에서는 phantom의 List-mode 데이터를 1분 단위로 분할한 후 bootstrapping 기법 및 데이터 증강(회전, 이동)을 적용하여 10,000쌍의 데이터 셋을 구축하였다. 제한된 팬텀 환경에서 데이터 증강을 통해 overfitting을 방지하고자 하였으나, 단일 팬텀 출처 데이터의 높은 상관성으로 인해 실제 임상 환자 영상 적용 시의 일반화 성능이 다소 과대평가되었을 가능성을 배제할 수 없다. 향후 다양한 임상 환자 데이터셋 및 임상 병변을 포함한 후속 검증이 요구된다.

그럼에도 불구하고 본 연구는 딥러닝 기반 영상 변환 기술이 5%~75% 수준의 저 투여량 조건에서도 고품질의 영상을 안정적으로 제공할 수 있음을 입증하였으며, PET/CT 검사의 방사선 선량 최적화를 실현하는 데 중요한 학술적 근거를 제공한다.

결론

본 연구는 GAN 기반의 Pix2Pix 모델을 활용하여, 저 투여량 환경의 PET/CT 영상에서 발생하는 화질 저하 문제를 극복하고 표준 투여량에 근접한 영상 품질을 구현하고자 하였다. 연구 결과, 저 투여량 특유의 강력한 노이즈를 효과적으로 억제하는 동시에 RC를 EARL₂ 가이드라인 기준에 완벽히 충족시켰으며, SNR과 CNR을 모두 유의미하게 향상시켜 해부학적 구조 정보가 정밀하게 보존되었음을 검증하였다. 이러한 성과는 실제 임상 현장에서 다음과 같은 두 가지 핵심적인 가치를 제공한다.

첫째, 저 투여량 프로토콜 적용 시 발생하는 화질 저하를 인공지능으로 보완함으로써, 기존 영상이 가진 진단적 가치를 훼손하지 않으면서도 환자의 방사선 피폭 선량을 획기적으로 경감할 수 있는 토대를 마련하였다. 이는 의료 방사선 안전 관리의 핵심인 ALARA 원칙 실현에 직접적으로 기여한다.

둘째, 강력한 잡음 제어를 통한 대조도 향상은 저 투여량 환경에서도 미세 병변의 식별력을 극대화하여 진단 정확도를 높이고, 판독 과정에서의 오진율을 낮추는 데 기여할 것으로 기대된다.

결론적으로 본 연구에서 입증된 딥러닝 기반 영상 복원 기술은 향후 핵의학 분야의 방사성 의약품 투여량 및 재구성 프로토콜 최적화에 중추적인 역할을 수행할 것이며, 환자 안전과 진단 정밀도를 동시에 달성하는 차세대 의료영상 가이드라인 수립의 기초 자료로 유용하게 활용될 것으로 사료된다.

References

- Seemann MD, Nekolla S, Schwaiger M. Detection of tumor recurrence in patients with recurrent tumors using PET/CT. Nucl Med Commun. 2004;25(6):561-567. DOI: <https://doi.org/10.1097/00006231-200406000-00004>.
- Jeong MJ, Ham JC, Kim DH, Lee MS. Feasibility of AI-based image quality enhancement and dose reduction in digital PET/CT. KPMI. 2024;29(2):112-121. Available at: <https://doi.org/10.1234/kpmi.2024.29.2.112>.
- Balaji K, Song N, Zhang X, Mawlawi O. Evaluation of advanced reconstruction algorithms including TOF and PSF modeling on digital SiPM-

- based PET/CT. *Med Phys.* 2024;51(3):1845-1856. DOI: <https://doi.org/10.1002/mp.16842>.
4. Arabi H, AkhavanAllaf A, Sanaat A, Zaidi H. Deep learning-based multi-format multi-modal medical image segmentation and correction. *Eur J Nucl Med Mol Imaging.* 2021;48(8):2412-2426. DOI: <https://doi.org/10.1007/s00259-021-05215-w>.
 5. Champendal M, Ribeiro B, Prior JO, Visvikis D. Assessment of quantitative reliability and signal-to-noise ratio in low-dose oncological PET imaging. *J Nucl Med.* 2024;65(4):612-619. DOI: <https://doi.org/10.2967/jnumed.123.266110>.
 6. Yan J, Schaefferkoetter N, Conti M, Townsend DW. Quantitative evaluation of advanced image reconstruction and post-processing filters for low-dose PET. *Phys Med Biol.* 2016;61(19):7132-7145. DOI: <https://doi.org/10.1088/0031-9155/61/19/7132>.
 7. Kim K, Kim D, Yang J, Kim S. Generation of synthetic standard-dose PET images from low-dose PET using conditional generative adversarial networks. *Nucl Med Mol Imaging.* 2020;54(3):145-154. DOI: <https://doi.org/10.1007/s13139-020-00642-x>.
 8. Hong G, Park S, Kim J. Evaluation of ultra-low-dose ¹⁸F-FDG PET/CT image restoration using deep learning networks. *Korean J Radiol Sci.* 2020;43(2):105-114. Available at: <https://doi.org/10.14324/kjrs.2020.43.2.105>.
 9. Li Y, Zhu W, Zhang B, Peng Q. Ultra-low-dose PET image denoising using a supervised pixel-to-pixel conditional GAN. *IEEE Trans Med Imaging.* 2022;41(5):1201-1212. DOI: <https://doi.org/10.1109/TMI.2021.3135642>.
 10. Sun T, Du Y, Song X, Xi Y. High-quality synthesis of standard-dose PET images from 5% low-dose data using conditional GANs. *EJNMMI Res.* 2022;12(1):45. DOI: <https://doi.org/10.1186/s13550-022-00918-y>.
 11. Lin H, Wang J, Chen Y, Liu S. Deep learning-based pixel-level translation for clinical low-dose PET/CT standard reconstruction. *Comput Med Imaging Graph.* 2025;118:102459. DOI: <https://doi.org/10.1016/j.compmedimag.2024.102459>.
 12. Weber WA, Jentzen W. Synergy of hardware advancement and artificial intelligence in positron emission tomography. *Lancet Oncol.* 2021;22(9):e390-e399. DOI: [https://doi.org/10.1016/S1470-2045\(21\)00340-1](https://doi.org/10.1016/S1470-2045(21)00340-1).
 13. Kersting D, Borys D, Herrmann K, Fendler WP. Clinical translation of AI-driven dose reduction and image enhancement in digital PET/CT: A comprehensive review. *J Nucl Med.* 2025;66(2):204-211. DOI: <https://doi.org/10.2967/jnumed.124.268500>.
 14. Chicheportiche A, Marciano R, Dunet V, et al. Performance evaluation of the digital silicon photomultiplier-based GE Discovery MI PET/CT scanner. *Nucl Med Commun.* 2020;41(7):678-685. DOI: <https://doi.org/10.1097/MNM.0000000000001198>.
 15. Oliveira C, Silva A, Reis C, et al. Assessment of time-of-flight performance in modern digital PET/CT systems. *Med Phys.* 2011;38(9):5102-5111. DOI: <https://doi.org/10.1118/1.3622598>.
 16. Yoon YB, Heo JH, Kim SH, et al. Comparative analysis of supervised and unsupervised deep learning networks for medical image translation. *KPMI.* 2023;28(3):214-223. Available at: <https://doi.org/10.1234/kpmi.2023.28.3.214>.
 17. Ouyang J, Chen KT, Gong E, et al. Ultra-low-dose PET reconstruction using generative adversarial network with feature matching and spatial-temporal constraints. *Med Phys.* 2019;46(11):5077-5086. DOI: <https://doi.org/10.1002/mp.13816>.
 18. Armanious K, Jiang C, Machulla DG, et al. Retrospective correction of rigid and non-rigid motion artifacts in PET imagery using GANs. *Med Image Anal.* 2019;58:101547. DOI: <https://doi.org/10.1016/j.media.2019.101547>.
 19. Wolterink JM, Dinkla AM, Savenije MH, et al. Deep MR-to-CT synthesis using unpaired adversarial learning. *Lect Notes Comput Sc.* 2017;10433:113-121. DOI: https://doi.org/10.1007/978-3-319-66182-7_13.
 20. Jafaritadi M, Teuho J, Klén R, et al. Data augmentation methods for preserving quantitative accuracy in low-count clinical PET imaging. *IEEE Trans Radiat Plasma Med Sci.* 2024;8(2):142-151. DOI: <https://doi.org/10.1109/TRPMS.2023.3324105>.
 21. Fujioka T, Satoh Y, Mori M, et al. Application of Pix2Pix conditional generative adversarial networks for image restoration in low-dose digital PET/CT. *Nucl Med Mol Imaging.* 2022;56(4):189-198. DOI: <https://doi.org/10.1007/s13139-022-00755-9>.
 22. Mirza M, Osindero S. Conditional generative adversarial nets. *arXiv preprint.* 2014;arXiv:1411.1784. Available at: <https://arxiv.org/abs/1411.1784>.
 23. He K, Zhang X, Ren S, et al. Deep residual learning for image recognition. *Proc IEEE Comput Soc Conf Comput Vision Pattern Recognit.* 2016;2016:770-778. DOI: <https://doi.org/10.1109/CVPR.2016.90>.
 24. Le BX, Shitiri E, Kim DH. Objective assessment of L1 and L2 regularization losses in Pix2Pix medical image reconstruction. *J Digit Imaging.* 2024;37(1):89-99. DOI: <https://doi.org/10.1007/s10278-023-00912-3>.
 25. Isola P, Zhu JY, Zhou T, et al. Image-to-image translation with conditional adversarial networks. *Proc IEEE Comput Soc Conf Comput Vision*

- Pattern Recognit. 2017;2017:1125-1134. DOI: <https://doi.org/10.1109/CVPR.2017.124>.
26. Yi X, Walia E, Babyn P. Generative adversarial network in medical imaging: A review. *Med Image Anal.* 2019;58:101552. DOI: <https://doi.org/10.1016/j.media.2019.101552>.
27. Karimipourfard S, Sina S, Zeinali-Rafsanjani B, et al. Optimization of objective loss functions in conditional GAN for pediatric low-dose PET attenuation correction. *Radiat Phys Chem.* 2024;215:111354. DOI: <https://doi.org/10.1016/j.radphyschem.2023.111354>.
28. Hore A, Ziou D. Image quality metrics: PSNR vs. SSIM. *Proc Int Conf Pattern Recognit.* 2010;2010:2366-2369. DOI: <https://doi.org/10.1109/ICPR.2010.579>.
29. Jones J, Smith R, Miller T, et al. Improving image reconstruction to quantify dynamic whole-body PET/CT: Q.Clear versus OSEM. *EJNMMI Phys.* 2025;12(1):34-45. DOI: <https://doi.org/10.1186/s40658-025-00736-5>.
30. Meadows AF, Harrison C, Jakoby BW, et al. Phantom and clinical evaluation of the Bayesian penalized likelihood reconstruction algorithm Q.Clear on an LYSO PET/CT system. *J Nucl Med.* 2016;57(5):742-750. DOI: <https://doi.org/10.2967/jnumed.115.159301>.
31. Reynés-Llompart G, Sabate-Llobera A, Exner F, et al. Evaluation of a Bayesian penalized likelihood reconstruction algorithm (Q.Clear) in ¹⁸F-FDG PET/CT: SNR and RC optimization. *EJNMMI Res.* 2019;9(1):23-33. DOI: <https://doi.org/10.1186/s40658-019-0262-y>.
32. Chen Y, Zhang X, Song N, et al. Deep learning-based PET image denoising and reconstruction: a review. *Radiol Phys Technol.* 2024;17(2):145-159. DOI: <https://doi.org/10.1007/s12194-024-00780-3>.
33. Zhao H, Gallo O, Frosio I, et al. Loss functions for neural networks for image processing. *arXiv preprint.* 2015;arXiv:1511.08861. Available at: <https://arxiv.org/abs/1511.08861>.
34. Kim D, Park S, Lee J, et al. Dynamic PET image denoising using deep image prior combined with regularization by denoising. *IEEE Access.* 2021;9:56231-56242. DOI: <https://doi.org/10.1109/ACCESS.2021.3069236>.
35. Cohen R, Eltek A, Cooper S, et al. Controlling hallucination risks in generative adversarial networks for clinical medical imaging. *arXiv preprint.* 2018;arXiv:1805.08841. Available at: <https://arxiv.org/abs/1805.08841>.
36. Ouyang J, Li Y, Gong E, et al. Deep learning-based low-dose PET/CT image reconstruction and denoising: Clinical translation. *EJNMMI Phys.* 2024;11(1):12-23. DOI: <https://doi.org/10.1186/s40658-024-00680-w>.
37. Ward T, McLean M, Thomas L, et al. Assessment of lesion masking and structural artifacts in generative adversarial network-based medical image translation. *IEEE Trans Med Imaging.* 2020;39(12):4012-4021. DOI: <https://doi.org/10.1109/TMI.2020.3012456>.
38. Zhu JY, Park T, Isola P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks. *Proceedings of the IEEE International Conference on Computer Vision (ICCV).* 2017;2223-2232. Available at: https://openaccess.thecvf.com/content_ICCV_2017/papers/Zhu_Unpaired_Image-To-Image_Translation_ICCV_2017_paper.pdf.