Journal of RADIATION INDUSTRY
Vol. 18, No. 4, pp. 399-404, 2024
https://doi.org/10.23042/radin.2024.18.4.399

Original article

SLAM 시스템과의 연계를 통한 3D 선량률 예측 심층신경망 모델 개발

곽다희[1] · 박평원[1] · 양인수[2] · 유보현[1,*]

[1]고등기술연구원, [2]한국전력기술(주)

Development of 3D Dose Rate Prediction DNN Model in conjunction with SLAM System

Dahui Kwack[1], Pyeongwon Park[1], Insu Yang[2], and Bohyun Ryu[1,*]

[1]Institute for Advanced Engineering, 175-28, Goan-ro 51beon-gil, Baegam-myeon, Cheoin-gu, Yongin-si, Gyeonggi-do 17180, Republic of Korea
[2]KEPCO E&C, Inc., 269, Hyeoksin-ro, Gimcheon-si, Gyeongsangbuk-do 39660, Republic of Korea

ABSTRACT Based on the principle of ALARA (As Low As Reasonable Achievable), workers in radiation field of should check their effective dose using dosimeters in the workplace and ensure that it does not exceed 50mSv per year, and 100 mSv for 5 years. However, the dosimeter, which has been mainly used such as a thermoluminescence dosimeter (TLD), is a method of evaluating the accumulated dose through post-processing and cannot be utilized to prevent additional exposure in real-time. This research team developed a Deep Neural Network (DNN) model that generates a 3D dose rate distribution map based on a Simultaneous Localization And Mapping (SLAM) algorithm considering time and location by combining the dosimeter and LiDAR sensor. The developed SLAM algorithm not only records the x, y, z coordinates and dose rates on the moving path, but also outputs a 3D point cloud data (PCD) that scans the entire space. Furthermore, to increase the prediction accuracy, d, which is the distance to the highest dose rate measurement location, was calculated through PCD and utilized in the DNN model. Finally, the DNN model was trained by setting the moving path coordinates and distance as input data and the dose rate as output data. The indoor/outdoor PCD and distance were used as inputs to the DNN model to predict the dose rate distribution for the entire space. The predicted value was integrated into the PCD file by setting the color map in proportion to its intensity. Finally, a system to predict the dose rates for the entire scan area and display them on the scanned 3D map was proposed. The generated 3D map can be used for follow-up management to minimize the exposure dose for the workers by enabling the prediction of the risk area for the entire area.

Key words: Dose Rate 3D Map, Survey meter, LiDAR, Simultaneous Localization and Mapping, Deep Neural Network

1. 서 론

사회적 이익을 위해 원자력을 활용하는데 있어, 작업자의 방사선 피해를 최소화하기 위한 방사선 장해 방어 전략은 무엇보다 중요하다. 이를 보장하기 위하여 '모든 피폭은 사회적 경제적 인자를 고려하면서 합리적으로 달성 가능한 낮게 유지해야 한다"는 ALARA 원칙은 국제방사선방호위원회에 의해 1970년대 도입되었다[1]. 해당 원칙에 의해 규정된 규제에 근거하여, 방사선 작업자들의 유효선량은 연간 50 mSv, 5년간 100 mSv를 초과해서는 안 된다. 이 규제는 특히 가동원전 혹은 원전해체와 같이 높은 선량이 예상되는 현장 작업자들에게 더욱 엄격히 지켜져야 한다.

가동원전 작업자의 경우, 일반적으로 열형광선량계, 유리선량계, 필름뱃지 등과 같은 개인 선량계를 착용하여 작업시간동안 누적된 피폭선량을 확인한다. 그러나 이러한 선량계의 경우 전문 판독 기관에서의 판독 작업이 필요하기에 실시간으로 작업자들이 받는 피폭선량을 실시간으로 모니터링할 수는 없다. 대안으로 실시간 피폭선량(률) 측정 및 확인을 위한 보조선량계를 사용하고 있으나, 보조 선량계의 데이터는 작업자에게 그 시점의 선량률을 알려 줄 뿐 따로 취합되거나 분석되어 사용되지는 못하고 있다. 그 외에도 가동 원전 내부에는 고선량이 예측되는 주요 지역들에 계측기를 설치해 감시한다. 그러나 이는 고정된 위치의 계측값을 주기적으로 기록할 뿐 모니터링의 개념은 아니

ISSN 1976-2402 http://www.ksri.kr/

Copyright© 2024 by Korean Society of Radiation Industry

*Corresponding author: Bohyun Ryu
Tel: +82-31-330-7438, E-mail: zzigee@iae.re.kr

Received 9 December 2024 Revised 23 December 2024 Accepted 24 December 2024

며, 특히 경상 및 계획예방정비 기간마다 방사능 오염원의 이동이 예상되나 이를 반영하지 못한다는 한계가 있다.

원전해체 현장은 이러한 실시간 모니터링의 부재가 더욱 문제가 된다. 원자로 및 증기발생기 등의 해체가 진행되면서 현장의 구조는 지속적으로 바뀌며, 그에 따른 오염원의 이동뿐만 아니라 방사능 물질의 직접적인 누출도 발생할 수 있다. 이에 철거 및 제염활동 등으로 인한 방사선(능) 준위의 변화 및 구조물의 변화를 추적관리하기 위하여 LiDAR를 이용한 3D 공간 스캔 기술의 적용은 많은 연구자들에 의해 고려되고 있다[2,3,4]. 그러나 해당 기술은 고정형으로 여러 포인트에서의 스캔이 요구되며, 스캔 데이터는 몇 개월 정도의 전문가 후처리 작업이 필요하기에 실시간으로 구조물의 변화가 예상되는 해체작업 현장에 도입되기는 적합하지 않다. 즉, 지속적으로 변화하는 현장의 구조를 추적관리 하면서, 작업자의 피폭량을 최소화하기 위한 기술의 개발이 부재하다.

후쿠시마 원전사고와 같은 원전 사고는 예상치 못한 방사성 물질의 누출을 야기했다. 그 결과 전혀 예상할 수 없는 구역에서 고선량 피폭의 위험이 발생할 수 있기에, 전체 현장 구조에 대한 방사선(능) 분포를 알수 있는 기술의 개발이 요구되어 왔다. Katagiri et al. [5]과 Sato et al. [6]은 Compton camera를 이용하여 건물 내부의 고선량 오염을 가시화하였으며, 가시화 영상을 스캐닝 LRF를 이용하여 3차원 방사선 분포도를 그렸다. 이후에는 Compton 카메라와 3D 스캔 장비를 이용하여 통합 방사선 이미징 시스템을 개발하였다 [7]. 그러나 해당 연구는 이동형 3D 스캔 결과인 PCD에 Compton 결과를 후처리 과정을 통해 단순히 함께 표시했을 뿐, 실시간으로 데이터를 연계하지 못하며 전체 공간에 대한 방사능 분포를 보여주지는 못한다.

특정 위치가 아닌 3D 영역에서의 방사능 또는 선량 예측은 매우 큰 연산 부하를 요구하게 된다. 이에 Lee 등[8]은 머신 러닝을 적용해 보다 낮은 코스트로 3D 방사능을 평가하는 기술을 개발하였다. 그러나 이는 공간이 아닌 구조물 내부의 방사능을 평가하기 위한 것으로, 현장 작업자의 피폭 방지를 위한 기술은 아니었다. 본 연구팀은 이러한 한계를 탈피하기 위해 이동형 3D 스캔 결과와 선량계 측정을 연계하고, 측정 데이터를 활용해 실시간 3D 선량률 지도를 생성하는 심층신경망(Deep Neural Network, DNN) 모델을 개발하였다[9]. 이 기술은 작업자의 이동경로에 따라 측정된 선량률과 3D 공간 스캔 데이터를 연계해 취득된 데이터들을 기반으로 DNN 모델을 학습시켜 전체 공간에 대한 선량률을 예측한 3D 선량률 분포 지도를 생성한다. 그러나 당시의 DNN 모델로 예측한 지도의 경우 선량률이 실제보다 과대 평가되고 선원의 위치가 실제와는 동떨어져 있다는 문제가 있었다. 이에 본 연구에서는 보다 합리적인 선량률과 선원 위치 예측이 가능한 3D 선량률 지도를 생성하기 위하여 기존 DNN 모델을 개선하기 위한 연구를 수행하였다. 선량률이 거리 자승에 반비례하는 것을 반영하기 위하여 거리 인자를 모델 학습 및 예측에 활용하였으며, 개선 모델의 예측 결과를 기존 모델과 비교 분석하였다.

2. 재료 및 방법

본 연구에서 개발한 3D 선량률 분포 지도 생성 기술의 구조를 Fig. 1에 나타내었다. 먼저 3D 스캔 데이터와 선량 계측값을 동시에 연계하여 처리하는 Simultaneous Localization And Mapping (SLAM) 시스템을 구축하였으며, 이를 2장 1절에 서술하였다. 구축한 SLAM 시스템의 출력 데이터들로 전체 공간에 대한 선량 평가를 하는 DNN 모델을 개발하였으며, 이를 2장 2절에 서술하였다. 작업자는 공간 스캔 후 모델을 학습시켜 간단히 전체 공간에 대한 3D 선량률 지도를 생성하고 확인할 수 있다.

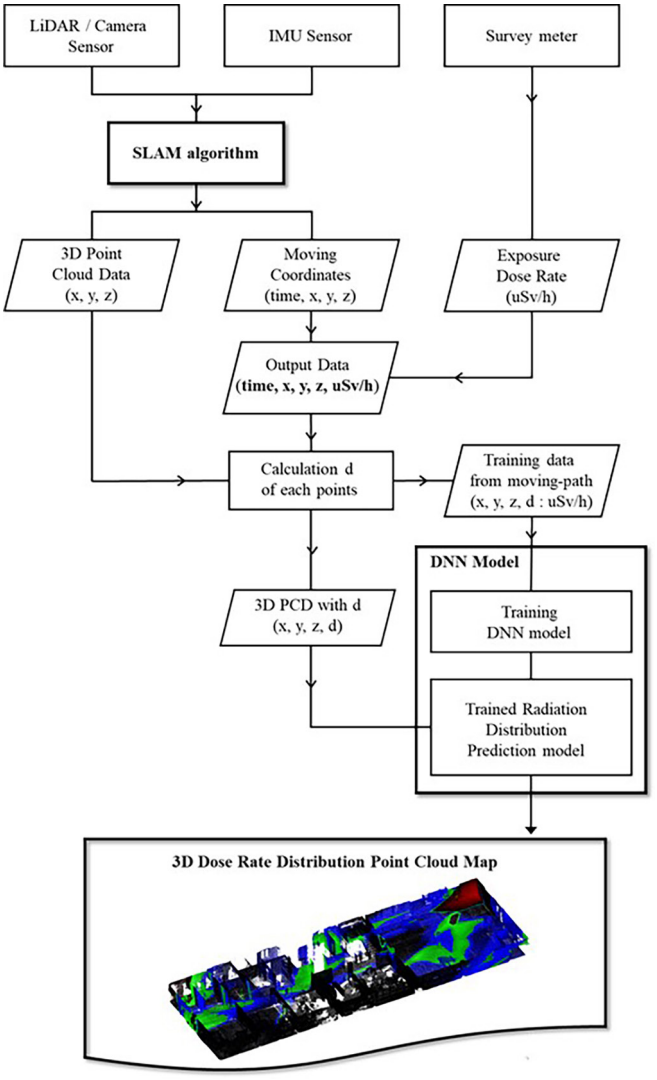

Fig. 1. Block diagram of developed system which combining SLAM and DNN model

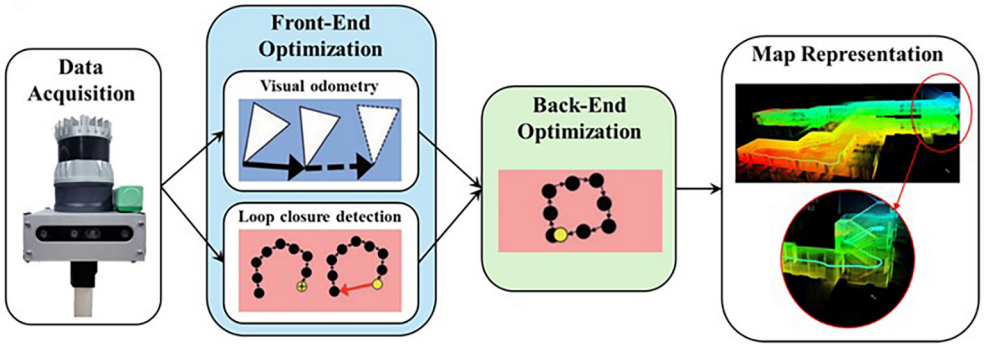

Fig. 2. Basic pipeline of SLAM algorithm

2.1. 선량계와 연계된 SLAM 시스템 개발

기본적인 SLAM 알고리즘의 파이프라인은 Fig. 2과 같다 [10]. 먼저 LiDAR 장비를 사용해 주변 환경에 대한 정보를 획득한다. 이후 연속된 데이터로부터 특징을 추출하고 대응관계를 수립, 센서의 상대적인 움직임을 예측하는 시각적 주행 거리 측정(Visual odometry) 과정을 수행한다. 그와 동시에 현재 센서가 있는 위치가 이전에 방문한 위치인지를 판단하는 루프 폐쇄 검출(Loop closure detection)을 수행한다. 여기까지가 프론트엔드 최적화(Frontend) 과정이며, 이후 불확실성을 제거하고 일관성 있는 지도를 만들기 위해 백엔드 최적화(Backend optimization) 과정을 수행한다. 백엔드 최적화 과정에서는 현재 센서의 자세와 주변 환경의 특징점을 추출해 그래프 노드로 표현하고 노드 사이의 제약조건을 그래프 엣지로 표현하여 모든 제약조건을 최소화하는 형태로 센서의 자세와 특징점 위치를 최적화한다. 이 최적화된 정보를 이용하여 지도를 생성하는 절차를 거쳐 3D point cloud map을 생성할 수 있으며, 최종적으로 전체 스캔한 공간에 대한 PCD 파일을 출력하게 된다. 개발한 SLAM 시스템의 공간 스캔 정확도를 평가하기 위하여 공인시험을 수행한 결과, 스캔 데이터와 실제와의 오차는 5 m 기준 0.08 m로 매우 높은 정확도를 나타내었다.

실시간으로 작업자의 이동좌표를 검출하기 위해서는 LiDAR 뿐 아니라 IMU 또한 필요하다. IMU 데이터는 프리적분 기법을 통해 초기 위치 및 자세 변화를 고속으로 추정하며 LiDAR 데이터를 기반으로 위치를 업데이트한다. 그리고 관성측정장치(Inertial Measurement Unit, IMU)와 LiDAR 데이터를 결합한 비선형 최적화 과정을 통해 최종 위치를 추정하게 된다. 본 연구에서는 보다 정확한 3D 스캔과 경로 추적을 위하여 SLAM 알고리즘 중 FAST-LiO [11]를 채택하여 사용하였다. FAST-LiO는 건물 내부와 같은 small-scale mobile에서도 내비게이션을 실용적으로 만들기 위한 계산에 효율적이고, 빠른 움직임이나 진동 노이즈에 대해 강한 LiDAR-inertial odometry 패키지이다. 그리고 작업자의 위치를 최종 추정하는 시점에서 survey meter로부터 수신된 공간선량 데이터를 함께 정합하여 기록하게 되며, survey meter로는 에너지 보상형 GM 계측기를 활용하였다. 최종적으로 작업자의 이동경로 좌표와 선량률이 매치된 csv 파일을 출력하게 된다.

Table 1. The detailed information of the developed DNN model

Category	Constituent	Setting
Model Structure	Input Data	x, y, z + d
	Output Data	Predicted dose rate
	Hidden Layer	8 (1^{st}: 100~8^{th}: 2)
Data set distribution	Training	60%
	Validation	20%
	Test	20%
Training Method	Optimizer	Adam optimizer
	Learning rate	0.001 (default)
	Epoch	4000
	Loss function	Mean Square Error

2.2. 거리 인자를 고려한 DNN 모델 개발

본 연구에서는 SLAM 시스템에서 출력된 데이터들을 이용하여 전체 스캔 공간에 대한 선량률 지도를 생성하고자 DNN 모델을 개발하였으며 [9], 자세한 기존 DNN 모델 구조는 Table 1에서 입력 인자 중 d를 제외한 것과 같다. 파이토치는 Facebook AI Research (FAIR)에서 개발한 오픈소스 딥러닝 프레임워크로, DNN 모델을 구축하고 학습하는 데에 사용되었다. 모델 아키텍처는 다층 퍼셉트론(Multilayer Perceptron, MLP) 기반의 DNN으로 설계되었다. 총 8개의 은닉층으로 구성되었으며, 각 은닉층은 LeakyReLU 활성화 함수를 사용하였다. 각 층의 뉴런 수의 경우 첫 번째 은닉층은 100으로 시작하고 점차 감소하여 8번째 은닉층의 뉴런 수는 2개로 구성되었다. 모델 학습에는 Adam 옵티마이저를 사용하였으며 Adam [12]은 모멘텀을 고려한 적응적 학습률을 제공하여 빠른 수렴과 높은 성능을 보장한다. 학습률은 기본값인 0.001을 사용하였다. 입력 데이터의 분

할 및 배치 구성은 전체 데이터를 훈련, 검증, 테스트 세트로 분할하였으며 데이터 분할 비율은 훈련 데이터 60%, 검증 데이터 20%, 테스트 데이터 20%로 설정하였다. 데이터 분할 전에 torch.randperm을 사용하여 데이터를 무작위로 섞었으며 모델은 총 4000 epoch 동안 학습하였고, 배치 사이즈는 128로 설정하였다. 손실 함수로는 평균 제곱 오차(MSE)를 사용하였으며 모델의 성능을 평가하기 위해 R^2 점수를 사용하였다.

기존 DNN 모델은 학습을 위하여 SLAM 시스템에서 csv 파일로 출력된 100 msec마다의 이동경로 x, y, z 좌표와 선량률 데이터가 사용되었다. 그리고 LiDAR 스캔으로 생성한 3차원 PCD의 x, y, z 좌표를 학습된 모델에 입력해 전체 공간에 대한 선량률을 예측하였다. 기존 모델의 3D 선량률 지도 예측 결과, 작업자 이동 경로에만 크게 의존하게 되어 선량률이 증가하는 방향의 경향성이 과도하게 반영되어 예측 선량률이 과대평가되는 문제가 존재했다. 또한 경향성에 의해 실제 선원의 위치가 아닌 선량률이 증가하던 방향의 끝 지점에서 최고 선량률이 예측되어 실제 선원의 위치를 특정할 수 없었다.

본 연구에서는 기존 모델의 한계를 탈피하기 위하여 x, y, z뿐 아니라 최고 선량률이 기록된 지점까지의 거리인 d값을 입력 데이터에 추가하였다. 선량률은 거리 자승에 반비례하기 때문에 거리 인자를 고려함에 따라 선량률 과대평가 문제를 해결할 수 있을 것으로 판단하였다. 또한 기존 모델처럼 경향성에 과대의존해 선원의 위치가 선량률이 증가하는 방향의 끝지점으로 판단되는 것보다 최고 선량률이 측정되었던 지점을 선원의 위치로 가정하는 것이 합리적이라고 판단하였다. 이에 d를 최고 선량률이 측정된 지점까지의 거리로 정의해 이동경로의 x, y, z 좌표와 거리 값인 d를 입력 데이터로 설정하였다. 다운 샘플링이 수행된 전체 PCD에 대해서도 d값을 계산하였으며, 전체 공간에 대한 PCD 좌표와 d값은 학습된 DNN 모델에 입력되었다. 최종적으로 각 point에 대한 방사선량의 예측치를 출력하여 3D 선량률 분포 지도를 생성하게 된다.

3. 결과 및 고찰

DNN 모델의 예측 결과를 확인하기 위하여 밀봉 선원을 이용한 실험을 진행하였다. 실험은 건물 내부 방안에 선원을 두고 공간을 스캔하며 진행되었으며, 같은 데이터를 활용해 기존 DNN 모델과 본 연구에서 개발한 DNN 모델이 예측한 3D 선량률 지도 결과를 비교하였다.

실험은 선원 사용 허가를 받은 계측기 제작 회사인 Nucare에서 진행되었으며, 회사 건물의 구조와 경로, 실험 공간에 대해 Fig. 3에 나타내었다. 공간선량 측정을 위해 선원을 2층 우측 room A 안쪽에 삼각 거치대를 이용해 배치하였다. 실험에 사용된 선원은 Cs-137로 자세한 정보는 Table 2에 정리하였다. 사용된 GM 카운터에서 충분히 계측 가능하도록 3개의 방사선원을 함께 사용하였으며 3개 모두 2010년 3월 제작된 10 μCi 선원이다. 실험일인 2024년 4월 기준으로 총 방사능은 최대 21.7 μCi였다. 스캔은 선원이 위치한 2층 큰 방인 Room A를 대상으로 진행되었으며, 방의 크기는 14 m×13 m×3 m로 스캔에 소요된 시간은 약 5분 정도였다.

Table 2. Information of the used sources

List	Material / Value
Radioactive nuclide	Cs-137
Activity	10 μCi
Date of production	Mar. 2010
Number of sources	3
Total activity at test date	~21.7 μCi

스캔 데이터를 통해 개발한 DNN 모델로 예측한 3D 선량률 지도를 Fig. 4에 나타냈다. 거리 'd' 추가에 따른 변화를 확인하기 위하여 이전 연구에서의 DNN 모델 예측결과를 Fig. 3의 (a)에, 본 연구에서 개발한 DNN 모델의 예측 결과를 (b)에 나타내 비교하였다. 모델 학습에 소요된 시간은 10분 정도로, 스캔 공간의 복잡도에 따라 다르나 약 500 m^3 정도의 규모에서 10분 정도로 소요되는 것을 알 수 있었다.

두 모델의 차이는 입력 인자에 'd'가 포함되었는지 여부밖에 없었으나, Fig. 4에서 알 수 있듯이 매우 다른 결과를 보여준다. 가장 큰 차이는 예측한 선량률의 최대값이다. 실제 스캔 당시 선원 바로 옆에서 가장 높은 선량률인 3.4 μSv/h가 계측되었나, 기존 DNN 모델의 경우 최대 선량률을 17 μSv/h 수준으로 예측하였다. 그러나 d를 고려해 개발된 DNN 모델의 경우 최대 선량률을 3.0 μSv/h 수준으로, 실제와 비슷하게 예측한 것을 알 수 있다. 무엇보다 이번 DNN 모델은 실제 선원의 위치 부근에서 가장 높은 선량이 예측되었다. 실험당시 선원을 위치시켰던 곳은 우측 상단 모서리보다 2 m가량 안쪽이었으나, 기존 모델은 경로의 경향성이 크게 반영되어 모서리 측에서 최고 선량이 예측되었다. 그러나 개선된 DNN 모델의 경우 Fig. 4의 (b)와 같이 실제 선원 위치 부근에서 최고 선량이 나타나고 모서리까지 일관되게 높게 예측되었던 선량률이 낮아진 것을 확인할 수 있다. 그럼에도 room A 위쪽 벽면 부근에서 비교적 높은 선량이 예측되었는데, 이는 d를 고려하였음에도 벽면쪽 경로에서 측정된 선량률이 다른 경로 대비 높았기 때문으로 판단된다. 현재 시스템에 연계된 선량계는 단순한 2 inch 직경의 보상형 GM 계측기로, 방사능이 입사하는 방향 등이 고려되지 못하기 때문에 사용자가 장치를 드는 자세 등에 따라 값이 다르게 측정될 수 있어 발생한 현상이라고 예상된다.

본 실험의 결과를 통해 개발한 예측 모델이 전체 공간에 대하여 보다 현실적인 3D 선량률 분포 지도를 생성할 수 있다는 것을 확인하였다. 선원의 위치 식별이 가능해졌으며, 예측한 선량

Fig. 3. The structure of the space where the sources were located and moving-path for scanning

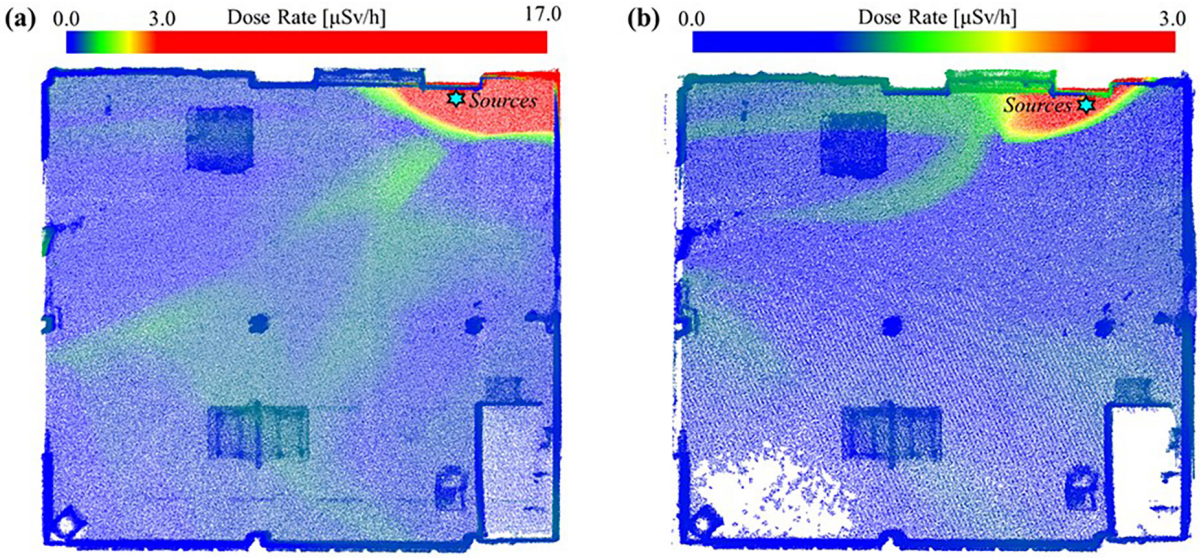

Fig. 4. 3D dose rate distribution maps: (a) was predicted by previous DNN model without 'd' and (b) was predicted by developed DNN model with considering 'd'

률 또한 과대평가되지 않고 정확도가 향상되었다. 그러나 여전히 작업자 이동 경로에서의 선량률에 의존하기 때문에 사실과는 다른 부분들이 존재했다. 이는 모델 학습 시에는 공간 안쪽 이동 경로 좌표에서의 공간선량 값만 활용되나, 모델이 예측하는 것은 스캔된 공간 표면의 선량이기에 단순한 회귀 모델로는 외삽이라는 한계가 있어 정확한 예측이 어려워지기 때문이다. 또한 현재 장치에는 방향성이 고려되지 않은 선량계가 사용되었기에 DNN을 이용해 가장 단순한 형태로 지도를 생성할 수밖에 없었다. 추후 정확한 3D 공간 표면 선량으로 내삽의 영역에서 지도를 생성하기 위해 방향성을 고려할 수 있도록 collimeter를 장착한 계측기를 연계 활용해 3D 선량 지도를 생성해 보고자 한다.

4. 결 론

본 연구는 3D 공간 스캔 장비인 LiDAR 데이터와 공간선량 측정을 위한 선량계 측정값을 실시간으로 연계하는 시스템을 구축하고, 정합된 데이터를 통해 스캔한 전체 공간에 대한 방사 선량률 지도를 생성하는 DNN 모델을 개발하였다. 본 시스템은 비

전문가인 현장 작업자도 직접 3D 스캔을 수행할 수 있으며, 협소하고 복잡한 건물 내/외부를 자유롭게 이동하면서도 측정이 가능하다. 또한 10분 안쪽의 시간으로 DNN 모델을 통해 3D 선량률 분포 지도를 생성할 수 있으며, 이 지도는 정확한 공간 선량률을 대표할 수는 없지만 작업공간에 대한 전체적인 선량률 분포를 판단하기 위해 활용될 수 있다. 원전 해체현장 같은 경우, 일간 단위의 작업현장 모니터링 및 방사능 오염원 추적 관리에 사용될 수 있다.

그러나 본 시스템은 계측된 공간선량률 값과 3D 선량률 분포 지도의 정확성 측면에서 명확한 한계가 있다. 단순한 보상형 GM 계측기를 연동하였기에 방향성이 결여되었으며, 경로기반의 데이터로 학습시키고 공간 표면의 선량을 예측하였기에 3D 지도의 타당성이 부족하다. 이에 본 연구팀은 보다 적절한 검출기에 collimeter를 장착해 방향성을 고려하고자 하며, 추가적으로 핵종 분석기를 연계하여 보다 정확한 3D 표면선량 지도 생성을 달성하고자 한다.

사 사

본 연구 성과는 산업통상자원부(MOTIE)의 재원으로 한국에너지기술평가원(KETEP)의 지원과 과학기술정보통신부(MIST)의 재원으로 한국연구재단(NRF)의 지원을 받아 수행된 연구임 (No. 20224B10300090 & No. RS-2022-00165166).

참고문헌

1. ICRP 1977. Recommendations of the ICRP, *ICRP Publication 26*, Ann. ICRP 1 (3).
2. MacFarlane JW, Payton OD, Keatley AC, Scott GPT, Pullin H, Crane RA, Smilion M, Popescu I, Curlea V and Scott TB. 2014. Lightweight Aerial Vehicles for Monitoring, Assessment and Mapping of Radiation Anomalies. *Journal of Environmental Radioactivity* **136**:127-130. https://doi.org/10.1016/j.jenvrad.2014.05.008.
3. Martin PG, Payton OD, Fardoulis JS, Richards DA and Scott TB. 2015. The Use of Unmanned Aerial Systems for the Mapping of Legacy Uranium Mines. *Journal of Environmental Radioactivity* **143**:135-140. https://doi.org/10.1016/j.jenvrad.2015.02.004.
4. Simons M, Schepper D, Demeester E and Schroeyers W. 2024. Localization of hotspots via a lightweight system combining Compton imaging with a 3D lidar camera, *Nuclear Engineering and Technology* **56**(8):3188-3198. https://doi.org/10.1016/j.net.2024.03.020.
5. Katagiri H, Satoh W, Enomoto R, Wakamatsu R, Watanabe T, Muraishi H, Kagaya M, Tanaka S, Wada K, Tanaka M and Uchida T, 2018. Development of an all-sky gamma-ray Compton camera based on scintillators for high-dose environments. *Journal of Nuclear Science and Technology* **55**(10):1172-1179. https://doi.org/10.1080/00223131.2018.1485598.
6. Sato Y, Tanifuji Y, Terasaka Y, Usami H, Kaburagi M, Kawabata K, Utsugi W, Kikuchi H, Takahira S and Torii T. 2018. Radiation imaging using a compact Compton camera inside the Fukushima Daiichi Nuclear Power Station building, *Journal of Nuclear Science and Technology* **55**(9):965-970. https://doi.org/10.1080/00223131.2018.1473171.
7. Sato Y and Terasaka Y. 2022. Radiation imaging using an integrated Radiation Imaging System based on a compact Compton camera under unit 1/2 exhaust stack of Fukushima Daiichi Nuclear Power Station. *Journal of Nuclear Science and Technology* **59**(6):677-687. https://doi.org/10.1080/00223131.2021.2001391.
8. Lee U, Chang P, Jung N, Jang J, Lee J and Lee H. 2024. Machine learning-based evaluation technology of 3D spatial distribution of residual radioactivity in large-scale radioactive structures, *Nuclear Engineering and Technology* **56**:3199-3209. https://doi.org/10.1016/j.net.2024.03.021.
9. Kwack D, Park P, Kim Y and Ryu B. Development of Real-time Path-based 3D Dose Rate Mapping System. *Nuclear Engineering and Technology* under review.
10. Shin D and Chang H. 2023. Understanding and Implementing SLAM with NVIDIA Jetson Nano. https://lnkd.in/g8En7kQX, pages 29-33.
11. Xu W and Zhang F. 2021. FAST-LIO: A Fast, Robust LiDAR-inertial Odometry Package by Tightly-Coupled Iterated Kalman Filter, *IEEE Robotics and Automation Letters* **6**(2):3317-3324. https://doi.org/10.48550/arXiv.2010.08196.
12. Kingma DP and Ba J. 2015. Adam: A method for stochastic optimization, in: Proc. *3rd Int. Conf. on Learning Representations*, San Diego. https://doi.org/10.48550/arXiv.1412.6980.