

채널 임펄스 응답을 이용한 FFNN 기반 환경 매핑

차경주, 이재복, 정민수, 정현진, 김선우
한양대학교 융합전자공학과

{lovelyckj, ok7393, qwjms, hyeonjingo, remero}@hanyang.ac.kr

FFNN based Environment Mapping with Channel Impulse Response

Kyeong-Ju Cha, Jaebok Lee, Minsoo Jeong, Hyeonjin Chung, and Sunwoo Kim
Department of Electronic Engineering, Hanyang University

요약

기존 radio SLAM (simultaneous localization and mapping) 기술은 낮은 연산량과 높은 정확도를 목표로 활발하게 연구되었다. 하지만, 이들은 공통적으로 알고리즘 성능 분석 시 매우 간단한 전파 환경을 가정하였기에 이를 실제의 복잡한 환경에 적용하기에는 한계가 있다. 이를 극복하기 위해 본 논문에서는 3GPP (3rd generation partnership project) 기고문을 고려한 open office 전파 환경을 구축하였다. Ray-tracing 방법을 통해 수집한 채널 임펄스 응답(channel impulse response : CIR)을 이용한 FFNN (feed forward neural network) 기반 환경 매핑 기법을 제안한다. MATLAB 시뮬레이션을 통해 벽 개수와 학습 횟수에 따른 매핑 성능을 통하여 제안 방법의 실효성을 분석한다.

I. 서론

최근, 통신 신호에 더 높은 주파수, 더 넓은 대역폭을 고려하기 시작하면서 통신 신호를 센싱에 이용하는 ISAC (integrated sensing and communication) 기술이 주목받고 있다[1]. ISAC의 대표 application인 radio SLAM(simultaneous localization and mapping)은 알려지지 않은 환경에서 전파 신호로 사용자의 위치를 정확하게 추정하며, 동시에 주변 환경의 구조를 알아내는 기술이다[2]. 기존의 radio SLAM 연구는 알고리즘 성능을 위해 매우 간단한 전파 환경을 가정하였기에 이를 실제의 복잡한 환경에 적용하기에는 한계가 있다[3]. 이를 해결하기 위해, 본 논문은 3GPP (3rd generation partnership project) 기고문의 parameter를 반영하여 open office 환경을 구성하고, ray-tracing을 진행하여 채널 임펄스 응답(channel impulse response : CIR)을 수집한다. 수집된 CIR을 이용한 환경 매핑을 구현하기 위하여 FFNN (feed forward neural network)[4] 기반 매핑 기법을 제안하였으며, MATLAB 시뮬레이션을 통해 벽 개수와 학습 횟수에 따른 환경 매핑 성능을 분석한다.

II. Ray-tracing 환경 및 FFNN 모델

1) Ray-tracing 환경 구축

3GPP 기고문 [5, Sec. 6.1]의 Scenario 1. open office 파라미터를 기반으로 전파 환경을 구축하였다. 120m×50m×10m 크기의 공간을 구성하여 2m 두께의 콘크리트 벽과 1.5m 높이의 UE (user equipment) 안테나, 3m 높이의 BS (base station) 안테나를 배치하였다. 캐리어 주파수는 30GHz, 전송 전력은 23dBm, 수신기 감도는 -100dBm, 시스템 손실은 0dB로 설정하였으며, ray의 최대 반사 횟수는 1회이다.

다양한 전파 환경을 고려하기 위하여 환경 내 벽의 수를 1개부터 4개까지 늘려가며 open office 환경을 구성하였다. 본 논문에서는 120m×2m×10m 크기의 type 1 벽과 2m×50m×10m 크기의 type 2 벽을 고려하였다. 벽이 1개인 경우는 type 1 벽 1개를, 벽이 2개인

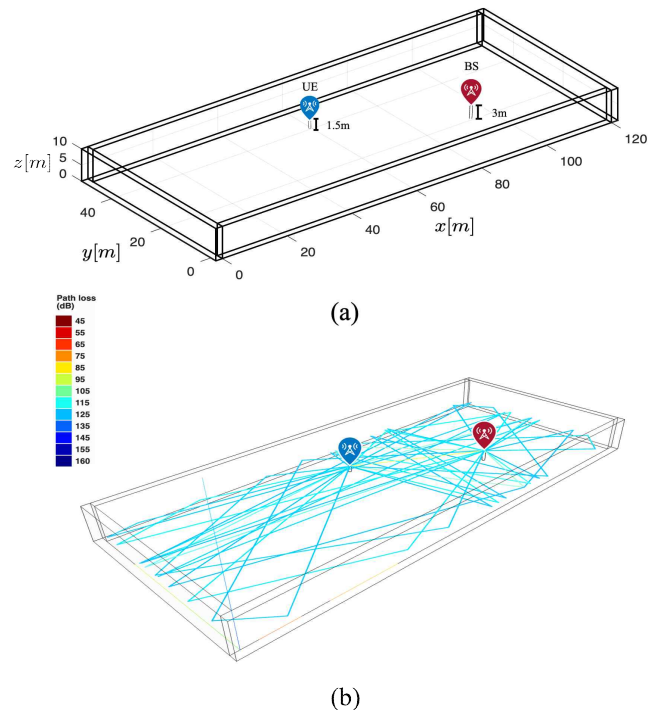


그림 1. 벽 4개, Tx 1개, Rx 1개를 배치한 전파 환경 (a) 3D 구축 환경, (b) ray-tracing 예시

경우는 type 1 벽 1개와 type 2 벽 1개를, 벽이 3개인 경우는 type 1 벽 1개와 type 2 벽 2개를, 벽이 4개인 경우는 type 1 벽 2개와 type 2 벽 2개를 설정하였다. 벽의 개수에 관계없이 UE와 BS의 안테나는 120m×50m 범위 안에서 임의로 배치하여 레이 트레이싱을 진행하였다. 그림 1은 벽 4개, BS 1개, UE 1개를 배치한 ray-tracing 환경의 예시이다.

2) FFNN 입출력 데이터 모델

Ray-tracing을 통해 BS에서 UE까지의 전파 경로 추적 결과와 앞서 언급한 시나리오 파라미터를 통하여 채널을 모델링한다. 해당

표 1. FFNN 학습에 사용된 하이퍼 파라미터

파라미터	값
은닉층 수	1
은닉층 하나당 노드의 수	10
입력 노드	306×1
출력 노드	3n×1
Epoch 수	100
목표 성능	0.001
훈련 함수	Levenberg-Marquardt

채널 모델로부터 채널 이득을 계산하고, 채널 필드 계수를 추출하여 CIR 데이터를 생성한다. 시간 t 에서 CIR $h(t)$ 는 다음과 같이 모델링된다.

$$h(t) = \sum_{k=1}^K c_k \delta(\tau - \tau_k), \quad (1)$$

이 때, K 는 다중 경로의 수이고, c_k 는 k 번째 경로에 대한 채널 이득이며, $\delta(\tau - \tau_k)$ 는 Dirac's delta function이다. τ_k 는 k 번째 시간 지연으로 $\tau_k \in [0, \frac{1}{f_s})$ 이며, f_s 는 subcarrier spacing이다. 본 연구에서는 그림 2와 같이 CIR 데이터 중 유의미한 값을 가지는 300개 sample 구간의 magnitude를 수집하였다. 결과적으로 Ray-tracing 환경에서 설정한 BS의 3차원 위치 좌표, 300 sample의 CIR 데이터를 입력 데이터로 설정하고, 모든 VA의 3차원 위치 좌표를 출력 데이터로 설정하였다. 이 때, 실제 VA의 위치는 ray가 반사된 벽을 기준으로 BS의 대칭점이다.

3) FFNN 신경망 모델

신경망은 표 1과 같이 은닉층 1개, 10개의 노드로 구성하였으며, 입력 노드와 출력 노드는 시뮬레이션에서 설정한 데이터셋의 수에 따라 다르게 설정하였다. 1개의 입력 노드는 306×1 크기의 벡터, 1개의 출력노드는 3n×1 크기의 벡터이며 (n : 벽의 수) 훈련 알고리즘은 비선형 최소 제곱 문제를 푸는 방법 중 하나인 LM (Levenberg-Marquardt) 알고리즘으로 지정하였다.

III. 시뮬레이션 결과 및 분석

FFNN 기반 매핑 알고리즘에 대한 시뮬레이션은 표 1과 같이 MATLAB에서 100의 epoch, 0.001의 성능 목표로 진행되었다. 수집한 데이터 중 훈련과 검증에 50%, 성능 테스트에 50%가 사용되었다. 시뮬레이션은 데이터셋의 수를 10, 100, 1000, 10000으로 설정하였으며, 입력출력 노드 수 또한 이와 동일하게 지정하였다.

제안 FFNN 알고리즘을 성능을 분석하기 위하여 환경 내 벽 개수와 데이터셋의 수에 따른 VA 추정 오차를 RMSE(root mean squared error)를 통해 그림 3과 같이 나타내었다. 이를 통해 벽 개수와 무관하게 학습 횟수가 증가함에 따라 모든 VA의 위치 추정 정확도가 향상됨을 확인하였다. 시뮬레이션 결과 벽이 3개인 경우 학습 횟수가 10회부터 10000회으로 증가할 때 매우 빠른 속도로 성능이 향상되었으며, 벽이 4개인 경우 다른 경우들에 비해 대체로

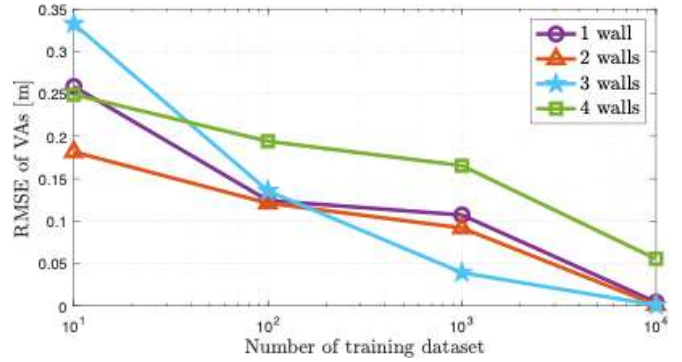


그림 3. 벽 개수와 학습 횟수에 따른 VA 추정 성능 비교

성능이 떨어짐을 볼 수 있다.

IV. 결론

본 논문에서는 3GPP 기고문을 고려한 open office 파라미터를 반영하여 환경을 구축하였다. 그리고, ray-tracing 방법을 통해 획득한 CIR을 입력으로 하는 FFNN 기반 환경 매핑 기법을 제안하였다. 제안 방법의 VA 추정 성능 분석을 위하여 MATLAB 시뮬레이션을 진행하였으며, 벽 개수와 학습 횟수에 따라 성능을 분석하였다. 분석 결과, 학습 횟수가 증가할수록 VA 추정 성능 또한 증가함을 확인하였으며 제안 방법을 통하여 CIR 데이터를 활용한 VA 추정이 가능함을 검증하였다.

ACKNOWLEDGMENT

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. NRF-2023R1A2C3002890).

참 고 문 헌

- [1] F. Liu, Y. Cui, C. Masouros, J. Xu, T. X. Han, Y. C. Eldar, and S. Bu, "Integrated sensing and communications: Towards dualfunctional wireless networks for 6G and beyond," *IEEE J. Sel. Areas Commun.*, vol. 40, no. 6, pp. 1728 - 1767, Jun. 2022.
- [2] H. Durrant-Whyte and T. Bailey, "Simultaneous localization and mapping: Part I," *IEEE Robot. Autom. Mag.*, vol. 13, no. 2, pp. 99 - 110, Jun. 2006.
- [3] B. Amjad, Q. Z. Ahmed, P. I. Lazaridis, M. Hafeez, F. A. Khan, and Z. D. Zaharis, "Radio SLAM: A review on radio-based simultaneous localization and mapping," *IEEE Access*, vol. 11, pp. 9260 - 9278, Jan. 2023.
- [4] G. Bebis and M. Georgiopoulos, "Feed-forward neural networks," *IEEE Potentials*, vol. 13, no. 4, pp. 27-31, 1994.
- [5] 3GPP Tech. Spec. Group Radio Access Netw., "Study on NR positioning enhancements (Release 17)," TR 38.857 (V17.0.0), Mar. 2021.