

UWB 통신에서 CIR과 딥러닝을 이용한 소규모 및 대규모 페이딩의 구분 연구

함도영, 김성철

서울대학교 전기정보공학부 뉴미디어통신공동연구소

wj2dy@maxwell.snu.ac.kr, sckim@maxwell.snu.ac.kr

Distinguishing Small- and Large-Scale Fading from Noise with Deep Learning in UWB Communication

Doyoung Ham, Seong-Cheol Kim

Dept. of Electrical and Computer Engineering and INMC, Seoul National Univ.

요약

본 논문에서는 채널 임펄스 응답(CIR)을 한 쌍 입력받아 같은 채널, 소규모 페이딩, 대규모 페이딩의 세 가지 카테고리로 분류하는 딥러닝 방식을 제안한다. 합성곱 신경망(CNN)을 활용하여 고전적 방식의 88% 정확도보다 높은 96% 정확도를 얻었다.

I. 서론

요즘 많은 장비들이 채널 임펄스 응답 (CIR), 또는 주파수 영역에서의 채널 상태 정보 (CSI) 등 자세한 채널 정보를 제공하기 시작하고 있다. 이러한 채널 정보를 이용하여 주위 환경을 감지하려는 연구도 많이 진행되고 있다. 몇몇 연구([1], [2])는 실내 측위 성능을 개선하려고 시도하였고, 또 다른 연구들([3], [4], [5])는 실내 환경을 보다 직접적으로 감지하려고 시도하였다. 이러한 연구들은 CIR에 주위 환경에 대한 많은 정보가 담겨 있음을 시사한다.

두 개의 서로 다른 CIR 값이 주어졌을 때, 두 채널이 실제로 다르거나, 아니면 같은 채널인데 CIR 추정 오차 때문에 다르게 보이거나, 이렇게 두 가지 가능성이 존재한다. 이 두 상황을 구분하는 것은 그렇게 간단하지 않은데, [6]에서는 이 문제를 딥러닝을 활용해 해결하려고 시도하였다. 관련된 또 다른 문제로는 소규모 페이딩 ($\sim \lambda$)과 대규모 페이딩 ($> 10\lambda$)을 구분하는 것이 있다. 본 논문에서는 이 두 가지 문제를 고전적인 방법과 딥러닝을 이용해 해결하려고 시도하였다. 두 CIR이 주어졌을 때, 본 논문의 모델은 그 CIR 쌍을 같은 채널, 소규모 페이딩, 대규모 페이딩의 세 카테고리로 분류한다.

II. 본론

2.1. 실험 장비 및 CIR 전처리 과정

본 논문에서는 Qorvo DWM3000 개발 보드를 이용해 CIR을 수집하였다. 수집된 CIR은 1.0016 ns 간격으로 샘플링된 1016개의 복소수 (In-phase/Quadrature) 값을 가진다. 사용된 UWB 중심 주파수는 6.5 GHz 였다.

11 개의 서로 다른 large-scale 환경(다른 방 혹은 다른 위치)에서 측정을 진행하였고, 각각의 large-scale 환경마다 2 cm 간격의 3 x 3 grid에서 small-scale 측정을 진행하였다. 2 cm 간격은 파장의 배수로 나타내면 0.43λ 이다. 각 small-scale 환경에서 20개의 CIR을 수집하였다.

수집된 CIR은 보간(10배), 시간 오프셋 보정, 그리고 normalization을

거쳐 사용되었다. 결과 CIR은 다시 원래대로 10배 decimation되었고, 위상은 무시하고 절댓값만 이용하였다. 신호를 전체적으로 포함하도록 설정된 값인 100 샘플만 이용하여 신경망의 크기를 줄였다.

2.2. 확률적 분석

두 CIR이 같은 채널에서 왔다고 가정하고(같은 방, 같은 위치), CIR 간의 시간 동기를 가정했을 때, 아래 식이 성립한다.

$$\begin{aligned} CIR_1[k] &= CIR_{true}[k] + w_1[k], \\ CIR_2[k] &= CIR_{true}[k] + w_2[k]. \end{aligned} \quad (1)$$

식 (1)이 성립한다는 가정하에 두 CIR을 빼서 나온 잔여 CIR 값 ($w_1[k] - w_2[k]$)를 정규분포와 비교하였다. (그림 1)




그림 1 CIR 차이 값들의 Q-Q 플롯

만약 잔여 CIR 값들이 정규분포를 따른다면 그림 1의 Q-Q 플롯은 직선이 되어야 하지만, 실험 결과 잔여 CIR 값들이 정규분포를 따르지 않고, 양 쪽 꼬리가 더 두꺼운 분포를 따르는 것을 알 수 있었다. 아마 CIR 간의 동기가 정확하게 맞지 않아 생기는 현상으로 추정한다.

그림 2에는 잔여 CIR 값들의 자기상관 함수가 나타나 있다. CIR 들이 ± 4 개의 샘플 정도에서는 서로 상관되어 있음을 알 수 있다.

그림 3에는 세 개의 CIR이 나타나 있다. 첫 둘은 같은 위치에서 나온

CIR이고, 세 번째는 small-scale 페이딩을 겪은 경우(송수신기 중 하나가 2 cm 움직임)이다. 자세히 살펴보면 첫 둘은 피크와 골짜기가 비슷하다는 것을 알 수 있고, 세 번째 CIR은 처음 둘과는 차이가 있음을 알 수 있다. 육안으로 small-scale 페이딩과 large-scale 페이딩을 구분하는 것은 쉽지 않다.




그림 4 잔여 CIR 값들의 자기상관




그림 3 세 CIR의 비교. 첫 두 그림은 같은 채널, 세 번째 그림은 다른 채널

2.3 고전적 구분 방식

2.2절의 내용에도 불구하고 문제를 간단히 하기 위해 $w_1[k]$ 와 $w_2[k]$ 를 백색잡음으로 가정하면, 두 CIR의 차를 제공한 뒤 thresholding을 하는 방식이 자연스럽다[6].

2.4 딥러닝 기반 방식

Multi-layer perceptron(MLP)와 1-D CNN의 두 가지 딥러닝 방식을 고려하였다. MLP 레이어는 각각 2000개, 1000개, 300개, 50개, 3개의 노드를 갖고, 마지막 레이어는 softmax, 그 외의 레이어는 ReLU를 활성화 함수로 사용하였다. CNN은 5개의 필터를 가지고 커널 사이즈가 5인 1차원 convolutional 레이어를 이용하였다. 그 후에는 max pooling, 또다시 conv1d layer(20 filters), 그리고 max pooling을 거친 뒤에 dense-connected layer(노드 30개, 50개, 3개)가 적용되었다.

III. 결론

3.1. 실험 결과

그림 4에 각 신경망에서 학습 및 validation 정확도가 나타나 있다. 표 1에서는 세 방식의 정확도를 비교한다. 고전적 및 MLP에서는 정확도가

88% 정도였지만, 1D-CNN을 이용한 경우 정확도가 96% 이상이었다.




그림 4 MLP와 CNN의 학습 및 validation 정확도

	Classical	MLP	1D-CNN
training	87.80%	97.80%	98.10%
validation	93.07%	87.53%	96.73%
test	92.87%	88.00%	96.43%

표 1 고전적, MLP, 1D-CNN의 분류 정확도

3.2. 결론 및 제언

결론적으로, 본 논문에서는 잡음 섞인 추정치 중에서 실제 채널의 차이를 구분해 내고, 그 차이를 small-scale 페이딩과 large-scale 페이딩으로 구분하는 딥러닝을 이용한 방식을 제안하였다. 본 논문의 방식을 확장하여 두 CIR의 차이를 측정하는 일반적인 metric에 대한 연구를 할 수 있을 것이다. 또, 본 논문의 방식을 generative 딥러닝 모델에 적용하여 딥러닝 데이터 augmentation에 활용할 수 있는 채널 생성기에 대한 연구도 가능할 것이다.

ACKNOWLEDGMENT

본 연구는 삼성전자의 지원(IO210202-08366-01)을 받아 수행된 결과임.

참 고 문 헌

- [1] Y. -M. Lu *et al.*, "Deep Learning for Ultra-Wideband Indoor Positioning," *2021 IEEE 32nd Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)*, 2021, pp. 1260-1266.
- [2] C. Jiang *et al.*, "UWB NLOS/LOS Classification Using Deep Learning Method," in *IEEE Communications Letters*, vol. 24, no. 10, pp. 2226-2230, Oct. 2020.
- [3] M. J. Bocus *et al.*, "UWB and WiFi Systems as Passive Opportunistic Activity Sensing Radars," *2021 IEEE Radar Conference (RadarCon21)*, 2021, pp. 1-6.
- [4] H. Cheng *et al.*, "Deep Learning Wi-Fi Channel State Information for Fall Detection," *2019 IEEE International Conference on Consumer Electronics - Taiwan (ICCE-TW)*, 2019, pp. 1-2.
- [5] H. B. Kwon *et al.*, "Hybrid CNN-LSTM Network for Real-Time Apnea-Hypopnea Event Detection Based on IR-UWB Radar," in *IEEE Access*, vol. 10, pp. 17556-17564, 2022.
- [6] D. Ham *et al.*, "Detecting Changes in Surrounding Environment using Impulse Response and Deep Learning," *2020 Winter Conference, The Korean Institute of Communications and Information Sciences*, vol. 68, pp. 430-431, 2019.