

심층신경망과 전이학습을 활용한 UWB 전파환경 분류

남성찬, 고영배
아주대학교 소프트웨어학과

skdiakffn@ajou.ac.kr, youngko@ajou.ac.kr

Classification of UWB propagation condition using Deep Neural Network and Transfer Learning

Sung Chan Nam, Young-Bae Ko
Dept. of Software and Computer Engineering, Ajou University

요 약

Ultra-wide-band(UWB)는 주로 고정밀 측위 연구에 사용된다. 다만, UWB의 경우 non-line-of-sight(NLOS) 환경에서 신호가 전파되면 측위 정확도가 저하된다는 단점이 있다. 따라서, UWB 측위 연구에서 NLOS를 식별하는 것은 매우 중요하다. 하지만 NLOS라고 모두 같은 전파환경을 나타내는 것은 아니다. 같은 NLOS이라고 해도 주위 환경에 따라 측위 결과는 달라진다. 여기서 UWB 전파환경 분류에 대한 기존 연구의 첫번째 한계점이 드러난다. 바로, 기존 연구는 전파환경을 더 자세히 분류하지 않고 단순히 line-of-sight(LOS)와 NLOS로 분류하여 연구를 진행하므로 NLOS 환경에서 측위 정확도 편차가 클 수 있다는 한계점이 있다. 또한, 기존 연구에는 두번째 한계점이 존재한다. 기존 연구는 channel impulse response 데이터에서 해당 연구에서 제안하는 특정 데이터를 추출하여 전파환경을 분류하는 방식을 이용하는데 여기서 두번째 한계점이 드러난다. 기존 연구에서 제안하는 추출 데이터는 모든 환경에 활용되기에 범용성이 부족하다는 한계점이 있다. 따라서, 본 논문에서는 non-line-of-sight를 더 자세히 분류하여 기존 연구의 첫번째 한계점을 해결한다. 또한, 범용성 높은 channel impulse response 데이터를 그대로 이용하기 위해 심층 신경망을 이용하였으며, 추가적으로 전이 학습을 이용하여 완성된 전파환경 분류기가 다양한 환경에서 활용될 수 있도록 하여 기존 연구의 두번째 한계점을 해결한다.

I. 서론

위치 기반 서비스는 예전부터 현재까지 각광받고 있는 서비스이다. 위치 기반 서비스에서 위치 정보는 중요한 역할을 한다. 야외 환경에서는 글로벌 항법 위성 시스템(Global Positioning System: GPS)을 통해 정확한 위치 정보를 얻을 수 있다. 그러나 GPS의 경우 실내 환경에서 유용한 위치 정보를 제공하지 못하거나 성능이 상당히 저하될 수 있다. 따라서, 이러한 GPS의 단점을 해결하기 위해서 실내 측위에는 무선 센서 네트워크, 소리, 적외선, 초광대역(Ultra-wide-band: UWB)와 같은 다양한 기술이 사용되어 왔다. 특히, UWB는 낮은 에너지 소비량, 센티미터 레벨의 정밀성, 특정 장애물 침투 능력 등 여러 가지 특성 때문에 고정밀 실내 측위 기술의 유망한 기술 중 하나로 여겨진다.[1] 다만, 초광대역의 경우 non-line-of-sight(NLOS) 환경에서 신호가 전파되면 측위 정확도가 저하된다는 단점이 있다.

따라서, UWB를 활용하기 위해서 NLOS를 식별하는 것이 중요하기 때문에 UWB의 NLOS를 식별하는 다양한 연구가 등장했다[2-4].

[2]와 [3]의 연구의 경우 측위를 위해 UWB의 NLOS를 식별하는 연구이다. [4]의 연구의 경우는 심층신경망(Deep Neural Network: DNN)을 이용해 UWB의 line-of-sight(LOS)와 NLOS를 식별하는 연구이다.

하지만, 해당 기존 연구에는 두가지 한계점이 존재한다. 첫째, UWB의 경우 같은 NLOS이라고 해도 주위 환경에 따라 측위 결과가 달라진다[5]. 그럼에도 불구하고 기존 연구는 전파환경을 더 자세히 분류하지 않고 단순히 LOS와 NLOS로 분류하여 연구를 진행하므로 NLOS 환경에서 측위 정확도 편차가 클 수 있다. 둘째, 기존 연구에서 제안하는 방식은 모든 환경에 활용되기에

범용성이 부족하다. [2]와 [3]의 연구는 Channel Impulse Response(CIR) 데이터에서 해당 연구에서 제안하는 특정 데이터를 추출하여 LOS와 NLOS를 분류하는 방식을 사용하고 있어서 모든 환경에 활용되기에 범용성이 부족하다. [4]의 연구는 CIR 데이터를 그대로 사용하기는 하지만 환경이 달라지면 머신 모델의 성능이 낮아지는 DNN 특성상 해당 연구에서 제안하는 방법이 다른 환경에서도 잘 작동할 것이라고 보기에 어렵다.

본 논문에서는 기존 연구의 두가지 한계점을 해결하고자 한다. 따라서, 첫번째 한계점을 해결하기 위해서 무선 전파환경을 단순히 LOS와 NLOS 두가지로 분류하지 않고 LOS, NLOS, NLOS with wall 이렇게 세가지로 분류하기로 한다. 또한, 두번째 한계점을 해결하기 위해서 CIR 데이터를 그대로 이용하며, 이를 위해서 심층신경망을 사용한다. 또한, 전이학습(Transfer Learning: TL)을 이용해 심층신경망을 통해 완성된 전파환경 분류기가 다양한 환경에서 활용될 수 있도록 한다.

II. 본론

(1) 제안 기법

본 논문에서는 무선 전파환경을 LOS, NLOS, NLOS with wall 이렇게 세가지로 분류하여 기존 연구의 첫번째 한계점을 해결하고자 한다. LOS는 통신하는 두 기기 사이에 아무런 장애물이 없는 경우이며, NLOS는 통신하는 두 기기 사이에 콘크리트 벽보다 얇은 장애물이 있는 경우이고, NLOS with wall은 통신하는 두 기기 사이에 콘크리트 벽이 있는 경우이다.

또한, 심층신경망과 전이학습을 사용해 만들어진 전파환경 분류기가 범용성을 갖도록 하여 기존 연구의

두번째 한계점을 해결하고자 한다. 본 논문에서 사용하는 심층신경망에서는 CIR 데이터를 심층신경망의 입력 벡터로 사용하며 심층 신경망은 CIR 데이터의 주파수 특성을 학습하여 무선 전파환경을 분류하며, 사용하는 심층신경망의 구조는 Figure 1 과 같다. DNN 특성상 환경이 달라지면 사전에 학습한 모델이 제대로 동작하지 않는 문제점이 있는데 무선 통신 환경에서 데이터를 수집할 때 데이터를 수집하는 장소가 달라지면, DNN 에서 환경이 달라지는 것으로 작용한다. 즉, 전파 환경을 분류하는 모델이 다른 환경에서 제대로 동작하지 않는다. 따라서, 이를 해결하기 위해 Figure 2 와 같은 전이학습 방식을 이용한다.




Figure 1. 심층신경망 구조




Figure 2. 전이학습

(2) 구현 및 결과 분석

제안 기법 구현 및 결과 분석을 위해 2 가지의 다른 공간(연구실, 강의실)에서 사전에 정의한 3 가지의 무선 전파환경(LOS, NLOS, NLOS with wall)에 대해서 데이터를 수집했다. 또한, 수집한 데이터와 Figure1 구조를 이용하여 심층학습을 진행했다.

연구실에서 학습한 모델을 테스트한 결과 정확도는 98%이었다. 또한, 연구실에서 학습한 모델을 강의실에서 수집한 데이터로 테스트한 결과 정확도가 43.33%이었다.




Figure 3. 전이학습 적용한 모델과 처음부터 학습한 모델을 테스트했을 때의 정확도 그래프

Figure 3 에서 위의 선은 연구실에서 사전에 학습한 모델에 강의실에서 수집한 데이터를 이용하여 전이학습을 적용했을 때 정확도이고, 아래의 선은 강의실에서 처음부터 학습한 모델의 정확도이다. Figure 4 를 확인하면, 전이학습을 적용한 경우가 더 빨리 모델의 성능이 수렴하고, 성능도 더 높다는 것을 확인할 수 있다.

구분	전이학습 미적용	전이학습 적용 모델	처음부터 학습한 모델
정확도	43.33%	99%	98%
학습 시간	X	7m 1s	16m 51s

본 논문에서는 전파환경을 단순히 LOS 와 NLOS 로 분류하지 않고 LOS, NLOS, NLOS with wall 이렇게 세가지의 전파환경을 재정의한 후 이를 분류했다. 또한 정의된 3 가지 전파환경을 출력 변수로 두고 모델을 학습시켰을 때, 분류기가 98%라는 정확도를 가지므로 전파환경을 LOS, NLOS 두가지로 분류하지 않고 LOS, NLOS, NLOS with wall 세가지로 분류해도 높은 정확도로 전파환경을 분류해낼 수 있다는 것을 알 수 있다. 즉, 기존 연구의 첫번째 한계점을 극복했다는 것을 확인할 수 있다. 또한, 전이학습을 적용하지 않았을 때는 43.33%라는 낮은 정확도를 보이므로 특정 공간에서 생성한 분류기가 다른 공간에서는 정상적으로 동작하지 않으므로 범용성이 낮다고 볼 수 있다. 하지만, 전이학습을 적용했을 때 99%라는 높은 정확도를 보이므로 본 논문의 기법으로 생성된 분류기가 범용성이 높다는 것을 알 수 있으므로 기존 연구의 두번째 한계점을 극복했다는 것을 확인할 수 있다.

III. 결론

본 논문에서는 기존 연구의 두가지 한계점을 해결하고자 했다. 따라서, 무선 전파환경을 단순히 LOS, NLOS 두가지로 분류하지 않고 NLOS with wall 을 추가로 정의하여 LOS, NLOS, NLOS with wall 세가지로 분류했다. 그리고 또한, 두번째 한계점을 해결하기 위해서 CIR 데이터를 그대로 이용하며, CIR 데이터를 그대로 사용하기 위해서 심층신경망을 사용했으며, 추가적으로 전이학습을 이용해 심층신경망을 통해 완성된 전파환경 분류기가 다양한 환경에서 활용될 수 있도록 했다.

ACKNOWLEDGMENT

“본 연구는 과학기술정보통신부 및 정보통신기획평가원의 SW 중심대학사업의 수행결과로 추진되었음”(2015-0-00908)

참 고 문 헌

- [1] Piccolo, Francesca Lo. "A new cooperative localization method for UMTS cellular networks." IEEE GLOBECOM 2008-2008 IEEE Global Telecommunications Conference. IEEE, 2008.
- [2] Schroeder, Jens, et al. "NLOS detection algorithms for ultra-wideband localization." 2007 4th Workshop on Positioning, Navigation and Communication. IEEE, 2007.
- [3] Yu, Kegen, et al. "A novel NLOS mitigation algorithm for UWB localization in harsh indoor environments." IEEE Transactions on Vehicular Technology 68.1 (2018): 686-699.
- [4] Jiang, Changhui, et al. "UWB NLOS/LOS Classification Using Deep Learning Method." IEEE Communications Letters (2020).
- [5] Chong, Chia-Chin, et al. "Statistical characterization of the UWB propagation channel in indoor residential environment." Wireless Communications and Mobile Computing 5.5 (2005): 503-512.