

Dominant radio path 정보를 활용한 딥러닝 기반 사용자 위치 추정 기법

김근우, 현성환, 김성철

서울대학교 전기 정보 공학부, 뉴미디어 통신 공동 연구소

{kimkeunwoo15, shhyun, sckim} @ maxwell.snu.ac.kr

Deep learning based user positioning using dominant radio path data

Keunwoo Kim, Seong-Hwan Hyun, Seong-Cheol Kim

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

요약

Beyond 5G, 6G 등 차세대 통신 시스템에서는 수 십 GHz 의 밀리미터파 대역 신호를 활용한 무선 통신 서비스를 제공할 것으로 예측된다. 이때, 밀리미터파 채널의 높은 경로 손실을 보상할 방법으로 채널 희소성을 활용한 사용자 위치 기반 신호 처리 기법이 많은 주목을 받고 있지만 도심지에서는 사용자 위치 추정 성능이 낮아 통신 성능이 저하될 수 있다. 본 논문에서는 이를 극복하고자 기지국에서 습득한 기지국-사용자 간 채널의 dominant radio path 정보를 활용하여 사용자의 위치를 딥러닝 기반으로 추정하는 방법을 제시하였다. 우리는 dominant radio path 정보를 입력으로, 사용자 위치를 출력으로 하는 딥러닝 모델을 통해 사용자의 위치 추정이 가능함을 확인하였으며 데이터 증강을 통해 위치 추정 성능 향상이 가능함을 확인하였다.

I. 서론

Beyond 5G, 6G 등 차세대 통신 시스템에서는 수 십 GHz 의 밀리미터파 대역 신호를 활용한 무선 통신 서비스를 제공할 것으로 예측된다. 이때, 밀리미터파 채널의 높은 경로 손실을 보상할 방법으로 다양한 multiple-input multiple-output (MIMO) 신호 처리 기법이 제시되고 있다 [1]. 그 중에서도 낮은 계산 복잡성과 높은 성능으로 인해 밀리미터파 채널의 희소성을 활용한 사용자 위치 기반 MIMO 신호 처리 기법이 많은 주목을 받고 있다 [2]. 하지만, 대부분의 사용자 위치 기반 신호 처리 기법의 경우 위성항법시스템 기반 위치 정보를 활용하지만 이는 도심지에서의 위치 추정 정확도가 낮고 사용자의 위치 정보 활용 동기가 필요하다는 단점이 존재한다.

본 논문에서는 기지국에서 습득한 기지국-사용자 간 채널의 dominant radio path 정보를 활용한 딥러닝 기반 사용자 위치 추정 기법을 제안한다. 우리는 다수의 기지국에서 습득한 dominant radio path 의 채널 이득 및 각도 정보들을 입력값으로, 사용자 위치를 출력값으로 하는 deep neural network (DNN)를 구성하였다. 우리는 이를 통해 높은 정확도의 사용자 위치 추정이 가능함을 확인하였고 데이터 증강을 통한 위치 추정 성능 향상 기법 또한 제시하였다.

II. 본론

가. 시스템 모델

본 논문에서는 안테나 요소간 간격이 반파장인 uniform planar array (UPA) 안테나를 보유한 하나의 지상 기지국과 지상 기지국을 보조하는 K 개의 UPA 안테나를 탑재한 unmanned aerial vehicle (UAV) 기지국이 존재하는 통신 시스템을 가정한다. 총 $K + 1$ 개의

기지국 가운데 $k \in \{0, 1, 2, \dots, K\}$ 번째 기지국의 위치는 $[x_k, y_k, z_k]^T$ 로 표현되며 지상 기지국의 위치는 $[x_0, y_0, z_0]^T$ 로 표현된다.

밀리미터파 채널의 희소성에 따라 k 번째 기지국과 $[x, y, z]^T$ 에 위치한 사용자간 채널 행렬 \mathbf{H}_k 는 다음과 같이 표현된다 [3].

$$\mathbf{H}_k = \sum_{l=1}^L \alpha_k^{(l)} \mathbf{a}(\phi_{k,r}^{(l)}, \theta_{k,r}^{(l)}) \mathbf{a}^H(\phi_{k,t}^{(l)}, \theta_{k,t}^{(l)})$$

여기서 $\mathbf{a}(\phi, \theta)$ 는 array response vector 이며 L 은 radio path 수이고 $\phi_{k,r}^{(l)}, \theta_{k,r}^{(l)}, \alpha_k^{(l)}$ 은 각각 수신단에서 측정된 $l \in \{1, \dots, L\}$ 번째 radio path 의 방위각, 고도각 및 채널 이득이다. 이때, $\alpha_k^{(1)} > \alpha_k^{(2)} > \dots > \alpha_k^{(L)}$ 라 가정한다. 편의상 앞으로는 $\phi_k = \phi_{k,r}^{(1)}, \theta_k = \theta_{k,r}^{(1)}, \alpha_k = \alpha_k^{(1)}$ 라 한다. 우리는 각 기지국이 사용자와의 채널 추정을 통해 dominant radio path 의 방위각, 고도각 및 채널 이득을 추정할 수 있으며 추정된 정보는 지상 기지국이 모두 취합할 수 있다고 가정한다.

나. 제안 딥러닝 네트워크 구조




그림 1. 제안 딥러닝 네트워크 구조도

본 논문에서는 딥러닝 기반 사용자 위치 추정을 위해 그림 1 과 같은 DNN 구조를 활용한다. 제안 DNN 구조는 총 8 개의 fully-connected layer 로 구성되어 있다. Input layer 는 $6(K + 1)$ 개의 뉴런, 6 개의 hidden layer 는 1024 개의 뉴런, output layer 는 3 개의 뉴런으로 구성되어 있으며 hidden layer 간에는 drop-out layer 가 존재한다. 입력값으로는 기지국의 위치 및 기지국-사용자간 채널 정보를 담은 정보 벡터 $[x_k, y_k, z_k, \phi_k, \theta_k, \alpha_k]^T$ 를 $K + 1$ 개 생성한 뒤 이를 모은 $6(K + 1)$ 크기의 벡터를 사용하였다. 이때, $K + 1$ 개의 정보 벡터를 순열하여 입력값을 생성하였으며 이를 통해 $(K + 1)!$ 배의 데이터를 생성하는 데이터 증강을 진행하였다. 출력값으로는 사용자 위치 벡터 $[x, y, z]^T$ 를 사용한다.

다. 모의 실험 설정



그림 2. 레이트레이싱 시뮬레이션 예시

우리는 제안한 딥러닝 모델 학습을 위한 입력 및 출력값 생성을 위하여 그림 2 와 같은 MATLAB 레이트레이싱 시뮬레이션을 진행하였다. 우리는 강남역 인근 지도 정보를 활용하여 하나의 고정된 지상 기지국과 지상 기지국 반경 100 m 내 영역에 균등하게 분산된 $K = 2, 4$ 개의 UAV 기지국 및 사용자 역할을 할 수신기 하나를 배치하였고 이들간의 채널 정보를 레이트레이싱 시뮬레이션을 통해 구하였다. 이때 중심주파수는 28 GHz 이며 채널 이득이 -150 dB 를 넘는 경우 기지국 민감도 한계로 인해 해당 채널 정보는 습득 불가하다 가정, 정보 벡터에 포함된 채널 정보 $\phi_k, \theta_k, \alpha_k$ 는 모두 0으로 입력된다고 가정하였다. 또한, UAV 기지국의 높이는 100 ~ 150 m 사이에서 균일하게 분포하고 지상 기지국 및 사용자의 높이는 각각 10m 와 1.5m로 고정되었다고 가정하였다.

10000 회의 레이트레이싱 이후, 각 시뮬레이션 별 $K + 1$ 개의 정보 벡터 및 사용자 위치 벡터를 생성하였다. 이후 데이터 증강을 통해 생성한 $10000(K + 1)!$ 개 데이터를 train:validation:test = 8:1:1 비율로 나눠 딥러닝 모델의 학습을 진행하였다. Batch size 는 2048, drop-out rate 는 0.5 이며 Adamax optimizer 를 사용하였고 learning rate 는 0.0001 이다. 총 1000 epochs 의 학습을 거쳤으며 학습에는 NVIDIA GeForce RTX 3080 Ti 가 사용되었다. 학습 이후, 출력값인 추정된 사용자 위치 정보를 실제 사용자 위치 정보와 비교하여 위치 추정 오차 (m)를 구하였다.

라. 모의 실험 결과

모의 실험 결과는 그림 3과 같다. 그림3에 따르면 UAV 기지국 개수 K 가 증가함에 따라 위치 추정 오차가 급격하게 줄어드는 것을 확인할 수 있다. 이는 두 요인에 따른 결과라 생각된다. 첫 번째 요인은 K 가 증가함에 따라 더 많은 기지국-사용자간 채널의 dominant radio path

정보를 획득하게 되고 이에 따라 더 큰 정보 벡터를 생성할 수 있게 됨에 따라 정확도가 높아진 것이다. 두 번째 요인은 제안한 데이터 증강 기법 적용 시 $(K + 1)!$ 배의 데이터가 생성되므로 K 가 증가함에 따라 생성되는 데이터 개수가 팩토리얼 단위로 늘어난다. 이로 인해 K 차이에 따라 학습 데이터의 수가 현격하게 차이 나게 되고 위치 추정 오차에 차이가 발생하게 된다. 이는 데이터 증강 여부에 따른 위치 추정 오차 CDF 를 통해서도 확인 가능하며 이를 통해 제안한 데이터 증강 기법을 통한 위치 추정 성능 향상이 가능한 것을 확인할 수 있다.




그림 3. UAV 기지국 개수 K 및 데이터 증강에 따른 위치 추정 오차 CDF

III. 결론

본 논문에서는 기지국-사용자간 채널의 dominant radio path 정보를 활용한 딥러닝 기반 사용자 위치 추정 기법을 제안하였다. 다수의 기지국이 사용자와의 채널 추정을 통해 추정된 dominant radio path 의 방위각, 고도각 및 채널 이득을 딥러닝 모델의 입력값으로, 사용자의 위치를 출력값으로 설정하는 방식으로 사용자 위치 추정을 진행하였다. 또한, 입력값을 구성하는 정보 벡터의 위치를 바꾸는 식으로 데이터 증강을 진행해 팩토리얼 단위로 학습 데이터 양을 증가시키는 방법 또한 제안하였다. 그 결과 기지국 개수가 증가함에 따라 위치 추정 오차가 급격하게 줄어드는 것을 확인할 수 있었고 데이터 증강을 통한 위치 추정 성능 향상이 가능한 것 또한 확인 가능하였다.

ACKNOWLEDGMENT

"본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학 ICT 연구센터육성지원사업의 연구결과로 수행되었음" (IITP-2023-2021-0-02048)

참고 문헌

- [1] Rappaport, T. S., Xing, Y., MacCartney, G. R., Molisch, A. F., Mellios, E., & Zhang, J. Overview of millimeter wave communications for fifth-generation (5G) wireless networks—With a focus on propagation models. *IEEE Transactions on antennas and propagation*, 65(12), 6213–6230 (2017)
- [2] Lee, Jong-Ho, and Jho Song. "Beamforming via array pattern synthesis for millimeter wave NOMA downlink transmission." *IEEE Transactions on Vehicular Technology* 67.12 (2018): 12363–12367.
- [3] Rappaport, T. S., Ben-Dor, E., Murdock, J. N., & Qiao, Y. 38 GHz and 60 GHz angle-dependent propagation for cellular & peer-to-peer wireless communications. *2012 IEEE international conference on communications (ICC)*, 4568–4573 (2012)