

불확실성 정량화를 이용한 연합학습 기반 핑거프린팅 실내측위

박준하, 김택윤, 김효원, 김선우
한양대학교 융합전자공학과

{eric0725, kty0264, khw870511, remero}@hanyang.ac.kr

Federated Learning-based Fingerprinting Indoor Localization with Uncertainty Quantification

Junha Park, Taekyoon Kim, Hyowon Kim, and Sunwoo Kim
Department of Electronic Engineering, Hanyang University

요약

본 논문에서는 불확실성 정량화를 이용한 연합학습(federated learning) 기반 핑거프린팅 실내측위 방법을 제안한다. 불확실성을 정량화하기 위해 dropout을 적용하여 연합학습의 뉴럴네트워크(NN: neural network) 모델을 생성하고, 학습이 완료된 모델은 테스트 과정을 반복하여 측위 오차의 분산을 정량화된 불확실성으로 변환한다. 서버는 분할된 모델에 정량화된 불확실성을 가중치로 주어 학습을 이어간다. 이에 따라 연합학습을 이용한 핑거프린팅 실내측위 보다 향상된 측위 정확도를 얻어낸다. 기존의 DNN(deep NN) 방법, 연합학습과 제안하는 측위 방법의 시뮬레이션 결과를 UJIIndoorLoc 데이터베이스를 통해 광범위한 지역의 실내 측위 정확도를 비교한다.

I. 서론

최근 인공지능 시스템은 크고 복잡한 데이터셋의 패턴을 인식하여 자율주행이나 의료진단과 같은 필수적인 의사 결정을 알리는데 이용되는 사례가 늘고 있다. 하지만, 이러한 의사 결정이 틀렸을 경우에 대한 불확실성에 대한 문제점은 항상 잠재되어 있었다. 이런 불확실성은 인공지능 관점에서 판단이나 의사결정에 필요한 적절한 정보의 부족으로 인한 잘못된 판단을 내릴 수 있는 가능성이라고 볼 수 있다[3]. 이를 위해 동일한 딥러닝 모델에 dropout을 적용하여 분류나 회귀 문제를 NN의 정량화된 불확실성을 얻을 수 있다[4].

딥러닝 방식은 막대한 양의 데이터를 분산하여 처리하기 위해 대표적으로 분산형 학습의 한 종류인 연합학습을 이용한다. 하지만 연합학습은 중앙 집중형학습인 DNN에[1] 비해 성능이 저하되는 단점이 있다. 이를 해결하기 위해 본 논문에서는 다양하고 막대한 양의 수신신호세기(RSSI: received signal strength indicator) 데이터를 학습에 사용하여 dropout을 적용한 연합학습 기반 실내측위 시스템을 제안한다. 시뮬레이션 성능 평가로는 기존 DNN 방식[1]과 연합학습 기반 측위 시스템[2]과 본 논문에서 제시하는 알고리즘의 테스트 결과의 차이를 비교하여 불확실성을 적용한 연합학습의 측위 성능을 평가한다.

II. 불확실성 정량화를 이용한 연합학습 기반 실내 측위

학습에 사용되는 데이터는 총 J 개의 Bluetooth AP(access point)가 분포되어 있는 네트워크에서 생성 및 수집되며, 단말은 각 AP로부터 RP(reference point)에 도달하는 수신신호세기를 수집한다. 학습을 위한 연합학습의 모델은 서버의 광역 모델(global model)과 각 단말의 지역 모델(local model)로 구분된다. 두 MLP(multi-layer perceptron) 모델은 동일한 입력층, 다중의 은닉층(hidden layer), 그리고 출력층으로 구성된다. 학습 데이터는 수신신호세기로 이루어진 크기 \mathbf{r}_i 의 입력벡터, 크기 \mathbf{p}_i 로 이루어진 출력벡터로 구성된다. 단말이 수집한 i 번째 샘플의 입력벡터와 출력벡터는 다음과 같다.

$$\mathbf{r}_i = [r_{i1}, r_{i2}, \dots, r_{ij}, \dots, r_{iJ}], \quad \mathbf{p}_i = [x_i, y_i], \quad (1)$$

여기서 r_{ij} 와 \mathbf{p}_i 는 각각 j 번째 Bluetooth AP가 수신하는 단말의 신호세기와 단말의 좌표이다. 이렇게 수집된 학습 데이터 m 개는 설계된 MLP 모델의 학습 과정에 이용한다. 변수 w 의 함수로 이루어진 모델은 손실함수(loss function) f_{loss} 를 최소화하는 방향으로 학습이 진행되며 다음과 같이 나타낼 수 있다.

$$\min_w \frac{1}{m} \sum_{i=1}^m f_{loss}(w, \mathbf{r}_i, \mathbf{p}_i). \quad (2)$$

기존 딥러닝 학습과정은 모든 데이터를 가지고 하나의 모델의 변수 w 를 업데이트하는 방식이다. 이와 다르게 연합학습에서는 각 단말 u 의 지역 모델은 각 단말이 수집한 데이터들만 가지고 학습을 진행하여 지역 모델의 변수 w_u 를 추정한다. 학습을 마친 U 개의 단말들은 자신들의 변수 w_u 들을 서버로 보내게 된다. 각 단말마다 학습시킨 데이터의 개수 m_u 에 전체 데이터의 개수 H 로 나눈 비율을 가중치 ρ_u 로 서버에서는 모든 지역 모델의 변수와 곱하여 평균을 취하게 된다. 서버는 각 단말들의 학습을 거치고 서버의 광역 모델로 돌아오는 t 번째 round를 반복하고 수렴할 때까지 학습을 진행한다. 이때, 광역 모델의 변수 w_g 는 다음 두 식을 이용한 것과 같다.

$$w_g^{t+1} = \frac{1}{H^t} \sum_{u=1}^U \rho_u^t w_u^t, \quad (3)$$

$$H^t = \sum_{u=1}^N m_u^t, \quad (4)$$

이와 다르게 불확실성 정량화를 이용한 연합학습 방식은 지역 모델이 각 round 마다 가지는 지역 가중치 ρ_u^t 에 모델의 정량화된 불확실성 수치를 대입한다. 불확실성 수치는 테스트 데이터에 따른 예측 결과값의 i 번째 샘플 $\hat{\mathbf{p}}_i$ 와 샘플들의 평균 $\bar{\mathbf{p}}_i$ 로 측위 오차의 표준편차 λ_n 를 계산할 수 있다. 이때, 테스트 데이터에 따른 예측 결과값 샘플의 개수는 테스트 과정의 반복 횟수 K 만큼 얻을 수 있고, 표준편차 λ_n 는 다음과 같이 계산한다.

$$\lambda_n^2 = \frac{1}{K} \sum_{k=1}^K \|\hat{\mathbf{p}}_i - \bar{\mathbf{p}}_i\|^2. \quad (5)$$

학습이 완료된 각 지역 모델들은 학습을 진행한 학습 데이터의 상태에 따라 서로 다른 불확실성을 보여준다. 따라서 이에 해당 테스트 데이터가 생성하는 N 개 표준편차들의 역수 평균을 위치 결과에 따른 정량화된 불확실성 C_u 를 계산하여 연합학습 가중치 ρ_u^t 에 대입하여 학습을 진행한다.

$$C_u = \frac{1}{N} \sum_{n=1}^N \frac{1}{\lambda_n}. \quad (6)$$

표 1. 딥러닝 기반 핑거프린팅 모델 매개변수

Parameters	Value
Optimizer	Adam
Learning rate	0.001
β_1, β_2	0.1, 0.99
Hidden layer format	512×1024×256×64
The number of users	18
Activation function	sigmoid×4, linear
Batch size	200
Local model epoch	20
Global model round	50
The number of train data	19937
The number of test data	1111
Loss function	MAE(mean absolute error)
Drop out rate	0.2

III. 시뮬레이션 성능평가

본 논문에서는 제안하는 광역 모델과 지역 모델 기존 딥러닝(classical DNN)의 모델과 동일한 MLP(multi-layer perceptron)으로 디자인한다. 다수의 단말이 가지는 수신신호세기의 특징을 얻기 위해 학습을 통해 실내에서 여러 단말의 좌표를 RP의 좌표로 이용하여 출력 레이블로 도출한다. 시뮬레이션에는 UJIIndoorLoc 데이터베이스[5]를 이용하고, 이는 520개의 AP와 19937개의 학습 데이터, 1111개의 테스트 데이터를 이용한다. 기존 DNN 방식과 연합학습 기반 측위 시스템 또한 동일한 데이터베이스를 이용하여 제안하는 모델의 성능을 비교한다. 표 1은 시뮬레이션에 사용된 매개변수를 나타내었으며 모두 동일한 모델을 사용한다. 학습은 4개의 은닉층으로 구성하고 sigmoid함수를 활성화함수(activation function)를 사용하고 마지막 활성화함수로는 정확한 좌표값을 찾아내는 회귀 함수에 적합한 linear함수를 사용한다. 손실함수(loss function)은 특이치(outlier)에 덜 민감한 평균 절대 오차(MAE)를 이용하였다. 또한, 위치 추정값의 RMSE(root mean squared error)를 사용하여 측위 정확도를 평가하였다.

시뮬레이션에서는 위와 같은 과정을 지역 모델에서 20번의 epoch를 수행하고 광역 모델에서 50번의 round를 진행한다. 그림 2는 제안하는 알고리즘 모델이 매 round 마다 도출하는 평균거리오차에 대한 기존 딥러닝 모델과 연합학습 모델과의 비교를 나타낸다. 중앙집중형의 학습인 DNN을 이용한 실내측위 결과는 약 5.6m의 오차범위를 가지고 있고 연합학습 기반 실내측위는 약 7.1m정도의 오차범위를 보여준다. 이에 비해 제안하는 알고리즘인 불확실성을 적용한 연합학습기반 실내 측위는 약 5.9m 정도의 향상된 측위 성능을 보여준다. 이를 통해 불확실성을 적용하여 기존 DNN에 비해 학습은 효율적이지만 그에 비해 떨어지는 성능 저하를 단점으로 가지는 연합학습 기반의 실내 측위 시스템 측위 오차를 줄여 중앙집중형 학습으로 도출된 결과에 근접함을 보여준다.




그림 1. (좌) 기존 딥러닝 과 (우) NN-dropout




그림 2. 광역 모델 round에 따른 위치 추정값의 RMSE

IV. 결론

본 논문에서는 정량화된 불확실성을 적용한 연합학습 실내 측위 방법을 제안하였다. 정량화된 불확실성의 수치는 dropout을 적용하여 예측값의 샘플링을 통해 표준편차값을 이용하였다. 데이터를 분할하여 학습하는 연합학습은 막대한 양의 데이터를 처리하는데에 효과적이지만, 중앙집중형 학습에 비해 떨어지는 성능을 보인다. 이와 달리 제안하는 알고리즘은 학습이 완료된 모델의 정량화된 불확실성을 가중치로 이용하여 연합학습 기반 실내 측위의 성능을 향상할 수 있다. 추가로 연합학습은 단말끼리 데이터를 주고 받지 않아 프라이버시 보존에 대한 이득도 기대할 수 있다. 추후에는 딥러닝의 분류 문제에서 불확실성을 적용한 실내측위에 대한 연구도 진행될 예정이다.

ACKNOWLEDGMENT

이 논문은 2021년도 정부(소방청)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임(No. 2019-0-01325, 재난현장 무선통신 추적기반 요구조사 및 소방관 위치정보시스템 개발).

참 고 문 헌

- [1] L. Xiao, A. Behboodi, and R. Mathar, "A deep learning approach to fingerprinting indoor localization solutions," in *Proc. 2017 Int. Telec. Netw. Appl. Conf. (ITNAC)*, Nov. 2017, pp. 22-24.
- [2] T. Li, A. K. Sahu, A. Talwalkar, and V. Smith, "Federated learning: Challenges, methods, and future directions," *IEEE Signal Process. Mag.*, vol. 37, no. 3, pp. 50-60, May 2020.
- [3] C. Blundell, J. Cornebise, K. Kavukcuoglu, and D. Wierstra, "Weight uncertainty in neural networks," *arXiv preprint arXiv:1505.05424*, May 2020.
- [4] Y. Gal, and Z. Ghahramani, "Dropout as Bayesian approximation: Representing model uncertainty in deep learning," in *Proc. International Conference on Machine Learning*, Jun. 2016, pp. 1050-1059.
- [5] J. Torres-Sospedra, R. Montoliu, A. Martinez-Us, J. P. Avariento, T. J. Arnau, M. Benedito-Bordonau, and J. Huerta, "UJIIndoorLoc: A new multi-building and multi-floor database for WLAN fingerprint-based indoor localization problems," in *Proc. 2014 Int. Conf. Indoor Positioning Indoor Navi. (IPIN)*, Oct. 2014, pp. 261-270.