

GAT와 GCN 조합을 통한 WiFi 위치 측위 기법 연구

문유진, 고승우
인하대학교, 인하대학교

yjmoon@inha.edu, swko@inha.ac.kr

Study on Integration of GAT and GCN for WiFi Positioning

Yu-Jin Moon, Seung-Woo Ko

Inha Univ., Inha Univ.

요약

WiFi 기반 위치 측위의 Non-Line-of-Sight (NLoS) 편향을 극복하기 위한 방법으로 Graph neural network (GNN)이 많은 관심을 받고 있다. GNN은 그래프로 연결된 local feature를 효율적으로 추출할 수 있기 때문에 지역적 correlation이 있는 NLoS 현상을 극복할 수 있을 것으로 기대하고 있다. 기존 GNN 기반 위치 측위 알고리즘은 연산의 복잡도가 낮은 Graph Convolution Network (GCN) 기반으로 설계가 되어 있다. 본 논문에서는 기존 GCN 구조에 Graph Attention Network (GAT)를 조합시킨 새로운 구조의 알고리즘을 제안한다. 제안하는 기법은 기존 standalone GCN 대비 RMSE가 Self-supervised learning, Semi-supervised learning 일 때, 각각 11.1%, 16.7% 감소함을 실측 실험 데이터를 통해 검증하였다.

I. 서론

WiFi 신호의 Non-Line-of-Sight 편향을 극복하기 위한 핵심 기술로 Graph Neural Network (GNN)에 대한 관심이 높아지고 있다 [1]. GNN은 그래프로 통해 연결된 노드 사이의 local feature를 효율적으로 추출할 수 있기 때문에 지역적 유사도를 가지고 있는 NLoS 현상에 대해 효과적으로 대응할 수 있을 것으로 기대를 받고 있다. GNN은 크게 연결된 노드를 동일한 가중치로 합치는 Graph Convolution Network (GCN) 계열과 Attention 기법을 통해 계산된 각 노드의 중요도를 가중치에 반영하여 합치는 Graph Attention Network (GAT) 계열이 있다. 대부분의 위치 측위 분야에서는 연산의 복잡도가 낮은 GCN 기반으로 설계가 되었으나 (e.g., [2]), GNN 분야에서는 GAT와 GCN의 조합을 통한 성능 향상 관련 연구가 최근 들어 등장하고 있다 [3]. 이러한 트렌드에 따라, 본 논문에서는 GAT와 GCN을 통합한 새로운 네트워크 구조를 제안하고 이를 WiFi 위치 측위를 통해 검증하고자 한다. 실험을 통해 기존 GCN 기반 위치 측위 알고리즘 대비 RMSE가 Self-supervised learning, Semi-supervised learning 일 때, 각각 11.1%, 16.7% 감소함을 검증하였다.

II. 본론

1) 시나리오

본 논문에서는 N개의 액세스 포인트 (AP)와 한 명의 이동 중인 사용자가 M개의 측정 지점 (MP)을 생성하는 시나리오를 고려한다. 각 MP에서는 모든 AP로부터 Round Trip Time (RTT)을 측정하여 거리 측정을 수행한다. Line-of-Sight (LOS) 상태에서는 측정 거리가 실제 거리와 비슷하게 측정되지만, Non-Line-of-Sight (NLOS) 상태에서는 측정 거리가 실제 거리와 차이가 나게 된다. 하지만, 측정 시점에서는 NLOS와 LOS를 구분할 수 없다.

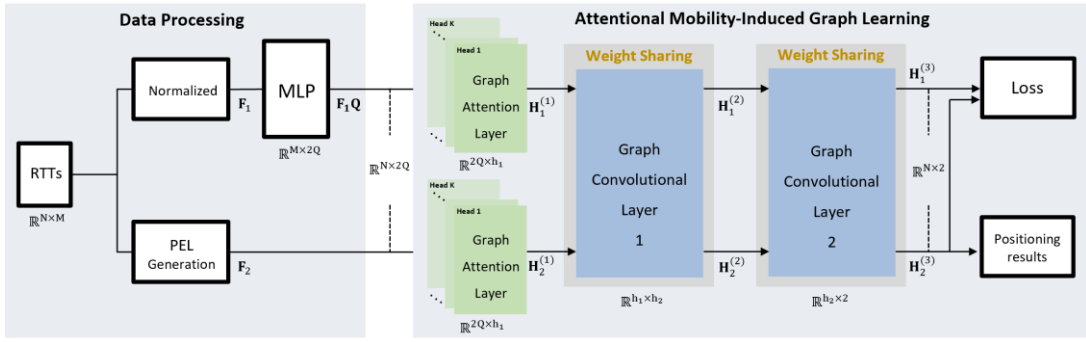
2) Attentional Mobility-Induced Graph Learning

본 논문에서는 GAT와 GCN을 조합한 네트워크 구조를 제안한다. 이 구조는 Mobility-Induced Graph Learning (MINGLE)[2]을 기반으로 설계하였고, MINGLE의 Input feature와 GCN Layer 사이에 GAT Layer를 추가하였기에, 제안한 구조를 Attentional MINGLE(A-MINGLE)이라 칭한다. 사용된 Input feature는 정규화된 RTT 데이터인 $\mathbf{F}_1 \in \mathbb{R}^{N \times M}$ 와 Combinatorial Data Augmentation (CDA)[4] 기법으로 생성한 잠재 위치 후보(PELS)인 $\mathbf{F}_2 \in \mathbb{R}^{N \times 2Q}$ 가 있으며, Graph는 일정 개수의 인접한 MP를 연결한 Graph \mathbf{G}_1 와, 유저의 직선적인 이동 경로에 위치한 각 MP를 연결한 Graph \mathbf{G}_2 가 있다[2]. \mathbf{G}_1 과 \mathbf{G}_2 는 adjacency matrix이다. A-MINGLE은 \mathbf{F}_1 과 \mathbf{F}_2 을 GAT Layer를 통해 Preprocessing을 진행한다. 이 Attention layer는 이웃 노드 간의 attention coefficient를 계산하고, 정규화된 attention score $\alpha_k \in \mathbb{R}^{N \times N}$ 을 구한다. 이렇게 계산된 α_k 와 weight인 $\mathbf{W}_{att} \in \mathbb{R}^{2Q \times h_1}$ 을 통해 각 이웃 노드의 중요도를 반영하며 aggregation을 진행한다[5]. 이를 통해 얻어진 $\mathbf{H}_k^{(1)}$ 는 다음과 같다.

$$\mathbf{H}_k^{(1)} = \rho(\alpha_k \mathbf{F}_k \mathbf{W}_{att}), \quad k \in \{1, 2\}.$$

ρ 는 ELU function이다. A-MINGLE의 전체적인 구조는 [그림 1]과 같다. Attention Layer를 사용하면 모델이 중요한 이웃 노드의 정보를 강조하여 보다 의미 있는 패턴을 학습할 수 있어, 더 정교하고 신뢰성 있는 특징을 추출할 수 있게 된다. A-MINGLE의 Weight는 다음과 같은 MSE-based Loss function을 최적화한다. A-MINGLE을 거친 추정 위치는 각 $\mathbf{a}_n = \mathbf{r}_n(\mathbf{H}_1^{(3)})$, $\mathbf{b}_n = \mathbf{r}_n(\mathbf{H}_2^{(3)})$ 로 표현할 수 있다. $\mathbf{r}_n(\cdot)$ 은 n번째 row-vector를 반환하는 함수이다.

$$\frac{1}{2} \text{MSE}_1(\{\mathbf{a}_n, \mathbf{b}_n\}, \mathbf{x}_n)_{n \in \mathcal{L}} + \frac{1}{2} \text{MSE}_2(\{\mathbf{a}_n, \mathbf{b}_n\}, \mathbf{c}_n)_{n \in \mathcal{L}^c}$$



[그림 1] A-MINGLE 의 구조

이 Loss function 의 MSE_1 은 semi-supervised loss 로 유저의 위치가 알려진 집합 \mathcal{L} 에 대해 계산하고, MSE_2 는 self-supervised loss 로 유저의 위치가 알려지지 않은 집합 \mathcal{L}^c 에 대해 계산한다. 이 때, \mathbf{x}_n 는 실제 위치이고, \mathbf{c}_n 은 CDA 기법을 통해 추정된 위치이다.

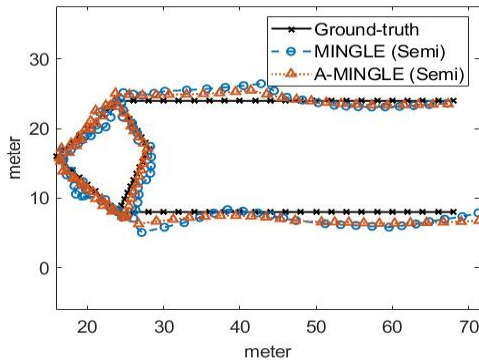
3) 실험 결과

[그림 2]와 같은 환경에서 실험을 수행하였다. 실험은 10 개의 AP 와 95 개의 MP 로 진행하였고, 유저의 알려진 위치 집합 \mathcal{L} 의 원소 개수는 8 개로 설정하였다. 기존의 MINGLE(GCN)와 MINGLE 의 Layer 를 GAT 로 바꾼 Two-Layer GAT 을 대조군으로 사용하였다. 이 때의 성능은 [표 1]과 같이 나타난다.

Learning	Method	50th	75th	95th	RMSE (m)
Self	MINGLE (GCN)	1.734	2.370	3.319	1.398
	Two-Layer GAT	1.892	2.585	3.593	1.565
	A-MINGLE	1.532	2.121	2.917	1.243
Semi	MINGLE (GCN)	1.224	1.730	2.707	1.073
	Two-Layer GAT	1.211	1.815	3.131	1.135
	A-MINGLE	0.963	1.379	2.345	0.894

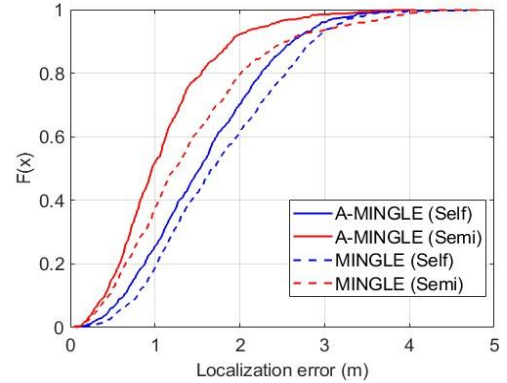
[표 1] A-MINGLE 과 기존 기법의 성능

[표 1]은 MAE 의 50th, 75th, 95th percentiles 와 RMSE 를 나타낸 것이다. 제안하는 기법은 대조군 MINGLE(GCN)와 Two-Layer GAT 에 비해 예러가 각각 self-supervised learning 일 때 11.1%, 20.1% 감소하였고, Semi-supervised learning 일 때, 16.7%, 21.2% 감소하였다.



[그림 2] Path 와 추정 위치

[그림 3]은 A-MINGLE 과 MINGLE 의 CDF 를 비교한 것이다.



[그림 3] 추정 위치에 대한 누적 분포 함수 비교

III. 결론

본 논문에서는 A-MINGLE 을 통한 위치 측위 기법을 제안했다. A-MINGLE 은 GAT layer 와 GCN layer 의 조합으로 인한 성능 향상을 보였다. 향후 연구에서는 기존 Transductive Learning 기법을 Inductive Learning 기법으로 변경하여, attention score 를 학습할 때의 시간 복잡도를 줄일 것이다.

ACKNOWLEDGMENT

이 논문은 2024 년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.2021-0-00347, 6G 통신을 위한 Post MAC).

참고 문헌

- [1] C. Chen, "Deep learning for inertial positioning: A survey." arXiv:2212.06908, 2023
- [2] K. Han, S. M. Yu, S.-L. Kim and S.-W. Ko. "Mobility-Induced Graph Learning for WiFi Positioning." accepts to be published in IEEE Journal on Selected Areas in Communications, 2023.
- [3] A. Javaloy, P. Sanchez-Martin, A. Levi, I. Valera. "Learnable graph convolutional attention networks." arXiv preprint arXiv:2211.11853 (2022).
- [4] S. M. Yu, J. Park, and S.-W. Ko. "Combinatorial Data Augmentation for Real-Time Indoor Positioning: Concepts and Experiments." 2022 IEEE 95th Vehicular Technology Conference:(VTC2022-Spring). IEEE, 2022.
- [5] P. Velickovic, G. Cucurull, A. Casanova, A. Romero, P. Lio, Y. Bengio. "Graph attention networks." stat 1050.20 (2017): 10-48550.