

RTT 측정 정보를 이용한 GCN 기반 협력측위 알고리즘

정흥석, 정민수, 김선우
한양대학교 융합전자공학과
{hssjung, qwjms, remero}@hanyang.ac.kr

GCN based Cooperative Localization with RTT Measurement

Hongseok Jung, Minsoo Jeong and Sunwoo Kim
Department of Electronic Engineering, Hanyang University

요약

본 논문에서는 round trip time (RTT) 측정 정보를 이용한 graph convolutional network (GCN) 기반 협력 측위 알고리즘을 제안한다. GCN은 모바일 네트워크를 노드와 링크로 표현하고 인접 단말의 위치와 RTT 측정 정보 간에 상호 관계를 분석하여 최적의 그래프 모델을 생성하는 방법으로 계산 복잡도가 낮고 잡음에 강건한 측위 성능을 보여준다. 3대의 base station (BS)와 user equipment (UE)가 구성된 시뮬레이션 공간을 구성하고, UE가 이동하는 환경에서 GCN 기반 협력측위 알고리즘과 sum-product over a wireless network (SPAWN), alternating direction multiplier method (ADMM) 알고리즘과의 측위 성능 및 연산 시간을 비교했다. 그 결과, 제안 알고리즘이 기존 협력측위 알고리즘 SPAWN, ADMM 대비 측위 정확도가 향상된 것을 검증했으며, SPAWN 대비 연산시간이 16배 증가한 것을 보였다.

1. 서론

GPS가 거부되거나 base station(BS)의 신호가 저하되어 측위 정확도가 감소하는 non-line of sight (NLOS) 환경에서 단말 간에 SL 통신 및 협력측위를 이용하여 위치 정확도를 향상할 수 있다 [1]. 협력측위의 대표적인 연구로는 factor-graph 기반의 sum-product over a wireless network (SPAWN) 알고리즘이다 [2]. 하지만, 이 방법은 확률분포 곱을 이용한 추정 알고리즘으로 연산 속도가 느린 문제가 있다. 이를 보완하고자 alternating direction multiplying method (ADMM) 기반 협력측위 알고리즘이 제안되었지만, SPAWN 대비 측위 정확도가 낮은 한계점이 존재한다 [3]. 본 논문에서 제안하는 graph convolutional network(GCN)은 factor-graph와 같은 그래프 구조에서 노드 간의 관계를 학습하고 최적의 그래프를 생성하여 측위 성능 및 연산 복잡성을 개선한다. 본 논문에서는 round trip time (RTT) 측정 정보를 이용한 GCN 기반 협력측위 알고리즘을 제안한다. 측위 성능 분석을 위해 기존 협력측위 알고리즘과 측위 정확도 및 연산 시간을 시뮬레이션을 이용하여 비교한다.

2. GCN 기반 협력측위 알고리즘

A. 시스템 모델

User equipment(UE)와 BS는 2차원 좌표로 구성되어 있으며 i 번째 UE 위치는 $\mathbf{x}_i = [x_i, y_i]^T$ 로 정의된다. UE는 이웃한 BS 또는 UE와 통신하며 RTT를 측정하며, i 번째 UE와 j 번째 이웃과의 RTT는 다음과 같이 계산된다.

$$\text{RTT}_{i,j} = \frac{t_i + t_j}{2}, \quad (1)$$

여기서, t_i 는 UE가 이웃에게 보낸 신호의 전달 시간이며, t_j 는 j 번째 이웃이 UE에게 보낸 신호의 수신 시간이다. RTT는 다음과 같이 거리 측정값으로 변환된다.

$$d_{i,j} = \text{RTT}_{i,j} \times c + n_d, \quad (2)$$

여기서, c 는 빛의 속도이며, 그리고, $n_d \sim N(0, \sigma^2)$ 는 white Gaussian noise이며, σ^2 은 RTT 측정 에러의 분산이다.

UE는 F 개의 feature로 구성된 feature vector $\mathbf{z}_i \in \mathbb{R}^F$ 에 측정 정보를 저장하며, i 번째 UE의 \mathbf{z}_i 는 다음과 같다.

$$\mathbf{z}_i = [\mathbf{x}_{j \in M(\mathbf{x}_i)}^T, \mathbf{r}_{i,j}^T]^T, \quad (3)$$

여기서 $\mathbf{x}_{j \in M(\mathbf{x}_i)}^T$ 은 \mathbf{x}_i 를 제외한 인접 UE의 GPS 위치 측정값이며, $\mathbf{r}_{i,j}^T = [d_{i,j}, \dots, d_{i,j}]^T$ 은 인접 단말과의 RTT 측정값 벡터이다.

B. GCN의 그래프 구조

GCN은 이웃 노드 간 위치와 RTT 측정 정보를 이용하여 새로운 특징 벡터를 생성하는 그래프 신경망 모델이다. 협력측위 문제에서 각 단말은 그래프의 노드 $\nu = \{v_1, v_2, v_3, \dots, v_N\}$ 로 표현된다. 여기서 N 은 노드의 수이다. 각 노드가 연결된 상태를 adjacency matrix $\mathbf{A} \in \mathbb{R}^{N \times N}$ 으로 표현되며 인접 노드와 연결된 경우 $a_{i,j} = 1$, 연결되지 않았다면 $a_{i,j} = 0$ 이다. 각 노드에 연결된 엣지의 수를 degree matrix $\mathbf{D} = \text{diag}(d_1, d_2, \dots, d_N) \in \mathbb{R}^{N \times N}$ 으로 표현하며, 여기서 $d_i = \sum_j a_{i,j}$ 이다. GCN은 인접 노드 간에 관계를 분석하는데 자신의 정보를 고려하기 위해 identity matrix를 adjacency matrix와 degree matrix에 더한다. 이를 통해 augmented adjacency matrix $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}$ 와 augmented degree matrix $\tilde{\mathbf{D}} = \mathbf{D} + \mathbf{I}$ 가 된다.

C. Feature exchange와 feature propagation

인접 노드 간 특징을 분석하고 예측하기 위해 feature matrix $\mathbf{X} = [\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_N] \in \mathbb{R}^{N \times F}$ 를 구성한다. Feature matrix는 feature representation의 초기값 $\mathbf{X} = \mathbf{H}^0$ 으로 사용된다. 특히, k 번째 layer마다 훈련이 가능한 weight matrix $\mathbf{W}^k \in \mathbb{R}^{M_k \times M_{k-1}}$ 를 구성한다. 여기서 M_k 는 k 번째 layer의 뉴런 수로 정의되며 이를 이용하여 feature를 분석할 수 있는 깊이를 조절할 수 있다. 또한, GCN은 인접 단말 간에 비선형적인 관계를 분석하고 feature representation 하기 위하여 activation function ϕ 가 사용된다. k 번째 layer의 feature representation은 다음과 같다 [4].

$$\mathbf{H}^k \leftarrow \phi(\hat{\mathbf{A}} \mathbf{H}^{k-1} \mathbf{W}^k), \quad (4)$$

여기서 $\hat{\mathbf{A}} = \tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-1/2}$ 으로 augmented normalized adjacency matrix이다. 두 개의 GCN 레이어를 사용하는 예제에서, 2차원 위치 추정 모델은 다음과 같다.




그림 1. UE가 이동하는 협력측위 시나리오

$$\hat{\mathbf{R}} = \hat{\mathbf{A}}\phi(\hat{\mathbf{A}}\mathbf{X}^0\mathbf{W}^k)\mathbf{W}^k, \quad (5)$$

여기서 $\hat{\mathbf{R}} = [\hat{\mathbf{x}}_1, \hat{\mathbf{x}}_2, \dots, \hat{\mathbf{x}}_N]^T$ 은 각 노드의 2차원 위치를 추정한 결과로 구성되어 있으며, \mathbf{W}^k 는 loss function을 통해 최적화된다.

3. 데이터 수집 및 결과

A. 데이터 수집

본 논문에서는 그림 1과 같이 90 m² 면적의 MATLAB 시뮬레이션 환경을 구성했다. 3개의 BS는 각 $\mathbf{BS}_1 = [0, 0]^T$, $\mathbf{BS}_2 = [0, 30]^T$, $\mathbf{BS}_3 = [30, 30]^T$ 에 위치했으며, 각 UE는 $\mathbf{UE}_1 = [7, 15.5]^T$, $\mathbf{UE}_2 = [15.5, 9]^T$, $\mathbf{UE}_3 = [5, 15]^T$ 에 위치하여 지정된 경로를 이동한다. GCN은 32개의 뉴런으로 구성된 1개의 레이어와 256개의 뉴런으로 구성된 2개의 레이어로 이루어져 있다. 15,000 epoch을 설정하여 학습을 진행하였으며, learning rate는 0.1, optimizer는 Adam, activation function은 ReLU를 사용하였다. RTT $\sigma = 0.2$ m에서 3개의 UE 시간마다 1m씩 이동하며, 각 UE 마다 10,000개의 데이터를 수집하여 총 30,000개의 데이터를 훈련에 사용했다. 테스트 데이터로는 그림 1에 제시된 이동 경로를 각 UE가 한 바퀴에 51걸음 이동하는 데이터를 사용하였다.

B. 실험 결과 및 분석

시뮬레이션은 Intel-i7 2.6 GHz CPU와 16GB 메모리가 탑재된 컴퓨터에서 수행되었다. 그림 2는 $\sigma = 0.2$ m, $\sigma = 0.3$ m에서 Monte-Carlo 100회 수행한 측위 결과를 RMSE와 CDF를 사용하여 분석했다. 표 1에서 볼 수 있듯이 제안하는 GCN 기반 협력측위 알고리즘은 $\sigma = 0.2$ m 환경에서 50 백분위수에서 0.31 m 결과를 보였다. 이는 SPAWN과 유사한 성능이며, ADMM 대비 0.06 m 향상된 측위 성능을 나타낸다. $\sigma = 0.3$ m 환경에서 측위 성능을 분석한 결과, 제안하는 GCN 알고리즘은 50 백분위수에서 0.49 m 정확도를 보여 다른 알고리즘 대비 높은 측위 성능을 보였다. 특히, ADMM과 비교했을 때 0.23 m 향상된 정확도를 보여 측위 성능이 크게 개선되었음을 확인할 수 있다. 90 백분위수에서는 SPAWN과 0.06 m 정확도 차이로 큰 성능 향상은 없었으나, ADMM과 비교하면 약 0.45 m 차이로 상당히 개선된 측위 성능을 나타냈다.

표 1에서 제안 알고리즘과 SPAWN, ADMM 알고리즘의 연산 시간을 비교한 결과에 따르면, 제안 알고리즘은 0.6 ms의 연산 시간으로 SPAWN 대비 약 16배 향상된 성능을 보였다. 그러나 ADMM 보다는 0.2ms 감소한

표 1 협력측위 성능 분석 결과

측위 알고리즘	$\sigma = 0.2$ m		$\sigma = 0.3$ m		연산 시간 [ms]
	50 th	90 th	50 th	90 th	
GCN	0.31 m	0.53 m	0.49 m	0.84 m	0.6 ms
SPAWN	0.33 m	0.59 m	0.54 m	0.90 m	10.2 ms
ADMM	0.37 m	0.66 m	0.73 m	1.3 m	0.4 ms




그림 2. RTT 에러의 표준편차에 따른 측위 성능 CDF 분석 결과

결과를 나타냈다. 이러한 연산 시간 결과를 통해 SPAWN 알고리즘은 단말의 성능이 제한된 실시간 측위가 필요한 환경에서는 적용하기 어려운 것으로 판단된다. 위의 실험 결과를 종합하면, 제안하는 알고리즘은 기존 협력측위 알고리즘 대비 높은 측위 정확도를 보이면서도 SPAWN보다 16배 향상된 연산 속도를 나타내어 측위 정확도와 연산 속도 측면에서 모두 우수한 알고리즘임을 검증했다.

4. 결론

본 논문은 RTT 측정 정보를 이용하는 GCN 기반 협력측위 알고리즘을 제안하였다. 알고리즘의 측위 성능과 연산 시간을 분석하기 위해 90 m² 면적에 3대의 BS를 구성하고, 3대의 UE가 이동하는 시뮬레이션 환경을 설정하였다. RTT 에러의 표준편차를 0.2 m, 0.3 m의 두 가지 조건으로 설정하여 측위 정확도를 실험한 결과, 모든 실험에서 제안 알고리즘이 SPAWN과 ADMM보다 높은 측위 정확도를 보였다. 특히, 에러 표준편차가 높은 환경에서 더 우수한 성능을 나타내어 강건성이 높은 것을 검증했다. 연산 시간 측면에서 제안 알고리즘은 0.6 ms의 결과로 ADMM 대비 0.2 ms 감소한 결과를 보였지만, SPAWN 대비 16배 향상된 연산 시간을 확인했다.

ACKNOWLEDGMENT

이 논문은 2024년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No. RS-2024-00337857, 5G 및 다중 GNSS 기반 긴급구조용 복합측위 기술 개발)

참고 문헌

- [1] ZK. Ganesan, "5G advanced: Sidelink evolution," in *IEEE Commun. Stand. Mag.*, vol. 7, no. 1, pp. 58-63, 2023.
- [2] H. Wymeersch, J. Lien, and M. Z. Win, "Cooperative localization in wireless networks," in *Proc. IEEE*, 2009.
- [3] H. Kim, S. H. Lee, and S. Kim, "Cooperative localization with distributed ADMM over 5G-based VANETs," in *Proc. IEEE Wirel. Commun. Netw. Conf.*, 2018.
- [4] F. Wu, A. Souza, T. Zhang, C. Fifty, T. Yu, and K. Weinberger, "Simplifying graph convolutional networks," in *Proc. Int. Conf. Mach. Learn.*, 2019.