

# 무인 군집 노드 운용 시 거리 정보 기반 상대 측위 기술에서 최적 앵커 노드 선택 기술

현인영, 윤승미, 정의림\*  
국립한밭대학교

ihnyoung@gmail.com, ysm4518@gmail.com, \*erjeong@hanbat.ac.kr

## Optimum Anchor Node Selection Technique for Distance Based Relative Localization in Unmanned Swarm Node Operation

Hyun In Young, Yun Seung Mi, Jeong Eui Rim\* (corresponding author)  
Hanbat National University

### 요약

본 논문에서는 실내 무인 군집 로봇 시스템에서 상대 측위 기술의 성능을 개선하기 위해 최적의 앵커 노드 배치 기술을 제안한다. 제안하는 기법은 평균 절대 편차(mean absolute deviation, MAD)를 사용하여 무작위로 생성된 대형에서 앵커 노드의 역할을 하는 노드를 최적화 배치함으로써 상대 측위 기술의 성능을 개선한다. 앵커 노드 선택 기술을 적용했을 때의 성능을 확인하기 위해 노드의 존재 범위를  $x, y$ 축을 각각  $\pm 30m$ 로 설정하여 모의실험한 결과, 최적의 앵커 노드 배치 기술을 적용하기 전 대비 좌표 추정 성능이 약  $0.5m$  더 우수하다.

### I. 서론

군집 로봇 시스템(swarm robot system)은 다수의 로봇이 협력하여 복잡하고 다양한 작업을 수행할 시 단일 로봇 이상의 성능을 내는 것을 목표로 하는 시스템이다.[1][2] 이때, 로봇 간의 상호작용을 최적화하기 위한 상대 측위가 주목받고 있다. 대표적으로 잘 알려진 실·내외 상대 측위 기술은 GPS(global positioning system)이다. GPS는 인공위성에서 측정된 신호를 바탕으로 앵커 노드(anchor node)와 단말 노드 간 계산된 거리를 통해 물체의 상대 위치를 파악한다. 그러나, 고정된 앵커 노드 없이 단말 노드들이 이동하는 상황에서는 GPS를 활용한 측위가 어렵다.

[3]는 앵커 노드를 포함한 군집 노드가 움직이는 상황에서 거리 정보만을 활용하여 DNN(deep neural network) 기반 상대 측위 기술에 대한 연구가 진행되었다. 이 기술은 DNN을 사용함으로써 기존의 측위 기법 대비 약  $0.5m$ 의 성능 개선을 보였다. 그러나 첫번째 앵커 노드와 두번째 앵커 노드의 거리가 가깝거나, 세 개의 앵커 노드가 일직선을 이루게 될 경우, 대형을 제대로 예측하지 못하는 문제가 발생할 수 있다. 따라서, 이와 같은 문제를 해결하고 성능을 개선하기 위해 최적의 앵커 노드 선택 및 대형을 재배치하는 단계가 필요하다.

본 논문에서는 딥러닝 상대 측위 기술에서의 앵커 노드 최적화 배치 기법 방안을 제안한다. 모의 실험 결과, DNN 측위 기법에 앵커 노드 최적화 배치 기법을 적용하였을 때의 노드의 좌표 추정 성능이 개선되며, 좌표평면상 존재하는 노드의 개수가 감소할수록 측위 성능이 높아진다.

### II. 제안하는 앵커 노드 최적화 배치 기법

본 논문에서는 최적의 앵커 노드를 선택하여 대형을 재배치하는 방안 두 가지를 제안한다. 이때, 최적의 앵커 노드는 앵커 노드 간 거리가 충분히 멀면서 일직선 대형이 아닌 정삼각형에 가까운 조합이어야 한다. 세 개의 노드의 조합은 노드가  $N$ 개 존재하는 경우  ${}_N C_3$  개 존재한다. 최적의 앵커 노드를 선택한 후엔 대형을 원점(평행), 회전, 대칭 이동을 통해 앵커 노드에 대한 제한 조건에 따라 재배치한다. 그 과정은 Fig.1과 같다.




Fig.1 앵커 노드 최적화 배치 단계가 포함된 DNN 측위 과정

#### 1. 평균 절대 편차 기반 앵커 노드 선택 기법

평균 절대 편차(mean absolute deviation, MAD) 기반 앵커 노드 설정 기법은 좌표평면상 존재할 수 있는 세 개의 노드 조합 중에서 정삼각형에 가까운 세 개의 앵커 노드를 선택하는 기법이며, 식 1과 같이 표현할 수 있다.

$$MAD = \frac{1}{3}(|d_{i,j} - m| + |d_{i,j} - m| + |d_{i,j} - m|),$$
$$m = \frac{d_{1,2} + d_{1,3} + d_{2,3}}{3} \quad (1)$$

식 1은 세 변의 평균에 대한 각 변의 평균 절대 편차를 구하는 수식이다. 이때, 각 변은 세 개의 앵커 노드 간 거리를 의미한다. 좌표평면상 존재할 수 있는 세 개의 노드를 각각  $a, b, c$ 라고 할 때,  $d_{a,b}, d_{b,c}, d_{a,c}$ 는 세 개의 앵커

노드 간 거리 정보를 의미하며,  $m$ 은 세 변의 평균을 의미한다. 정삼각형의 가까운 세 개의 앵커 노드를 재선정하기 위해 세 변의 평균에 대한 각 변의 평균 절대 편차가 가장 작은 세 개의 앵커 노드를 선택하게 된다.

## 2. 평균 절대 편차 정규화 기반 앵커 노드 선택 기법

평균 절대 편차 정규화 기법은 2.1 절의 과정을 거쳐 평균 절대 편차를 모든 변의 합으로 나누어 정규화를 수행한 후, 그 값이 가장 작은 노드 조합을 선택하는 기법이다. 이 기법은 식 2와 같이 표현할 수 있다.

$$MAD_{normalization} = \frac{MAD}{(d_{1,2} + d_{1,3} + d_{2,3})} \quad (2)$$

정규화를 진행함으로써 세 개의 앵커 노드가 이루는 세 변에 대한 평균 절대 편차의 상대 크기가 가장 작은 세 개의 앵커 노드를 선택하게 된다.

## 3. 최적의 앵커 노드 선택 후 대형 재배치 시 고려사항

최적의 앵커 노드 선택 후 앵커 노드에 대한 제한 조건에 따라 재배치하는 과정이 수행된다. 앵커 노드에 대한 제한 조건은 다음과 같다. 2차원 좌표 평면상  $i$ 번째 노드의  $x, y$  좌표를  $(x_i, y_i)$ 이라 할 때, 첫 번째 노드는  $(x_1 = 0, y_1 = 0)$ , 두 번째 노드는  $(x_2 > 0, y_2 = 0)$ 로 지정한다. 세 번째 노드는  $x, y$  좌표 모두 생성하되,  $(y_3 > 0)$ 로 지정한다. 이러한 제한 조건에 따라 앵커 노드를 재배치하는 단계에서 대형이 설정한 노드의 제한 범위를 넘어가는 경우가 발생할 수 있다. 따라서, 노드가 존재할 수 있는 제한 범위를  $k$ 라고 할 때,  $k$ 를 넘어가는 경우 발생 가능한 최대값은  $2 \times k \times \sqrt{2}$ 이므로 이를 고려하여 노드 제한 범위를 설정해야 한다.

## III. 모의 실험 환경 및 결과

모의 실험을 위한 데이터는 MATLAB을 통해 생성하며, DNN 학습 및 성능 검증은 Tensorflow에서 진행한다. 좌표평면상 존재하는 노드의 개수는 4~8개로 가정한다. 추정하고자 하는 노드가  $N$ 개일 때, 입력데이터는 거리 정보로서  $N C_2$ 개이며, 출력데이터는 각 노드의 좌표 정보로서  $(2N - 3)$ 개이다. 노드의 개수에 따라 각각 최적화된 네트워크를 사용하여 학습하며, DNN 모델 학습 시 노드의 제한 범위는  $\pm 30m$ 로 지정하며, 데이터의 개수는 100,000개이다. 또한, 모델 검증 시 노드의 제한 범위는  $\pm 10m$ 로 지정하며, 데이터의 개수는 25,000개로 구성한다. 노드 간 거리 측정 오차는 표준편차(standard deviation, SD) 0.00m에서 0.10m 사이의 가우시안 잡음(gaussian noise)으로 가정한다. 좌표 추정 성능 평가 지표로는 평균 제곱근 오차(root mean squared error, RMSE)를 사용한다.

Fig. 2는 앵커 노드 최적화 배치 기법 적용 시 잡음의 표준편차에 따른 성능 그래프이다. 존재하는 노드의 개수를 5개로 고정하여 성능을 확인한 결과, 잡음의 표준편차와 상관없이 앵커 노드 최적화 배치 기법 적용 전 대비 적용 후 성능이 개선되었으며, 평균 절대 편차 정규화 기법의 성능이 가장 우수하다. 또한, 잡음의 표준편차가 커질수록 좌표 추정 성능이 저하된다.

Fig. 3는 앵커 노드 최적화 배치 기법 적용 시 존재하는 노드의 개수에 따른 성능 그래프이다. 잡음의 표준편차를 0.05m로 고정하여 성능을 비교한 결과,

노드의 개수가 감소할수록 좌표 추정 성능이 높아지며, 평균 절대 편차 정규화 기법의 성능이 가장 우수하다.




Fig.2 앵커 노드 최적화 배치 기법 적용 시 잡음의 표준편차에 따른 성능




Fig.3 앵커 노드 최적화 배치 기법 적용 시 노드의 개수에 따른 성능

## IV. 결론

본 논문에서는 실내 군집 로봇 시스템에서 상대 측위 기술의 성능을 개선하기 위한 최적의 앵커 노드 배치 기술을 제안하였다. 모의실험 결과에 따르면, 제안하는 최적의 앵커 노드 배치 기술을 적용한 경우, 적용 전 대비 잡음의 표준편차 0.05m 기준 RMSE가 약 0.5m 개선되었다. 또한, 노드의 개수가 감소할수록 좌표 추정 성능이 높아지며, 평균 절대 편차 정규화 기법의 성능이 가장 우수함을 확인하였다. 따라서, 제안하는 기술은 기존 DNN 기반 측위 기법의 좌표 추정 정확도를 높이는 데 기여하며, 주어진 환경에서 군집 로봇 간 원활한 상호작용과 협력을 지원할 것으로 기대된다.

## ACKNOWLEDGMENT

본 과제(결과물)는 2023년도 교육부의 재원으로 한국연구재단의 지원을 받아 수행된 지자체-대학 협력기반 지역혁신 사업의 결과입니다.(2021RIS-004)

## 참고 문헌

- [1] B. H. La, "Formation Motion Control for Swarm Robot," Journal of The Korean Institute of Electrical Engineers, pp.1886-1887, 2011
- [2] J. H. Heo, S. M. Hwang, C. Y. Kim, M. C. Lee, "Swarming Robot Control Algorithm Design," Proceedings of KIIS Spring Conference, Republic of Korea, pp. 399-402, 2020
- [3] I. Y. Hyun, S. M. Yun, J. E. Oh, M. S. Yang, E. R. Jeong, "Development of Indoor Relative Positioning Technology Using Distance Information of Swarm Nodes Based on Deep Learning," Proceedings of Symposium of the Korean Institute of communications and Information Sciences, pp. 1642-1643, 2023