

멀티로봇 위치 인식을 위한 강화 다차원 척도법

Robust Multidimensional Scaling for Multi-robot Localization

제 홍 모¹, 김 대 진²

Je Hong-Mo¹, Kim Daijin²

Abstract This paper presents a multi-robot localization based on multidimensional scaling (MDS) in spite of the existence of incomplete and noisy data. While the traditional algorithms for MDS work on the full-rank distance matrix, there might be many missing data in the real world due to occlusions. Moreover, it has no considerations to dealing with the uncertainty due to noisy observations. We propose a robust MDS to handle both the incomplete and noisy data, which is applied to solve the multi-robot localization problem. To deal with the incomplete data, we use the Nystrom approximation which approximates the full distance matrix. To deal with the uncertainty, we formulate a Bayesian framework for MDS which finds the posterior of coordinates of objects by means of statistical inference. We not only verify the performance of MDS-based multi-robot localization by computer simulations, but also implement a real world localization of multi-robot team. Using extensive empirical results, we show that the accuracy of the proposed method is almost similar to that of Monte Carlo Localization(MCL).

Keywords : Multidimensional Scaling, Multi-Robot Localization, Nystrom approximation, Monte Carlo Localization.

1. 서 론

이동 로봇이 주어진 임무를 완수하기 위해서 현재의 위치를 인식하는 것은 매우 중요하다. 최근에는 단일 로봇에 대한 위치 인식 뿐만 아니라 협력적으로 여러 대의 로봇들(멀티로봇)의 위치를 동시에 인식하는 문제들이 연구되어 지고 있다. 부가적인 인프라를 필요로 하지 않는 협력적인 방식의 멀티로봇 위치인식이 [1]에서 제안되었다. 이 방법은 “고정자-이동자” 전략에 기반한 방법으로 전체 로봇들을 우선 두 그룹으로 나눈다. 어느 한 시점에서 한 그룹은 “고정자”가 되어 정지해 있고, 또 한 그룹은 “이동자”가 되어 목표를 향해 주행하게 된다. 이동자 그룹에 속하는 로봇들은 고정자에 속한 로봇들을 랜드마크로 삼고 주행

중 발생하는 오도메트리(Odometry) 오차를 보정하게 된다. 각 그룹들은 목표 지점에 도달하기 까지 각각 역할을 바꾸어 가면서 주행하게 된다.

개개의 로봇에 대한 위치 인식을 위하여 확률론적인 방법인 몬테카를로 위치인식(Monte Carlo Localization ; MCL)이 제안되었고, 이 알고리즘을 기반으로 유사한 방법들이 많이 제안되었다^[2]. 또한 멀티로봇들이 적절하게 협력하면서 로봇들의 수가 증가 할 때마다 MCL의 정확도가 향상됨을 [3]에서 보였다. MCL에 기반 하지 않고 로봇들 상호간의 상대적 위치와 방향 관측치들의 관계만을 이용하는 방법들은 [4], [5], [6]에서 제안되었다. 최대우도추정법(Maximum Likelihood Estimation)을 이용한 멀티로봇 위치인식 방법이 [7]에서 소개되어졌으며, Extended Kalman Filter를 이용한 방법들도 [8], [9]에서 이미 제안되었다.

최근에 제안되어진 대부분의 멀티로봇 위치인식 방법들은 일반적으로 주어진 환경 내에서 “로봇들 자신이 어디에 있는가?”의 질문에 초점을 맞추고 있다.

※ 이 연구(논문)는 산업자원부 지원으로 수행하는 21세기 프론티어 연구개발사업(인간기능 생활지원 지능로봇 기술개발사업)의 일환으로 수행되었습니다

¹ 포항공대 컴퓨터공학과 박사과정

² 포항공대 컴퓨터공학과 교수

이 때 맵을 가지고 있어서 잘 알려져 있거나 한 번도 방문하지 않은 미지의 환경일 수도 있다. 그러나 본 논문에서 제안하는 방법으로 해결하고자 하는 멀티로봇 위치인식문제는 멀티로봇들로 구성된 팀 내에서 로봇 각자의 상대적인 위치를 찾는 과정이다. 따라서 본 논문은 주어진 환경 내에서 로봇의 위치좌표를 찾아내는 전역적 위치 추정과 맵빌딩을 위한 과정으로서의 위치인식을 고려하는 것이 아니라 로봇 팀 내에서의 상대적 위치인식에만 초점을 맞춘다. 만일 모든 로봇들의 전역적 위치를 파악하려면 멀티로봇 팀을 대표하는 한 대 이상의 로봇에 GPS 등 정밀위치 측정장비를 부착하거나 그 로봇에 대해서만 잘 알려진 전역위치인식 방법을 적용한 후 그 로봇의 위치를 원점으로 삼고 상대적 위치 변위를 보정함으로써 해결할 수 있다. 제안 하는 방법은 거리매핑(Distance Mapping)에 기반한 멀티로봇위치인식 방법이다. 거리매핑이란 오브젝트들간의 상대적 위치정보만을 가지고 오브젝트들의 좌표를 구해내는 과정으로써 본 논문에서는 다차원척도법(Multidimensional Scaling ; MDS)를 적용하였다. 본 논문에서 제안하는 방법은 2가지 특징이 있다. 첫째, 거리 매트릭스에서 부족한 관측치들에 대한 문제(Incomplete Data Problem)를 Nyström approximation을 이용하여 Full-Rank 매트릭스로 근사화 하였다. 둘째, 노이즈 혹은 관측오차등의 불확실성(Uncertainty)를 다룰 수 있도록 해석적 방법에 기반한 Classical MDS를 Bayesian 수식화를 통해 통계적 추론 기반의 MDS로 재구성하였다.

본 논문의 구성은 다음과 같다. 2장에서는 제안하는 방법의 핵심요소인 MDS 프레임워크에 대하여 서술한다. 3장에서는 MDS에 기반한 멀티로봇 위치인식 방법을 나타내었다. 4장에서는 제안하는 방법의 실효성을 검증하기 위해 실시한 여러 시뮬레이션 실험에 대한 결과를 요약하였다. 마지막으로 5장에서 본 논문의 결론 및 향후 과제를 정리하였다.

2. Multidimensional Scaling

MDS는 원래 오브젝트들의 근접성 혹은 유사도의 패턴을 시각화 하기 위해 고안되었다. 예를 들어 도시들 간의 거리 정보를 가지고 있는 매트릭스가 주어졌을 때, MDS를 통해 그려지는 도시들 간의 맵은 가까운 거리의 도시는 맵상에서도 가깝게, 먼 거리의 도시는 맵상에서도 멀게 나타내어지도록 함으로써, 도시들의 지리적인 실제 위치를 잘 반영하게 된다.

2.1 Classical MDS

Classical MDS 는 주어진 유클리드 거리 매트릭스(Euclidean Distance Matrix)로부터 오브젝트들의 P 차원좌표 즉 $\mathbf{x}_r(r=1, \dots, n)$ 를 구하는 과정을 말한다. 두 오브젝트 \mathbf{x}_i 와 \mathbf{x}_j 사이의 유클리드 거리는 다음과 같이 정의한다.

$$d_{ij}^2 = (\mathbf{x}_i - \mathbf{x}_j)^T (\mathbf{x}_i - \mathbf{x}_j). \quad (1)$$

\mathbf{x} 의 내적 매트릭스를 \mathbf{B} ($[\mathbf{B}]_{ij} = b_{ij} = \mathbf{x}_i^T \mathbf{x}_j$)라고 할 때 유클리드 d_{ij}^2 와 \mathbf{B} 의 관계식을 다음과 같이 표현할 수 있다.

$$\begin{aligned} d_{ij}^2 &= \mathbf{x}_i^T \mathbf{x}_i + \mathbf{x}_j^T \mathbf{x}_j - 2\mathbf{x}_i^T \mathbf{x}_j \\ &= b_{ii} + b_{jj} - 2b_{ij}. \end{aligned} \quad (2)$$

여기서 좌표 매트릭스 \mathbf{X} 를 원점에 대해 Double-Centering 함으로써($\sum_{i=1}^n b_{ij} = 0$) 식 (3)와 같이 나타낼 수 있다.

$$\begin{aligned} \frac{1}{N} \sum_{i=1}^N d_{ij}^2 &= \frac{1}{N} \sum_{i=1}^N b_{ii} + b_{jj}, \\ \frac{1}{N} \sum_{j=1}^N d_{ij}^2 &= b_{ii} + \frac{1}{N} \sum_{j=1}^N b_{jj}, \\ \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N d_{ij}^2 &= \frac{2}{N} \sum_{i=1}^N \sum_{j=1}^N b_{ii}. \end{aligned} \quad (3)$$

$$b_{ij} = -\frac{1}{2}(d_{ij}^2 - d_i^2 - d_j^2 + d^2) = (a_{ij} - a_i - a_j + a) \quad (4)$$

, 여기서 $a_{ij} = -\frac{1}{2}d_{ij}^2$ 이다.

Centering matrix $\mathbf{H} = \mathbf{I} - N^{-1}\mathbf{1}\mathbf{1}^T$ 가 주어졌을 때, $\mathbf{B} = \mathbf{H}\mathbf{A}\mathbf{H}$ 로 표현함으로써 $[a_{ij}] = \mathbf{A}$ 에 대한 Double-Centering을 적용할 수 있다. 매트릭스 \mathbf{B} 는 Symmetric 하고 Positive Semi Definite이다. 또한 $rank(\mathbf{B}) = rank(\mathbf{X}^T \mathbf{X}) = rank(\mathbf{X}) = p$ 이므로 식(5)와 같이 분해할 수 있다.

$$\mathbf{B} = \mathbf{\Gamma} \mathbf{\Lambda} \mathbf{\Gamma}^T, \quad (5)$$

여기서 $\mathbf{\Lambda} = diag(\lambda_1, \dots, \lambda_p)$ 는 \mathbf{B} 의 Eigenvector $\mathbf{\Gamma} = (\gamma_1, \dots, \gamma_p)$ 에 매칭되는 Eigenvalue들의 대각행렬이다. 마지막으로 p 차원의 좌표 $\mathbf{X} \in \mathbf{R}^p$ 얻기 위해서 식 (6)을 계산한다.

$$\mathbf{X} = \mathbf{\Gamma}\mathbf{\Lambda}^{1/2}. \quad (6)$$

2.2 Nyström approximation

Classical MDS는 Full-Ranked 거리 매트릭스가 주어질 경우 모든 오브젝트들에 대한 좌표를 계산할 수 있다. 그러나 식(5)에서 수행하Singular Value Decomposition은 계산복잡도가 $O(N^3)$ 로써 오브젝트들의 개수가 많아지면 적용하기 어려운 문제점이 있다. 이 문제를 해결하기 위하여 근사법을 적용하였다. Nyström Approximation은 Gram kernel 혹은 유클리드 거리매트릭스의 채움문제(Completion Problem)에 이용되는 방법이다. Nyström approximation은 거리매트릭스 \mathbf{D} 의 부분행렬만을 사용하여 커널매트릭스 \mathbf{K} 를 구할 수 있다. 다음과 같이 두개의 매트릭스 \mathbf{K} 와 \mathbf{D} 를 정의할 수 있다.

$$\mathbf{D} = \begin{bmatrix} \mathbf{A} & \mathbf{B} \\ \mathbf{B}^T & \mathbf{C} \end{bmatrix}, \mathbf{K} = \begin{bmatrix} \mathbf{E} & \mathbf{F} \\ \mathbf{F}^T & \mathbf{G} \end{bmatrix} \quad (7)$$

, 여기서 \mathbf{N} 을 전체행렬의 크기라고 할 때, \mathbf{A} , \mathbf{E} 의 행렬크기는 $m \times m$, \mathbf{B} 와 \mathbf{F} 의 행렬크기는 $m \times (N-m)$, 그리고 \mathbf{C} 와 \mathbf{G} 의 행렬크기는 각각 $(N-m) \times (N-m)$ 이 된다. Nyström approximation은 매트릭스 \mathbf{K} 에 속한 \mathbf{E} 와 \mathbf{F} 만으로 모든 오브젝트들의 좌표 \mathbf{X}_i 를 구할 수 있다.

$$\mathbf{K} = \begin{bmatrix} \mathbf{X}^T \mathbf{X} & \mathbf{X}^T \mathbf{Y} \\ \mathbf{Y}^T \mathbf{X} & \mathbf{Y}^T \mathbf{Y} \end{bmatrix} \quad (8)$$

식 (8)과 식 (7) 관계에 의해 부분행렬을 다음과 같이 계산할 수 있다.

$$\mathbf{E} = \mathbf{X}^T \mathbf{X}, \quad \mathbf{F} = \mathbf{X}^T \mathbf{Y}, \quad (9)$$

여기서 \mathbf{E} 는 2.1절에서 설명한 Classical MDS에서의 \mathbf{B} 와 같다고 고려한다. 그러면 \mathbf{E} 에 대하여 SVD를 적용하여 $\mathbf{E} = \mathbf{\Gamma}\mathbf{\Lambda}\mathbf{\Gamma}^T$ 식(6)의 좌표를 구할 수 있다. 이 좌표들을 가지고 선형시스템을 풀어서 \mathbf{F} 에 해당하는 좌표를 계산할 수 있다. 우선 \mathbf{F} 와 관련있는 오브젝트 좌표들을 \mathbf{Y} 로 두고 다음 식을 계산한다.

$$\mathbf{Y} = \mathbf{X}^{-T} \mathbf{F} = \mathbf{\Gamma}^T \mathbf{\Lambda}^{-1/2} \mathbf{F}. \quad (10)$$

\mathbf{X} 와 \mathbf{Y} 를 식(8)에 대입하면 \mathbf{K} 를 다음과 같이 근사화 할 수 있다.

$$\tilde{\mathbf{K}} = \begin{bmatrix} \mathbf{E} & \mathbf{F} \\ \mathbf{F}^T & \mathbf{F}^T \mathbf{E}^{-1} \mathbf{F} \end{bmatrix}. \quad (11)$$

식 (11)에서와 같이 근사화한 \mathbf{K} 의 rank는 m 보다 작거나 같다. 근사화의 등식은 $\|\mathbf{G} - \mathbf{F}^T \mathbf{E}^{-1} \mathbf{F}\|$ 에 비례하게 된다. 부분행렬 \mathbf{E} 와 \mathbf{F} 는 실제 거리매트릭스인 \mathbf{D} 의 부분행렬 \mathbf{A} 와 \mathbf{B} 로부터 계산할 수 있다. (\mathbf{A} 와 \mathbf{B} 는 거리데이터 이므로 \mathbf{E} 를 \mathbf{F} 를 구하기 위해서는 Double-Centering을 적용해야 한다.)

$$E_{ij} = -\frac{1}{2} \left(A_{ij}^2 - e_i \frac{1}{m} \sum_r A_{rj}^2 - e_j \frac{1}{m} \sum_s A_{is}^2 + \frac{1}{m^2} \sum_{r,s} A_{rs}^2 \right) \quad (12)$$

$$F_{ij} = -\frac{1}{2} \left(B_{ij}^2 - e_i \frac{1}{m} \sum_r B_{rj}^2 - e_j \frac{1}{m} \sum_r A_{ir}^2 \right) \quad (13)$$

, 여기서 e_i 는 모든 요소가 1인 벡터이다. 이렇게 식 (13)은 식(4)와 유사한 형태가 된다.

2.3 통계적 추론기반 MDS

Classical MDS에서는 관측값의 불확실성(uncertainty)을 다루지 않는다. 하지만 실제 응용에서는 센서의 부정확성 혹은 외부잡음등의 요인으로 관측값에 불확실성이 추가되어 지고, 어떠한 방법으로든 이를 다룰 수 있어야 한다. 이 문제를 해결하기 위해 우리는 통계적 추론에 기반한 MDS를 고려하였다. 먼저 잡음이 포함된 관측값 δ 은 정규분포를 따른다고 가정하였다. $\delta_{ij} \sim N(d_{ij}, \sigma^2)$, 여기서 d_{ij} 는 실제거리이고 σ^2 는 잡음 분포의 분산이다. 일반적으로 두 오브젝트간의 진짜 거리는 관측을 통해서 알 수 없다. 센서를 통해 측정된 거리는 센서의 특성에 의한 잡음분포의 영향을 받게 된다. 통계적 추론 기반의 MDS를 위해 다음의 매트릭스들을 정의하였다.

$$\mathbf{D} = \begin{bmatrix} d_{11}^2 & \cdots & d_{1N}^2 \\ \vdots & d_{ii} & \vdots \\ d_{N1}^2 & \cdots & d_{NN}^2 \end{bmatrix}, \mathbf{\Lambda} = \begin{bmatrix} \delta_{11} & \cdots & \delta_{11} \\ \vdots & \delta_{11} & \vdots \\ \delta_{N1} & \cdots & \delta_{NN} \end{bmatrix}, \quad (14)$$

여기서 \mathbf{D} 는 추정하고자 하는 거리, $\mathbf{\Delta}$ 는 관측한 거리에 대한 매트릭스 들이다. Classical MDS에서는 $\mathbf{\Delta}$ 를 실제거리라 가정하지만, 본 논문에서는 \mathbf{D} 를 통계적 추론에 기반하여 추정하였다. \mathbf{D} 와 $\mathbf{\Delta}$ 간의 Bayesian 수식을 다음과 같이 표현할 수 있다.

$$P(\mathbf{\Delta}|\mathbf{D}) = \frac{P(\mathbf{D}|\mathbf{\Delta})P(\mathbf{\Delta})}{\int P(\mathbf{D}|\mathbf{\Delta})} \quad (15)$$

$\mathbf{\Delta}$ 가 주어졌을 때, 식(15)에 의해 \mathbf{D} 를 추론함으로써 실제 거리를 추정할 수 있다. $P(\mathbf{D}|\mathbf{\Delta})$ 의 최대사후확률(Maximum A Posterior ;MAP)는 다음과 같이 구할 수 있다.

$$\ln P(\mathbf{D}|\mathbf{\Delta}) = -\frac{1}{2} \ln[(2\pi)^2 |\mathbf{\Sigma}|] - \frac{1}{2} (\mathbf{D}-\mathbf{\Delta})^T \mathbf{\Sigma}^{-1} (\mathbf{D}-\mathbf{\Delta}). \quad (16)$$

식(16)을 풀기 위해 [10]에서 소개한 'Metropolis Hasting' 알고리즘을 이용하였다. 식(17)의 해를 거리 매트릭스의 추정치로 한다.

$$\arg \max_{\mathbf{D}} \ln P(\mathbf{D}|\mathbf{\Delta}). \quad (17)$$

3. Robust MDS 기반 멀티로봇 위치인식

이 절에서는 불완전한 거리정보를 채우기 위해 Nyström approximation으로 근사화 하고, 통계적 추론으로 관측값의 불확실성을 다룰 수 있는 Robust MDS에 기반한 멀티로봇 위치인식에 대하여 설명한다. 로봇 상호간의 거리 정보를 획득하기 위해 적절한 거리측정장비 (레이저, 초음파, 비전센서등)를 사용한다고 가정한다. 또한 거리매트릭스 초기화에서 이동정보를 활용하기 위해 이동거리 혹은 방향을 계산할 수 있는 장치들(방향계, Odometry)이 장착되어 있다고 가정한다. 시간 t 에서 로봇 i 의 위치를 $x_i(t)$ 라고 할 때 우리가 추정하고자 하는 상태는 다음과 같이 표시할 수 있다.

$$X(t) = [x_1(t), x_2(t), x_3(t), \dots, x_N(t)]. \quad (18)$$

표1 에서 제안하는 위치인식 방법의 알고리즘을 요약하였다.

관측치 매트릭스 $\mathbf{\Delta}$ 중 거리측정센서의 범위 밖

에 있거나, 다른 로봇 혹은 장애물에 의해 가려진 경우 관측치를 획득하지 못할 경우가 있다. 이를 해결하기 위해 3가지 초기화 방안을 고려할 수 있다.

표 1. Robust MDS기반 위치 인식 알고리즘

초기화:
- N 개의 로봇에 대한 거리 관측치 매트릭스 $\mathbf{\Delta}$ 를 획득 - 식 (17)로 거리매트릭스 \mathbf{D} 를 추정 - 식 (7)의 A행렬(m 차원의 부분행렬)이 우선 되도록 정렬
Nyström approximation:
- 식 (12)와 식(13)을 이용하여 거리 매트릭스 \mathbf{D} 로부터 부분행렬 \mathbf{E} 와 \mathbf{F} 를 계산 - Full-Ranked 커널 \mathbf{K} 를 $\tilde{\mathbf{K}}$ 로 근사화
좌표계산 :
- 식(5) SVD로 $\mathbf{E} = \mathbf{\Gamma}\mathbf{\Lambda}\mathbf{\Gamma}^T$ 계산 - 식(6)을 계산 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]$: 멀티로봇들의 상대적 위치 좌표

RANDOM - 주어진 환경이나 로봇의 이동과 관련한 어떤 정보도 얻을 수 없는 경우 가장 쉽게 고려할 수 있는 방법이다. 각 각의 좌표를 난수에의해 초기화 한다.

$$X^{(0)}(t) \sim N(\mu, \sigma^2)$$

PREVIOUS - 매 스텝마다 로봇의 움직임이 적은 경우에는 이전 단계에서 계산한 위치를 현재 단계에서 초기치로 부여하는 방법이다.

$$X^{(0)}(t) = X(t-1)$$

PREDICTION - 만일 로봇 스스로 움직인 거리에 대한 정보를 획득할 수 있으면 이전단계에서 계산했던 위치에 현재 이동 정보를 보정함으로써 현재 단계에서의 초기치를 부여할 수 있다.

$$X(t) = X(t-1) + \rho X(t)$$

여기서 $\rho X(t)$ 는 로봇의 이동 정보이다.

4. 실험결과

4.1 초기화 전략에 따른 성능

그림 1은 3절에서 설명한 관측치 거리 매트릭스의 3가지 초기화 전략에 따른 성능비교에 관한 결과를

보인다. MATLAB에서 100대의 로봇의 이동과 관측 거리를 모델링하여 1200 스텝에 대하여 위치인식을 수행할 때, 수렴하는 데 소요된 반복횟수(iterations) (그림 1(a))와 위치 인식 결과 중 한 예(그림 1(b))를 보였다. MDS는 100대 로봇에 대한 상대위치를 계산했지만, 기준이 되는 로봇의 절대위치가 매 스텝마다 시뮬레이션 프로그램에 의해 주어지므로 좌표변환에 의해 위치인식 결과를 표시할 수 있다. 실험결과 RANDOM의 평균반복횟수는 40.92, PREVIOUS는 18.20, PREDICTION은 12.46회 에 수렴하였으며, 이때 상대적인 위치 오차는 RANDOM은 0.16(meters), PREVIOUS는 0.143, PREDICTION은 0.132를 보였다. 이동정보를 활용할 수 없는 경우에도 PREVIOUS를 통해 RANDOM보다는 좋은 성능을 기대할 수 있다.

4.2 모든 거리 정보를 가지고 있는 경우

로봇에 부착된 거리측정 장비가 장애물에 의한 가리움의 영향을 받지 않고 (RFID, 무선표지기반), 모든 로봇들간의 상대적 거리를 획득할 수 있는 이상적인 공간을 가정하였다.

그림 2는 로봇이 4대에서 20대사이 일 때 MCL에 의한 방법과 제안한 Robust MDS에 기반한 멀티로봇 위치 인식의 평균 성능이다. 제안하는 위치인식 방법은 다른 로봇들이 랜드마크의 역할을 할 필요가 없지만, MCL을 멀티로봇 위치인 식으로 확장





그림 2. 위치인식 성능비교 MCL vs Robust MDS

하기 위해서 “고정자-이동자” 전략을 통해 고정자 그룹에 속한 로봇들을 랜드마크로 활용하였다. 실험결과 MCL방법의 평균오차는 0.43이고, Robust MDS 방법의 평균오차는 0.41로 비슷한 성능을 보였다.


4.3 미관측 거리 정보들을 포함하고 있는 경우

실제환경에 보다 근접한 시뮬레이션을 위해 Player/Stage환경^[11]에서 실험을 수행하였다. 그림 3(a)는 실험을 수행한 시뮬레이션 환경을 나타낸다.

모델된 로봇은 P3DX이며 각 로봇은 8미터 관측 가능거리, 180도 시야각의 SICK200을 탑재하고 로봇의 ID를 인식할 수 있는 바코드를 부착하게 하였다. 따라서 검은색 사각형으로 표시된 장애물에 의




(a) 각 step에서 수렴을 위해 소요된 반복횟수 비교




(b) 로봇 100대의 위치 인식

그림 1. 초기화 전략에 따른 성능



(a) 9대 로봇 Player / Stage 환경



(b) 주행 자취 (Dot; ground Truth, 도형; 위치인식결과)

그림 3. 시뮬레이션 환경에서의 멀티로봇 위치인식

해 가리워지거나, 관측가능거리 혹은 시야각을 벗어난 로봇들에 대한 거리 정보는 획득할 수 없다. 9대의 로봇이 교차로형 복도에서 Π 형태로 이동하는 중 위치인식결과를 그림 3(b)에서 나타내었다. 9대의 로봇들을 위한 거리매트릭스를 위해서 81개의 관측치가 필요하지만, 시뮬레이션 중에는 30~65개 사이의 미관측치가 발생하였다. 실험결과 관측치의 잡음에 대한 분산이 0.2(meters), 이동 정보의 불확실성에 대한 분산이 0.1일 대 평균오차는 0.42를 보였다.

5. 결 론

본 논문에서는 전역적 위치인식과 맵 빌딩에 관한 내용은 다루지 않았다. 멀티로봇의 상대적인 위치를 인식하기 위해 제안한 Robust MDS방법은 통계적 추론을 위한 Bayesian 수식화를 통해 불확실성을 다룰 수 있게 하였고 Nyström Approximation으로 무거운 계산복잡도의 과정을 근사화 하였다. 제안한 방법의 실효성을 확인하기 위해 시뮬레이션 환경 뿐만 아니라 실제 멀티로봇팀의 위치인식에 적용하였다. 기존 방법과의 비교에서 MCL방법에 의한 멀티로봇 위치인식에 근접한 성능을 보임을 확인하였다.

참 고 문 헌

[1] R. Kurazume, S. Nagata, and S. Hirose. "Cooperative positioning with multiple robots", *ICRA*, vol. 2, pp. 1250-1257, May 1994.

[2] D. Fox, W. Burgard, and H. Thrun, "A Probabilistic Approach to Collaborative Multi-Robot Localization", *Autonomous Robots*, vol. 8, pp. 325-344, 2000.

[3] I. M. Rekleitis, G. Dudek, and E. E. Milios, "Multi-robot Cooperative localizations: a study of trade-off between efficiency and accuracy", *IROS 2002*, vol. 3, Lausanne Switzerland, pp. 2690-2695, Oct. 2002.

[4] H. Sugiyama, "A method for an autonomous mobile robot to recognize its position in the global coordinate system when bulding a map", *IROS 1993*, vol. 3, Yokohama Japan, pp. 2186-2191, 1993.

[5] J. Hyams, M. W. Powell, and R. Murphy, "Cooperative Navigation of micro-rovers using color segmentation", *ICRA 1999*, pp. 195-201, 1999.

[6] A. Howard, M. J. Mataric, G. S. Sukhatme, "Putting the 'I' in 'Team': An Ego-Centric Approach to Cooperative Localization", In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA03)*, pp. 868-892, Taipei, Taiwan, September 2003.

[7] A. Howard, M. J. Mataric, and G. S. Sukhatme, "Localization for Mobile Robot Teams Using Maximum Likelihood Estimation", In *Proceedings of the 2002 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems*, vol. 3, Lausanne Switzerland, pp. 2849-2854, Oct. 2002.

[8] S. I. Roumeliotis and G. A. Bekey, "Distributed Multirobot Localization", *IEEE Transaction On Robotics And Automation*", vol. 18, no. 5, Oct. 2002.

[9] A. Martinelli, F. Font, and R. Siegwart, "Multi-Robot Localization Using Relative Observations", In *Proceedings of the 2005 IEEE Int. Conf. on Robotics and Automation*, Barcelona Spain, pp. 2808-2812, April 2005.

[10] Man-Suk Oh and Adrian E. Raftery, "Bayesian multidimensional scaling and choice of dimension", *Journal of the American Statistical Association*, vol. 96, no. 455, pp. 1031-1045, 2001.

[11] B. P. Gerkey, R. T. Vaughan, A. Howard, "The Player/stage Project: Tools for Multi-Robot and Distributed Sensor Systems", In *Proceedings of the International Conference On Advanced Robotics (ICAR 2003)*, pp. 317-323, Coimbra Portugal, Jun. 2003.



제 흥 모

1999 영남대학교 컴퓨터공학과 (공학사)
2002 포항공과대학교 컴퓨터공학과 (공학석사)

2003~현재 포항공과대학교 컴퓨터공학과 박사과정
관심분야: 로보틱스, 인간기계상호작용



김 대 진

1981 연세대학교 전자공학과 (공학사)
1984 KAIST 전기전자공학과 (공학석사)
1991 Syracuse University 전기 컴퓨터공학과 (공학박사)

2000~현재 포항공과대학교 컴퓨터공학과 교수
관심분야: 컴퓨터비전, 생체인식, 인간기계상호작용