

효율적인 몬테카를로 위치추정을 위한 샘플 수의 감소

Reduction in Sample Size for Efficient Monte Carlo Localization

양 주 호, 송 재 복*

(Ju-Ho Yang and Jae-Bok Song)

Abstract : Monte Carlo localization is known to be one of the most reliable methods for pose estimation of a mobile robot. Although MCL is capable of estimating the robot pose even for a completely unknown initial pose in the known environment, it takes considerable time to give an initial pose estimate because the number of random samples is usually very large especially for a large-scale environment. For practical implementation of MCL, therefore, a reduction in sample size is desirable. This paper presents a novel approach to reducing the number of samples used in the particle filter for efficient implementation of MCL. To this end, the topological information generated through the thinning technique, which is commonly used in image processing, is employed. The global topological map is first created from the given grid map for the environment. The robot then scans the local environment using a laser rangefinder and generates a local topological map. The robot then navigates only on this local topological edge, which is likely to be similar to the one obtained off-line from the given grid map. Random samples are drawn near the topological edge instead of being taken with uniform distribution all over the environment, since the robot traverses along the edge. Experimental results using the proposed method show that the number of samples can be reduced considerably, and the time required for robot pose estimation can also be substantially decreased without adverse effects on the performance of MCL.

Keywords : monte carlo localization, topological map, grid map, thinning technique

I. 서론

이동로봇의 주행에 있어서 자신의 위치를 정확히 추정하는 위치추정(localization)은 매우 중요한데, 크게 국부 위치추정(local localization)과 전역 위치추정(global localization)으로 분류한다. 국부 위치추정 또는 위치추적(position tracking)은 로봇이 알고 있는 자신의 초기위치를 기준하여 이동하는 동안의 위치의 변화를 측정함으로써 자신의 위치를 추정한다. 반면에, 전역 위치추정은 자신의 초기위치를 모른다는 가정하고 로봇이 위치할 수 있는 전체 영역을 대상으로 자신의 위치를 추정하여야 하므로, 국부 위치추정보다는 훨씬 어려운 문제이다.

위치추정의 문제를 해결하기 위해서 현재까지 개발된 방법은 칼만필터(Kalman Filter; KF)를 이용한 방법[1]과 마코프 위치추정(Markov localization)[2], 몬테카를로 위치추정(Monte Carlo Localization; MCL)[3], 그리고 두 가지 방법을 혼합한 방법 등이 있다. KF를 이용한 방법은 주어진 초기위치로부터 센서에 의한 이동정보를 KF를 통한 보정을 통해서 오차를 최소화하여 위치추정을 수행한다. 그러므로 초기위치를 정확하게 알고 센서의 오차가 작다면, 정확하고 효과적으로 위치를 추정할 수 있다. 반면에, 마코프 위치추정 방법은 전역 위치추정에 주로 사용된다. 격자지도를 이용할 경우 로봇이 위치할 수 있는 모든 격자에 대하여 로봇이 위치할 확률을 계산해야 하므로 위치추정 시간이 오래 걸리고, 확률이 격자 단위로 산출되므로 격자 크기에 따라 위치 정확도가 좌우된다. 몬테카를로 위치추정(MCL)도 마코프 위치추정처럼 전역

위치추정을 수행하지만, 전체 격자에 대해서 계산을 수행하지 않고 일정수의 샘플에서만 로봇의 위치 가능성을 계산하기 때문에 수행시간이 마코프 위치추정 방법보다 짧다. 혼합 방식은 KF와 마코프 위치추정이나 KF와 MCL의 조합으로 두 방법의 장점을 취합하여 위치추정의 효율을 높이는 데 목적이 있다.

현재 MCL은 로봇의 위치추정 문제를 가장 잘 해결할 수 있는 방법으로 인정되고 있으나, KF에 비해 수행시간이 오래 걸리는 문제가 있다. MCL은 로봇이 위치할 가능성이 있는 모든 영역에서 로봇의 위치를 나타내는 샘플을 랜덤하게 추출하고, 각 샘플이 실제 로봇의 위치인지를 계산하는 과정을 거치게 된다. 따라서 추출한 샘플의 수는 MCL의 성능 및 수행시간과 직접적으로 연관이 있다. 샘플 수가 많으면 위치 정확도는 향상되고 위치추정 실패율은 감소되지만, 수행시간이 길어져 위치갱신이 늦어진다. MCL은 거리센서의 정보를 받아 위치추정 알고리즘을 이용하여 추정위치를 갱신하는 과정을 반복적으로 수행하게 된다. 이 과정에서 로봇은 계속 이동하게 되므로 위치추정을 통해 갱신된 위치는 현재 로봇의 위치가 아니라 위치추정 알고리즘이 수행되기 시작할 때 위치에 해당하게 된다. 그런데 한 과정이 오래 걸려 위치 갱신이 늦어지면 갱신된 위치와 현재 로봇의 위치의 차이가 커지게 되어 로봇 위치추정의 실시간성을 저하시키게 된다. 이러한 이유로 MCL의 위치추정 정확도를 저하시키지 않는 전제하에서 최소한의 샘플을 사용하여 수행시간을 감소시키는 것이 중요하다.

이를 위해 처음에는 전역환경에서 기존의 MCL처럼 샘플을 추출하지만, 샘플들이 로봇의 실제 위치 주변으로 수렴하여 처음보다는 적은 수의 샘플로도 위치추정을 할 수 있게 되면 likelihood[4]나 KLD-sampling[5]을 적용하여 적절한 샘플수로 조절하는 방법이 있다. likelihood를 이용하는 방법은 미리 입력된 지도를 바탕으로 샘플위치에서 계산한 환경정보

* 책임저자(Corresponding Author)

논문접수 : 2005. 8. 2., 채택확정 : 2006. 1. 17.

양주호, 송재복 : 고려대학교 기계공학과

(mfls200@korea.ac.kr/jbsong@korea.ac.kr)

※ 이 연구는 산업자원부 지원으로 수행하는 21세기 프론티어 연구 개발사업(인간기능 생활지원 지능로봇 기술개발사업)의 일환으로 수행되었음.

와 로봇이 실제 주위를 측정한 환경정보의 유사도(likelihood)를 바탕으로 적절한 샘플 수를 결정한다. KLD-sampling은 샘플의 최고 유사도와 확률분포 사이의 거리를 Kullback-Leibler distance(KL-distance) 공식에 의해 측정하여 이 값에 의해 샘플 수를 선택한다. 이렇게 샘플 수를 조절하면 MCL 알고리즘 1회 수행시간이 감소하여 실시간성을 향상시킬 수 있다. 그러나 로봇의 위치를 모르는 초기에는 샘플 수가 여전히 기존 방법과 같아서 초기 수행시간은 단축되지 못한다.

초기에 샘플이 많이 필요한 이유는 샘플링이 환경 전역을 대상으로 수행되기 때문이다. 만약, 로봇이 위치할 가능성이 높은 영역에 대해서만 샘플을 추출한다면, MCL의 초기에도 기존의 방법에 비하여 필요한 샘플 수를 획기적으로 감소시켜 MCL 알고리즘의 1회 수행시간을 단축시킬 수 있다. 따라서 위치추정의 전반에 걸쳐서 기존의 방법에 비해 빠른 위치 갱신을 할 수 있다. 그러나 이 방법에서는 로봇이 위치할 가능성이 높은 영역을 어떻게 설정하느냐가 관건이 된다. 본 연구에서는 이를 해결하기 위해 위상정보(topological information)를 이용하였다. 장애물로부터 등거리에 위치하는 보로노이 선도와 유사한 위상에지(topological edge)를 추출하고, 로봇이 이 에지 상을 주행한다면 에지 주변이 바로 로봇이 위치할 가능성이 높은 후보 영역이 된다. 이러한 위상에지는 연구실에 보유하고 있는 세선화(thinning) 기반의 위상지도 작성 기술을 이용하여 거리센서(range sensor)의 데이터로부터 실시간으로 작성할 수 있다[6].

II. 몬테카를로 위치추정(MCL)

1. Bayes filtering

MCL은 로봇이 환경상의 임의의 위치에 있을 가능성을 확률로 나타낸다. 즉, 로봇은 엔코더로부터의 이동정보와 거리센서로부터의 거리정보를 바탕으로 베이저언 갱신 공식(Bayesian update formula)을 이용하여 belief라 불리는 사후확률(posterior probability)을 다음과 같이 계산한다[7].

$$bel(x_t) = p(x_t | z_{0...t}, u_{0...t}) \tag{1}$$

여기서, x_t 는 시간 t 에서의 로봇의 위치(x, y, θ)를 나타낸다. 그리고 $z_{0...t} = \{z_0, z_1, \dots, z_t\}$ 는 시간 t 까지의 거리센서(예, 레이저, 초음파, 적외선 센서 등)로부터의 거리정보를 나타내며, $u_{0...t} = \{u_0, u_1, \dots, u_t\}$ 는 시간 t 까지의 엔코더로부터의 이동정보를 표시한다. 여기서 거리센서의 데이터는 센서의 정밀도에 따라 데이터의 신뢰성이 달라질 수 있고, 엔코더의 이동정보는 노면의 상태(미끄러움, 울퉁불퉁함 등)나 로봇 운동부의 정밀도(양쪽 바퀴의 크기, 바퀴들의 기계적 정렬, 바퀴의 놀림 등)에 따라 비교적 큰 오차가 발생할 수 있다. 그러므로 이러한 불확실성에 대처하기 위하여, 이러한 데이터의 오차에 대한 확률모델인 센서모델(sensor model)과 이동모델(motion model)을 수립한다. 베이즈 필터링은 예측(prediction)과 갱신(update)의 두 단계로 수행된다.

예측단계에서는 로봇의 이동모델에 엔코더로부터의 이동정보를 입력하여 다음 시간에서의 로봇의 위치를 추정한다.

$$bel^-(x_t) = \int p(x_t | x_{t-1}, u_{t-1}) bel(x_{t-1}) dx_{t-1} \tag{2}$$

이전 위치 x_{t-1} 에서의 확률 $bel(x_{t-1})$ 에 이동모델인 $p(x_t | x_{t-1}, u_{t-1})$ 을 적용함으로써 새로운 위치 x_t 에서의 확률 $bel(x_t)$ 를 계산한다. 이때, 새로운 위치 x_t 는 마코프 가정에 의해 단지 이전 위치 x_{t-1} 와 이동명령(즉, 엔코더로부터의 이동정보) u_{t-1} 에만 의존한다.

갱신단계에서는 앞의 단계에서 예측한 로봇의 위치를 센서모델 $p(z_t | x_t)$ 을 이용하여 보다 정확한 현재 위치의 확률 $bel(x_t)$ 를 다음과 같이 구한다.

$$bel(x_t) = \eta_t p(z_t | x_t) bel^-(x_t) \tag{3}$$

여기서, η_t 는 정규화상수(normalization constant)이다. 앞의 두 확률모델은 가우시안(Gaussian) 분포를 이루고, 적용되는 오차도 평균이 0인 가우시안 확률분포를 이룬다고 가정한다.

2. Particle filtering

MCL에서는 지도상의 임의의 위치(x, y, θ)를 로봇이 위치할 수 있는 후보위치로 선정하고, 이를 샘플(또는 particle)이라고 한다. 이러한 샘플을 여러 개 추출하여 로봇이 이에 위치할 가능성을 확률로 나타낸다. 여러 particle filter 중 가장 많이 사용되는 SIR (Sampling Importance Re-sampling) 알고리즘은 다음 세 단계로 수행된다[8].

Sampling: $bel(x_{t-1})$ 에 따라 분포된 이전의 샘플 집합 X_{t-1} 에서 이동모델 $p(x_t | x_{t-1}, u_{t-1})$ 에 따라 새로운 샘플 집합 X_t 를 추출한다.

Importance weighting: 거리센서 정보로부터 얻은 확률분포를 이용하여 다음 식으로 샘플 $x_t^{(i)}$ 의 가중치 $\omega_t^{(i)}$ 를 구한다.

$$\omega_t^{(i)} = \eta p(z_t | x_t^{(i)}) \tag{4}$$

여기서, η 는 정규화상수이다. 이때 $p(z_t | x_t^{(i)})$ 는 유사도 측정함수(similarity measure function)를 이용하여 계산하였다[9]. 이 방법은 로봇의 현재위치에서 스캔한 $0^\circ \sim 180^\circ$ 의 레이저 스캔 정보 z_t 와 샘플 i 의 위치 $x_t^{(i)}$ 에서 지도를 스캔한 181개의 데이터를 각 1° 마다 비교하여 그 차이를 제공하여 모두 더한다. 이때 이 차이가 크면 그 샘플에 작은 가중치를 적용하고, 작으면 큰 가중치를 적용한다.

Re-sampling: 샘플 $x_t^{(i)}$ 에 가중치 $\omega_t^{(i)}$ 를 적용하여 새롭게 분포시킨 샘플 집합 X_t 를 추출한다.

$$X_t = \{x_t^{(j)} | j=1 \dots N\} \sim \{x_t^{(i)}, \omega_t^{(i)}\} \tag{5}$$

이때, 새로운 샘플 집합 X_t 의 가중치 $\omega_t^{(i)}$ 는 $1/N$ 로 초기화된다. 위의 세 과정을 반복함으로써 높은 확률 주위로 샘플들이 수렴하게 된다.

III. 위상 정보

1. 세선화 기반의 위상지도의 작성

세선화 알고리즘(thinning algorithm)[10]은 영상 이미지의 골격을 추출하는 방법으로 널리 알려진 영상처리 기법이다. 주어진 격자지도의 각각의 격자를 이미지의 셀로 나타낸 지도 이미지에 적용함으로써 에지와 노드로 구성되는 위상지도(topological map)를 얻을 수 있다. 이는 측정정보를 바탕으로 주위 물체의 중간지점에서 위상정보를 얻는 GVG 선도와 비슷한 형태를 이룬다. 그러나 세선화를 이용하여 얻은 위상정보가 계산이 단순하고, 더 간결한 형태로 작성되는 장점이 있다.




그림 1. 세선화 알고리즘에 의한 위상에지와 노드의 추출.
 Fig. 1. Extraction of topological edges and nodes by thinning algorithm.

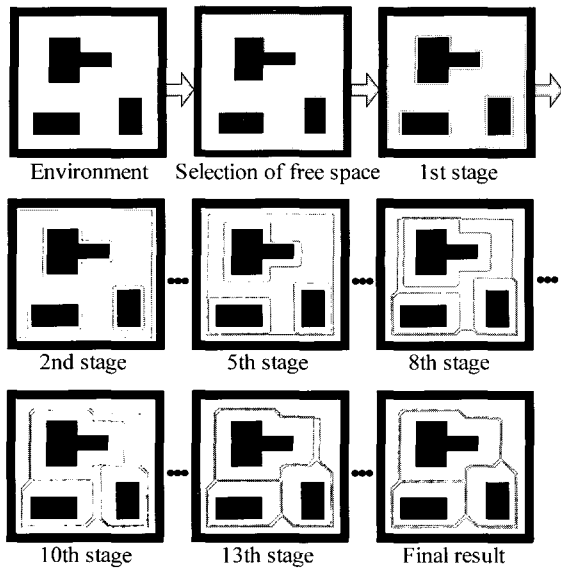


그림 2. 주어진 격자지도에 대한 위상지도의 작성과정 (시물레이션).
 Fig. 2. Construction process of topological map from a given grid map (simulations).

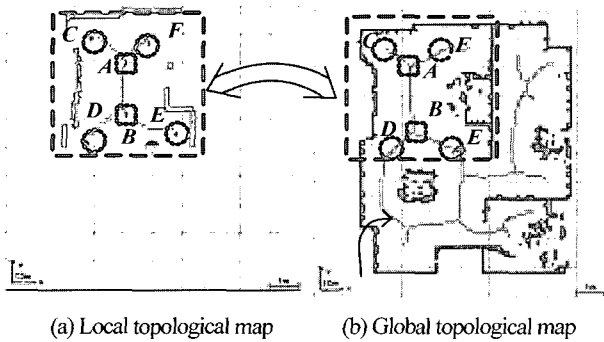


그림 3. 국부 및 전역 위상지도의 비교.
 Fig. 3. Comparison of local with global topological maps.

그림 1은 세선화 알고리즘을 이용하여 위상에지를 얻는 예를 보여준다. 좌측 그림은 일반적으로 표현된 하나의 교차점을 갖는 물체의 형상으로, 이에 세선화 기법을 적용하여 물체의 골격을 추출하면 우측 그림과 같게 된다. 여기서 추출된 골격은 최소단위의 두께(예, 한 격자 크기)로 표현되며, 좌측 그림과 동일한 위치에서 교점을 가짐으로써 그 특성이 유지되는 가장 단순한 모습을 알 수 있다. 위상지도에서는

이러한 골격을 에지라 하는데, 에지는 이동로봇의 주행에서 로봇이 장애물과 충돌 없이 이동할 수 있는 경로로 활용될 수 있다. 그리고 에지의 끝에 해당하는 말단노드(end node)와 3개 이상의 에지의 교점에 해당하는 분기노드(branch node) 등을 추출할 수 있다.

그림 2는 주어진 환경에 대하여 세선화 기법을 적용하여 위상지도를 작성하는 절차를 나타낸 것이다. 우선 주어진 격자지도에서 로봇이 주행할 수 있는 비점유격자를 대상으로 골격을 추출한다. 이를 위해서 벽 및 장애물 등의 점유격자의 경계로부터 시작하여 빈 공간을 매 단계마다 한 격자 두께씩 제거하여 나간다. 이 과정을 반복하면 최종적으로 벽이나 장애물로부터 동일한 간격에 있는 위상에지를 추출할 수 있다.

2. 위상 정보의 강인성

로봇은 실시간으로 국부 격자지도를 작성하여 그림 3(a)와 같은 국부 위상지도를 작성하게 되는데, 지도가 완전히 작성되기 전까지는 작성 정도에 따라 에지나 노드의 위치가 변하게 된다. 이는 가시도(visibility) 문제로 인하여 물체의 보이지 않는 뒷면이나, 전방에 위치한 레이저 센서의 탐지범위에 속하지 않아서 지도에 표현되지 않은 로봇의 후방에 위치한 공간의 정보가 로봇의 이동으로 지도에 반영되어 지도가 확장되기 때문이다. 이런 공간들이 모두 반영되어 환경 전역에 대한 지도작성이 완료되면 그림 3(b)와 같은 전역(global) 위상지도가 추출되는데, 이 지도는 더 이상 변하지 않는다. 이상적으로 국부 위상지도와 전역 위상지도는 일치하여야 하지만, 실제로는 어느 정도 차이가 있다. 이 두 지도의 차이가 크면 국부 위상정보는 전역 위상정보와 상관성이 낮기 때문에 로봇의 위치추정에 이용하기 어려워지므로, 이 두 정보의 차이는 되도록 작아야 한다. 그림 3(a)는 그림 3(b)의 점선 부분에 해당하는 국부 위상지도다.

그림 3을 좀더 상세히 분석하여 보자. 위상정보 중 분기노드는 노드 주변의 격자지도가 거의 완성된 상태에서 세선화 기법을 적용되므로 그 위치가 상당히 강인하게 추출된다. 따라서 그림 3에서 분기노드 A와 B의 위치는 국부지도와 전역지도에서 거의 차이가 없다. 말단노드도 C와 같이 주위 환경에 대한 탐지가 거의 완료된 상태에서 구석이나 막힌 통로 등에 형성된 경우는 분기노드와 같이 그 위치가 국부지도와 전역지도가 거의 동일하다. 그러나 레이저 센서의 측정범위의 한계로 인해 주변환경에 대한 탐지가 완료되지 않은 경계 부분에 형성된 말단노드 D, E, F는 탐지가 진행되면서 그 위치가 계속하여 변하거나 사라지게 된다.

결론적으로, 국부지도의 분기노드의 위치는 상당히 강인하게 유지되지만, 말단노드의 위치는 변할 가능성이 크다. 이러한 말단노드를 제외한다면, 그림 3에서 보듯이 국부 위상지도의 에지는 전역 위상지도의 에지의 형상과 거의 유사하게 된다. 본 연구에서는 이를 확인하기 위해 그림 3과 같은 10m×10m의 환경 내 임의의 위치에 로봇을 위치시킨 후 국부 위상지도를 작성하는 실험을 180회 수행하였다. 이 실험을 통해 얻은 국부 위상정보와 전역 위상정보를 비교해 본 결과 국부 위상지도의 에지의 약 90% 정도가 전역 위상지도 에지의 양측으로 대략 2.5격자 내에 위치한 것을 확인할 수 있었다.

IV. 위상정보를 이용한 위치추정

1. 에지 주위에서의 샘플링

MCL은 거리센서 정보와 환경에 대한 격자지도 정보를 비교하여 로봇의 위치를 추정한다. 주행이 수행되는 환경에 대한 격자지도가 미리 주어지면, 앞서 설명한 세션화 기법을 적용하여 전역 위상지도를 생성한다. 그리고 전체 환경에 대하여 샘플을 추출하지 않고, 작성된 전역 위상지도의 위상에 지 위에서만 집중적으로 샘플을 추출한다.

이 방식이 성공하기 위해서는 샘플이 추출되는 위상에 지 위에 로봇이 항상 위치하여야 한다. 이를 위해서 로봇은 현재의 위치에서 레이저 스캐너의 거리데이터를 사용하여 실시간으로 국부 위상지도를 작성한다. 이렇게 작성된 국부 위상지도와 전역 위상지도는 3.2절에서 설명한 바와 같이 어느 정도 차이가 나게 되므로, 이를 보완하기 위해 샘플 추출 영역을 전역 위상지도의 위상에 지 및 그 주위로 확장한다. 이때 확장된 영역의 크기를 3.2절에서 설명한 바와 같이 격자 2.5개의 크기(한 격자의 크기는 100mm×100mm)에 해당하는 250mm로 설정하였다. 따라서 그림 4에서 보듯이, 중심이 되는 에지 격자 주위로 5grid×5grid의 영역을 설정하였다. 이를 전체 지도에 적용하면, 그림 4의 우측에서 보는 바와 같이 에지 주위에 일정한 영역이 생성된다. 로봇이 국부 위상지도를 작성하여 그 에지 상으로 이동하게 되면 로봇의 실제 위치는 확률적으로 전역 위상에 지 주위에 위치하게 되므로 MCL을 수행하여 위치를 추정할 수 있다. 이때 샘플 추출 영역이 에지 주위로 확장되어도 전체 영역보다 훨씬 작다.

실제 10m×10m 환경에 샘플 3000개를 추출할 때 그림 5(a)는 기존의 MCL 방법에 의해 샘플을 추출한 경우이고, 그림 5(b)는 본 연구에서 제안한 MCL/TI (MCL with Topological Information) 방법에 의하여 에지 및 그 주위에서 샘플을 추출한 경우이다. 그림 5(a)와 (b)를 비교해 보면 샘플을 에지 및 그 주위에서 추출하면 샘플 추출 영역이 기존의 1/3정도로 감소하게 된다. 이때 MCL/TI의 경우 기존의 MCL에 비해서 샘플이 추출되는 단위 면적당 샘플 수가 증가되고, 불필요한 영역에서의 샘플 추출은 감소하게 된다. 기존의 MCL이 전역의 빈 공간에 N개의 샘플을 추출하여 위치추정을 성공적으로 수행할 수 있다면, MCL/TI는 기존의 1/3인 에지 주위 영역에서만 추출하면 되므로 단위 면적당 동일한 샘플 수를 갖도록 할 때, 필요한 샘플 수는 N/3개이다. 이때 한 격자가 100cm²이므로, 빈 공간의 면적은 비점유격자의 수로 계산할 수 있다.

2. 위상정보를 이용한 MCL 수행과정

본 논문에서 위상정보는 위치추정을 위해 두 가지 면으로 이용되고 있다. 첫 번째는 로봇의 주행을 위한 주행경로로서의 이용이고, 두 번째는 샘플 추출을 위한 에지의 주위영역을 결정하기 위한 것이다.

위상정보를 로봇의 주행에 이용하기 위해 로봇은 실시간으로 국부 위상지도를 작성하고 에지를 추출한다. 이때 로봇의 전방에 위치하며 센서와 근접해 있는 위상 노드와 에지의 정보가 상대적으로 정확하고 전역 위상지도와 비슷하게 추출되므로, 로봇은 주로 이러한 근접한 에지를 이용하여 주행을 하고 멀리 위치한 에지는 거의 이용하지 않는다. 그림 6은 에지 위에서의 주행을 보여주고 있다. (a)에서와 같이 처




그림 4. 에지 주위에 설정된 영역을 적용한 위상지도.
Fig. 4. Sampling region near topological edges.

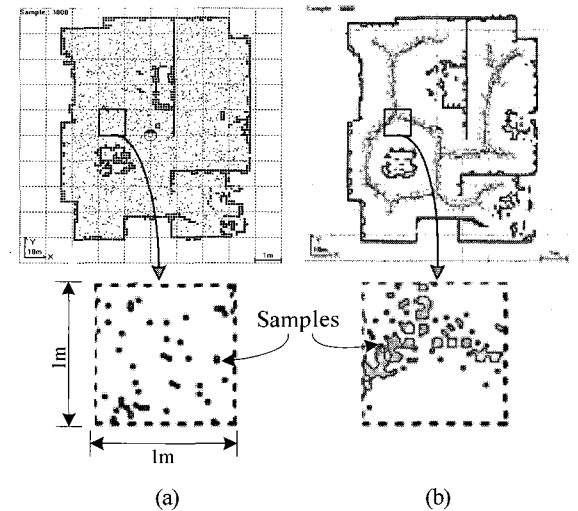


그림 5. (a) 전역환경에 대한 임의의 샘플링 및 (b) 에지 주위 영역에서의 샘플링.
Fig. 5. (a) Random sampling on global region, and (b) sampling on the region near edges.




그림 6. 위상정보를 이용한 로봇의 이동.
Fig. 6. Robot motion using topological information.

음에 로봇은 레이저센서로 주위를 스캔하여 국부 위상지도를 작성하고 에지를 추출한다. (b)에서는 노드를 추출하여 제일 가까운 분기노드로 이동하고, 노드에 도착하면 MCL의 수행이 시작된다. (c)에서 분기노드로 이동한 로봇은 전방에 가장 가까이 위치한 에지를 따라 주행하게 된다. 여기서 분기노드를 이용하는 이유는 다른 정보보다 추출되는 위치가 강인하므로, 전역 위상지도와 비슷한 위치에 추출되기 때문이다. 만약, 분기노드가 너무 멀리 존재하거나 없다면, 로봇은 전방의 가장 가까운 에지로 이동한다. 그림 6(a)에서 국부 위상지도의 좌측 하단 부분에 물체가 없는데도 등골게 나오는 이유는 레이저 센서의 거리 데이터를 9m로 제한하기

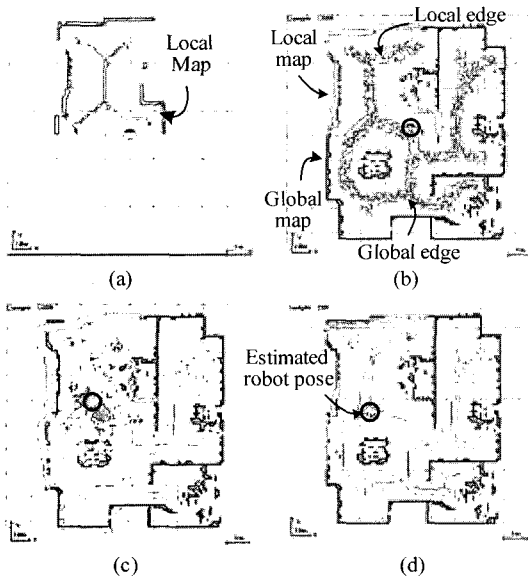


그림 7. 위상정보를 활용한 MCL (MCL/TI) (실험).
Fig. 7. MCL with topological information (experiments).

때문이다.

로봇이 자신과 가깝고 전방에 위치한 국부 위상지도상의 에지 위를 주행한다면 로봇은 전역 위상지도의 에지 주위에 있다고 추측할 수 있다. 따라서 로봇은 전역 위상지도의 에지 주위에서 샘플을 추출하는 MCL을 수행할 수 있다. 그림 7은 위에서 설명한 MCL의 수행과정을 실험적으로 보여준다. 그림 7(a)에서는 처음 로봇이 주행을 위해 국부 위상지도를 작성하고, 에지를 추출하는 상황을 보여준다. 그림 7(b)는 전역 위상지도의 에지 주위에서 MCL을 위한 샘플이 추출되고, (a)에서 추출한 에지 위로 주행하는 상황을 보여준다. 그림 7(c)는 로봇이 주행 중 MCL의 수행으로 샘플이 로봇의 주위로 수렴되고 있는 상황을 보여준다. 최종적으로 그림 7(d)에서 보는 바와 같이 로봇이 위치추정을 완료하게 된다.

V. 실험 및 고찰

실험은 SICK LMS200 Laser range-finder를 설치한 Pioneer 3 로봇을 이용하였다. 로봇은 평균 0.2m/s로 이동하였다. 실험에 사용한 컴퓨터는 펜티엄4 1.4GHz의 노트북이다. 실험환경은 그림 8(a)와 같이 약 9.5m×7.5m의 실내공간에 일반 아파트의 거실처럼 가구를 배치하여 구성하였다.

실험에 사용되는 환경은 10m×10m 크기이고, 한 격자의 크기는 10cm로 설정되었다. 실험환경에는 책상이나 의자들이 배치되어 있으나, 레이저센서 높이가 지면에서 44cm정도 이어서 다리 부분만 검출되므로 지도에는 정확한 의자나 책상의 모양은 반영되지 않는다.

이동로봇의 위치추정에서 위치정확도, 수행시간, 실패율 등이 성능 판단의 기준이 된다. 본 실험에서는 샘플 추출 영역의 축소를 이용하여 샘플 수를 감소시켰을 때의 성능 향상 정도를 알기 위해서, 첫째로 동일한 크기의 환경에서 비슷한 위치추정 실패율을 갖는 샘플 수를 측정하여 샘플 수의 감소 정도를 알아보고, 둘째로 위치추정 시간을 측정하여 샘플 수의 감소에 따른 위치추정 시간의 단축 정도를 계산해 보았다.

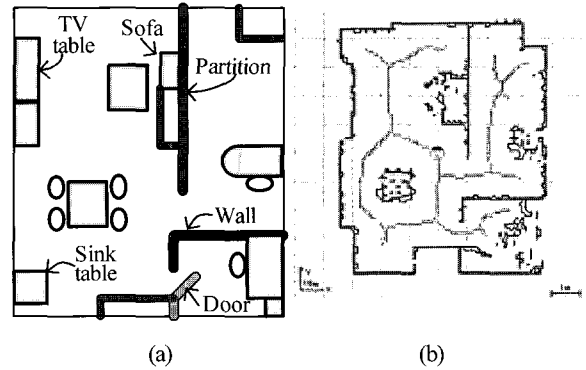


그림 8. (a) 실험환경과 (b) 전역지도.
Fig. 8. (a) Experimental environment and (b) Its global map.




그림 9. MCL과 MCL/TI의 위치추정 실패율.
Fig. 9. Localization failure rates for MCL and MCL/TI.

1. 샘플 수

샘플 수를 과도하게 감소시키면 로봇의 실제 초기위치에서 샘플이 추출되지 않는 경우가 발생하기 때문에 위치추정 실패율이 증가하게 된다. 그러므로 위치추정 실패율을 작게 하기 위해서는 일정 면적에 대해서 일정 수 이상의 샘플이 필요하다. 이 실험에서는 10m×10m의 일정한 크기를 갖는 환경에서 샘플을 전체 영역에서 추출하는 기존의 MCL과 에지 주위 영역에서만 추출하는 MCL/TI(MCL using Topological Information)이 샘플 수에 따라 위치추정 실패율이 어떻게 변하는지 실험해 보았다.

그림 9를 보면 동일한 샘플 수에서 MCL/TI의 위치추정 실패율이 기존의 MCL보다 상당히 낮은 것을 알 수 있다. 예를 들어, 샘플 수가 1,000개인 경우에 MCL/TI의 실패율이 대체적으로 60%정도 낮아진다. 이는 제안한 MCL/TI 방식에서는 위상 정보를 이용하여 로봇이 위치할 가능성이 높은 영역에서 집중적으로 샘플을 추출하여 단위면적당 샘플수가 증가하기 때문이다. 그래프를 보면 900개의 샘플을 사용한 MCL/TI와 3,000개의 샘플을 사용한 기존 MCL이 비슷한 위치추정 실패율을 보여준다. 결론적으로 MCL/TI는 기존 MCL에 비하여 대략 30%의 샘플만을 가지고도 비슷한 정도로 위치추정에 성공할 수 있음을 알 수 있다.

2. 위치추정 시간

이번에는 샘플 수 감소에 따른 MCL 수행시간의 영향을 살펴보기 위한 실험을 수행하였다. 이때 샘플 위치 (x_i, y_i) 의 공분산과 방위 θ_i 의 분산을 (6)에 적용하여 전체 분산 σ_i 를 정의하였다.

$$\sigma_t = \sqrt{\alpha \cdot |\text{cov}(x_t, y_t)| + \beta \cdot \text{var}(\theta_t)} \quad (6)$$

여기서, α 와 β 는 $\text{cov}(x, y)$ 와 $\text{var}(\theta)$ 의 단위가 틀리기 때문에 이를 조절해 주기 위한 상수이다. σ_t 는 샘플들의 수렴 정도를 보여주므로 이전 σ_{t-1} 에 비해 σ_t 의 변화가 거의 없으며 충분히 샘플들이 수렴되어 위치추정이 완료되었다고 다고 판단하였다.

그림 10에서 보는 바와 같이 샘플 수를 3000개에서 1000개로 감소시킬 경우 유사한 위치추정 성능을 유지하면서 대략 70%의 시간 단축 효과가 있었다. 이는 샘플 수의 감소로 인해 MCL 알고리즘의 수행시간이 단축되고 샘플의 초기 수렴 속도가 향상되었기 때문이다. 그래프를 보면 같은 수의 샘플을 사용해도 제안한 MCL/TI의 위치추정 시간이 다소 작게 소요되는데, 이는 초기에 샘플이 위상에서 주위로 집중되기 때문에 전체 빈 공간에 샘플이 추출되는 기존의 방법에 비해 이미 로봇 위치의 불확실성이 대폭 감소되었기 때문이다. 로봇이 초기에 현재 위치에 대한 아무런 정보가 없어도 어느 정도 로봇의 위치에 대한 예측을 통해 위치추정 과정의 최적화가 수행된다고 볼 수 있다. 이때 위상정보를 추출하는 데는 20msec 정도로서 전체 위치추정 수행시간에 비하여 무시할 만하다.

이제 비슷한 위치추정 성능을 내는 3,000개의 샘플을 사용하는 기존 MCL과 900개를 사용하는 MCL/TI를 비교하여 보자. 두 알고리즘은 샘플 추출 이외에는 거의 동일하기 때문에 수행시간도 비슷하다. 이때 로봇은 0.2m/sec로 움직이면서 레이저 스캐너로 0.2~0.3sec 정도마다 한번씩 주위 환경을 측정한다. 그림 11에서 3,000개의 샘플을 사용하는 MCL 알고리즘의 1회 수행시간은 약 1.1sec가 소요되므로, 다음 수행 시까지 레이저 측정정보를 4~5번 정도 놓치고, 알고리즘으로

추정한 로봇의 위치와 실제 환경 상의 로봇이 위치한 곳과는 로봇의 이동으로 22cm 정도 차이가 난다. 따라서 환경변화를 신속하게 반영하지 못하고, 추정위치와 실제위치간의 차이가 커서 추정된 위치정보의 신뢰성이 저하된다. 그러나 900개의 샘플을 사용하는 MCL/TI는 1회 수행시간이 0.4sec 정도이므로, 레이저 측정정보는 1회 정도만 놓치고, 추정위치와 실제 위치간의 차이도 8cm 정도로 감소된다. 그러므로 위치추정 시 새로운 측정값을 신속하게 반영시킬 수 있어 환경변화에 대한 정보가 빠르게 확률분포에 적용된다. 또한, 추정위치와 실제위치의 차이가 적으므로 신뢰할 수 있는 위치정보를 신속하게 로봇에게 제공해 주어 위치추정의 실시간성이 향상된다. 즉, 로봇이 이동하면서 위치를 추정해도 신뢰할 수 있는 위치정보를 얻을 수 있다.

VI. 결론

본 논문에서는 MCL 수행시 위상정보를 이용하여 샘플 수를 감소시키는 방법에 대하여 설명하였다. 위상정보를 이용하여 로봇의 위치를 위상지도의 에지 주위로 예측하여 위치추정 수행 전에 위치에 대한 불확실성을 감소시킬 수 있다. 또한, 샘플 추출 영역이 에지 주위로 축소되어 불필요한 샘플 추출을 줄일 수 있어 기존 MCL에 비해 적은 수의 샘플로 위치추정 실패율과 위치추정 시간을 감소시킬 수 있다. 그리고 적은 수의 샘플 사용으로 초기 수렴속도를 포함한 위치 갱신이 신속하게 수행되어, 새로운 센서정보를 신속하게 반영시킬 수 있어 위치추정의 실시간성이 향상된다. 또한, 센서정보로부터 생성된 위상에지를 주행경로로 이용함으로써 다른 경로생성 알고리즘이 필요하지 않게 되어 이에 대한 부하도 줄일 수 있다. 따라서 본 논문에서 제안한 MCL/TI를 이용하면 실제 자율주행을 수행하면서 위치추정시 경로생성 없이도 위상정보를 이용하여 로봇은 안전한 주행을 하면서 최적의 MCL을 수행할 수 있다.

참고문헌

- [1] F. Lu and E. Milios, "Globally consistent range scan alignment for environment mapping," *Autonomous Robots*, vol. 43, pp. 333-349, 1997.
- [2] D. Fox, W. Burgard, and S. Thrun, "Active markov localization for mobile robots," *Robotics and Autonomous Systems*, vol. 25, pp. 195-207, 1998.
- [3] S. Thrun, D. Fox, W. Burgard, and F. Dellaert, "Robust monte carlo localization for mobile robots," *Proc. of National Conf. on Artificial Intelligence*, vol. 128, 2001.
- [4] D. Fox, W. Burgard, F. Dellaert, and S. Thrun, "Monte carlo localization: efficient position estimation for mobile robots," *Proc. of National Conference on Artificial Intelligence*, 1999.
- [5] C. Kwok, D. Fox, and M. Meila, "Real-time particle filters," *Advances in Neural Information Processing Systems*, vol. 92, no. 3, 2004.
- [6] B. Y Ko and J. B. Song, "Real-time building of thinning-based topological map with metric features," *Proc. of International Conference on Intelligent Robots and Systems*, pp. 1524-1529, 2004.
- [7] A. Doucet, S. Godsill, and C. Andrieu, "On sequential monte carlo sampling methods for bayesian filtering," *Statics and*




그림 10. MCL과 MCL/TI의 위치추정 시간.
Fig. 10. Pose estimation time for MCL and MCL/TI.





그림 11. 샘플 수당 MCL의 1회 수행시간.
Fig. 11. Cycle time of MCL as a function of sample size.

Computing, vol. 10, no. 3, 2000.

- [8] A. Doucet, N. J. Gordon, and N. de Freitas (editors), *Sequential Monte Carlo Methods in Practice*, 2000.
- [9] D. H. Lee, W. Chung, and M. S. Kim, "A reliable position estimation method of the service robot by map matching," *Proc.*


of IEEE/RSJ International Conference on Robotics and Automation, pp. 2830-2835, 2004.

- [10] G. A. Baxes, *Digital Image Processing*, John Wiley & Sons, 1994.



양주호

1978년생 4월 1일생. 2004년 고려대학교 기계공학과(공학사). 2006년 고려대학교 기계공학과(공학석사). 현재 만도 근무 중. 관심분야는 이동로봇의 위치추정 알고리즘 개발.



송재복

1960년 8월 5일생. 1983년 서울대학교 기계공학과(공학사). 1985년 서울대학교 기계설계학과(공학석사). 1992년 MIT 기계공학과(공학박사). 1993년~현재 고려대학교 기계공학과 교수. 관심분야는 이동로봇의 주행, 로봇 팔의 설계 및 제어, 햅

틱스.