

논문 2008-03-15

동적 환경에서 불완전한 지도를 이용한 이동로봇의 강인한 위치인식 알고리즘의 개발

(Robust Localization Algorithm for Mobile Robots in a Dynamic Environment with an Incomplete Map)

이 정 석*, 정 완 균, 남 상 업

(Jung-Suk Lee, Wan Kyun Chung, Sang Yep Nam)

Abstract : We present a robust localization algorithm using particle filter for mobile robots in a dynamic environment. It is difficult to describe moving obstacles like people or other robots on the map and the environment is changed after mapping. A mobile robot cannot estimate its pose robustly with this incomplete map because sensor observations are corrupted by un-modeled obstacles. The proposed algorithms provide robustness in such a dynamic environment by suppressing the effect of corrupted sensor observations with a selective update or a sampling from non-corrupted window. A selective update method makes some particles keep track of the robot, not affected by the corrupted observation. In a sampling from non-corrupted window method, particles are always sampled from several particle sets which use only non-corrupted observation. The robustness of proposed algorithm is validated with experiments and simulations.

Keywords : Localization, Mobile robot, Particle filter, MCL, Pose tracking, Dynamic environment

1. 서론

위치인식 기술은 이동로봇의 가장 필수적인 기술 요소 중 하나이다. 이동로봇은 박물관 안내, 물건 전달 등의 주어진 작업을 수행하기 위해 환경 내에서 자신의 위치를 인식할 수 있어야 한다.

이동로봇의 위치인식을 위해서는 환경의 지도가 주어져야 하지만, 모든 물체를 지도에 표현하기는 쉽지 않다. 또한 지도 작성 이후 환경이 변하거나 사람과 같이 움직이는 장애물이 존재한다. 본 논문에서는 지도에 표현되지 않은 물체와 이동하는 물체를 통틀어 비모형화 장애물(un-modeled obstacle)이라 표현한다.

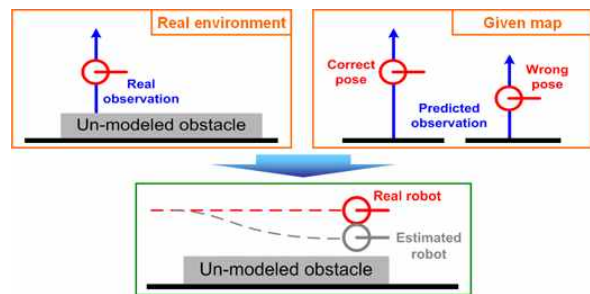


그림 1. 비모형화 장애물의 영향

Fig. 1. The effect of an un-modeled obstacle

로봇은 실제 환경에 비모형화 장애물이 존재할 경우 이를 감지한다(그림 1, 왼쪽 위). 하지만 위치 인식에서는 장애물이 표현되어 있지 않은 지도를 이용하기 때문에 올바른 로봇 위치에서의 예측 센서 정보 (predicted observation)는 비모형화 장애물 건너편 벽까지의 긴 거리 값을 얻게 된다(그림 1, 오른쪽 위). 이러한 센서 정보의 불일치는 이동로봇의 위치인식을 방해한다. 특히 로봇이 오랜 시간동안 이러한 장애물 근처를 주행할 경우 위치를

* 교신저자(Corresponding Author)

논문접수 : 2008. 4. 15., 채택확정 : 2008. 5. 31.

이정석 : 포항공과대학교 기계공학과 박사과정

정완균 : 포항공과대학교 기계공학과 교수

남상업 : 국제대학 정보통신학부 교수

※ 이 논문은 2007년도 정부(과학기술부)의 재원으로 한국과학재단의 지원을 받아 수행된 연구임 (No. ROA-2003-000-10308-0).




그림 2. 센서 정보의 교란 여부 판단 : 분포된 파티클 집합은 로봇의 이동 오차를 극복할 수 있음

Fig. 2. Discriminate corruption by all particles : Distributed particles can compensate for the odometry error, but the expected pose, which only follows odometry path, cannot

완전히 잃어버리게 된다. 따라서 위치인식 알고리즘은 불완전한 지도를 이용하는 상황에서, 동적인 환경에 존재하는 비모형화 장애물에 의한 센서 정보 교란 (corruption)에 강인해야 한다. 따라서 위치인식 알고리즘은 교란된 센서 정보와 올바른 센서 정보를 구별할 수 있어야 하며, 교란된 센서 정보의 영향을 억제할 수 있어야 한다.

이동로봇의 위치인식에서 가장 널리 사용되는 기법은 확장 칼만필터 (extended kalman filter, EKF)를 이용한 위치인식 기법이다 [1,2]. 확장 칼만필터 위치인식은 정확하고 효율적이지만 가우시안 (gaussian) 확률분포를 가지는 모델에만 적용할 수 있다는 제약을 가지고 있다. 이를 극복하기 위한 방법으로 격자 기반의 마코프 위치인식 (markov localization) [3,4]과 파티클 필터 (particle filter)를 이용한 몬테 카를로 위치인식 (monte carlo localization, MCL) [5,6]이 있다. 두 기법 모두 광역 위치인식 능력을 가지며 구현하기 쉽지만, 확률이 높은 위치에 계산을 집중시킬 수 있는 몬테 카를로 위치인식 기법의 계산 효율이 더 높다.

본 논문에서는 동적 환경에서 로봇의 위치인식을 위하여 기본적인 파티클 필터 알고리즘에 다음과 같은 특징을 추가하였다. 우선, 실제 환경에서 얻은 이동로봇의 센서 정보와 주어진 환경지도에서 얻어진 모든 파티클의 예측 센서 정보를 비교하여 센서 정보의 교란 여부를 판단하였다 (그림 2). 로봇의 센서 정보와 유사한 센서 정보를 가지는 파티클이 존재할 경우, 이 센서 정보는 비모형화 장애물에 의해 교란되지 않았기 때문에, 로봇의 위치를 추정하는데 도움이 된다고 생각할 수 있다. 반대의 경우 이 센서 정보는 로봇의 위치인식을 방해한다. 따라서 교란된 센서 정보는 위치인식 과정에 이용

되지 않도록 해야 한다.

본 논문에서는 교란된 센서 정보의 영향을 억제할 수 있는 두 가지 방법을 제안한다. 첫 번째로, 파티클의 가중치를 선택적으로 부여하는 선택적 갱신 (selective update) 파티클 필터 알고리즘을 제안한다. 두 번째로, 파티클을 비 교란 창 (non-corrupted window)에서 추출하는 새로운 파티클 필터 구조를 제안한다. 전통적인 파티클 필터에서는 가장 최근의 파티클 집합에서 새로운 파티클을 추출한다. 이와 달리 새로운 파티클 필터에서는 교란된 센서 정보를 사용하지 않은 집합에서만 파티클을 추출함으로써 교란된 센서 정보의 영향을 제거할 수 있다. 또한 센서 정보의 교란 여부를 잘못 판단할 수 있기 때문에, 한 개의 집합이 아닌 여러 개의 비 교란 집합 (non-corrupted set)에서 파티클을 추출한다.

본 논문의 구성은 다음과 같다. 2장에서는 파티클 필터를 이동로봇의 위치인식에 적용한 기존의 연구와 전통적 몬테 카를로 위치인식 기법에 대해 설명한다. 3장에서는 선택적 갱신 파티클 필터 알고리즘을 제안하고 4장에서 비 교란 창을 이용한 새로운 구조의 파티클 필터를 이용한 위치인식 기법을 소개한다. 5장에서 제안된 기법의 성능평가 결과를 보이고, 마지막으로 결론을 내린다.

II. 연구 배경

1. 관련 연구

Sequential Monte Carlo (SMC) 기법으로도 알려진 파티클 필터는 시뮬레이션을 기반으로 하는 모델 추정 (model estimation) 기법이다 [7]. 파티클 필터는 여러 분야에서 condensation [8], bootstrap filtering [9], survival of the fittest [10] 등의 이름으로 널리 사용되고 있다. 이동로봇의 위치인식 분야에서는 1999년 처음 몬테 카를로 위치인식이라는 이름으로 파티클 필터가 적용되었다 [5,11,12]. 이 연구에서는 천정의 조명을 랜드마크 (landmark)로 사용하는 비전 센서와 레이저 거리 측정 센서를 이용하여, 박물관 안내 로봇 'Minerva'의 위치인식에 전통적 파티클 필터 기법인 Sampling Importance Resampling (SIR)을 적용하였다.

그 다음해인 2000년에는 센서 정보를 바탕으로, 또는 무작위로 일부의 파티클을 추가하는 Sensor Resetting Localization (SRL) [13] 과 Condensation with Random Sampling [14]이 제

안되었다. 이 방법들은 위치인식의 강인성을 높여 주었지만, 특정 종류의 센서나 환경지도만을 이용할 수 있다. 2001년에는 필요한 개수의 파티클만을 이용하는 KLD-resampling 기법이 제안되었다 [15]. 이 연구에서는 파티클 집합이 묘사하는 확률 분포와 목표 확률분포를 쿨백-라이블러 거리 (Kullback-Leibler Distance, KLD)를 이용해 비교함으로써 필요한 파티클의 개수를 결정하였다. 같은 해에 dual MCL 기법도 제안되었다 [16]. 이 방법에서는 센서 정보를 기반으로 파티클을 추출한 후 로봇의 이동 모델을 이용하여 파티클의 가중치를 결정하였다. 또한 standard MCL과 dual MCL을 함께 사용하는 mixture MCL 기법도 함께 제안되었다. 이 방법은 위치인식의 강인성을 높여주었다. 하지만 많은 계산을 필요로 하고, 특정 종류의 센서와 환경지도에만 적용할 수 있다는 단점을 가지고 있다.

2002년에는 효율적인 구조를 가진 Real-Time Particle Filters (RTPF)를 이용한 위치인식 기법이 제안되었다 [17]. RTPF에서는 필요한 파티클을 update window내의 여러 개의 집합으로 나누어 처리하기 때문에 효율적인 구현이 가능하다. 이 방법은 KLD-sampling과 합쳐져서 update window내의 집합의 개수를 조절하는 방법으로 발전되었다 [18].

이와 같이 파티클 필터를 이용한 이동로봇의 위치인식 연구는 활발하게 진행되어 왔다. 하지만 대부분의 방법은 실제 환경과 주어진 지도가 일치한다는 가정이 필요하다. 동적인 환경에서 위치인식을 위한 방법으로는 Dependable Localization [19]이 있다. 이 방법에서는 예측 위치에서의 센서 정보와 실제 로봇의 센서 정보가 비슷할 경우에만 센서 정보를 이용한다. 하지만 예측 위치는 로봇의 오도메트리 정보만을 이용하여 추정하기 때문에, 오도메트리 오차에 민감하다는 단점이 있다. 이러한 단점을 해결하기 위해 III, IV 장에서 센서 정보의 교란 정도에 따라 선택적으로 파티클을 추출하는 선택적 갱신 파티클 필터 알고리즘과 비 교란장에서 파티클을 추출하는 새로운 위치인식 기법을 소개한다.

2. 전통적 몬테 카를로 위치인식

새로운 방법을 제안하기 전에 전통적 몬테 카를로 위치인식에 대해 간단히 설명한다. 몬테 카를로 위치인식은 로봇의 위치인식을 위하여 베이지 필터 (Bayes filter)를 파티클의 집합을 이용하여 구현한

것이다. 가중치를 가지는 파티클 집합이 로봇의 위치를 표현하는 사후분포 (posterior) $p(x_t|u_{1:t}, z_{1:t})$ 를 묘사하고, 이를 베이지 정리 (Bayes rule)를 이용하여 전개하면 다음 식과 같다.

$$\begin{aligned} p(x_t|u_{1:t}, z_{1:t}) &= \frac{p(z_t|x_t, u_{1:t}, z_{1:t-1})p(x_t|u_{1:t}, z_{1:t-1})}{p(z_t|u_{1:t}, z_{1:t-1})} \\ &= \eta p(z_t|x_t) \int p(x_t|u_{1:t}, z_{1:t-1}, x_{t-1}) \\ &\quad \times p(x_{t-1}|u_{1:t}, z_{1:t-1}) dx_{t-1} \\ &= \eta p(z_t|x_t) \int p(x_t|u_t, x_{t-1}) \\ &\quad \times p(x_{t-1}|u_{1:t-1}, z_{1:t-1}) dx_{t-1} \end{aligned} \quad (1)$$

위의 식에서 $x_t, u_{1:t}, z_{1:t}, \eta$ 는 각각 시간 t 일 때 로봇의 위치 (상태 벡터), 시간 t 까지 누적된 오도메트리 정보, 센서 정보, 정규화 상수를 뜻한다.

식 (1)에서와 같이 시간 t 의 로봇의 사후분포는 사전분포 (prior distribution) $p(x_{t-1}|u_{1:t-1}, z_{1:t-1})$ 로부터 계산한다. 우선, $p(x_{t-1}|u_{1:t-1}, z_{1:t-1})$ 에서 파티클을 추출하고 이를 이동 모델 $p(x_t|u_t, x_{t-1})$ 을 따라 이동시킨다. 그리고 각 파티클에 센서 모델 $p(z_t|x_t)$ 의 공산 (likelihood)을 통해 가중치를 부여한다. 이러한 방식으로 모든 센서 정보를 이용하여 현재 로봇의 위치를 확률적으로 추정할 수 있다. 하지만 로봇이 가지고 있는 환경지도와 실제 환경이 일치하지 않을 경우 센서 정보가 교란되고, 파티클이 잘못된 가중치를 가지게 되어, 위치인식이 실패하게 된다. 따라서 다음 장에서 이를 극복하기 위한 새로운 위치인식 알고리즘을 소개한다.

III. 선택적 갱신 파티클 필터

전통적 몬테 카를로 위치인식에서는 로봇의 센서 정보와 유사한 센서 정보를 가지는 파티클이 높은 가중치를 가지게 된다. 그리고 로봇의 추정 위치는 재추출 단계를 거치며 높은 가중치를 가지는 파티클로 수렴한다. 하지만 실제 환경과 지도가 일치하지 않을 경우, 로봇과 같은 위치에 있는 파티클이 높은 가중치를 갖지 못하여 위치인식에 실패하게 된다. 따라서 동적 환경에서의 강인한 위치인식을 위해서는, 비모형화 장애물로 인해 교란된 센서 정보를 구분하고, 이의 영향을 최소화 하는 과정이 필요하다.

교란된 센서 정보의 영향을 억제하기 위해 다음 식과 같이 일부의 파티클은 현재 센서 정보를 그대로 이용하여 가중치를 부여받고, 나머지 파티클은 센서 정보를 이용하지 않도록 하였다.

$$p(x_t | u_{1:t}, z_{1:t})' \\ = \alpha p(x_t | u_{1:t}, z_{1:t-1}) + (1-\alpha)p(x_t | u_{1:t}, z_{1:t}) \quad (2) \\ , 0 \leq \alpha \leq 1$$

위 식에서와 같이 $1-\alpha$ 비율의 파티클은 현재 센서 정보 z_t 를 이용하여 가중치를 부여받는다. 반면 나머지 α 의 파티클은 식 (3)과 같이 현재 센서 정보를 이용하지 않고 u_t 를 이용하여 로봇과 함께 이동만 하게 된다.

$$p(x_t | u_{1:t}, z_{1:t-1}) \\ = \int p(x_t | u_{1:t}, z_{1:t-1}, x_{t-1}) \\ \times p(x_{t-1} | u_{1:t}, z_{1:t-1}) dx_{t-1} \quad (3) \\ = \int p(x_t | u_t, x_{t-1}) \\ \times p(x_{t-1} | u_{1:t-1}, z_{1:t-1}) dx_{t-1}$$

만약 현재의 센서 정보 z_t 가 비모형화 장애물에 의해 교란되었다면, $1-\alpha$ 의 파티클은 잘못된 위치로 수렴하게 된다. 하지만 교란된 센서 정보의 영향을 받지 않은 α 의 파티클은 로봇의 움직임에 추종하게 된다. 이러한 방법으로 서로 다른 과정을 통해 다뤄진 파티클 중 일부가 실제 로봇 근처에 존재하여 로봇의 위치를 강인하게 추정할 수 있다.

제안된 알고리즘에서 서로 다른 과정으로 다루지는 파티클의 개수는 교란도 α 에 따라 결정된다. 센서 정보가 교란되어 α 가 큰 값을 가질 경우, 대부분의 파티클은 로봇의 오도메트리 경로만을 추종하게 된다. 따라서 이 파티클들은 잘못된 센서 정보의 영향을 받지 않게 된다. 반대의 경우 올바른 센서 정보를 이용하여 정확하게 로봇의 위치를 추정할 수 있다. $\alpha=1$ 인 경우 제안된 알고리즘은 오도메트리 정보만을 이용하는 상대 위치인식 기법과 같고, $\alpha=0$ 인 경우에는 전통적 몬테 카를로 위치인식과 동일하게 작동한다.

제안된 알고리즘에서 교란도는 센서 정보가 비모형화 장애물의 영향을 얼마나 받았는지를 나타낸다. 이 값은 파티클이 얻은 가장 높은 공산 값과 미리 정해진 역치를 비교하여 다음 식과 같이 결정된다.

$$\alpha = \begin{cases} 1 - \frac{p(z_t | x_t^m)}{P_t} & \text{if } \frac{p(z_t | x_t^m)}{P_t} < 1 \\ 0 & \text{if } \frac{p(z_t | x_t^m)}{P_t} \geq 1 \end{cases} \quad (4)$$

위 식에서 $m = \text{argmax}_i p(z_t | x_t^i)$, P_t 는 각각 가장 높은 공산 값을 가지는 파티클의 지수와 역치를 의미한다. 가장 높은 공산 값이 역치보다 클 경우, 최

소한 한 개 이상의 파티클이 실제 로봇 근처에 존재하고, 로봇과 동일한 센서 정보를 얻었다고 생각할 수 있다. 따라서 교란도는 0이 된다. 반대의 경우에는 가장 높은 공산 값과 역치의 비율에 따라 교란도 값이 결정된다.

여기서 사용되는 역치는 센서 정보가 비모형화 장애물에 의해 교란되었는지의 여부를 판단하는데 중요한 역할을 한다. 본 연구에서는 가우스 분포 (Gaussian distribution) 형태로 모델링된 센서 모델을 이용하여 two-sigma bound 값을 역치로 이용하였다.

지금까지 설명한 바와 같이 선택적 갱신 파티클 필터를 이용할 경우, 좀 더 강인한 이동로봇의 위치추정이 가능하다. 하지만 환경의 변화가 심하면 교란된 센서 정보가 오랜 시간 들어올 수 있다. 이러한 환경에서는 잘못된 센서 정보의 영향을 받지 않은 파티클의 개수가 재추출 과정을 통해 줄어들어 위치인식에 실패할 수 있다. 다음 장에서는 이를 극복할 수 있는 방법을 소개한다.

IV. 비 교란 창에서의 파티클 추출

이번 장에서는 교란된 센서 정보의 영향을 억제하기 위해, 올바른 센서 정보만을 이용한 여러 개의 파티클 집합에서 파티클을 추출하는 알고리즘에 대해 설명한다. 제안된 파티클 필터에서는 가장 최근의 파티클 집합에 역치 이상의 공산 값을 가지는 파티클이 하나도 없을 경우, 이 집합을 이용하지 않는다. 대신 역치를 넘는 공산 값을 가지는 파티클이 포함된 최근 집합에서만 파티클을 추출한다. 이렇게 함으로써 로봇은 교란된 센서 정보의 영향을 받지 않고 위치를 추정할 수 있다.

하지만 파티클이 넓게 분포하여 있거나 환경이 복잡할 경우, 실제 로봇의 위치와 다른 위치에 있는 파티클이 역치 이상의 공산 값을 얻을 수 있다. 추출 대상 파티클 집합이 잘못 판단될 경우, 이로 부터 추출된 파티클은 로봇의 위치를 올바르게 추정할 수 없다. 이를 극복하기 위해서 파티클을 한 개의 파티클 집합이 아닌 L 개의 파티클 집합에서 추출한다. L 개의 집합 중에 잘못 판단된 집합이 있더라도 나머지 집합에서 추출되는 파티클이 로봇의 위치를 올바르게 추정할 수 있다. 올바른 센서 정보를 이용한 L 개의 파티클 집합들의 모임을 비교란 창이라 한다.

비교란 창 내의 L 개의 비교란 집합에서 파티클을 추출하여 로봇의 위치를 추정하는 과정은 아

래와 같이 표현할 수 있다.




그림 3. 제안된 파티클 필터 구조 : 비 교란 창에서의 파티클 추출

Fig. 3. Proposed particle filter framework : Sampling from non-corrupted window

$$\begin{aligned}
 & p(x_t | u_{1:t}, z_{1:t}) \\
 &= \frac{p(z_t | x_t, u_{1:t}, z_{1:t-1}) p(x_t | u_{1:t}, z_{1:t-1})}{p(z_t | u_{1:t}, z_{1:t-1})} \\
 &= \eta p(z_t | x_t) p(x_t | u_{1:t}, z_{1:t-1}) \\
 &= \eta p(z_t | x_t) \sum_{i \in \{NC\}} \beta_i \int p(x_t | u_{1:t}, z_{1:t-1}, x_{t-i}) \\
 &\quad \times p(x_{t-i} | u_{1:t}, z_{1:t-1}) dx_{t-i} \quad (5) \\
 &= \eta p(z_t | x_t) \sum_{i \in \{NC\}} \beta_i \int p(x_t | u_{t-(i-1):t}, x_{t-i}) \\
 &\quad \times p(x_{t-i} | u_{1:t-i}, z_{1:t-i}) dx_{t-i}
 \end{aligned}$$

위 식에서 NC , β_i 는 각각 비 교란 창을 구성하는 파티클 집합들과 i 번째 집합의 혼합 가중치를 의미한다.

비 교란 창은 최근 L 개의 비 교란 집합으로 이루어져 있다. 그림 3에는 $L=3$ 인 비 교란 창에서 파티클을 추출하는 파티클 필터 구조가 표현되어 있다. 이 그림에서 t_1, t_4, t_6 의 집합은 올바른 센서 정보를 이용하였기 때문에 비 교란 창에 포함되었다. 나머지 집합들은 교란된 센서 정보 때문에 교란 집합으로 판단되었고, 비 교란 창에 추가되지 않았다. 따라서 t_7 에서는 비 교란 창 내의 집합에서만 파티클을 추출하여 교란된 센서 정보의 영향을 억제할 수 있다.

비 교란 창에서 파티클을 추출하여 위치인식 과정을 거친 후, 현재의 파티클 집합 t_7 이 비 교란 창에 포함될 것인지를 판단해야 한다. 미리 정해진 역치보다 높은 공산 값을 가지는 파티클이 존재할 경우, 이 파티클 집합 t_7 은 비 교란 창에 추가된다. 대신 가장 오래된 t_1 의 집합을 제거한다. 반대로 하나의 파티클도 역치보다 높은 공산 값을 갖지 못하면 비 교란 창은 그대로 유지된다.

비 교란 창의 각 집합에서 추출되는 파티클 개

수는 각 집합의 혼합 가중치에 비례하여 결정된다.

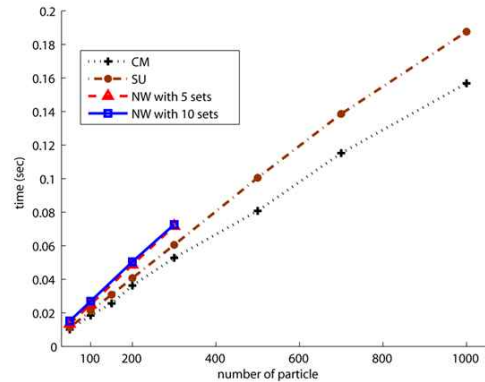


그림 4. 파티클과 집합의 개수에 따른 각 알고리즘의 계산 효율 비교

Fig. 4. The computation time per each time step (observation interval) in each method under various numbers of particles and sets


이 혼합 가중치는 아래 식과 같이 각 집합의 파티클이 가지는 가장 높은 공산에 비례하여 결정한다.

$$\beta_i \propto p(z_{t-i}, |x_{t-i}^m) \quad (6)$$

이와 같이 올바른 센서 정보만을 이용한 파티클을 비 교란 창으로부터 추출하여 로봇의 위치를 인식하기 때문에, 교란된 센서 정보의 영향을 억제할 수 있다. 센서 정보의 적합성이 잘못 판단될 경우에도 하나의 비 교란 집합이 아닌 여러 개의 집합을 이용함으로써 이를 극복할 수 있다. 또한 비 교란 창 내의 가장 오래된 집합에서 파티클을 추출할 경우, 이 파티클들이 이동 모델에 의해 최근의 집합에서 추출된 파티클보다 넓게 분포되기 때문에, 모델링되지 않는 오도메트리 오차도 극복할 수 있다.

V. 성능 평가

이번 장에서는 본 논문에서 제안한 위치인식 알고리즘의 성능을 평가한다. 우선 비모형화 장애물이 존재하는 환경에서 건물의 도면을 이용하여 위치인식을 수행하는 시뮬레이션을 통해 알고리즘의 성능을 확인하였다. 다음으로 실제 환경에서 로봇의 위치인식 성능을 평가해 보았다. 제안된 선택적 갱신 파티클 필터 (이하 SU : Selective Update) 알고리즘과 비 교란 창에서 파티클 추출 (이하 NW : Non-corrupted Window) 알고리즘의 성능을 전통적 몬테 카를로 위치인식(이하 CM : Conventional MCL) [20], Dependable



(a) Given map (b) Real environment

그림 5. 시뮬레이션에 사용된 지도와 환경 : 회색 (푸른) 영역과 (붉은) 선은 비모형화 장애물과 로봇의 이동경로

Fig. 5. Given map and real environment used in simulation : Grey (blue) area and (red) line in real environment mean un-modeled obstacles and robot path, respectively

Localization(이하 DL) [19]과 비교하였다.

위치인식 성능을 비교하기 전에 파티클의 개수와 비 교란 창에 포함되는 집합의 개수에 따른 각 알고리즘의 계산 효율을 비교하여 보았다. 각 알고리즘의 계산 효율은 그림 4에서 확인할 수 있다. DL의 경우 로봇이 올바른 센서 정보를 얻었을 경우 CM과 동일하게 동작하기 때문에 따로 계산 효율을 측정하지 않았다.

SU 알고리즘은 갱신되는 파티클과 오도메트리만을 따라가는 파티클의 가중치를 따로 계산하기 때문에 CM에 비해 1.17배 정도의 계산을 필요로 한다. NW의 경우 집합의 개수에 따라 1.6~1.7배의 계산이 필요하다. 하지만 사용되는 파티클의 총 개수를 고려하면 비효율적이라고 단정할 수는 없다. NW의 경우 다른 방법과 같이 파티클의 개수에 비례하여 계산량이 증가하지만, 비 교란 창을 구성하는 집합의 개수 변화에는 큰 영향이 없다. 따라서 필요에 따라 집합의 개수를 조절하여 위치인식 성능을 높일 수 있다.

1. 시뮬레이션

많은 수의 비모형화 장애물이 존재하는 환경에서 각 알고리즘의 위치인식 성능을 시뮬레이션을 통해 비교해 보았다. 로봇의 위치인식을 위해 건물의 구조만이 묘사되어 있는 도면을 이용하였고, 센서 정보는 건물 내에 많은 비모형화 장애물이 존재하는 상태에서 얻어 들였다 (그림 5).

우선 파티클과 비 교란 창을 구성하는 집합의 개수에 따른 NW의 성능을 확인해 보았다. 모든 시뮬레이션 결과는 150번의 반복 실험을 통해 얻어

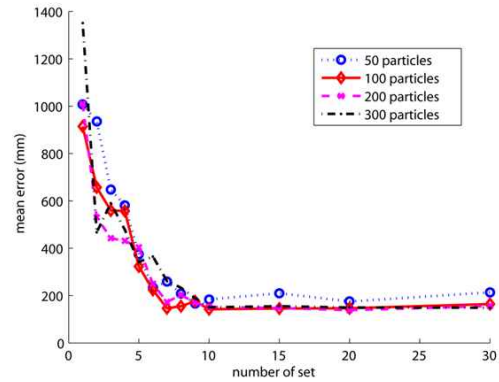


그림 6. 파티클, 집합의 개수에 따른 비 교란 창에서의 파티클 추출의 위치인식 평균 오차 (센서 모델의 표준편차 $\sigma = 150\text{mm}$, 오도메트리 오차 = 10%)

Fig. 6. Mean error of the sampling from non-corrupted window under various numbers of particles and sets with un-modeled obstacles (σ of observation model = 150mm, odometry error = 10%)

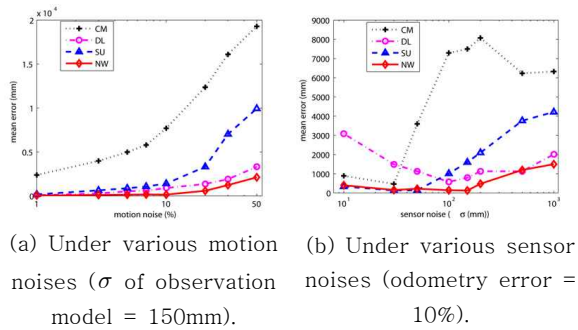
표 1. 실험에 사용된 파티클 (집합)의 개수

Table 1. Number of particle (Set) used for each method

	CM/DL	SU	NW
Simulation	160	130	100 (7)
Exp. in home	250	220	100 (12)
Exp. in bldg.	250	220	100 (15)

내었다. 그림 6에서 확인할 수 있듯이 파티클과 집합의 개수가 늘어날수록 평균 에러가 줄어드는 경향을 볼 수 있다. 따라서 계산 시간을 고려하여 파티클과 집합의 개수를 결정하였다. 우선 NW에 사용되는 파티클과 집합의 개수를 실험적으로 결정하였고, 다른 방법의 파티클 개수는 이와 동일한 계산시간을 보이도록 결정하였다. 시뮬레이션과 실제 실험에서 사용된 각 방법의 파티클의 개수는 표 1에서 볼 수 있다. 표 1과 같이 파티클의 개수를 결정함으로써 동일한 계산 효율 하에서 각 알고리즘의 성능을 비교하였다.

각 알고리즘의 위치인식 성능은 그림 7에서 확인할 수 있다. 그림 7 (a)는 다양한 오도메트리 오차에서 각 방법의 위치인식 평균 에러를 보인다. 평균 오차는 각 time step (observation이 들어온 시간)에서 로봇과 추정된 위치 사이의 거리 차이를



(a) Under various motion noises (σ of observation model = 150mm). (b) Under various sensor noises (odometry error = 10%).

그림 7. 비모형화 장애물이 존재하는 환경에서 각 알고리즘의 위치인식 평균 오차

Fig. 7. Mean error for each method from simulation with un-modeled obstacles

계산하여 얻었다. 그림 7(b)는 다양한 센서 성능 하에서 위치인식 성능 비교 결과를 보인다. 대부분의 경우 NW 알고리즘이 가장 좋은 성능을 보였다. NW 알고리즘은 다른 방법에 비해 오도메트리와 센서의 성능에 영향을 덜 받는다는 것을 확인할 수 있다. SU 또한 CM보다는 강인한 성능을 보였지만, 오도메트리와 센서의 성능이 낮을 경우 좋은 성능을 보이지는 않았다. 이는 오도메트리나 센서의 성능이 낮을수록 로봇의 위치를 올바르게 추종하는 파티클의 개수가 빨리 줄어들기 때문으로 보인다. DL의 경우 센서가 정확하거나 오도메트리 오차가 클 경우 위치인식에 실패하는 것을 볼 수 있다. 이는 센서 정보의 이용 여부를 판단할 때, 예측 추정 위치에서의 센서 정보만을 이용하기 때문인 것으로 보인다. 오도메트리 성능이 낮아서 실제 로봇의 위치와 예측 추정위치의 차이가 커질 경우, 올바른 센서 정보를 얻더라도 이를 이용하지 않게 된다. 또한 정확한 센서를 사용할 경우에도 실제 로봇과 예측 추정위치의 차이가 크지 않더라도 센서 정보가 잘못되었다고 판단할 수 있기 때문에 올바른 위치인식이 불가능하였다.

2. 실제 환경 실험

제안된 알고리즘의 성능을 실제 환경에서도 평가하여 보았다. 차동구동 방식의 Pioneer 3-DX 로봇을 사용하였고, 로봇의 진행방향 양쪽의 2개의 초음파 센서를 이용하였다. 센서의 최대 측정거리는 3.5m이고, 가우시안 확률 모델로 표현된 센서 모델의 표준편차 σ 는 150mm, 오도메트리는 2%의 표준편차를 가진다. 로봇은 평균 200 mm/s의 속도로 이동하였고 사람 한명이 로봇의 주위를 통과하




그림 8. 가정환경 (15m x 15m) : 왼쪽/위쪽 사진은 격자지도 작성 시의 환경, 오른쪽/아래쪽 사진은 실험시의 변화된 환경. (녹색) 별 표시는 추정오차 측정 지점, (붉은) 점선은 오도메트리 경로

Fig. 8. Home environment (15m x 15m) : Left/upper pictures show the environment when the grid map is drawn, right/lower pictures show environment that the experiment is done. (Green) Asterisk and (red) dotted line mean waypoint and odometry path, respectively




그림 9. 건물 환경 (61.3m x 34.0m) : 사진은 실험시의 실제 환경. (녹색) 십자가는 추정오차 측정 지점. (붉은) 점선은 오도메트리 경로

Fig. 9. Building environment (61.3m x 34.0m) : Pictures show configuration of real environment. (Green) Crosses and (red) dotted line mean waypoints and odometry path, respectively

거나 로봇과 나란히 걷는 등의 행동으로 센서 정보 획득을 방해하였다. 각 센서와 오도메트리 정보를 3Hz로 저장한 후 오프라인으로 100번씩 각 알고리




그림 10. 가정환경에서의 실험 결과
Fig. 10. Experimental results in home environment




그림 11. 건물 환경에서의 실험 결과
Fig. 11. Experimental results in building environment

즘의 위치인식 성능을 평가하였다.

첫 번째 실험은 가정환경에서 SLAM과정을 통해 작성된 격자지도 [21]를 이용하여 수행하였다. 격자지도가 작성된 후 그림 8과 같이 환경을 변화시킨 후 위치인식을 수행하였다. 그림 8에서 로봇은 오른쪽 가운데 부분의 별표 위치에서 출발하여 총 23분 동안 수행하였고, 총 10번 출발점을 통과하였다. 로봇이 출발점을 통과할 때 마다 로봇의 위치 오차를 측정하였다.

두 번째 실험은 포항지능로봇연구소 (PIRO) 건물에서 수행되었다. 건물의 도면이 환경지도로 이용되었다. 하지만 실제 환경에는 책상, 의자, 가구 등의 물체가 존재한다 (그림 9). 오른쪽 가운데 방의 경우 임시 벽으로 인하여 구조 자체가 변하였다. 또한 각 방의 문턱을 통과할 때 마다 큰 오도메트리 오차가 발생하였다. 로봇은 건물 내부를 30분 동안 주행하였으며, 총 10번 그림 9에 표시된 5곳의 십자가에서 실제 위치와 추정 위치의 차이를 측정하였다.

두 환경에서 각 위치인식 알고리즘의 성공률과 성공한 경우의 평균 오차는 그림 10, 11에서 확인할 수 있다. 위치인식 성공률은 100번의 시도 중,

로봇의 최종 위치 오차가 1m 이내인 경우의 비율을 뜻한다. NW 알고리즘은 가정환경 실험에서 위치인식에 대부분 성공하였고 평균 오차 또한 가장 적었다. 건물 환경 실험의 경우, 로봇이 문턱을 넘을 때의 큰 오도메트리 오차 때문에 65% 정도의 성공률을 보였다. 하지만 다른 방법에 비해 월등한 성능을 보여주었다. SU의 경우 로봇이 방으로 들어가서 나오는 긴 시간 동안 비모형화 장애물 교란을 받아 좋은 성능을 보이지는 못하였다. 따라서 SU 위치인식은 변화가 많은 환경 보다 움직이는 장애물이 존재하는 환경에서의 위치인식에 이용하는 것이 적합할 것으로 보인다.

VI. 결론

본 논문에서는 비모형화 장애물을 표현하지 못한 환경지도를 이용하더라도 강인하게 위치인식을 수행할 수 있는 알고리즘을 제안하였다. 모든 파티클의 예측 센서 정보와 비교함으로써, 실제 로봇의 센서 정보가 교란되었는지의 여부를 판단하였다. 센서 정보가 교란된 경우, 선택적 갱신 파티클 필터와 비 교란 창을 이용함으로써 교란된 센서 정보의 영향을 억제할 수 있었다.

선택적 갱신 파티클 필터 알고리즘은 일부의 파티클이 교란된 센서 정보의 영향을 받지 않도록 한다. 비 교란 창에서 파티클을 추출하는 알고리즘에서는 비 교란 창으로부터 파티클을 추출함으로써 교란된 센서 정보의 영향으로부터 벗어날 수 있다. 제안된 방법은 파티클이 비모형화 장애물에 의해 교란된 센서 정보의 영향을 받지 않도록 함으로써, 로봇의 위치를 강인하게 추정할 수 있다. 시뮬레이션과 실제 환경에서의 실험을 통해 제안된 알고리즘의 성능을 검증하였다.

참고문헌


[1] J. J. Leonard and H. F. Durrant-Whyte, "Mobile robot localization by tracking geometric beacons," *IEEE Trans. on Robotics and Automation*, vol. 7, no. 3, pp. 376-382, 1991.

[2] J. S. Gutmann, T. Weigel, and B. Nebel, "Fast, accurate, and robust self-localization in polygonal environments," *Proc. of IEEE/RSJ Int. Conf. on Intelligent Robots and Systems*, vol. 3, pp. 1-7, 1999.

- [3] W. Burgard, D. Fox, D. Hennig, and T. Schmidt, "Estimating the absolute position of a mobile robot using position probability grids", Proc. of the National Conf. on Artificial Intelligence, 1999.
- [4] D. Fox, W. Burgard, and S. Thrun, "Active Markov localization for mobile robots", Robotics and Autonomous Systems, vol. 25, no.3-4, pp. 191-207, 1998.
- [5] D. Fox, W. Burgard, E. Dellaert, and S. Thrun, "Monte Carlo localization: Efficient position estimation for mobile robots", Proc. of the National Conf. on Artificial Intelligence, 1999.
- [6] P. Jensfelt, O. Wijk, D. Austin, and M. Andersson, "Feature based condensation for mobile robot localization", Proc. of the IEEE Int. Conf. on Robotics and Automation, vol. 3, pp. 2531-2537, 2000.
- [7] A. Doucet, N. de Freitas, and N. Gordon, Sequential Monte Carlo in Practice, Springer-Verlag, New York, 2001.
- [8] J. MacCormick and A. Blake, "A probabilistic exclusion principle for tracking multiple objects", Proc. of the Seventh IEEE Int. Conf. on Computer Vision, vol. 1, pp. 571-578, 1990.
- [9] N. J. Gordon, D. J. Salmond, and A. F. M. Smith, "Novel approach to nonlinear non-Gaussian Bayesian state estimation", IEE Proc. F: Radar and Signal Processing, vol. 140, no. 2, pp. 107-113, 1993.
- [10] K. Kamazawa, D. Koller, and S. Russell, "Stochastic simulation algorithms for dynamic probabilistic networks", Proc. of the Eleventh Conf. on Uncertainty in Artificial Intelligence, pp. 346-351, 1995.
- [11] E. Dellaert, D. Fox, W. Burgard, and S. Thrun, "Monte Carlo localization for mobile robots", Proc. of the IEEE Int. Conf. on Robotics and Automation, vol. 2, pp. 1322-1328, 1998.
- [12] E. Dellaert, W. Burgard, D. Fox, and S. Thrun, "Using the CONDENSATION algorithm for robust, vision-based mobile robot localization", Proc. of IEEE Computer Society Conf. on Computer Vision and Pattern Recognition, vol. 2, 1999.
- [13] S. Lenser and M. Veloso, "Sensor resetting localization for poorly modeled mobile robots", Proc. of the IEEE Int. Conf. on Robotics and Automation, vol. 2, pp. 1225-1231, 2000.
- [14] P. Jensfelt, O. Wijk, D. J. Austin, and M. Andersson, "Experiments on augmenting CONDENSATION for mobile robot localization", Proc. of the IEEE Int. Conf. on Robotics and Automation, vol. 3, pp. 2618-2624, 2000.
- [15] D. Fox, "KLD Sampling: Adaptive particle filters", Advances in Neural Information Processing Systems 17, 2001.
- [16] S. Thrun, D. Fox, W. Burgard, and E. Dellaert, "Robust Monte Carlo localization for mobile robots", Artificial Intelligence, vol. 138, no. 1-2, pp. 99-141, 2001.
- [17] C. Kwok, D. Fox, and M. Meila, "Real-time particle filters", Advances in Neural Information Processing Systems 15, 2001.
- [18] C. Kwok, D. Fox and M. Meila, "Adaptive real-time particle filters for robot localization", Proc. of the IEEE Int. Conf. on Robotics and Automation, vol. 2, pp. 2803-2811, 2001.
- [19] D. Lee and W. Chung, "Dependable localization strategy in dynamic real environments", Proc. of IEEE RSJ Int. Conf. on Intelligent Robots and Systems, pp. 3746-3751, 2003.
- [20] S. Thrun, W. Burgard, and D. Fox, Probabilistic Robotics, The MIT Press, 2005.
- [21] W. K. Chung, S. Ahn, J. Lee, K. Lee, J. Choi, and M. Choi, "POSTECH navigation frame: Toward a practical solution for indoor SLAM and navigation", Proc. of 33th Int. Symposium of Robotics Research, pp. 277-288, 2007.

저 자 소 개

이 정 석



2001년 포항공과대학교 기계공학과 학사.
2003년 포항공과대학교 기계공학과 석사.
2003~현재, 포항공과대학교 기계공학과 박사과정.

관심분야 : Localization, Navigation.
Email : badol@postech.ac.kr

정 완 균



1981년 서울대학교 기계설계학과 학사.
1983년 한국과학기술원 기계공학 석사.
1987년 한국과학기술원 로봇공학 박사.

1987~1993년 포항공과대학교 기계공학과 조교수.
1988년 CMU 방문교수.
1995년 U.C. Berkeley visiting scholar.
1993~2000년 포항공과대학교 기계공학과 부교수.
2000~현재, 포항공과대학교 기계공학과 교수.
관심분야 : SLAM, Navigation, Underwater robots, Robust controller.
Email : wkchung@postech.ac.kr

남 상 업



1982년 단국대학교 전자공학과 학사.
1984년 단국대학교 전자공학과 석사.
1987~1998년 삼성종합기술원, (주)모토로라 반도체통신 연구소.

2002년 단국대학교 전자공학과 박사.
현재, 국제대학 정보통신학부 교수.
관심분야 : Embedded system, RFID/USN, Speech recognition, Medical image processing, Ubiquitous robotic companion.
Email : r13337@unitel.co.kr