

Rao-Blackwellized 파티클 필터에서 파티클 생존을 위한 전략 게임

Strategic Games for Particle Survival in Rao-Blackwellized Particle Filter for SLAM

곽 노 산¹ · KITA Nobuyuki² · YOKOI Kazuhito²

Nosan Kwak¹, Nobuyuki Kita², Kazuhito Yokoi²

Abstract Recently, simultaneous localization and mapping (SLAM) approaches employing Rao-Blackwellized particle filter (RBPF) have shown good results. However, due to the usage of the accurate sensors, distinct particles which compensate one another are attenuated as the RBPF-SLAM continues. To avoid this particle depletion, we propose the strategic games to assign the particle's payoff which replaces the importance weight in the current RBPF-SLAM framework. From simulation works, we show that RBPF-SLAM with the strategic games is inconsistent in the pessimistic way, which is different from the existing optimistic RBPF-SLAM. In addition, first, the estimation errors with applying the strategic games are much less than those of the standard RBPF-SLAM, and second, the particle depletion is alleviated.

Keywords: Strategic Games, Rao-Blackwellized Particle Filter, SLAM, Particle Diversity

1. 서론

로봇의 위치(pose) 및 환경맵(map)을 동시에 추정하는 SLAM (Simultaneous Localization And Mapping) 문제를 해결하기 위해 많은 연구가 진행되어 오고 있다. SLAM은 위치와 환경맵을 동시에 추정해야 하므로 어려운 문제이지만, SLAM 문제의 구조적 특성을 이용하고, 파티클 필터를 적용하면 효율적인 추정이 가능하다. 이 특별한 파티클 필터가 Rao-Blackwellized 파티클 필터 (RBPF)^[1,2]이며, 최근 확장 칼만 필터(Extended Kalman Filter, EKF)보다 주로 사용되고 있다. Rao-Blackwellization의 의미는, SLAM에서 추정하고자 하는 위치와 환경맵의 서로 다른 두 개의 상태를 각각 위치에 대한 상태와 환경맵의 상태로 분리하는 것이다. 그렇게 함으로써 얻을 수 있는 두 가지 장점은, 첫째, 기존의 EKF를 이용한 SLAM (EKF-SLAM)의 복잡도는 특

징점(feature)의 수의 제공에 비례하는데, RBPF를 이용한 SLAM (RBPF-SLAM)은 복잡도가 특징점 개수의 선형으로 증가한다. 두 번째 장점은, 강인한 다중 측정 데이터 연관 (data association) 인데, 이것은 EKF-SLAM이 하나의 추정치만을 저장하는 것과 달리, 파티클 각각 다른 추정치를 저장함으로써, 추정치간의 보완이 가능하기 때문이다^[3].

하지만, RBPF-SLAM의 단점은 파티클의 다양성 손실로 인한 추정 성능 저하이다. RBPF-SLAM에서는 파티클들이 재귀적 알고리즘에 의해 로봇의 위치 및 환경을 동시에 추정하는데, 알고리즘의 마지막 단계인 재추출 과정에서 파티클의 복사 혹은 제거가 발생한다. 이 때, 제거된 파티클이 가지고 있던 정보는 모두 사라지고, 결국 특정 파티클이 파티클 집합을 장악하게 된다. 이것이 파티클의 다양성 손실 문제인데^[4], 파티클의 다양성을 잃음으로써, RBPF-SLAM의 장점인 강인한 측정 데이터 연관을 수행할 수 없게 된다^[5].

또 다른 주요 문제는 RBPF-SLAM의 성능에 대한 일관성이다. 즉, 비교적 정확한 추정 성능을 일관적으로 오랫동안 보장할 수 있는 문제가 중요한 이슈가 되고 있다.^[6]에

Received: February 12, 2009, Reviewed: March 25, Accepted: April 6, 2009

※ 본 연구는 일본 학술진흥회(JSPS)의 Grant-in-for JSPS Postdoctoral Fellowship for Foreign Researchers을 통한 연구비 지원으로 수행되었다.

¹ 일본 산업총합기술연구원(AIST) JSPS Postdoctoral Fellow

² 일본 산업총합기술연구원(AIST) Humanoid Research Group

따르면, 하나의 필터는 낙관적(optimistic)으로 추정 성능을 신뢰하거나 비관적(pessimistic)으로 신뢰하여 성능의 일관성을 유지하지 못한다. 현재까지의 RBPF-SLAM^{[5][7]}은 파티클의 다양성 손실로 인해 소수의 파티클들에 의해 성능이 좌우되는 낙관적 추정으로 비일관적이었다. Beever^[7]는 “block proposal distribution” 방법을 도입하고, Kim^[8]은 EKF를 UKF로 대체하여 RBPF-SLAM의 일관성을 향상시켰지만, 오랜 시간 동안 일관성을 유지시키지는 못했다. 또한, Kim^[9]는 파티클 가중치의 차이를 완화(smoothing)와 재추출과정을 로봇 경로 교차(loop-closure) 시점까지 연기하여 파티클 다양성을 유지하였지만, 경로 교차 지점에서의 비일관성은 여전히 발생하였다.

위에서 언급한 두 문제는 모두 파티클의 다양성 손실에 기인한다^[10,11]. 파티클 다양성 손실의 근본 원인은 파티클을 평가하는 가중치의 불균형인데, 이로 인해 소수의 파티클이 높은 가중치를 받아 파티클 집합에서 살아남아 집합을 지배하여, 다양성이 손실된다. 본 논문에서는 이 파티클 가중치의 불균형 문제를 해결하고자 전략 게임방법을 도입하여 가중치를 대신하는 “보수(payoff)”를 할당하는 방법을 제안한다.

2장에서는 RBPF-SLAM의 개요와 파티클 다양성과 일관성에 대해서 기술한다. 3장에서는 전략 게임 방법에 대한 설명을 하고, 4장에서 컴퓨터 모의 실험을 수행하고, 그 결과를 나타내고, 결과에 대한 검토를 기술한다. 마지막으로 5장에서는 본 연구의 결론과 적용 대상에 대해서 언급한다.

2. RBPF-SLAM 및 파티클 다양성

2.1 RBPF-SLAM의 개요

SLAM문제는 로봇이 로봇의 위치와 환경맵을 동시에 추정해야 하는 어려움이 있다. 하지만, RBPF-SLAM은 Rao-Blackwellization을 이용하여, 센서 측정값과 특징점 간의 연관관계 c_{1t} 를 안다고 가정했을 때, (1)과 같이 SLAM 사후 확률(Posterior)을 로봇 위치 추정 확률부분과 환경맵 추정 확률 부분으로 인수분해 할 수 있다^[12].

$$p(x_{1t}, M | z_{1t}, u_{1t}, c_{1t}) = p(x_{1t} | z_{1t}, u_{1t}, c_{1t}) \prod_{n=1}^{N_f} p(m_n | x_{1t}, z_{1t}, c_{1t}) \quad (1)$$

여기서, x_{1t} , z_{1t} , u_{1t} 은 초기부터 현재 시간 t 까지의 각각 로봇 경로, 센서 측정값, 로봇 제어 입력을 나타낸다. 그리고, m_n 은 n 번째 특징점(feature)을 나타내고, N_f 개의 특징점들이 환경맵 M 을 구성한다.

RBPF-SLAM은 재귀적 네 단계, 즉 추출, 특징점 정보 갱신, 파티클 가중치 계산, 재추출 과정으로 이루어져 있

다. 추출 과정은 각각의 파티클이 로봇의 위치를 추정하기 위해 추정 확률 분포로부터 임의의 점을 뽑아내는 것이다. 두 번째 단계는 센서의 측정 데이터를 이용하여 각각의 파티클이 가지고 있는 특징점의 정보를 갱신하는 과정이다. 세 번째 단계로, 파티클의 성능을 평가하기 위해 시간 t 에서 k 번째 파티클의 가중치 $w_t^{[k]}$ 를 다음과 같이 실제 확률 분포(target distribution)과 추정 확률 분포(proposal distribution)의 비로 구한다.

$$w_t^{[k]} = \frac{\text{target distribution}}{\text{proposal distribution}}$$

마지막 단계인 재추출 과정에서는 파티클의 가중치를 이용하여, 다음 재귀 단계에서 이용될 파티클을 다시 뽑는다. 이 마지막 과정은 재생산 과정이라고도 불린다. 이 때, 제거된 파티클들이 가지고 있던 로봇 경로 정보 및 환경맵은 파티클과 같이 사라지게 된다.

2.2 파티클 다양성

RBPF-SLAM의 장점인 다중 측정 데이터 연관은 파티클의 다양성에 기인한다. 하지만, RBPF-SLAM의 마지막 단계인 재추출 과정에서, 제거되는 파티클들이 발생하고, 장기적으로는 소수의 파티클들이 파티클 집합을 차지하여 다양성을 잃게 되는 문제가 발생한다. 파티클 다양성이 낮아졌을 때, 소수의 파티클에 비교적 큰 오차가 발생하면, RBPF-SLAM은 더 이상 추정을 제대로 수행할 수가 없게 된다. 파티클의 다양성이 낮아지는 직접적인 원인은 재추출 과정에서 가중치가 낮은 파티클들은 바로 제거되고, 가중치가 높은 파티클들은 복사되기 때문이다. 따라서, 우리는 RBPF-SLAM에 일반적으로 쓰이는 재추출 방법들을 비교 검토하였지만^[10], 파티클의 다양성을 장기적으로 유지할 수 없었다. 일례로, 여러 재추출 알고리즘에 의한 파티클의 다양성을 측정하기 위해, 초기의 파티클 집합으로부터 제거되지 않고 남아 있는 파티클의 개수(distinct particles)를 측정한 결과가 그림 1에 나타나 있다. 그림 1에서, 비교된 재추출 방법은 부분 재추출(Partial Resampling, PR), 체계적 추출(Systematic Resampling, SR)과 SR을 개선시킨 잉여 체계적 추출(Residual Systematic Resampling, RSR)이다. 그림에는 두 곳의 로봇 경로가 교차하는 loop-closure도 같이 표시되어 있다. 모든 경우에서 파티클의 다양성이 급격하게 감소함을 알 수 있다. 첫 번째 경로 교차에서, 초기 100개의 파티클 중에서 실제적으로 파티클 집합에 남아 있는 개수는 단 한 개였고, 나머지는 이 파티클의 복사본이었다. 따라서, 과거에 우리는 파티클의 다양




그림 1. 재추출 방법에 따른 파티클 다양성 변화

성을 유지하고자 재추출 방법을 대신하는 보정 방법을 제안하였고, 이로 인한 RBPF-SLAM의 성능을 향상 시켰다⁵⁾.

2.3 성능 일관성

필터의 일관성을 검사하기 위해 일반적으로 chi-square 분포가 쓰이는데, 이것은 필터의 실제 오차가 추정치의 분산과 일관적인지 검사하는 것이다^[6]. RBPF-SLAM의 경우는 필터의 일관성 검사를 위해 모의 실험에서 로봇의 위치 추정 확률 분포를 이용하여 일관성 검사를 수행한다. 모의 실험이 반드시 필요한 이유는 실제 환경에서는 로봇의 실제 위치를 알 수가 없기 때문에 추정 확률 분포를 구할 수 없기 때문이다. 일관성 검사를 위한 정규 추정 오차 제곱 (Normalized Estimation Error Squared, NEES)은 식(2)과 같이 정의된다. NEES는 여러 논문^[5,6,7,8,9]에서 일관성 검사를 위해 사용되었다.

$$\varepsilon_t = (x_t - \hat{x}_t)^T P_t^{-1} (x_t - \hat{x}_t) \quad (2)$$

여기서, $\{\hat{x}_t, P_t\}$ 는 시간 t 에서 파티클 추정치의 평균 및 분산이다. 필터의 일관성 측정은 N 번의 Monte Carlo 수행에 대한 평균 NEES값으로 얻어진다. 여기서, 필터가 일관적이고, 근사적으로 선형 정규 분포라고 가정하면, NEES는 $\dim(x_t)$ 의 자유도를 가지는 χ^2 (chi-square) 분포를 형성한다. 따라서, RBPF-SLAM의 일관도는 Monte Carlo 수행을 N 번 수행하여 다음과 같은 수식을 통해 얻을 수 있다.

$$\bar{\varepsilon}_t = \frac{1}{N} \sum_{i=1}^N \varepsilon_t^i \quad (3)$$

위에서 가정한 선형 일관적 필터에서, $N\bar{\varepsilon}_t$ 는 $N \dim(x_t)$ 를 갖는 χ^2 밀도를 갖는다. 따라서, 3개의 자유도를 갖는 2차원 평면에서의 로봇 위치는 $N=50$, 즉 Monte Carlo 수행을 50번 수행했을 때, $\bar{\varepsilon}_t$ 의 확률분포의 95%은 [2.36, 3.72] 영역에 제한된다. 만약, $\bar{\varepsilon}_t$ 이 상한보다 현격하게 크다면, 필터는 낙관적인 비일관성(optimistic inconsistency)라고 하고, 반대로, 하한보다 현격하게 작다면, 비관적인 비일관성(pessimistic inconsistency)라고 한다. 그림 2에 기존의 RBPF-SLAM 프레임 워크의 일관도 검사 수행 결과를 나타내었다. 그림을 보면, RBPF-SLAM은 알고리즘 수행 후 곧 비일관적이 되는 것을 볼 수 있다. 좀 더 자세히 말하면, 그림의 3000 time step부터 낙관적인 비일관성을 보이고 있다.




그림 2. 기존의 RBPF-SLAM의 일관성 테스트 결과를 평균 NEES로 표시. 두 개의 수평선은 Monte Carlo 수행을 50번 했을 때, 일관성을 유지하는 필터의 상한과 하한을 나타냄.

3. 전략 게임

이타적 협동이나 이타적 행동은 인간 사회에서 자주 목격된다. 오랫동안 이런 이타적 협동의 진화에 대해 많은 연구가 진행되었으며, 아직도 명확한 설명이 없는 상태이다^[13]. 본 논문에서는 이타적 협동 전략을 파티클 필터에 적용시키고자 한다.

중요 가중치(importance weight)를 이용하는 재추출 방식은 어떤 파티클이 살아남아 다음 라운드에 계속해서 추정을 수행할까를 결정하는 매우 중요한 것이다. 하지만, 기존의 재추출 방식들은 파티클의 다양성을 심각하게 손상시키기 때문에, 추정 성능이 떨어지고, 성능 보장이 어렵게 된다. 일례로, 가중치가 큰 파티클이 파티클 집합을 지배하게 되는데, 즉 파티클들이 추정하는 추정치에 대해서

지나치게 신뢰(over confident)하게 되고, 오차에 대한 보정 여지가 사라지게 되어 필터로서의 성능이 감소된다. 이런 점에서, 파티클 다양성 문제는 파티클의 생존의 문제이며, 전략 게임을 도입함으로써 파티클 다양성을 개선시킬 수 있다.

좀 더 자세히 기술하면, 파티클의 중요 가중치를 사용하지 않고, 파티클간의 전략 게임을 통해 파티클의 생존을 결정함으로써 파티클 다양성이 유지될 수 있다. 파티클은 전략 게임을 통해서 어떤 파티클은 높은 보수를 받고, 다른 것은 낮은 보수를 받을 수도 있지만, 협동 전략에 따라, 모두 높은 보수를 받을 수 있다. 따라서, 게임 전략에 대해서 논의해 볼 가치가 있다.

3.1 게임 이론

게임 이론이라 하면, 일반적으로 많이 알려진 ‘죄수의 딜레마’가 대표적이다. 이것은 두 명의 죄수가 죄의 형량을 최소로 하기 위해 죄를 ‘부인(deny)’하거나 ‘고백(confess)’하는 것을 선택하는 문제이다. 이타적 게임에서^[14] 각 선택에 따른 보수가 표 1에 나타나 있다. 표 1에서는 이타적 게임을 하기 위한 보수 표이다. 따라서, 선택할 수 있는 전략은 협동(COOPERATE)이거나 배신(DEFECT)이다. 표에서 P_b 는 Player 1이 Player 2에 주는 보수이며, P_c 는 Player 2를 위해 희생하는 비용 값이다. 예를 들어, Player 1은 협동 전략을 택하고, Player 2는 배신전략을 택하게 되면, Player 2는 Player 1으로부터 P_b 만큼의 보수를 받고, Player 1는 희생의 대가로 P_c 를 잃는다.

표 1에서 P_b 가 P_c 보다 크다면, 이것은 전형적인 죄수의 딜레마 게임과 같게 된다. 따라서, 이타적 게임을 만들기 위해서는 P_b 가 P_c 보다 작게 하여야만 이타적 게임이 성립된다.

게임 이론에서 중요한 세 가지 개념이 있는데, 그것은 최적 반응(best response), Nash 평형(equilibrium), 그리고 지배 전략(dominant strategy)이다. 최적 반응은 상대방의 전략에 따라 최대의 보수를 주는 전략이다. Nash 평형은 전략들의 쌍의 집합으로써, 한 플레이어가 전략을 변경함으로써 더 나은 보수를 얻지 못하는 상태이다^[14]. 지배 전략

은 상대방의 전략과 상관없이 자신에게 최대의 보수를 주는 전략이 명백한 전략이다. 표 1의 이타적 게임에서는 배신(DEFECT)가 두 Players에게 지배 전략이며, (DEFECT, DEFECT)는 Nash 평형이다. 하지만, 두 플레이어 모두 DEFECT를 선택하게 되면 받는 보수는 각각 0이 된다. 왜 협동을 하여 더 나은 보수는 받을 수 없는 것인가? 이 질문에 대한 고찰이 파티클 필터와 SLAM 관점에서 본 논문에서 다루어 지게 된다.

3.2 파티클 생존을 위한 게임 전략

파티클 생존을 위한 게임 전략은 여러 가지가 있을 수 있지만, 크게 다음과 같이 네 가지로 나누어 생각해 볼 수 있다.

- ① 임의의 전략(RS): 각각의 파티클은 협동과 배신 전략 중에 임의로 전략을 선택한다.
- ② Tit for Tat 전략(TS): 각각의 파티클은 상대방의 전 단계의 전략을 따라서 전략을 결정한다. 이것은 이에는 이, 눈에는 눈 전략이라고도 불린다.
- ③ 이웃 전략(NS): 각각의 파티클은 이웃 파티클의 총 보수의 합이 큰 쪽을 선택한다. 식(4)에서 TPC는 협동 전략을 가지고 있는 이웃 파티클의 총 보수를 나타내고, TPD는 배신 전략을 가지고 있는 이웃 파티클의 총 보수를 나타낸다.

$$TP_C = \sum_{i=1}^{N_c} P_C^i, \quad TP_D = \sum_{i=1}^{N_d} P_D^i \quad (4)$$

두 보수가 같을 때는, 임의의 전략을 택한다.

- ④ 협동 전략(AS): 파티클들은 항상 협동 전략을 택한다. 위에서 언급한 전략 게임은 표 2와 같이 기존의 RBPF-SLAM 프레임워크에 삽입된다. 모든 파티클은 제일 처음 임의의 전략(RS)으로 RBPF-SLAM을 수행한다. 이 때, 파티클간의 짝짓기(전략 게임을 수행하기 위한 pairing)는 임의적으로수행한다.

4. 모의 실험 결과

본 논문에서 제안한 전략 게임을 검증하기 위해 모의 실험을 수행하였다. 이 때, 오차 분석 및 일관성 검사를 하기 위해서는 로봇의 실제 위치가 필요하므로 모의 실험만을 수행하였다. 또한, 센서의 측정값과 환경맵상의 특징점 매칭은 알고 있다는 가정을 추가하였는데, 이것은 제안한 전략 게임의 효율성을 집중적으로 검증하기 위한 것이다. 모의 실험은 제안된 방법의 성능을 검증하기 위해, 주로 파티클 다양성, 일관성, 오차에 대해서 수행하였다. 이를

표 1. 이타적 게임에서의 전략에 따른 보수

		Player 2	
		COOPERATE	DEFECT
Player 1	COOPERATE	$(P_b - P_c), (P_b - P_c)$	$(-P_c), (P_b)$
	DEFECT	$(P_b), (-P_c)$	$(0), (0)$

표 2. 전략 게임을 추가한 RBPF-SLAM 알고리즘

Algorithm RBPF-SLAM with Strategic Game	
Input:	A set of particles
Output:	A set of survived particles
Line	Program Description Language
1:	Predict the robot pose per particle independently.
2:	IF the measurement is not ready
3:	RETURN
4:	ELSE
5:	Obtain the measurement data of sensors.
6:	IF the detected features are new
7:	Add the features to a map of each particle
8:	ELSE
9:	Sample particles with the recent measurement
10:	Update the feature data in each particle
11:	Compute the importance weight
12:	IF the effective sample size is larger than 50%
13:	RETURN
14:	ELSE
15:	Perform strategic games among all particles
16:	Resample particles with obtained payoffs
17:	RETURN

위해, NEES, Root Mean Square (RMS) 추정 오차 등이 사용되었다.

4.1 모의 실험 환경

제안 방법의 검증에 위해 모의 환경을 다양하게 하여 실험을 하였다. 즉, 특징점의 밀도가 높은 환경, 특징점의 밀도가 낮은 환경, 크기가 작은 환경, 크기가 큰 환경 등에서 골고루 실험을 수행하였다. 여러 환경 중 하나가 그림 3에 나타나 있는데, 이 환경은 특징점 수(=50개)가 작고 크기(40m x 40m)가 작은 환경이다. 수행된 모든 모의 실험은 100개의 파티클을 사용하였다.

그림 3에서 로봇의 경로 교차점은 점 C에서 한 번만 발생하게 된다. 재추출 과정과 전략 게임 과정은 표 2의 알고리즘에 나타난 대로, 유효 샘플 사이즈 (effective sample size)[15]가 전체 파티클의 50% 이하일 때만 수행한다. 표 2의 주요 가치치(importance weight)는 단순히 유효 샘플 사이즈를 계산하기 위해서만 사용되었음을 밝힌다. 로봇의 이동 잡음 및 센서의 측정 잡음은 (0.2m/s, 3°/s), (0.1m, 1°)로 설정하였다. 또한, 제어 입력 주기는 25ms, 센서 측정 주기는

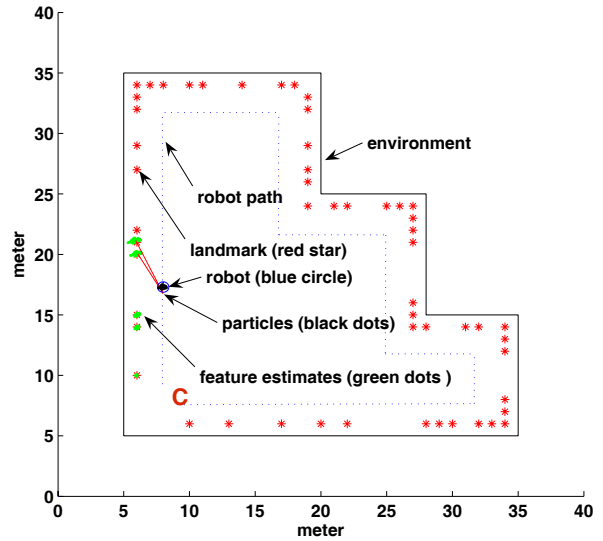


그림 3. 특징점의 밀도가 낮고, 크기가 작은 환경

200ms 였다. 전략 게임에 사용된 보수표는 Axelrod^[16]의 표와 유사한 표 3을 사용하였다. RBPF-SLAM은 확률 기반이므로, 대번 임의의 결과가 얻어지므로, 결과의 검증에 위해 50번의 Monte Carlo 실험을 수행하였다.

표 3. 모의 환경에서 사용된 전략에 따른 보수

		파티클2	
		COOPERATE	DEFECT
파티클1	COOPERATE	(2.0), (2.0)	(0.5), (3.0)
	DEFECT	(3.0), (0.5)	(1.0), (1.0)

4.2 게임 전략에 따른 성능 비교

먼저, 3장 2절에서 제안한 게임 전략에 따른 필터의 일관성, 추정 오차, 파티클 다양성 검사를 수행하였다. 이 때, 전략 게임을 사용하지 않는 기존의 RBPF-SLAM 알고리즘과의 결과 비교도 같이 수행하였다. 기존의 알고리즘에서는 재추출 과정에는 일반적으로 많이 쓰이는 잉여 체계적 추출 방식(Residual Systematic Resampling, RSR)^[10]을 사용하였다. 각 전략 게임에 따른 파티클 다양성 변화 그래프가 그림 4에 나타나 있다.

그림 4를 보면, 전략 게임 중 TS, NS, AS의 경우 파티클의 다양성의 50% 이상 유지되었다. 이것은 전략 게임을 사용하지 않은 일반적인 경우에 비해 큰 차이를 보여준다. 그림 5에는 일관성 검사를 위해 각 경우의 평균 NEES 변화를 나타내었다. 그림 5에서 두 수평선의 안쪽에 NEES 값이 유지되면, 필터가 일관적이라고 말할 수 있지만, 일관적이라고 판단할 수 있는 경우는 없었다. 하지만, 전략 계




그림 4. 파티클 다양성 변화. 파티클 재추출과정에서 살아남은 파티클의 비율을 측정.




그림 5. 평균 NEES의 변화. 전략 게임을 수행하지 않은 경우, 경로교차부근에서 값이 크게 증가하여 표시 안함.

임을 사용하지 않은 경우, 경로 교차 부근에서 평균 NEES가 급격하게 커져서 파티클의 추정 성능을 지나치게 신뢰하는 경우가 발생했다. 반면에 전략 게임을 사용한 경우는 모두 추정 성능에 대해 신뢰가 부족한 결과를 보였다.

위 결과가 도출 된 모의실험에서 파티클들의 평균 전략의 변화를 그림 6에 나타내었다. 그림에서 TS, NS, AS의 경우 평균전략이 DEFECT(1)이거나 COOPERATE(0)으로 수




그림 6. SLAM 수행하는 동안의 파티클들의 평균전략

렴한 것을 볼 수 있다. 이것은 모든 파티클이 같은 전략을 갖게 되면, 같은 보수를 받게 되는데, 이것은 생존 확률이 모두 같다는 것을 의미한다.

마지막으로, 각 경우의 추정 오차를 표 4와 표 5에 나타내었다. 표에서 로봇의 RMS 위치, 방향, 특징점 오차가 각각 RMS_p , RMS_o , RMS_f 로 나타나 있다. 또한, 파티클의 다양성을 나타내는 DP (Distinct Particle) 비율도 같이 표시하였다. 여기서 나타난 값들은 모든 파티클들의 평균값이다. 평균값을 사용한 이유는 [11]에 의하면, 파티클의 평균을 취하는 것이 가장 좋은 결과를 보여주기 때문이다. 표에 나타났듯이, 전략 게임을 적용했을 때, 추정 오차는 급격하게 줄어든 것을 확인할 수 있다. 하지만, 로봇의 방향 오차는 거의 줄어 들지 않거나 커졌다. 그 차이는 0.03° 로 위치 오차와 특징점 오차의 감소와 비교했을 때 미미하였다. 비록, 전략 게임은 필터의 일관성은 유지할 수 없었지만, 파티클 다양성을 높이고, 추정 오차를 현격히 줄이는 결과를 보였다. 환경 크기가 $240m \times 240m$ 인 곳에서도 모의 실험을 수행한 결과 TS가 추정 오차 면에서 가장 좋은 결과를 보여줬다. 그 결과를 표 6에 나타내었다.

표 6을 보면, 전략 게임(TS)을 사용한 경우 추정 오차가 현저하게 줄어든 것을 확인할 수 있다.

그리고, 일관성 검사를 위한 NEES를 그림 7에 나타내었다. 전략 게임을 사용하지 않은 경우 필터는 초반에 급격히 추정에 대해 지나치게 신뢰하는 것을 보여주고, 전략

표 4. 특징점 밀도 낮은 환경에서의 추정 오차비교

전략	$RMS_p(m)$	$RMS_o(rad)$	$RMS_f(m)$	DP(%)
No game	0.2744	0.0495	0.3476	24.3
RS	0.1643	0.0499	0.2124	36.4
TS	0.1016	0.0496	0.1016	67.5
NS	0.1056	0.0494	0.1065	85.4
AS	0.1107	0.0496	0.1167	75.3

표 5. 특징점 밀도 높은 환경에서의 추정 오차비교

전략	$RMS_p(m)$	$RMS_o(rad)$	$RMS_f(m)$	DP(%)
No game	0.3168	0.0441	0.3143	13.1
RS	0.1987	0.0456	0.2394	24.2
TS	0.1322	0.0449	0.1284	64.4
NS	0.1348	0.0452	0.1329	83.9
AS	0.1401	0.0447	0.1403	73.9

표 6. 240m x 240m 환경에서의 추정 오차

전략	$RMS_r(m)$	$RMS_o(rad)$	$RMS_f(m)$	DP(%)
No game	4.6709	0.0669	4.7884	4.9
TS	1.1202	0.0824	1.0847	63.6




그림 7. 240m x 240m 환경에서의 평균 NEES 변화

게임을 사용한 경우는 앞의 결과와 유사하게 추정에 대해서 신뢰가 부족함을 보여준다.

5. 결론

본 논문에서는 기존 RBPF-SLAM의 파티클 다양성 문제를 해결하고자, 기존의 중요 가중치를 사용하지 않고, 전략 게임에 의해 파티클의 보수를 사용하는 방법을 제안하였다. 이것은 중요 가중치 정보를 사용하지 않고 게임을 함으로써, 파티클 분포에 큰 영향을 주는 문제점을 가지고 있지만, 게임 전략에 따른 파티클의 생존과 성능 향상 관계 파악을 위해 제안되었다. 비록, 제안된 전략 게임 방식들이 RBPF-SLAM을 일관되게 만들지는 못하였지만, 파티클의 다양성을 충분히 유지하도록 했으며, 추정 오차 또한 기존의 방식보다 현저하게 낮추는 결과를 보였다. 향후 연구로는 전략의 다양화를 통하여 일관적인 RBPF-SLAM을 실현하는 것이다.

참고문헌

- [1] K. Murphy, "Bayesian map learning in dynamic environments," *Advanced in Neural Information Processing Systems*, MIT Press, 1999.
- [2] A. Doucet, N. de Freitas, K. Murphy, et al., "Rao-Blackwellized particle filtering for dynamic Bayesian networks," in *Proc. of Conference on Uncertainty in Artificial Intelligence*, pp. 176-183, 2000.
- [3] M. Montemerlo, *FastSLAM: A factored solution to the simultaneous localization and mapping problem with unknown data association*, Ph.D. Dissertation, Carnegie Mellon University, 2003.
- [4] R. Merwe, A. Doucet, N. de Freitas, et al., *The unscented particle filter*, Cambridge University Engineering Department, Technical Report CUED/F-INFENG/TR380, 2000.
- [5] T. Bailey, J. Nieto, and E. Nebot, "Consistency of the FastSLAM algorithm," in *Proc. of IEEE Int'l Conf. on Robotics and Automation*, pp. 424-429, 2006.
- [6] Y. Bar-Shalom, X. R. Li, and T. Kirubarajan, *Estimation with Applications to Tracking and Navigation*, John Wiley and Sons, 2001.
- [7] K. R. Beevers and Wesley H. Huang, "Fixed-lag sampling strategies for particle filtering SLAM," in *Proc. of IEEE International Conference on Robotics and Automation*, pp. 2433-2438, Rome, April 2007.
- [8] C. Kim, R. Sakthivel, and W. K. Chung, "Unscented FastSLAM: A robust and efficient solution to the SLAM problem," *IEEE Trans. on Robotics*, Vol. 24, No. 4, Aug., pp. 808-820, 2008.
- [9] C. Kim and W. K. Chung, "Delayed Resampling in a Rao-Blackwellized Particle Filtering for SLAM for Consistent Loop Closures," *Proc. of 2008 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems*, pp. 2084-2090, 2008.
- [10] N. Kwak, G. W. Kim, and B. H. Lee, "A new compensation technique based on analysis of resampling process in FastSLAM," *Robotica*, vol. 26, no. 2, pp. 205-217, March 2008.
- [11] N. Kwak, B. H. Lee, and K. Yokoi, "Result Representation of Rao-Blackwellized Particle Filter for Mobile Robot SLAM," *Journal of Korea Robotics Society*, vol. 3, no. 4, pp. 308-314, December 2008.
- [12] S. Thrun, W. Burgard, and D. Fox, *Probabilistic robotics*, Cambridge: MIT Press, 2005.
- [13] J.-K. Choi and S. Bowles, "The coevolution of parochial altruism and war," *Science*, vol. 318, pp. 636-640, 2007.
- [14] A. Dixit and S. Skeath, *Games of Strategy 2nd Edition*, W. W. Norton & Company, Inc., 2004.
- [15] J. S. Liu and R. Chen, "Blind deconvolution via sequential imputations," *Journal of the American Statistical Association*, vol. 90, no. 430, pp. 567-576, 1995.
- [16] *The Evolution of Cooperation*, New York: Basic Books, 1984.



곽 노 산

2001 아주대학교 기계공학(공학사)
2008 서울대학교 전기·컴퓨터공학(공학박사)
2008~현재 AIST 자율행동제어
JSPS Postdoctoral Fellow

관심분야 : SLAM, Particle diversity and cooperation,
Humanoid robot exploration



Nobuyuki Kita

1979 Osaka University, Control Eng. (B.E.)
1980 Osaka University, Control Eng. (M.E.)
2001~현재 AIST Senior Researcher
관심분야 : Robot Vision



Kazuhito YOKOI

1984 Nagoya Institute of Technology, Mechanical Eng. (B.E.)
1986 Tokyo Institute of Technology, Mechanical Eng. Science (M.E.)

1994 Tokyo Institute of Technology, Mechanical Eng.Science (Ph.D.)

2003~2008 Joint Japanese-French Robotics Lab.
Co-director

2009-현재 AIST Humanoid Research Group Leader

2005~현재 University of Tsukuba, 교수

관심분야 : Humanoid robots, Intelligent robot systems