

비용 인지 RRT 경로 계획 알고리즘

A Cost-Aware RRT Planning Algorithm

서 정 훈¹, 오 성 회[†]

Junghun Suh¹, Songhwai Oh[†]

Abstract In this paper, we propose a cost-aware Rapidly-exploring Random Tree (RRT) path planning algorithm for mobile robots. A mobile robot is presented with a cost map of the field of interest and assigned to move from one location to another. As a robot moves, the robot is penalized by the cost at its current location according to the cost map. The overall cost of the robot is determined by the trajectory of the robot. The goal of the proposed cost-aware RRT algorithm is to find a trajectory with the minimal cost. The cost map of the field can represent environmental parameters, such as temperature, humidity, chemical concentration, wireless signal strength, and stealthiness. For example, if the cost map represents packet drop rates at different locations, the minimum cost path between two locations is the path with the best possible communication, which is desirable when a robot operates under the environment with weak wireless signals. The proposed cost-aware RRT algorithm extends the basic RRT algorithm by considering the cost map when extending a motion segment. We show that the proposed algorithm gives an outstanding performance compared to the basic RRT method. We also demonstrate that the use of rejection sampling can give better results through extensive simulation.

Keywords: Path Planning, Rapidly-Exploring Random Tree, Cost Map, Mobile Robots

1. 서론

경로 계획은 로봇틱스 분야에서 매우 중요한 문제이기 때문에 연구자들의 많은 관심을 끌어 왔다^[1-3]. 경로 계획 방식의 목적은 로봇의 세부 제한 사항을 만족하면서 동시에 장애물과 충돌하지 않고 시작점으로부터 목적지까지 로봇의 연속적인 경로를 찾는 것이다. 자주 사용되는 경로 계획 방식인 RRT(Rapidly-Exploring random tree)^[4]는 샘플링을 기반으로 하는 알고리즘이다. RRT는 상태 공간 내에서 랜덤으로 포인트를 선택함으로써 재빨리 상태공간을 탐색하고 랜덤 포인트 방향으로 tree를 확장하여 점차적으로 tree를 키워나간다. RRT는 정적 환경^[5-7]에서 그리고 동적 환경^[8-10]에서 많은 연구자에 의해 응용되어 지고 있다.

하지만 위에서 언급한 방식들은 로봇이 계획된 경

로를 따라 움직일 때 발생하는 비용을 고려하지 않는다. 예를 들어 만약 로봇이 위험한 지역을 이동해야 한다고 하면 로봇은 지역의 위험도를 나타내는 지도를 바탕으로 위험도가 낮은 지역을 지나도록 설계되어야 한다. 이러한 경우를 다루기 위해 최근에 많은 개선이 이루어졌다^[11-14]. 경로의 질을 높이기 위해 RRT의 트리를 확장할 때, [11,12]에서는 선택된 임의의 점과 가장 가까운 트리 내의 한 점은 시작점부터 이 점까지의 경로의 비용을 고려하여 선택되어 진다. Choi 등은 [13]에서 공간의 환경 파라미터들을 추정하고 로봇들을 가장 정보가 많은 지역 쪽으로 움직이게 제어한다. 하지만 그들은 로봇의 경로에 따른 비용을 고려하지 않았다. 이러한 발전들이 동기가 되어 본 논문에서 우리는 비용 인지 네비게이션 기술을 제안한다. 온도, 습도, 화학 물질의 밀집도, 신호 강도 그리고 은밀도 등과 같은 환경의 파라미터들을 나타내는 비용 지도를 가지고 있다고 가정한다. 본 논문의 목적은 시작점에서 목적지까지 이동 시간, 경로의 종료 시점의 비용 그리고 이동 경로의 비용을 고려하여 최소의 비용을 갖는 경

Received : Apr. 7. 2012; Reviewed : Apr. 20. 2012; Accepted : Apr. 24. 2012

※ 이 논문은 2010년도 교육과학기술부의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임 (No. 2010- 0013354).

† 교신저자 : 서울대학교 전기정보공학부 교수

¹ 서울대학교 전기정보공학부 박사과정

로 로봇을 이동시키는 경로 계획 방식을 설계하는 것이다. 본 논문에서 비용지도는 복잡한 물리적 현상을 잘 모델링할 수 있는 가우시안 프로세스(Gaussian processes)를 사용하여 구한다. 가우시안 프로세스는 복잡한 물리적 현상을 추정하고 예측하기 위해 사용되는 비모수적 regression 방법이다^[4].

본 논문에서 제안하는 경로 계획 알고리즘은 RRT tree를 확장해 나갈 때 비용 지도를 고려하여 최소의 비용을 갖는 모션 세그먼트를 결정하므로 기존 RRT의 변형된 알고리즘이다. 또한 제안하는 알고리즘은 랜덤 포인트를 선택할 때 비용 지도를 기반으로 기각표본추출법(rejection sampling)^[21]을 사용하여 샘플링을 하여 경로의 질을 개선시킨다. 이는 기존 RRT의 장점인 국소최저치에 빠지지 않고 확률적으로 완전하게 목적지에 도달하게 하면서 동시에 경로의 질을 개선하여 최소의 비용으로 로봇을 제어할 수 있다는 것을 의미한다. 본 논문에서는 모의실험을 통해 제안된 알고리즘의 타당성을 검증하고 기존의 RRT보다 더 좋은 결과를 얻을 수 있다는 것을 보여준다.

본 논문의 구성은 다음과 같다. 2절에서는 가우시안 프로세스 regression과 RRT를 간단히 설명하고 3절에서는 비용인지 경로 계획 문제를 정의하고 제안하는 알고리즘을 설명한다. 4절에서는 모의실험을 통하여 제안된 알고리즘의 타당성을 검증하고 5절에서는 결론을 맺는다.

2. 관련 이론

먼저, 이 장에서는 가우시안 프로세스 regression과 rapidly-exploring random trees (RRT)를 소개한다.

2.1 가우시안 프로세스 Regression

가우시안 프로세스(Gaussian Process, 이하 GP)는 함수의 공간상에서 가우시안 분포를 갖는 확률 변수들을 무한차원으로 일반화한 개념이다. GP는 비모수적 방법을 이용하여 복잡하거나 노이즈가 심한 확률과정을 추정할 수 있다. 만약 $z(X)$ 가 GP의 분포를 갖는 함수라면, 여기서 $X \in D \subseteq R^n$, $z(X)$ 는 평균함수 $\mu(X)$ 와 공분산 함수 $K(X, X')$ 로 완전하게 나타낼 수 있고 $z(X) \sim GP(\mu(X), K(X, X'))$ 로 표시한다. 여기서 평균함수는 $\mu(X) = \mathbb{E}(z(X))$ 이고 공분산 함수는 $K(X, X') = \mathbb{E}[(z(X) - \mu(X))(z(X') - \mu(X'))]$ 이다.

장소 $X = [X_1, X_2, \dots, X_n] \in D$ 에서 측정된 데이터 $Y = [y_1, y_2, \dots, y_n]^T \in R^n$ 를 보통 측정 오차를 포함한 $y_i = f(X_i) + w_i$ 로 나타낼 수 있다. 여기서 w_i 는 분산 σ_w^2 을 갖는 화이트 가우시안 노이즈이다. 새로운 장소 X_* 에서의 추정값 $z(X_*)$ 는 측정된 데이터 Y 를 기반으로 하여 다음과 같은 평균 $\hat{z}(X_*)$ 과 분산 $cov(\hat{z}(X_*))$ 을 가지는 가우시안 확률 변수임을 보일 수 있다.

$$\begin{aligned} \hat{z}(X_*) &= K_*^T(K + \sigma_w^2 I)^{-1} Y \\ cov(\hat{z}(X_*)) &= k(X_*, X_*) - K_*^T(K + \sigma_w^2 I)^{-1} K_* \end{aligned} \quad (1)$$

여기서 $K = [K_{ij}]$ 는 i 번째 행 j 번째 열의 원소 $K_{ij} = k(X_i, X_j)$ 를 갖는 커널 행렬이고 $K_* = [k(x_1, x_*), \dots, k(x_n, x_*)]^T$ 이며 $cov(\hat{z}(X_*))$ 는 추정값 $\hat{z}(X_*)$ 의 공분산이다^[4]. 본 논문에서 우리는 커널 함수로써 가장 많이 사용되는 squared exponential 함수를 사용하며 그 형태는 다음과 같다.

$$k(X, X') = \sigma_f^2 \exp\left(-\frac{1}{2\sigma_l^2} \sum_{m=1}^n (X_m - X'_m)^2\right) \quad (2)$$

여기서 σ_f 와 σ_l 은 커널의 하이퍼파라미터(hyperparameter)이고 커널 함수는 두 장소 사이의 거리의 척도를 나타낸다.

2.2 Rapidly-Exploring Random Tree

RRT^[4]는 무작위 샘플링을 사용하여 고차원의 구성 공간을 탐색하는 흔히 사용되는 경로 계획 알고리즘이다. 시작점과 목적지가 정해지면 RRT는 반복적으로 구성 공간 내에서 임의의 한 점 x_{rand} 를 뽑고 초기에 시작점으로만 구성되어 있는 검색 트리 T 를 확장시킨다. x_{rand} 는 공간 내에서 균등분포를 사용하여 선택되지만 목적지까지 더 빨리 도달하게 하기 위해서 x_{rand} 가 목적지에 치우치게 하는 분포형태도 사용한다. 검색 트리 T 는 만약 트리 내에 존재하는 노드들 중에 x_{rand} 와 가장 가까운 점 x_{near} 가 존재한다면 x_{rand} 의 방향으로 새로운 점, x_{new} 까지 x_{near} 부터 연결해 나가면서 확장된다. x_{new} 는 x_{near} 부터 정해진 시간 Δt 동안 로봇의 다이내믹 모델에 제어 입력 $u \in U$ (U 는 적용할 수 있는 입력의 집합이다)를 적용하여 찾을 수 있다. 트리 T 가 목적지에 도달하면 목적지부터 시작점까지 재귀

적으로 트리를 검색하여 경로를 찾게 된다.

3. 비용 인지 경로 계획

3.1 문제 설정

$\chi \subset R^n$ 를 로봇의 상태 공간이라 하자. 여기서 χ 는 χ_{free} 와 χ_{obs} 로 구성되어 있다. χ_{obs} 는 장애물이 있거나 로봇이 액추에이터의 한계 때문에 충돌할 수 있는 공간을 나타낸다. 반대로 $\chi_{\text{free}} = \chi \setminus \chi_{\text{obs}}$ 는 자유공간을 나타낸다. 로봇의 상태 방정식은 입력제어 u 와 로봇의 상태 x 의 함수 $\dot{x} = f(x, u)$ 로 나타낼 수 있다. $x_0 \in \chi$ 를 로봇의 시작점, $x_{\text{goal}} \subset \chi$ 를 목적지라고 하고 π_u 를 시간 $t=0$ 부터 $t=T$ 까지 주어진 제어 입력 $u(t)$ 를 적용했을 때의 상태 방정식의 해라고 가정하자. 제어 입력 $u(t)$ 가 주어지고 비용지도 ($C: \chi \rightarrow R^+$)를 기반으로 했을 때 전체 경로의 비용은 다음과 같이 나타낼 수 있다.

$$J(u) = \left(\frac{1}{T} \int_0^T C(\pi_u(t)) dt + C_T(\pi_u(T)) \right). \quad (3)$$

여기서 T 는 전체 경로의 종료 시간이고 $C_T: \chi \rightarrow R^+$ 는 종료 비용이다.

로봇의 경로를 따라 비용함수를 적분하게 되면 경로의 질을 결정할 수 있다. 그럼 최소 비용의 경로 계획 문제는 다음과 같은 형태의 최적화 문제로 바뀌게 된다.

$$\begin{aligned} & \min_{u(t): 0 \leq t \leq T} J(u) \\ & \text{subject to } \pi_u(t) \in \chi_{\text{free}} \text{ for all } t \in [0, T]. \end{aligned} \quad (4)$$

종료 비용함수 C_T 는 로봇의 최종 상태가 얼마나 목적지에 가까운가를 측정한다. 비용함수 $C(x) = \alpha + C_{\text{costmap}}(x)$ 를 정의함으로써 로봇의 이동 시간이 비용함수에 관여를 하게 된다. 여기서 $\alpha > 0$ 는 이동 시간에 따라 비용에 각각 다른 가중치를 주기 위해 사용되어 지는 계수이다. 하지만 만약 우리가 비용함수으로써 (4)를 사용하게 되면 목적지에 도달하지는 못하지만 목적지까지 도달하는 경로를 보다 더 적은 비용을 갖는 경로가 존재할 수 있는 문제가 발생할 수 있게 된다. 이러한 상황을 피하기 위해서 우리는 최소 비용의 경로 계획 문제를 다음의 최적화 문제로 수정하였다.

$$\begin{aligned} & \min_{u(t): 0 \leq t \leq T} \left(\frac{1}{T} \int_0^T C(\pi_u(t)) dt \right) \\ & \text{subject to } \pi_u(t) \in \chi_{\text{free}} \text{ for all } t \in [0, T] \quad (5) \\ & \text{and } C_T(\pi_u(T)) < \tau \end{aligned}$$

여기서 τ 는 작은 값을 갖는 상수이다.

위에서 언급한 최적화 문제를 통해서 우리는 (4)에서 발생할 수 있는 상황을 피하면서 목적지에 가까이 도달하는 경로들 중에 최소 비용을 갖는 경로를 찾을 수 있게 된다. 본 논문에서 우리는 로봇의 이산 시간 다이나믹 모델을 사용했고 (5)의 목적함수는 $\frac{1}{T} \sum_{k=0}^T C(\pi_u(k))$ 로 근사화 한다. 여기서 $\pi_u(k)$ 는 제어 입력 $u(k)$ 가 주어지면 이산시간 k 에서의 이산 다이나믹 모델의 해가 된다. 이산시간 문제에서는 (5)의 제약은 $\pi_u(k) \in \chi_{\text{free}}$ for all $k = 1, \dots, T$ 로 근사화 된다.

3.2 비용지도(Cost Map)

로봇들이 할당된 임무를 수행하는 공간 χ 를 생각해 보자. 온도, 습도, 화학 물질의 밀집도, 신호 강도 그리고 은밀도 등과 같은 환경의 파라미터들을 나타내는 비용지도가 공간 χ 에 정의되어 있다고 가정하자. 각각의 모든 장소에서 환경의 파라미터를 구할 수 없기 때문에 측정할 수 없는 장소에서의 환경 파라미터를 추정하기 위해서 비모수적 regression방법인 가우시안 프로세스 regression을 사용한다. 가우시안 프로세스 regression은 비정상 geostatistical 데이터 분석^[15], 비선형 regression^[16], 무선 신호강도 추정^[17], 실내 온도 필드 모델링^[18], 그리고 지형 지도제작^[19]과 같은 복잡한 물리적 현상을 모델링하기 위해 널리 사용되는 비모수적 regression 기술이다. 모수적 regression방법과 비교했을 때, 비모수적 regression 방법은 물리적 현상을 더 잘 표현하고 일반화 가능성이 더 높기 때문에 복잡한 환경을 모델링하는데 더 적합하다. 특히 가우시안 프로세스는 또 다른 비모수적 regression방법인 서포트 벡터 머신(SVM)과는 다르게 추정값의 불확실성을 제공해 주기 때문에 모바일 센서네트워크에 더 적합하다고 볼 수 있다. 그 예로 [13]에서는 가우시안 프로세스를 사용하여 공간의 불확실성을 최소로 하는 곳으로 이동하는 다중 에이전트 시스템을 제안하였다.

비용함수 C 로 정의하는 환경 파라미터가 가우시안 프로세스이고 공간 χ 에서 N 개의 데이터를 측정했다고 가정해 보자. 데이터가 측정된 장소들을 x_1, x_2, \dots, x_N , 그 장소들에서의 측정값을 y_1, y_2, \dots, y_N 이라고 하고 $Y = [y_1, y_2, \dots, y_N]^T$ 이라고 정의해 보자. 그럼 (1)을 사용하여 임의의 장소 $x_* \in \chi$ 에서의 비용함수의 추정값은 $C(x_*) = K_*^T(K + \sigma_w^2 I)^{-1}Y$ 와 같다. 그 결과 비용지도는 연속적인 공간 χ 에서 정의된다. 그렇기 때문에 우리는 무한차원의 해상도를 갖는 비용지도를 얻을 수 있으며 이러한 사실은 이산적인 공간에서 비용함수를 정의했던 기존의 방법들과는 다르다고 볼 수 있다. 비용함수를 추정하기에 앞서 측정한 데이터를 이용하여 커널함수와 측정모델의 분산에서 사용되어지는 적절한 파라미터들을 먼저 추정해야한다는 것에 주의해야 한다.

3.3 비용 인지 RRT 알고리즘

우리는 이제 RRT의 트리를 확장해 나갈 때 비용지도에 따라 모션 세그먼트를 결정하는 비용 인지 RRT 알고리즘을 설명한다. 알고리즘의 진행과정은 표 1에 나타난 것처럼 기존의 RRT 진행과정과 유사하다. 그러나 x_{rand} 는 기각표본추출법을 사용하여 비용지도에 따라 선택되어 진다. 기각표본추출법을 비용 지도에 적용하게 되면 높은 비용을 갖는 지역보다는 낮은 비용을 갖는 지역에서 더 많은 샘플의 선택이 가능하게 된다. 선택한 지역의 비용의 역 ($C(x)^{-1}$)을 취한 값과 균등 분포에서 임의로 선택한 값을 비교하여 $C(x)^{-1}$ 가 더 큰 값을 가지면 그 지역에서의 샘플을 선택하기 때문이다. 기각표본추출법은 직접적으로 추출하기 어려운 다양한 분포로부터의 표본추출을 가능하게 하는 강력한 도구이다. 본 논문에서처럼 비용 지도와 같은 분포를 가지고 있다면 우리는 상태 공간상에서의 분포를 완벽하게 구현할 수가 없기 때문에 기각표본추출법(rejection sampling)을 사용하여 표본을 추출하기 쉬운 분포로 바꾼다. 즉 다시 말하면, 균등분포로부터 임의의 한 점 x 를 선택하고 그 점에서의 비용 $C(x)$ 에 따라 샘플링한 점을 선택할지 결정한다. 트리 T 는 처음에 오직 시작점만으로 구성되어 있다. 미리 정의된 거리 메트릭 D 에 따라 T 에 존재하는 노드 중 x_{rand} 와 가장 가까운 점 x_{near} 를 찾으면 트리 T 를 확장하기 위해 비용지도에 따라 모션 세그먼트를 결정한다. 모션 세그먼트는 최소 비용의 경로 계획 문제 (5)로부터 결

표 1. 비용 인지 알고리즘

<p>Input :</p> <ol style="list-style-type: none"> 1) 시작점 x_0, 목적지 x_{goal} 2) 총 경로의 수 N_t 3) 엘리트 계수 η_a <p>Output : 시작점부터 목적지까지의 최소 비용의 경로</p> <ol style="list-style-type: none"> 1) 기각추출표본법을 사용하여 상태공간에서 샘플 포인트 x_{rand}를 선택한다. 2) 거리 메트릭 D에 따라 x_{rand}와 가장 가까운 트리 T 내의 한 점을 찾는다. 3) N_t개의 경로에 대해 $C_T(\pi_u(k))$를 계산하여 적은 값을 갖는 η_a개의 경로를 찾는다. 4) η_a개의 경로 중 $\frac{1}{T} \sum_{k=0}^T C(\pi_u(k))$를 계산하여 가장 적은 값을 갖는 경로를 찾는다. 5) 트리 T가 목적지에 다다를 때까지 1-4를 반복한다.

정된다. 모션 세그먼트의 결정 과정은 다음과 같다. 우리는 먼저 엘리트 계수 η_a 를 정의한다. 알고리즘은 로봇의 다이내믹에 각각의 제어 입력 $u(k)$ 를 적용하여 x_{near} 부터 x_{rand} 까지 총 N_t 개의 경로를 찾고 전체 경로 중에서 작은 $C_T(\pi_u(k))$ 를 갖는 η_a 개의 경로를 선택한다. 그 후에 선택된 η_a 개의 경로 중 가장 작은 $\frac{1}{T} \sum_{k=0}^T C(\pi_u(k))$ 값을 갖는 경로를 선택한다. 이렇게 두 단계의 필터링을 거쳐 항상 목적지에 도달하는 (5)의 해인 최적의 경로를 찾을 수 있다. RRT의 트리가 목적지에 도달하면 알고리즘은 종료하고 목적지부터 시작점까지 재귀적으로 트리를 검색하여 최종 경로를 찾는다.

본 논문에서 제안한 알고리즘은 기존 RRT와 전체적인 구조를 공유하기 때문에 국소최저지에 빠지지 않고 목적지에 도달할 수 있다. 반면에, 경로를 따라 움직일 때 발생하는 비용을 고려하지 않은 기존의 RRT와는 다르게 트리를 확장할 때 비용 지도를 고려하여 모션 세그먼트를 결정하므로 경로의 질도 개선시킬 수가 있다.

4. 모의실험

4.1 상태 공간

시물레이션에서 로봇의 상태 공간 χ 를 x 축, y 축의 2차원 공간 ($\chi \subset R^2$)으로 설정하였고 상태 공간의 각 축의 경계는 [-45m, 45m]로 설정하였다. 상태 공간은

3절 A에서 언급한 것처럼 χ_{free}, χ_{obs} 이렇게 두 개의 부분공간으로 구성되어 있다. 부분공간 χ_{obs} 는 n 개의 장애물, 즉 $O_1, O_2, \dots, O_n \subset \chi_{obs}$ 를 포함하고 있고 또한 액추에이터의 한계 때문에 로봇이 장애물과 충돌할 가능성이 있는 지역도 포함하고 있다. 우리는 이 지역을 [20]에서의 ICS(Inevitable Collision State)와 유사한 준장애물 지역이라 부르고, 준장애물 지역은 각각의 장애물에서부터 반경 r 에 이르는 지역을 포함한다. 본 논문에서 준장애물 지역은 거리의 함수인 $\Phi(d) \in R$ 에 따라 값을 갖도록 설정한다.

$$\Phi(d) = \begin{cases} 0 & \text{if } d > r, \\ 1 & \text{if } d = 0, \\ \frac{1}{1 + \exp(-v(d - \frac{r}{2}))} & \text{otherwise} \end{cases} \quad (6)$$

다시 말해서, 그림 1.(a)에서 나타나듯이 χ_{free} 지역





그림 1. (a)는 함수 $\Phi(d)$ 의 결과. (b)는 함수 $\Phi(d)$ 를 적용하여 얻은 비용 지도

과 χ_{obs} 지역은 각각 0과 1의 값을 갖고 준 장애물 지역은 $\Phi(d)$ 에 따른 함수 값을 갖게 된다. 본 논문에서는 각각의 계수 $v=5, r=2$ 를 사용하였다. 상태 공간에서 장애물에 함수 $\Phi(d)$ 를 적용하여 얻은 비용 지도는 그림 1.(b)에 나타나 있다.

4.2 로봇 다이내믹

본 논문에서는 Dubin 차와 같이 두 개의 바퀴를 가진 로봇의 다이내믹 모델을 사용했다. r_x 와 r_y 를 로봇의 x축, y축의 위치라고 하고 θ 를 로봇의 진행 방향이라고 정의하자. 또한 $v(t)$ 를 로봇의 병진 속도, $u(t)$ 를 로봇의 각속도라고 하면, 전체적인 로봇의 다이내믹은 다음과 같다.

$$\begin{aligned} \dot{r}_x(t) &= v(t)\cos(\theta(t)) \\ \dot{r}_y(t) &= v(t)\sin(\theta(t)), \\ \dot{\theta}(t) &= u(t) \end{aligned} \quad (7)$$

본 논문에서는 $v(t)$ 가 상수라고 가정했다. 그러나 이러한 연속 시간상의 다이내믹 모델은 다루기 어렵기 때문에 우리는 다음과 같이 이산 시간상의 다이내믹 모델로 변환한다.

$$\begin{aligned} r_x[k+1] &= \begin{cases} \text{if } u[k] \neq 0, \\ r_x[k] + \frac{2v}{u[k]} \sin\left(\frac{u[k]t_s}{2}\right) \cos\left(\theta[k] + \frac{u[k]t_s}{2}\right) \\ \text{otherwise,} \\ r_x[k] + vt_s \cos(\theta[k]) \end{cases} \\ r_y[k+1] &= \begin{cases} \text{if } u[k] \neq 0, \\ r_y[k] + \frac{2v}{u[k]} \sin\left(\frac{u[k]t_s}{2}\right) \sin\left(\theta[k] + \frac{u[k]t_s}{2}\right) \\ \text{otherwise,} \\ r_y[k] + vt_s \sin(\theta[k]) \end{cases} \\ \theta[k+1] &= \theta[k] + u[k]t_s \end{aligned} \quad (8)$$

여기서 $-\tan(\frac{\pi}{2}) < u < \tan(\frac{\pi}{2})$, t_s 는 샘플링 주기를 나타내며, 시뮬레이션에서는 $t_s = 0.1$ 로 설정했다.

4.3 거리 메트릭

두 상태 x_1 과 x_2 사이의 거리의 척도를 결정하기 위해서 다음과 같이 경험적으로 메트릭 함수 $D: R^2 \rightarrow R$ 를 정의했다.

$$D(x_1, x_2) = w_p \|x_1 - x_2\|^2 + w_a |\theta_1 - \theta_2| \quad (9)$$

단 w_p 와 w_a 는 각각 위치와 방향에 대한 양의 가중치를 나타낸다. $\|x_1 - x_2\|^2$ 가 특정 한계 값보다 작으면 가중치 w_a 를 증가시켰고 w_p 를 1로 고정시켰다.

4.4 결과

본 논문에서 제안하는 알고리즘(CA-RRT)의 성능을 확인하기 위해 경로의 비용을 고려하여 기존 RRT (B-RRT) 알고리즘과 비교했다. 커널 함수 (2)를 갖는 가우시안 프로세스 (1)을 사용하여 6개의 각각 다른 비용지도를 갖는 시나리오를 만들었다. 본 논문에서는 $\sigma_f^2 = 1.0$, $\sigma_l^2 = 5.0$ 을 사용했다. 그림 3은 시뮬레이션에 사용된 시나리오를 보여준다. 각 시나리오는 $x \in [-45, 45]^2$ 에 대한 비용지도 $C(x)$ 로 구성되어 있고 그림에서 진한 갈색은 장애물을 나타낸다. 본 논문에서 사용된 비용 지도를 모델링하기 위해 가우시안 프로세스 MATLAB toolbox^[11]를 사용했다. 그 예가 그림 2에 나타난다.

모의실험을 위해 $(-\frac{\pi}{2} + 0.01)$ 부터 $(\frac{\pi}{2} - 0.01)$ 까지 0.01의 간격으로 총 99개의 제어 입력을 사용했다. 종료비용은 다음과 같이 정의하였다.

$$C_T(x_T) = \beta \|x_T - x_{\text{goal}}\|^2 \quad (10)$$




그림 3. 시나리오의 예

여기서 β 는 양수이고 $C_T(x_T)$ 를 계산할 때 로봇의 진행방향은 고려하지 않았다.

각각의 비용 지도에 대해서 10번의 독립적인 시행을 하였고 각각의 시행은 600초 동안 진행되었다. 이 시간은 각각의 알고리즘의 최종 종료시한을 의미한다. 또한 시뮬레이션의 진행 시간을 단축하기 위해 RRT 트리의 확장 횟수를 500번으로 제한했다. 즉, 시작점만을 포함한 RRT 트리에 500번의 모션 세그먼트를 연결하면 최종 경로의 목적지 도달 여부에 상관없이 알고리즘은 종료하고 최종 종료시한인 600초 내에서 시작점부터 다시 시작한다.

각 시나리오에서 찾은 최소 비용의 경로가 그림 2에서 나타난다. 두꺼운 검정색 라인은 장애물을 포함한 준 장애물 지역을 나타낸다. 본 논문에서는 준 장애물 지역에서 랜덤 포인트가 선택되지 않고 경로 또한 준 장애물 지역을 통과할 수 없다. 필드의 색은 비용 지도를 나타낸다. 비용 지도는 다른 색깔의 경계선으로 나타난다. 높은 비용의 지역은 빨간색으로 나타나고 낮은 비용의 지역은 파란색으로 나타난다. 그림 2.(a)-2.(c)에서 표시된 검정 원은 시작점과 목적지를 나타낸

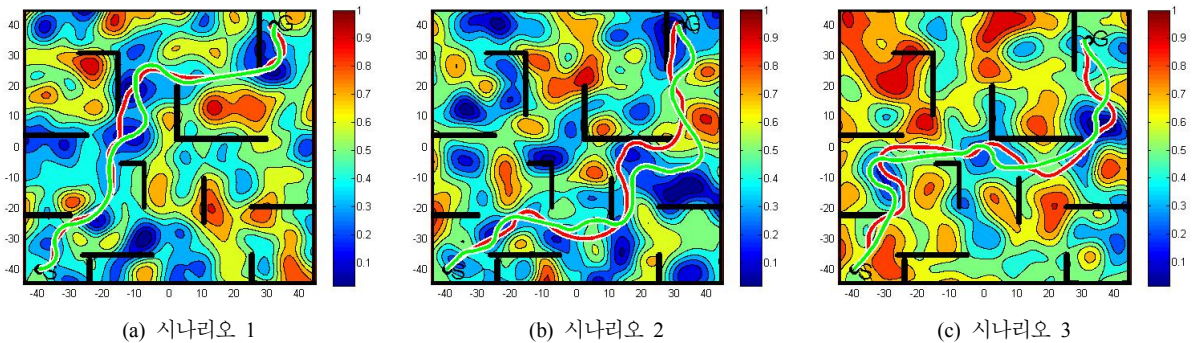


그림 2. 모의실험에 사용된 시나리오들과 각 알고리즘에서 찾은 최소 비용 경로.

다. 빨간색과 녹색 선은 각각 CA-RRT, B-RRT로부터 찾은 경로를 나타낸다.

각 알고리즘의 수행시간이 다르기 때문에 본 논문에서는 종료 시한을 설정했고 각 종료 시한 내에서 알고리즘 수행을 반복했다. 각 알고리즘의 최소 비용 경로는 최종 종료 시한까지 알고리즘을 여러 번 수행하여 그 중 가장 적은 비용을 갖는 경로로 선택했다. 본 논문에서는 200초부터 최종 종료 시한 600초까지 100초 간격으로 5개의 종료 시한을 설정했다. 그림 4는 각 알고리즘에서 10번의 시행에 대한 평균 비용과 함께 표준 편차를 나타내는 에러 바를 보여준다. CA-RRT와 B-RRT의 결과가 각각 빨간색과 파란색으로 나타난다. 평균 비용과 비용의 분산은 종료 시한이 늘어날수록 감소하는 경향을 보인다. 하지만 그림 4.(a)의 B-RRT에서처럼 종료 시한 300초부터 400초에서 평균과 분산이 증가한 사실을 확인할 수 있다. 그 이유는 각 알고리즘의 수행 시간이 정해져 있지 않기 때문이다. 즉, B-RRT의 어떤 시행은 300초 전에 완성되지 않고 400초 전에 높은 비용을 갖는 경로를 찾았다는 것을 의미한다.

모든 시나리오에 대해서 제안한 알고리즘이 더 적은 비용의 경로를 찾았다는 것을 확인할 수 있다. 각

표 2. 비용 인지 알고리즘

종료 시한	200 초	300 초	400 초	500 초	600 초
CA-RRT	0.067	0.065	0.062	0.060	0.0579
B-RRT	0.1	0.091	0.089	0.088	0.0865

알고리즘의 평균 경로 비용은 표 2에 나타나 있다. 역시 제안한 알고리즘의 성능이 모든 종료 시한에 대해서 더 좋다는 것을 보여준다.

본 논문은 또한 앞서 모의 실험한 시나리오들을 바탕으로 CA-RRT에 기각표본추출법을 사용하여 모의 실험을 수행했다. 그림 5는 기각표본추출법과 균등분포를 사용했을 때의 경로의 평균 비용을 나타낸다. 그림 4와 마찬가지로 샘플링 방식에 따라 10번의 시행에 대한 평균 비용과 함께 표준 편차를 나타내는 에러 바를 보여준다. 기각표본추출법과 균등분포를 사용했을 때의 결과가 각각 빨간색과 녹색으로 나타난다. 모든 경우에 기각표본추출법을 사용했을 때 균등분포를 사용했을 때와 유사하거나 더 적은 비용의 경로를 찾는 것을 확인했다. 모든 시나리오에 대한 평균 비용이 표 3에 나타나 있다. 역시 기각표본추출법을 사용했을 경우 성능이 모든 종료 시한에 대해서 더 좋다는 것을 보여준다.

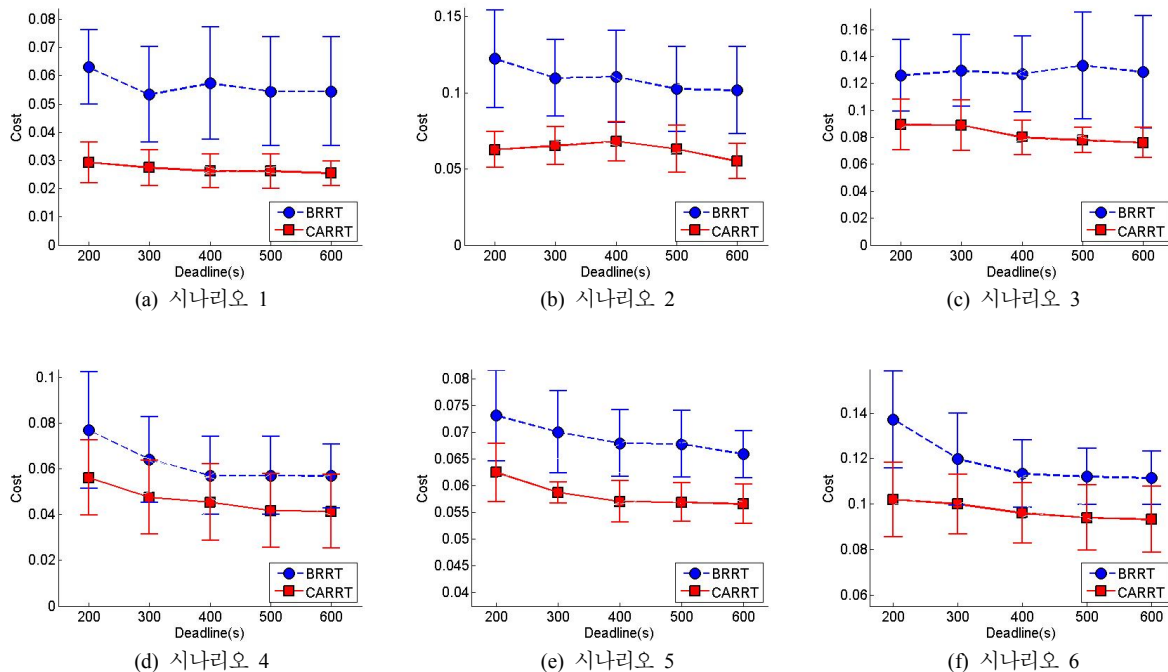


그림 4. 종료 시한의 함수로써 평균 경로 비용.

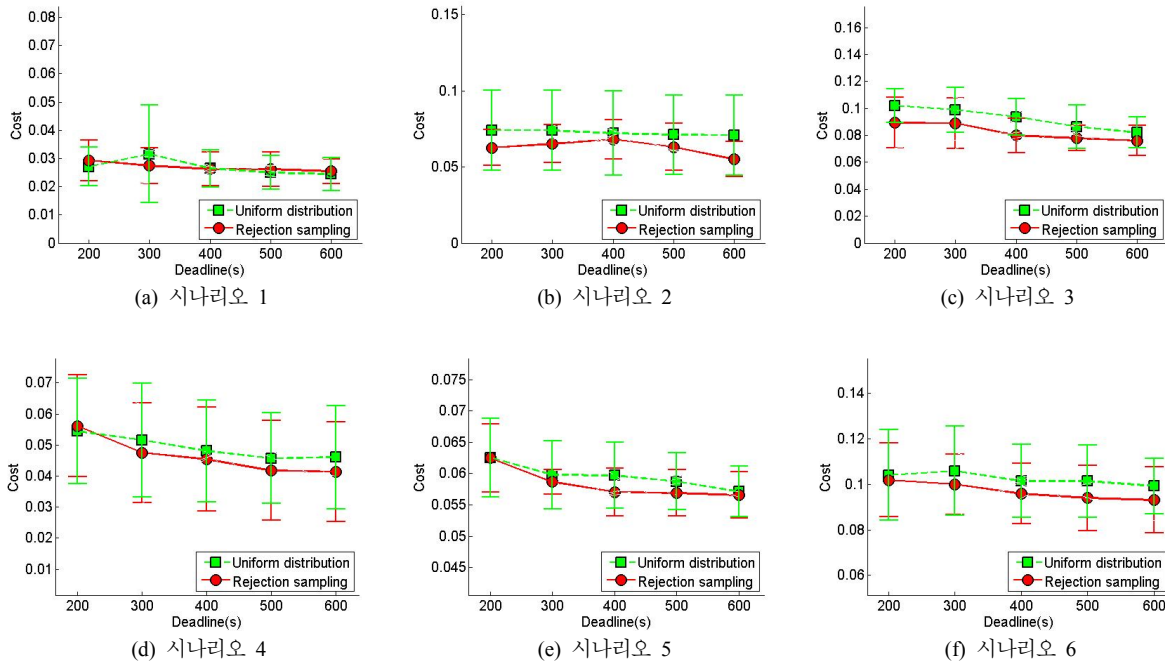


그림 5. CA-RRT에 기각표본추출법과 균등 분포를 사용했을 때 경로의 평균 비용.

표 3. 다른 종료 시한에서 기각표본추출법과 균등분포를 사용했을 때 모든 시나리오의 평균 비용

종료 시한	200 초	300 초	400 초	500 초	600 초
기각표본추출법	0.067	0.065	0.062	0.060	0.058
균등분포	0.071	0.070	0.067	0.065	0.063

5. 결론

본 논문에서는 비용 인지 경로 계획 알고리즘을 제안하였다. 상태 공간에 대한 비용 지도가 이용 가능하면 제안하는 알고리즘은 최소의 비용을 갖는 로봇의 경로를 찾는다. RRT 트리를 키워나갈 때 비용지도를 고려하여 모션 세그먼트를 결정하므로 기존 RRT를 확장한 알고리즘이다. 모의실험을 통해서 제안하는 알고리즘과 기존의 RRT를 비교하였고 기존 RRT에 비해 성능이 뛰어나다는 것을 보여 주었다. RRT의 장점인 국소최저치에 빠지지 않고 확률적으로 완전하게 목적지에 도달하게 하면서 동시에 비용 지도에 따라 모션 세그먼트를 결정하여 경로의 질을 개선할 수 있다. 우리는 제안한 알고리즘이 경로 계획 문제에 있어 로봇틱스 분야의 많은 문제들에 적용될 수 있기를 기

대한다.

참고문헌

- [1] D. Kim and D. Kang, "Optimal Path Planning of Mobile Robot for Multiple Moving Obstacles," The Journal of Korea Robotics Society, Vol.2, pp.183-190, 2007.
- [2] J. Beak and C. Lee, "An Analysis on the Influential Factors to Set the Path Planning Algorithm for Unmanned Ground Vehicle in Combat Environment," The Journal of Korea Robotics Society, Vol.4, pp.233-242, Aug. 2009.
- [3] Y. Chang and Y. Yamamoto, "Path planning of wheeled mobile robot with simultaneous free space locating capability," Intelligent Service Robotics, Vol.2, pp.9-22, 2009.
- [4] S. M. LaValle and J. J. Kuffner, "Randomized kinodynamic planning," The International Journal of Robotics Research, Vol.20, pp.378-400, May 2001.
- [5] S. Rodriguez, X. Tang, J. Lien, and N. M. Amato, "An obstacle-based rapidly-exploring

- random tree,” in IEEE International Conference on Robotics and Automation, May 2006.
- [6] N. A. Melchior and R. Simmons, “Particle RRT for path planning with uncertainty,” in IEEE International Conference on Robotics and Automation, Roma, Apr. 2007.
- [7] J. V. der Berg, P. Abbeel, and K. Goldberg, “LPG-MP: Optimized path planning for robots with motion uncertainty and imperfect state information,” The International Journal of Robotics Research, Vol.30, pp.895-913, Jun. 2011.
- [8] C. Fulgenzi, C. Tay, A. Spalanzani, and C. Laugier, “Probabilistic navigation in dynamic environment using rapidly-exploring random trees and gaussian processes,” in Intelligent Robots and Systems, Nice, Sep. 2008, pp.1056-1062.
- [9] M. Zucker, J. Kuffner, and M. Branicky, “Multipartite rrt for rapid replanning in dynamic environments,” in IEEE International Conference on Robotics and Automation, Apr. 2007.
- [10] Y. Kuwata, G. A. Fiore, J. Teo, E. Frazzoli, and J. P. How, “Motion planning for urban driving using rrt,” in IEEE/RSJ Intl. Conference on Intelligent Robotics and Systems, Sep. 2008.
- [11] C. Urmson and R. Simmons, “Approaches for heuristically biasing rrt growth,” in IEEE/RSJ Intl. Conference on Intelligent Robotics and Systems, Oct. 2003.
- [12] D. Ferguson and A. Stentz, “Cost based planning with rrt in outdoor environment,” in IEEE/RSJ Intl. Conference on Intelligent Robotics and Systems, Oct. 2006.
- [13] J. Choi, J. Lee, and S. Oh, “Swarm intelligence for achieving the global maximum using spatio-temporal gaussian processes,” in American Control Conference, Seattle, WA, Jun. 2008, pp.135-140.
- [14] C. E. Rasmussen and C. K. Williams, Eds., Gaussian Processes for Machine Learning. Cambridge: The MIT Press, 2006.
- [15] N. Cressie, “Kriging nonstationary data,” Journal of the American Statistical Association, Vol.81, pp.625-634, Nov. 1986.
- [16] M. N. Gibbs and D. J. C. MacKay, “Efficient implementation of gaussian processes,” Cambridge, Tech. Rep. 1997.
- [17] B. Ferris, D. Fox, and N. Lawrence, “WiFi-SLAM using Gaussian process latent variable models,” in Proc. of the 20th International Joint Conference on Artificial Intelligence, 2007.
- [18] A. Krause, A. Singh, and C. Guestrin, “Near-optimal sensor placements in gaussian processes: Theory, efficient algorithms and empirical studies,” Journal of Machine Learning Research, Vol.9, pp.235-284, Feb. 2008.
- [19] H. Durrant-Whyte, F. Ramos, E. Nettleton, A. Blair, and S. Vasudevan, “Gaussian process modeling of large scale terrain,” in Proc. of the 2009 IEEE International Conference on Robotics and Automation, 2009.
- [20] S. Petti and T. Fraichard, “Safe motion planning in dynamic environments,” in IEEE-RSJ Int. Conf. on Intelligent Robots and Systems, Aug. 2005.
- [21] C. M. Bishop, “Pattern Recognition and Machine Learning,” Springer, New York, 2006



서 정 훈

2009 광운대 전기공학과(공학사)

2011 서울대 전기공학부 석사

2011~현재 서울대 전기·정보공학부 박사과정

관심분야: path planning, mobile sensor networks



오 성 회

- 1995 UC Berkeley EECS
학사
- 2003 UC Berkeley EECS
석사
- 2006 UC Berkeley EECS
박사

1995~1998 Design Engineer, Intel Corp.

1998~2000 Senior Engineer, Synopsys

2007~2009 Univ. of California, Merced 조교수

2009~현재 서울대 전기·정보공학부 조교수

관심분야 : cyber-physical systems, wireless sensor
networks, robotics, machine learning