

이동 로봇을 위한 온라인 동시 지도작성 및 자가 위치 추적 알고리즘

김병주¹

¹영산대학교 컴퓨터공학과

접수 2011년 7월 11일, 수정 2011년 8월 16일, 게재확정 2011년 9월 29일

요약

본 연구에서는 실제 환경에 적용 가능한 지능형 자율 이동 방법을 개발하기 위해 위치정보를 사용하지 않고 지도 작성이 가능한 지능형 이동 알고리즘을 제안한다. 제안한 알고리즘은 온라인으로 동작하면서 위치 정보를 사용하지 않고 지도 작성이 가능 할 뿐 아니라 현실 세계에 적용 가능하기 위해 많은 계산량을 요구하지도 않는다. 이는 이동 로봇의 실세계 주행과 같은 대용량의 이미지 처리가 필요한 경우에는 매우 유용하게 사용될 수 있다. 토이 자료와 대용량 자료에 대해 제안한 알고리즘을 적용한 결과 기존의 방법에 비해 적은 메모리와 새로운 입력에 대해 고유공간을 새로 계산하지 않아도 되어 로봇의 현실세계의 주행에도 문제가 없는 것으로 판단되었다.

주요용어: 동시 지도 작성 및 자가 위치 추적 기법, 위치 정보, 지도 작성, 지능형 주행 알고리즘.

1. 서론

지능형 로봇산업은 가까운 미래에 세계적으로 고도성장이 예견되는 분야이다. 처음의 로봇은 하나의 로봇 내에 모든 기능과 센서 기능이 탑재된 형태였으며 이러한 로봇은 한정된 기능밖에 수행하지 못하는 단점이 있다. 이를 극복하기 위해 최근에 고성능 서버를 통해 로봇의 기능과 능력을 외부로 분산시켜 이를 통해 언제 어디서나 나와 함께 하면서 나에게 필요한 서비스를 제공하는 로봇인 URC (Ubiquitous Robotic Companion)이 등장하게 되었다. URC 구현을 위해 다양한 기술이 필요하지만 그 중에서 물리적 행동을 실현하기 위한 지능형 주행 기술은 매우 중요한 기술이다. 지능형 주행 기술은 1980년대 이후 학계를 중심으로 활발히 연구되어 왔다. 그러나 그 이후의 연구에도 불구하고 현재의 기술 수준은 사람에게 비유하자면 ‘어두운 곳에서 두 팔을 뻗어 주변의 거리를 인식하고, 걸음수를 세어가며 이동한 거리를 예측해야 하는 정도’ 밖에 되지 않는다. 따라서 현재의 지능형 주행 기술은 로봇에 직접 적용할 수 있는 수준은 아니다.

로봇의 지능형 이동 기술에 필요한 것은 로봇 자신이 현재 어디에 있으며, 어느 곳이 다음에 이동해야 하는 장소이며, 그 장소로 가기위해서는 어떻게 가야하는 지를 결정하는 것이다. 지능형 이동 로봇에게 이러한 기초 기능을 수행하는 것, 즉 주변 환경에 대해서 지도를 작성하고 (map building) 동시에 그 안에서 로봇 자신의 위치를 파악하는 것이 지능형 이동에 있어서 가장 필요한 요소이다. 또한 제작된 지도를 이동 중에도 계속 수정 및 개선해 나가는 것도 매우 중요한 기능이다. 야외용 로봇은 GPS (Global Positioning System)를 이용하고 실내에서는 GPS 신호를 수신하여 증폭기를 통하여 실내에 송신하거

¹ (626-847) 경남 양산시 웅상읍 주남동 산 150번지, 영산대학교 컴퓨터공학과, 교수.
E-mail: bjkim@ysu.ac.kr

나 비전 시스템들을 이용한다. 이렇게 파악한 자신의 위치와 사전정보 (a prior knowledge) 등을 이용하여 탐지 되는 주변 환경의 위치를 파악하는 기법이 사용되어져 왔다. 이러한 기법은 대부분 로봇이 이동하는 환경에 대한 사전 정보를 요구하고 있어, 자신의 위치를 파악하고 있다고 가정하더라도 사전 정보가 없는 지역에서는 사용이 제한되는 단점을 가지고 있다. 이러한 문제를 해결하기 위해 동시 지도 작성 및 자가 위치 추적 기법 (simultaneous localization and mapping method: SLAM, 이하 SLAM으로 칭함)이 제안되었다. SLAM 방법은 새로운 물체가 탐지 될 때 마다 새로이 탐지된 물체를 시스템 상태 벡터에 추가 하게 되어 시간이 지남에 따라 시스템 상태 벡터가 매우 커지게 되어 이로 인하여 많은 계산 시간이 소요되게 되는 단점을 가지고 있다 (Newman, 1999). 이러한 계산소요 시간 증가는 SLAM 기법을 실제 로봇 적용 시 실시간 사용의 어려움을 가져올 수 있기 때문에 계산소요 시간을 효율적으로 줄이기 위한 여러 가지 노력이 많은 연구자들에 의해 시도되어 왔다. 이러한 계산 시간 및 성능에 대한 요구는 본질적으로 SLAM 기법을 실제 환경에 적용할 때 언제나 야기되는 문제이다. 따라서 이동 로봇의 지도 작성 방법에 대한 다른 접근법이 필요하다. 본 논문에서는 아직 국내에서 연구가 이루어지지 않은 위치정보를 사용하지 않고 지도 작성이 가능한 알고리즘을 제안 한다.

2. 선행 연구 및 문제점

2.1. 선행연구

선행 연구 분석에서는 먼저 SLAM 기법에 대한 성능 향상 기법과, 계산상의 효율성을 위해 위치 정보를 사용하지 않고 지도 작성 하는 방법에 대해 분석한다. 그리고 SLAM을 구현 하기위해 차원 축소 방법으로 많이 사용되는 주성분분석 방법의 문제점인 일괄처리 방식, 학습 자료간의 선형 관계가 있는 경우에만 적용 가능한 문제점들을 해결하기 위한 기존의 연구를 분석한다.

2.1.1. SLAM 기법

지능형 주행 기술에 대한 최근의 연구는 대부분 SLAM 기법에 대한 계산 시간 및 성능 향상 연구에 집중되어 있다. SLAM 기법을 구현하기 위해서는 로봇과 물체의 위치를 동시에 추정하여야 하는데 이를 위하여 칼만 필터 (Kalman filter)가 주로 사용되어져 왔다. 비선형 시스템 상태 방정식을 가진 시스템에 대해서는 시스템 방정식을 테일러 급수 (Taylor series)를 이용하여 선형화하여 사용하는 확장 칼만 필터 (extended Kalman filter: EKF, 이하 EKF로 칭함)가 주로 사용 되어져 왔다 (Castellanos 등, 1999). 확장 칼만 필터를 사용하기 위해서는 비선형 시스템일지라도 부분 선형성을 가진다는 가정을 만족하여야 하는데 지능형 이동 로봇의 운동 방정식이 속도와 선수각의 곱으로 표시되는 비선형 방정식이기 때문에 부분 선형성에 대한 가정을 충족시키지 못할 가능성이 있다. EKF의 비선형성에 대한 약점을 극복하고자 여러 대안들이 연구되어져 왔다 (Wen과 Durrant, 1991; Simon과 Chia, 2002; De Geeter 등, 1997; Julier와 Uhlmann, 1997). 이 중 무향 칼만 필터 (unscented Kalman filter: UKF, 이하 UKF로 칭함)는 비선형 시스템에 대해서 자코비안을 이용한 선형화 과정을 거치지 않고 비선형 시스템 상태 방정식을 그대로 이용함으로써 시스템 상태 방정식의 비선형성에 의해서 발생하는 오차 문제를 방지할 수 있다. 이러한 비선형성에 대한 강인함으로 인해 최근 SLAM 기법에 UKF 적용이 활발히 연구되고 있다 (Andrade 등, 2005; Langelaan와 Rock, 2005; Martinez과 Castellanos, 2005; Lee와 Kim, 2006). 그러나 UKF를 SLAM에 적용할 경우 비선형성을 극복하기 위해 수행하는 시그마 포인트 (김기열, 2010)를 선택하는 작업으로 인하여 EKF에 비해 많은 계산 시간이 소요되어 이 방법을 실제 지능형 이동 로봇에 적용하기에는 문제가 있다. 이러한 문제를 해결하기 위해 많은 연구가 이루어지고 있으며 이를 정리하면 다음과 같다.

압축필터 (compress filter)를 이용한 기법은 이미 탐지되어 시스템 상태 벡터를 구성하고 있는 물체에 대해 탐지가 되지 않을 경우 당해 물체에 대한 지도 작성 및 갱신 작업을 연기하여 계산량에 대한 부담을 줄이는 방법이다. 하지만 이 방법은 재 탐지가 되는 순간 연기된 작업을 모두 수행하여야 하기 때문에 많은 계산량이 짧은 시간에 요구되는 단점이 있다. 희소확장 정보필터 (sparse extended information filter)를 이용한 기법은 칼만 필터의 공분산 행렬을 이용하는 대신 정보필터 (information filter)와 정보 필터의 희소성 (sparseness)을 SLAM에 적용함으로써 예측과 갱신 작업을 매우 효율적으로 수행할 수 있는 장점이 있으나 실제 적용을 위해서는 희소성에 대한 가정에 대한 검증이 필요하여 현실적이지 못하다 (Guivant와 Nebot, 2001; Thrun 등, 2002). 순차 지도결합 (sequential map joining) 기법은 로봇이 이동하는 순서에 따라 작성되는 부분 지도들을 합쳐서 전체 지도를 구성하며, 부분 지도 내에 포함되는 지도의 개수가 적기 때문에 $O(n^2)$ 의 계산량이 필요하지만 지도가 일단 합쳐지면 다시 나누는 것이 매우 어렵기 때문에 실제 적용에 문제가 있다 (Tardos 등, 2002; Williams 등, 2002). 분리 (decoupled) SLAM 기법은 작성되어진 전역 원점 (global reference)을 가지고 있는 여러 개의 부분 지도 (submap)로 나누어서 각 지도에 대한 SLAM 적용을 통하여 $O(1)$ 의 계산 복잡도가 요구되는 장점이 있지만 위치 추정치에 대한 수렴성 (convergence)과 일관성 (consistency)을 획득하기 위한 가정에 대한 신중한 검토가 필요하여 실제 환경에 적용하기에는 어려움이 있다 (Leonard와 Feder, 2001).

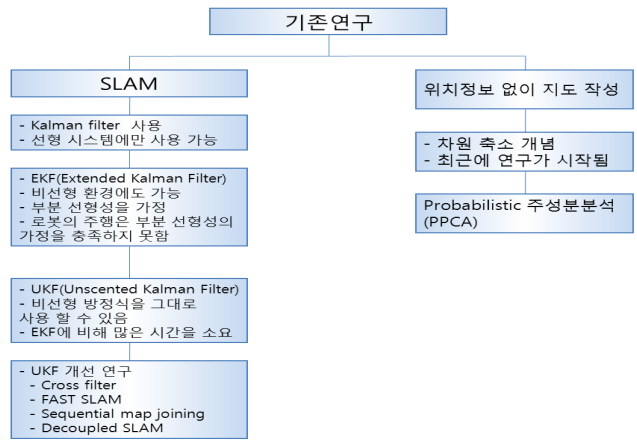


그림 2.1 지능형 자동 주행에 대한 기존 연구

2.1.2. 위치 정보를 사용하지 않고 지도 작성 하는 방법

이동 로봇의 자율 이동을 위한 또 다른 접근 방법으로는 자기 위치 (locality) 추정 없이 지도를 작성 하는 접근 방법이다 (Yairi, 2007). 확률적 주성분분석 (Probabilistic PCA; Brunskill과 Roy, 2005)과 주성분 분석 방법을 이용한 접근 방법 (Pierced와 Kuipers, 1994) 등이 이에 해당한다. 이 방법은 이동 로봇에서 지도 작성 과정은 3차원 공간상의 물체를 특징 공간상의 2차원의 좌표공간으로 변환시키는 과정으로 볼 수 있으므로 차원 축소 개념으로 접근하였다. 이 방법은 실제 환경에 적용하기에 좋으나 온라인으로 동작하는 것이 아닌 일괄처리 (batch way) 방식으로 동작하는 문제점이 있다.

주성분 분석 방법을 기반으로 하는 SLAM 알고리즘은 좋은 접근 방법이지만 하나 주성분 분석 방법은 다음과 같은 단점이 있다. 첫째 주성분분석은 일괄처리 방식으로 동작한다. 이는 로봇의 주행과 같이

이미지 자료를 기반으로 하는 경우 이미지의 차원이 크기 때문에 심각한 문제를 발생시킨다. 두 번째 문제는 새로운 이미지가 추가 되면 고유공간 (eigenspace)을 다시 계산 하여야 한다. 세 번째 문제점은 주성분 분석 방법의 적용범위는 학습자료 간의 선형 상관관계 (linear correlation)가 있는 경우로만 국한된다. 이러한 문제점을 해결하기 위한 기존의 연구를 살펴보면 다음과 같다. 일괄처리 방식의 문제점을 해결하기 위해 학습 자료를 순차적으로 받아들이며 이전의 고유공간과 새로이 추가된 학습 자료에 의해 새로운 고유공간을 계산하는 온라인 방식은 크게 두 가지로 나눌 수 있다. 하나는 새로운 고유공간을 계산하는데 있어 평균의 1순을 허용하지 않는 방법이며(Murakami와 Kumar, 1982; Winkler와 Chandrasekaran, 1999) 또 다른 접근 방법은 Hall에 의해 제안된 방법으로 평균의 1순을 허용하는 방법이다 (Hall 등, 1998). 주성분분석에서의 세 번째 문제점인 학습 자료간의 선형관계에만 국한되는 문제에 대한 기존의 연구를 살펴보면 다음과 같다. Tipping과 Bishop (1998)은 선형 주성분분석 기법을 결합한 결합 주성분 분석방법 (Mixture PCA)으로 비선형 문제를 해결하고자 하였다. Scholkopf (1998)는 커널함수 (kernel function)를 이용한 커널 주성분 분석 (kernel PCA: KPCA, 이하 KPCA로 칭함) 방법을 제안하였다. 이는 선형 주성분분석 방법에서와 유사한 방법으로 고유치 (eigenvalue) 문제를 해결함으로써 비선형 특징을 추출한다. 비록 KPCA 방법이 비선형 자료에 대해 특징 추출을 수행할 수 있지만 다음과 같은 단점이 있다. KPCA는 학습 자료의 개수가 N 개 일 때 $N \times N$ 크기의 커널 행렬을 저장해야 할 뿐만 아니라 커널행렬의 고유값을 구해야 한다. 만약 N 값이 큰 경우에는 고유값을 계산하기 위해 많은 양의 메모리가 필요하다. 최근에 이미지가 큰 경우에 대해 KPCA의 문제점을 해결하는 몇몇 시도가 있었다. Rosipal (2001)은 계산상에 있어 단순하고 효율적인 EM (Expectation Maximization) 알고리즘을 KPCA에 적용하는 방법을 제안하였다. 하지만 이 방법도 일괄처리 방식으로 수행되어 커널 행렬을 저장해야 하는 문제점을 해결 하지는 못했다. Scholkopf (1999)에 의해 제안된 축약된 집합 선택 기법 (reduced set selection method)은 KPCA의 메모리 문제를 어느 정도 해결 하였으나 많은 계산량이 요구 되는 단점이 있다. Smola (1999)는 희소 커널 특징 분석 (sparse kernel feature analysis)을 제안하여 KPCA의 계산상의 문제점을 해결하였다. 하지만 이 방법은 커널 행렬을 저장해야 하는 문제점을 해결하지는 못했다.

앞에서 열거한 선형 연구의 문제점을 정리하면 다음과 같다.

① SLAM 기법 : SLAM 기법에 대한 지금까지의 선형 연구를 정리하면 계산 시간 및 성능 향상에 대한 부분적인 성능 향상을 위한 기법들은 많이 제안 되었으나 SLAM 기법에서 요구되는 계산량에 대한 근본적인 개선이 이루어지지 않아 아직까지는 실제 환경에 적용하기에는 어려움이 있다.

② 위치 정보를 사용하지 않고 지도 작성 하는 방법 : 이 방법은 사전 정보가 거의 필요하지 않아 실제 환경에 적용하기에 좋으나 SLAM 기법에 비해 온라인으로 동작하는 것이 아닌 일괄처리 방식으로 동작하는 문제점이 있다. 또한 SLAM 기법에 비해 더 많은 관측치를 필요로 하여 SLAM 기법에 비해 더 많은 계산량을 요구한다.

따라서 온라인으로 동작하면서, 위치 정보를 사용하지 않고 지도 작성이 가능하고, 많은 계산량을 요구하지 않은 자율 이동 로봇의 주행 기법을 개발하는 연구가 필요하다.

3. 온라인 주성분 분석 알고리즘

본 논문에서 접근하는 지도 작성 방법은 위치정보 없이 가능하며 이는 차원 축소 (dimensionality reduction) 개념을 기본으로 하고 있다.

온라인 주성분 분석 방법을 위한 기존의 연구를 살펴보면 다음과 같다. 일괄처리 방식의 문제점을 해결하기 위해 학습 자료를 순차적으로 받아들이며 이전의 고유공간과 새로이 추가된 학습 자료에 의해 새로운 고유공간을 계산하는 온라인 방식은 크게 두 가지로 나눌 수 있다. 하나는 새로운 고유공간을




그림 3.1 위치 정보를 사용하지 않고 지도 작성 하는 방법 아이디어

계산하는데 있어 평균의 갱신을 허용하지 않는 방법이며 또 다른 접근 방법은 Hall에 의해 제안된 방법으로 평균의 갱신을 허용하는 방법이다. Hall은 그의 논문 (Hall 등, 1998)에서 평균을 갱신하는 방법이 고정하는 방법에 비해 분류 문제 에서 우수한 성능을 나타냄을 보였다. 여기서는 Hall에 의해 제안된 온라인 주성분 분석 방법을 간략히 설명한다. 이를 유도하기 위해 먼저 다음을 정의한다. 행렬 $U = [u_j]$, $j = 1, \dots, k$ 는 현재 까지 학습 자료 X_i , $i = 1, \dots, \Lambda$ 에서 구한 고유벡터 집합을 나타내며, λ 는 고유치 행렬 (eigenvalue matrix) Λ 의 대각요소를 내림차순으로 정렬한 것을 나타내며 \bar{x} 는 x 의 평균을 의미한다.

온라인 주성분 분석 방법은 학습자료 x_{N+1} 이 추가 되었을 때 이전 학습 자료에 대한 커널 행렬의 저장 없이 갱신하는 것이다. 먼저 새로운 학습 자료가 추가 되었을 때 갱신된 평균은 식 (3.1)과 같이 구한다.

$$\bar{x}' = \frac{1}{N+1}(N\bar{x} + x_{N+1}) \tag{3.1}$$

식 (3.1) 의해 새로운 평균이 구해지면 추가된 학습 자료에 의해 갱신된 고유 벡터 집합 을 구할 수 있다. 이를 위해서는 이전의 고유벡터를 회전행렬 (rotational matrix)에 적용하여야 하는데 이를 위해 먼저 직교잔차벡터 (orthogonal residual vector)를 구해야 한다. 직교잔차벡터는 식 (3.2) 와 같이 계산된다.

$$\hat{h} = (Ua_{N+1} + \bar{x}) - x_{N+1} \tag{3.2}$$

식 (3.2) 에서 구한 \hat{h} 을 정규화한 것은 식 (3.3)과 같이 표시된다.

$$h_{N+1} = \begin{cases} \frac{h_{N+1}}{|h_{N+1}|_2}, & \text{만약 } |h_{N+1}|_2 > 0 \\ 0, & \text{그 외} \end{cases} \tag{3.3}$$

새로운 고유벡터 U 은 식 (3.3)에 의해 구해진 h_{N+1} 과 이전의 고유벡터 U 에 의해 생성된 행렬을 회전 행렬 R 에 적용하여 구할 수 있으며 식 (3.4)와 같이 구한다.

$$U' = [U, h_{N+1}]R \tag{3.4}$$

여기서 $R \in R^{(k+1) \times (k+1)}$ 크기의 회전행렬 이며 식 (3.5)와 같은 고유공간의 해이다.

$$DR = R\Lambda' \tag{3.5}$$

여기서 Λ' 은 새로운 고유치들의 대각 행렬이다. 행렬 $D \in R^{(k+1) \times (k+1)}$ 는 다음과 같이 구성 할 수 있다.

$$D = \frac{N}{N+1} + \frac{N}{(N+1)^2} \quad (3.6)$$

여기서 $\gamma = h_{N+1}^T(x_{N+1} - \bar{x})$ 이며 $\alpha = U^T(x_{N+1} - \bar{x})$ 이다. 행렬 D 를 구성하는 몇 가지 방법이 제안되었는데 Hall이 제안한 방법만이 평균을 갱신할 수 있도록 제공하는데 이 기법은 평균의 갱신을 허용하지 않는 기법에 비해 성능이 우수한 것으로 알려져 있다. 따라서 본 연구에서는 Hall이 제안한 평균의 갱신을 허용하는 방법을 주성분 갱신의 기본 방법으로 사용할 예정이다.

3.1. 온라인 동시 지도 작성 및 자가 위치 추적 알고리즘

앞에서 설명한 온라인 주성분 분석 방법은 그 적용 범위가 학습 자료간의 선형적인 관계가 존재할 때 적용이 가능하다. 학습 자료 간에 비선형성이 존재하는 경우에 대해 온라인 주성분 분석 방법을 적용하고자 할 경우에 Cover의 정리 (Vapnik, 1998; 박혜정, 2009; 석경하, 2010; 황진수와 김지연, 2009; 황창하와 신사임, 2010)가 하나의 해결책이 될 수 있다. 그의 정리를 간단히 요약하면 “몇 가지 조건이 만족될 때 입력 공간에서 선형적으로 분리 불가능한 문제가 비선형 사상을 적용한 고차원 특징 공간 (feature space)에서는 선형적으로 분리 가능한 문제로 변환될 확률이 높다”이다. 비록 고차원 공간으로의 사상이 학습 자료간의 비선형 문제를 해결할 수는 있지만 고차원 공간으로의 사상으로 인한 계산 비용의 증가를 초래한다. 이러한 문제는 커널 기법 (kernel trick)으로 해결이 가능하다. 커널 함수 $K(x_i, x_j)$ 는 다음과 같이 표현할 수 있다.

$$K(x_i, x_j) = (\phi(x_i) \cdot \phi(x_j)) \quad (3.7)$$

식 (3.7)이 의미하는 것은 만약 특징 사상 ϕ 를 적절히 선택하면 특징 공간에서의 내적 (inner product)은 입력공간에서의 커널과 동일하다는 것으로 고차원의 특징 공간에서 계산할 필요가 없어 계산상의 증가를 줄일 수 있다는 것이다. 커널 함수는 Mercer의 조건 (Mercer, 1909)을 만족하는 함수들이 사용 가능하다고 알려져 있다. 커널함수 K 가 양반정치행렬 (semi positive definite)이면 특징 사상 함수 ϕ 가 존재한다는 것을 Vapnik은 증명하였다 (Vapnik, 1998). 하지만 다항식 커널 함수를 제외한 나머지 커널 함수에서 특징 사상 함수 ϕ 를 구하는 것은 상당히 어려운 문제이다. 다항식 커널함수에서 특징 사상 함수를 구하는 과정은 다음과 같다. 설명을 위해 $d = 2$, $x = (x_1, x_2)$, $y = (y_1, y_2)$ 라 두면,

$$\begin{aligned} (x \cdot y)^2 &= (x_1^2, \sqrt{2}x_1x_2, x_2^2)(y_1^2, \sqrt{2}y_1y_2, y_2^2)^T \\ &= (\phi(x) \cdot \phi(y)) \end{aligned} \quad (3.8)$$

따라서 $\phi(x) = (x_1^2, \sqrt{2}x_1x_2, x_2^2)$ 이 된다. 다항식 특징 사상 함수의 경우 차원 d 의 값에 따라 성능은 큰 차이를 보이지 않는다.

따라서 본 논문에서는 KPCA의 일괄처리 방식의 문제점은 Hall이 제안한 온라인 주성분분석 방법을 적용하여 해결하고, 선형 자료에만 적용이 가능한 문제는 다항식 커널 함수에서 구해진 특징 사상함수를 온라인 주성분분석 방법에 적용하여 온라인으로 동작하면서, 위치 정보를 사용하지 않고 지도 작성이 가능하고, 많은 계산량을 요구하지 않은 온라인 SLAM 알고리즘을 제안한다.




그림 3.2 전체적인 흐름도

표 3.1 온라인 SLAM 알고리즘

Online SLAM Algorithm
x_1, x_2, \dots, x_n : polynomial feature mapped training data
λ : already built eigenvalue by previous data
D : already built eigenvector by previous data
\bar{x} : already computed mean by previous data
for $k = 1$ to n : begin re-learning iteration
$\bar{x}' = \frac{1}{N+1}(N\bar{x} + x_{N+1})$: update the mean
$a_{n+1} = U^T(x_{n+1} - \bar{x})$: compute new principal component
$h_{n+1} = (Ua_{n+1} + \bar{x}) - x_{n+1}$: compute orthogonal residual vector
if ($ h_{n+1} _2 > 0$)
$h_{n+1} = \frac{h_{N+1}}{ h_{N+1} _2}$: normalize \hat{h}'_{n+1}
else
$\hat{h}_{n+1} = 0$
$\gamma = h_{N+1}^T(x_{N+1} - \bar{x})$: compute auxiliary vector
$D = \frac{n}{n+1} \begin{bmatrix} \Lambda & 0 \\ 0^T & 0 \end{bmatrix} + \frac{n}{(n+1)^2} \begin{bmatrix} aa^T & \gamma a \\ \gamma a^T & \gamma^2 \end{bmatrix}$: construct matrix D
$DR = RA$: solve eigenproblem
$U = [U, \hat{h}_{n+1}]R$: compute new eigenvector
if($(n+1)\lambda_{k+1} > 0.7$): update eigenvector using the criterion rule
update eigenspace
else
retain current eigenspace
end: end of re-learning iteration

4. 실험 및 결과

일반적으로 온라인 방법은 일괄처리 방식에 비해 메모리 효율성이 좋고 학습 자료의 추가를 허용하는 유연한 기법이지만 일괄처리 방식에 비해 정확도가 떨어지는 것이 문제가 된다. 따라서 실험은 먼저 토이 (toy) 자료에 대해 제안한 방법과 커널 주성분 분석 방법과의 주성분값, 재구성 오차 (reconstruction error), 고유벡터의 비교 등을 통해 제안된 온라인 SLAM 알고리즘의 정확도를 검증한다. 이때 사용하는 데이터는 Scholkopf (1998)가 그의 논문에서 사용한 비선형 자료를 사용한다. 토이 자료에 대해 온라인 SLAM 알고리즘의 타당성을 검정한 후 대용량 데이터에 대한 온라인 SLAM 알고리즘의 메모리 효율성, 정확도 및 학습의 유연함을 검증하기 위해 기계학습 분야에서 많이 사용하는 바나나 학습 자료

에 대해 적용한다.

4.1. 토이 자료

토이 (toy) 자료는 다음과 같이 생성한다. 여기서 ϵ 은 평균 0, 분산 1인 정규분포로부터 생성된 임의의 오차항이다.

$$y = x^2 + 0.2\epsilon, \quad \epsilon \sim N(0, 1), \quad x = [-1, 1] \quad (4.1)$$

이때 사용하는 다항식 특징 사상 함수의 차원 d 는 2로 하였다. 온라인 SLAM 알고리즘의 성능 평가는 재구성오차 (reconstruction error), 그리고 KPCA와 온라인 SLAM 알고리즘에서 구해진 고유벡터의 $\cos\theta$ 값에 의한 유사도에 의해서도 평가할 수 있다. 먼저 재구성 오차는 다음과 같이 정의한다 (값에 의한 유사도에 의해서도 평가할 수 있다. 먼저 재구성 오차는 다음과 같이 정의한다 (Yogesh, 2006).

$$\delta = |\phi(x^n) - P_i\phi(x^n)|^2 \quad (4.2)$$

여기서 P_i 은 온라인 SLAM 알고리즘 방법에 의해서 구해진 주성분이다. 그림 4.1은 식 (4.2)에서 정의한 재구성 오차를 재학습에 의해 제공 평균 오차 (Mean Square Error: MSE, 이하 MSE로 칭함)가 감소하는 과정을 나타낸 그래프이다.




그림 4.1 온라인 KPCA방식에서 재학습에 의한 재구성오차의 변화

순차적으로 입력된 학습 자료에 대해 제안된 방법에 의한 재구성 오차의 MSE는 0.0090이다. MSE의 값이 0.0090이라는 의미는 특징공간에서 학습 데이터와 온라인 SLAM 알고리즘에 의해서 추정된 학습 데이터의 오차가 거의 없다는 것을 의미한다. 이는 제안된 방법이 일괄처리 방법과 유사한 성능을 나타냄을 보여준다.

또 다른 성능평가 방법으로 일괄처리 KPCA와 온라인 SLAM 알고리즘에서 구한 고유벡터가 이루는 값의 유사도에 의해 평가할 수 있다. 아래의 행렬 B와 I는 각각 KPCA과 온라인 SLAM 알고리즘을 실험에 적용하여 구한 고유벡터 행렬이다.

$$B = \begin{bmatrix} 0.53856 & -0.095116 & 0.81604 \\ 0.094315 & 0.49981 & -0.19613 \\ 0.82981 & -0.11002 & -0.5259 \\ 0.11171 & 0.85384 & 0.13795 \end{bmatrix}, \quad I = \begin{bmatrix} 0.53856 & -0.095114 & -0.8166 \\ 0.094314 & 0.49981 & 0.19364 \\ 0.82981 & -0.11002 & 0.52635 \\ 0.11171 & 0.85384 & -0.13649 \end{bmatrix}$$

두 행렬의 고유벡터가 이루는 $\cos\theta$ 는 다음과 같이 정의 한다.

$$\cos\theta = \frac{\alpha \cdot \beta}{|\alpha| |\beta|} \quad (4.3)$$

식 (4.3)에 의해 구해진 $\cos\theta$ 와 θ 값이 표 4.1에 나타나 있다. 표에서 알 수 있듯이 모든 고유벡터의 θ 값은 0이다. 즉 두 벡터가 같다는 것을 의미한다. 고유벡터를 비교한 결과에서도 일괄처리 커널주성분 방법과 제안한 온라인 SLAM 알고리즘의 성능이 같음을 알 수 있다.

표 4.1 KPCA와 온라인 SLAM 알고리즘 방법에서
구한 고유벡터의 $\cos\theta$ 와 θ 값

고유벡터	$ \cos\theta $	θ
1	1	0
2	1	0
3	1	0

4.2. 대용량 자료

로봇은 대용량 서버 시스템과 달리 임베디드 시스템 (embedded system)처럼 제한된 메모리를 가진다. 따라서 온라인 SLAM 알고리즘 또한 적은 양의 메모리에서 동작하는 것은 매우 중요하다. 제안된 온라인 SLAM 알고리즘 방법의 메모리 효율성 및 정확도를 검증하기 위해 대용량의 학습 자료에 대한 실험을 수행하였다. 학습 자료는 기계학습에서 학습 알고리즘의 성능을 평가 하는 벤치마킹 자료로 많이 사용되는 바나나 학습 데이터 이다. 바나나 학습 자료는 2개의 클래스로 구성된 비선형 자료이며 학습 알고리즘의 성능을 평가하기 위해 학습용 자료 400개와 테스트 자료 4900개로 분리되어 있다. 하지만 본 논문에서는 분류가 아닌 차원 축소 성능에 대한 평가가 목적이므로 두개를 합친 5300개의 학습 자료에 대해 실험을 하였다. 바나나 학습 자료에 대해 제안한 알고리즘의 수행결과 5번의 재학습에 의한 재구성 오차의 MSE는 0.0021이다. 앞의 실험 결과와 마찬가지로 대용량의 학습 데이터에 대해서도 온라인 SLAM 알고리즘의 수행 능력이 일괄처리 방식의 KPCA와 유사함을 알 수 있다. 반면에 메모리 효율 면에서 보면 바나나 학습 자료를 일괄처리 방식의 KPCA에 적용할 경우 5300×5300 크기의 커널 행렬을 저장하여야 한다. 하지만 온라인 SLAM 알고리즘은 커널 행렬을 저장할 필요 없이 3×3 크기의 고유벡터만이 필요하며 부가적으로 4×4 크기의 D 행렬, 4×1 크기의 γ 행렬, 3×1 크기의 \hat{h} 행렬 정도만이 필요하여 메모리 효율성이 KPCA에 비해 매우 높음을 보여준다. 본 실험 결과는 제안한 온라인 SLAM 알고리즘 방법의 메모리 효율성을 보여주는 것으로 이동로봇의 실세계 주행과 같은 대용량의 이미지 처리가 요구되는 환경에 유용하게 적용될 수 있음을 보여준다.

표 4.2 온라인 SLAM 알고리즘과 일괄처리 KPCA의 메모리 효율성

	KPCA	제안한 방법
커널 행렬	5300×5300	필요없음
고유벡터	필요없음	3×3
R 행렬	필요없음	4×4
D 행렬	필요없음	4×4

5. 결론

본 논문에서는 이동 로봇을 위한 지능형 주행 알고리즘인 온라인 SLAM 알고리즘을 제안한다. 제안된 알고리즘은 다음과 같은 의미를 가진다.

첫째, 비선형 자료의 특징 추출 성능에서는 온라인 SLAM 알고리즘 방법이 기존의 일괄처리 KPCA와 유사한 성능을 나타내었다.

둘째, 기존의 SLAM 알고리즘에 비해 메모리 사용면에서 매우 효율적이다. 기존의 일괄처리 방식의 KPCA의 경우 학습 자료의 개수가 N 개 일 때 고유공간 (eigenspace)을 계산하기 위해 $O(N^2)$ 만큼의 메모리가 필요하다. 반면에 제안된 온라인 SLAM 알고리즘의 경우 k 를 학습 자료의 차원이라 하면 $O(k+1)^2$ 만큼의 메모리가 필요하다. 이는 이동로봇의 실세계 주행과 같은 대용량의 이미지 처리가 요구되는 환경에 유용하게 적용될 수 있음을 보여준다.

세번째, 학습 자료의 추가에 의한 유연성이다. 기존의 일괄처리 방식의 경우 새로운 학습 자료가 추가 되면 고유벡터와 고유값을 새로 계산해야 하는 단점이 있다. 하지만 제안된 온라인 SLAM 알고리즘 방법은 학습 자료의 추가를 허용 하면서 위치 추정 및 지도 작성을 할 수 있다. 이상의 실험 결과를 바탕으로 제안한 방법은 지능형 주행을 위한 이동 로봇의 SLAM 알고리즘으로 적합한 것을 알 수 있다. 앞으로의 연구 방향은 본 논문에서 제안한 알고리즘의 경우 최적의 중단 규칙 (stopping rule)이 없이 휴리스틱 (heuristic)에 의해 재학습 횟수를 설정하였다. 향후 연구에서는 최적의 중단 규칙 (stopping rule) 개발과 제안된 알고리즘에 의해 작성된 지도를 바탕으로 주변의 사물을 인식하여 지능형 주행을 할 수 있는 인식 알고리즘을 개발하여 이를 실제 로봇에 적용하여 그 타당성을 검증 하고자 한다.

참고문헌

- 김기열 (2010). <무향칼만필터를 이용한 로봇 위치인식의 향상>, 석사학위논문, 인하대학교, 서울.
- 박혜정 (2009). 최소제곱 서포터벡터기계를 이용한 시장점유율 자료 분석. <한국데이터정보과학회지>, **20**, 879-886.
- 석경하 (2010). 최소제곱 서포터벡터기계 형태의 준지도 분류. <한국데이터정보과학회지>, **21**, 461-470.
- 황진수, 김지연 (2009). 마이크로어레이 자료에서 서포터벡터머신과 데이터 덩스를 이용한 분류방법의 비교 연구. <한국데이터정보과학회지>, **20**, 419-425.
- 황창하, 신사임 (2010). 커널기계 기법을 이용한 일반화 이분산 자기회귀모형 추정. <한국데이터정보과학회지>, **20**, 879-886
- Andrade, J., Vidal, T. and Sanfeliu, A. (2005). Unscented transformation of vehicle state in SLAM. *Proceeding International Conference on Robotics and Automation*, 323-328.
- Brunskill, E. and Roy, N. (2005). SLAM using Incremental probabilistic PCA and dimensionality reduction. *Proceeding International Conference on Robotics and Automation*, 342-347.
- Castellanos, J. A., Montiel, M. M., Neira, J. and Tardos, J. D. (1999). The spmap: A probabilistic framework for simultaneous localization and map building. *IEEE Transactions on Robotics and Automation*, **15**, 948-952.
- De Geeter, J., Brussel, H. and De Schutter, J. (1997). A smoothly constrained Kalman filter. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **19**, 1171-1177.
- Guivant, J. and Nebot, E. (2001). Optimization of the simultaneous localization and map-building algorithm for real-time implementation. *IEEE Transactions on Robotics and Automation*, **17**, 242-257.
- Hall, P., Marshall, D. and Martin. R. (1998). Incremental eigenanalysis for classification. In *British Machine Vision Conference*, **1**, 286-295.
- Julier, S. and Uhlmann, J. (1997) A new extension of the Kalman filter to nonlinear systems. *Proceeding 11th International Symposium Aerospace/Defense Sensing, Simulation and Controls*, 182-193.
- Julier, S. and Uhlmann, J. (2004). Unscented filtering and nonlinear estimation. *Proceeding of the IEEE*, **92**, pp.401-422.
- Langelaan, J. and Rock, S. (2005). Passive GPS-free navigation for small UAVs. *IEEE Aerospace Conference*, 1-9.
- Lee, S., Lee, S. and Kim, D. (2006). Recursive unscented Kalman filtering based SLAM using a large number of noisy observations. *International Journal of Control, Automation, and Systems*, **4**, 736-747.
- Leonard, J. and Feder, H. (2001). Decoupled stochastic mapping. *IEEE Journal of Oceanic. Engineering*, **26**, 561-571.
- Martinez-Cantin, R. and Castellanos, J. (2005). Unscented SLAM for large-scale outdoor environments. *Proceeding IEEE International Conference of Intelligent Robots and System*, 328-333.

- Mercer, J. (1909). Functions of positive and negative type and their connection with the theory of integral equations. *Philosophy Transaction Royal Society London*, **209**, 415-446.
- Montemerlo, M., Thrun, S., Koller, D. and Wegbreit, B. (2002). Fast-SLAM: A factored solution to the simultaneous localisation and mapping problem. *Proceeding Artificial Intelligence for Interactive Digital Entertainment Conference*, 593-599.
- Moerland, P. (2000). *An on-line EM algorithm applied to kernel PCA*, Instituto de Investigación Agropecuaria de Panamá Research Report, 00-18.
- Murakami, H. and Kumar, B. V. K. V. (1982). Efficient calculation of primary images from a set of images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **4**, 511-515.
- Newman, P. (1999). *On the structure and solution of the simultaneous localization and map building problem*. Ph.D, dissertation, University Sydney, Australia.
- Pierce, D. and Kuipers, B. (1994). Learning to explore and build maps. Accessible at <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.45.2516>.
- Rosipal, R. and Girolami, M. (2001). An expectation maximization approach to nonlinear component analysis. *Neural Computation*, **13**, 505-510.
- Scholkopf, B., Smola, A. and Muller, K. R. (1998). Nonlinear component analysis as a kernel eigenvalue problem. *Neural Computation*, **10**, 1299-1319.
- Scholkopf, B., Mika, S., Burges, C., Knirsch, P., Miller, K. R., Ratsch, G. and Smola, A. J. (1999). Input space versus feature space in kernel-based methods. *IEEE Transactions on Neural Networks*, **10**, 1000-1017.
- Simon, D. and Chia, T. (2002). Kalman filtering with state equality constraints. *IEEE Transactions on Aerospace and Electronic Systems*, **38**, 128-136.
- Smola, A. J., Mangasarian, O. L. and Scholkopf, B. (1999). *Sparse kernel feature analysis*, Technical Report 99-03, University of Wisconsin, Data Mining Institute, Madison.
- Tardos, J. D., Neira, J., Newman, P. and Leonard, J. (2002). Robust mapping and localization in indoor environment using sonar data. *International Journal of Robotics Research*, **21**, 311-330.
- Thrun, S., Koller, D., Ghahramani, Z., Durrant-Whyte, H. and Ng, A. Y. (2002). Simultaneous mapping and localization with sparse extended information filter. Accessible at <http://robotics.caltech.edu/readinggroup/thrun.tr-seif02.pdf>.
- Tipping, M. E. and Bishop, C. M. (1998). Mixtures of probabilistic principal component analysers. *Neural Computation*, **11**, 443-482.
- Wen W. and Durrant-Write, H. (1991). Model based active object localization using multiple sensors. *Proceeding Intelligent Robotics and Systems*, 1448-1452.
- Williams, S. B., Dissanayake, G. and Durrant-Whyte, H. (2002). An efficient approach to the simultaneous localization and mapping problem. *Proceeding IEEE International Conference on Robotics and Automation*, 406-411.
- Winkler, J., Manjunath, B. S. and Chandrasekaran, S. (1999). Subset selection for active object recognition. In *Proceeding Computer Vision and Pattern Recognition*, **2**, 511-516.
- Yairi, T. (2007). Map building without localization by dimensionality reduction techniques. Accessible at <http://www.machinelearning.org/proceedings/icml2007/papers/224.pdf>.
- Yogesh, R. S., Dambreville, S. and Tannenbaum, A. (2006). Statistical Shape Analysis using Kernel PCA. accessible at <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.60.7604>.
- Vapnik, V. (1998). *Statistical learning theory*, John Wiley & Sons, New York.

Online SLAM algorithm for mobile robot

Byung Joo Kim¹

¹Department of Computer Engineering, Youngsan University

Received 11 July 2011, revised 16 August 2011, accepted 29 September 2011

Abstract

In this paper we propose an intelligent navigation algorithm for real world problem which can build a map without localization. Proposed algorithm operates online and furthermore does not require many memories for applying real world problem. After applying proposed algorithm to toy and huge data set, it does not require to calculate a whole eigenspace and need less memory compared to existing algorithm. Thus we can obtain that proposed algorithm is suitable for real world mobile navigation algorithm

Keywords: Intelligent navigation algorithm, localization, map building, SLAM.

¹ Professor, Department of Computer Engineering, Youngsan University, Yangsan 626-847, Korea.
E-mail: bjkim@ysu.ac.kr