

한 대의 카메라와 Fiducial 마커를 이용한 SLAM

Indoor Single Camera SLAM using Fiducial Markers

임 현, 양 지 혁, 이 영 삼*, 김 진 겈
(Hyon Lim, Ji Hyuck Yang, Young Sam Lee, and Jin Geol Kim)

Abstract : In this paper, a SLAM (Simultaneous Localization and Mapping) method using a single camera and planar fiducial markers is proposed. Fiducial markers are planar patterns that are mounted on the ceiling or wall. Each fiducial marker has a unique bi-tonal identification pattern with square outlines. It can be printed on paper to reduce cost or it can be painted using retro-reflective paint in order to make invisible and prevent undesirable visual effects. Existing localization methods using artificial landmarks have the disadvantage that landmark locations must be known a priori. In contrast, the proposed method can build a map and estimate robot location even if landmark locations are not known a priori. Hence, it reduces installation time and setup cost. The proposed method works good even when only one fiducial marker is seen at a scene. We perform computer simulation to evaluate proposed method.

Keywords : SLAM, fiducial marker, mobile robot, extended Kalman filter, localization, map building

1. 서론

로봇이 자기 위치를 인식하기 위해서는 주행거리계 등의 내부 상태를 이용하는 한편 외부의 환경도 인식하여야 한다. 즉, 위치 추정과 지도 작성을 동시에 해야한다. 이러한 동시 간 위치추정 및 지도작성(Simultaneous Localization and Mapping) 문제는 축약하여 SLAM [1,2]으로 불리우며 이동로봇 연구자들 사이에서 중요한 연구 주제로서 논의되어 왔다. SLAM은 이동로봇에 자율이동 능력을 부여하기 위하여 위치가 알려지지 않은 랜드마크를 기준으로 로봇의 위치를 인식하고 주어진 환경에 대한 지도를 작성하는 문제로 정의할 수 있다.

최근 비전 기반의 SLAM은 영상에서 안정한 특징점들을 랜드마크(landmark)로 사용하는 것으로 발전되어 왔다 [2]. 하지만, 이러한 랜드마크를 사용하는 방법의 큰 단점중 하나는 데이터 연관(data association) 문제이다 [3]. 데이터 연관문제는 현재 관찰된 정보를 이전에 관찰된 정보와 대응시키는 것이다. 그동안 데이터 연관 문제를 해결하기 위하여 active search [4] 같은 기법이 적용되어 왔다. 그럼에도 불구하고 안정한 특징점들을 랜드마크로 사용하는 것은 실제로 움직이는 물체가 많은 환경에서 잘 동작하지 못한다. 그것은 움직이는 물체가 잘못된 데이터 연관을 유발하기 때문이다.

실내 로봇은 주로 사무실, 집 혹은 건물 내부에서 동작될 것이다. 이는 야외 환경과 달리, 미지의 환경을 매번 받아들여야 할 필요가 없음을 의미한다. 움직이는 경로도 일정하고 반복적일 것이다. 또한 사람과 같은 움직이는 물체는 항상 존재할 것이다. 그러므로, 앞에서 언급한 방법인 영상내에서 특징점을 추출하여 이를 이용하는 것 보다, 움직이며 복잡한 배경 가운데서 분리해내기 쉬운 인공 랜드마크를 이용하는 것이 더 강력한 결과를 제공 할 것이다. 본 논문에서 사용하는 인공 랜드마크는 fiducial 마커이다. Fiducial 마커는 일종의 검은색과 흰색

만 가지는 사각형의 코딩된 패턴으로 그림 5와 같다.

기존에도 비전 기반의 인공 랜드마크를 이용하는 실내 위치인식 방법은 활발히 연구되어 왔다 [5]. 하지만 기존의 방법은 랜드마크의 위치를 사전에 저장하고 있어야 했다. 이것은 곧 로봇의 위치인식을 위해서 사전에 정교한 측정작업이 수반되어야 함을 의미한다. 이러한 작업은 넓은 실내 공간에서 수행되기 어렵다. 또한 측정의 정확도가 위치인식의 정확도에 지속적인 영향을 주게 된다. 이렇듯 기존의 연구는 제약사항이 뒤따른다. 그래서 본 논문에서는 사전 교정(calibration) 작업이 불필요하고 센서가 가지는 불확실성을 위치인식 수행 과정에 포함시키기 위하여 확장 칼만 필터(EKF : Extended Kalman Filter)를 이용하였다. 본문에서 기술하는 상태 벡터와 EKF를 통하여 랜드마크와 로봇의 위치는 출발점을 원점으로 하는 좌표계 상에서 미터 단위로 추정된다.

1. Paper Structure and Contribution

본 논문에서는 fiducial 마커와 한 대의 카메라를 이용한 실내 위치인식 방법을 제안한다. 제안한 방법은 디지털 부호화(coding)가 되어 있는 fiducial 마커를 이용하여 데이터 연관 문제를 간단하게 한다. Fiducial 마커는 이미지 정보 속에서 fiducial 마커를 찾아내기 쉽게 하도록 여러가지 영상기술이 포함된 일종의 패턴이다(그림 5 참조). 이로 인하여 영상 프레임간의 데이터 연관이 간단해지는 장점이 있다. 또한 제안한 방법의 fiducial 마커는 역반사(retro reflective) 성질(그림 4 참조)을 가지는 투명 형광 도료로 탑재 될 수 있기 때문에 사람이 보는 환경의 변화를 최소화하여 위치인식을 수행 할 수 있는 장점이 있다.

본 논문은 준-미지(quasi-unknown)의 환경 하에서 정확한 위치인식을 수행하기 위한 이론과 모의 실험 결과를 기술한다. 미지의 환경이란 기존의 환경에 아무런 변화를 가하지 않은 상태를 말한다. 반대로 의도된 환경은 초음파 위성이나 랜드마크의 설치가 이루어진 상황을 말한다. 하지만 본 논문에서 정의하는 준-미지의 환경은 랜드마크를 보이지 않게 탑재 할 수 있으며 탑재를 하더라도 그 랜드마크의 위치를 측정할 필요가 없으며 무작위로 설치해도 되는 환경을 의미한다.

* 책임저자(Corresponding Author)

논문접수 : 2009. 1. 30., 채택확정 : 2009. 2. 25.

임현, 양지혁, 이영삼, 김진걸 : 인하대학교 전기공학부

(alex@alexlab.net/zero1zuck@hanmail.net/lys@inha.ac.kr/john@inha.ac.kr)

※ 본 연구는 지식경제부의 지원에 의하여 기초전력연구원(R-2007-2-059) 주관으로 수행된 과제임.




그림 1. [2]의 MonoSLAM.

Fig. 1. Figures from MonoSLAM[2].

본 논문의 구성은 다음과 같다. II 장에서는 관련 연구에 대하여 소개하고 본 논문에서 제안하는 방법의 장점에 대해서 설명한다. III 장에서는 본 논문에서 제안하는 fiducial 마커 기반의 SLAM 방법에 대하여 구체적으로 기술한다. 3.1 절에서는 그동안의 연구와 본 연구의 차이점에 대하여 기술하고 독창성과 차별성에 대하여 설명한다. 또한 Gaussianity 검증을 통하여 EKF의 적용 가능성에 대하여 기술한다. 3.2 절에서는 랜드마크와 로봇의 상태를 SLAM 프레임워크에서 이용할 수 있는 형태로 기술하는 방법에 대하여 설명한다. 3.3 절에서는 fiducial 마커를 측정치로 이용하는 과정을 기술한다. 3.4 절에서는 fiducial 마커의 위치를 추정하는 방법에 대해서 기술한다. 3.7 절에서는 통합된 프레임워크 상에서 랜드마크와 로봇의 위치를 EKF를 이용한 추정방법에 대하여 소개한다. 3.8 절에서는 랜드마크 정보를 관리하는 전략에 대하여 설명한다. IV 장에서는 제안된 방법을 컴퓨터 모의실험을 통하여 수행한 결과를 제시한다. 비전 센서가 있는 경우와 없는 경우로 나누어 실험한 결과를 비교하였다. 그리고 V 장에서 결론을 맺는다.

II. Related Work

그 동안 랜드마크 기반의 위치인식 연구는 일반적으로 삼각 측량법을 사용하고 있다. 삼각 측량법은 알고있는 고정 물체에 대한 방위각(bearings)을 측정하여 자신의 위치를 알아내는 것이다. 대표적인 연구로는 [6-8]이 있다. [6]에서는 어안렌즈 카메라를 이용하여 주변 영상을 한번에 취득한다. 취득한 영상에서 찾아낸 랜드마크의 방위각을 알아내어 삼각 측량법으로 현재 위치를 알아낸다. [7]에서는 n 개의 랜드마크들이 위치 $\mathbf{P}_i \in \mathbb{R}^2$ 가 알려진 상태에서 각 랜드마크들과의 방위각 관계로부터 로봇의 현재 위치를 구하는 이론을 제시하였다. 제시된 이론은 계산량이 낮은 장점이 있다. [8]에서는



그림 2. [9]의 Stargazer. Passive 랜드마크의 위치를 미리 정해 주어야만 그에 대한 상대 위치로 로봇의 위치 계산이 가능하다.

Fig. 2. Stargazer of [9]. Location estimation is only available from a priori landmark location.



그림 3. [10]의 U-Sat. 초음파 위성 4개와 수신기 1개로 구성되어 있다. 초음파 위성에는 전원이 공급되어야 한다.

Fig. 3. U-Sat of [10]. Four ultra-sonic satellites and one receiver are needed to estimate location. Each ultra-sonic satellite needs power supply.

평면체 랜드마크를 이용하여 위치인식을 수행한다. 이 연구는 랜드마크를 기계학습(machine learning)를 통하여 학습시킨 후 랜드마크의 위치를 미리 알고 있는 상태에서 위치인식을 수행한다. 국내 연구로는 인공 랜드마크를 관찰한 후 삼각 측량법을 응용하여 위치를 추정하는 방법이 있다 [9](그림 2 참조). 이 연구에서는 랜드마크와의 기하관계를 사전에 설정해야 한다. 즉, 랜드마크번호마다 그 위치를 데이터베이스화 하여 로봇에 저장해야 한다. 설치 후에 랜드마크의 위치를 바꿀 때마다 그 데이터베이스를 수동으로 갱신해 주어야 한다. 앞 단락에서 다른 내용은 모두 랜드마크의 위치가 $\mathbf{P}_i \in \mathbb{R}^2$ 의 형태로 알려져 있는 연구이다. 이 같은 형태의 위치인식은 지도를 미리 만들어 두어야 하며 랜드마크의 학습 및 데이터 연관에도 많은 계산량이 따른다. 삼각 측량법이 아닌 한 대의 카메라(monocular camera)를 이용한 SLAM에 대한 연구는 MonoSLAM [2]이 대표적이다(그림 1 참조). MonoSLAM은 corner 검출기를 이용하여 영상에서 특징점을 추출하고 이 특징점을 기반으로 SLAM을 수행한다. MonoSLAM이 한 대의 카메라를 이용하고 영상에서 특징점을 추출하므로 미지의 공간에서 위치인식을 할 수 있는 장점이 있으나, 움직임이 부드러워야 한다는 가정을 가지고 있다. 따라서 급격한 이동과 로봇이 충격을 받을 경우 이 후의 위치 추정값은 오차를 가지게 된다.

영상을 이용하지 않는 연구에는 실내에서 초음파의 도달 시간 차이(time difference of arrival)를 이용한 방법이 있다 [10]. 이 방법은 실내 일정한 곳에 4개 이상의 초음파 발신기를 설치해놓고 로봇에 수신기를 장착하여 초음파 발신기와 거리를 측정하고 이를 삼각 측량법을 이용하여 3차원상의 로봇의 위치를 추정하는 것이다 (그림 3 참조). 하지만 이 방법은 발신기와 수신기간의 무선 동기가 필요하고 거리가

제한적이며 센서간의 기하학적 관계를 미리 설정해주어야 한다. 게다가 4개의 센서로부터의 거리를 모두 측정하기 이전에 로봇이 움직이게 되면 추정 정확도가 낮아진다. 한 대의 로봇 개체가 위치 인식을 하기 위해서는 일정 공간 내에 4개 이상의 초음파 발신기를 설치해야 하고 이들 발신기에 전원을 공급해 주어야 한다. 또한 온도와 기상상황에 따라 위치 정밀도가 변하게 된다.

본 논문에서는 한 대의 카메라를 이용하여 영상정보를 기반으로 로봇의 SLAM 문제를 해결한다. 영상은 데이터 연관 문제를 해결하는데 많은 어려움이 있다. 조명, 시점에 따른 영상 변형에 대한 문제와 번짐, 급격한 이동에 따른 영상 왜곡으로 인하여 많은 고려가 필요하다. 따라서 본 논문에서는 fiducial 마커 [11]를 이용하여 데이터 연관 문제를 해결한다.



(a) Visible markers



(b) Invisible markers captured by visible ray camera without IR light



(c) Invisible markers with a IR light

그림 4. (a)는 레이저 프린터 등을 이용하여 손쉽게 출력 할 수 있는 fiducial 마커의 형태. (b)는 [12]의 retro-reflector를 이용한 보이지 않는 마커. (c)는 IR light 를 비추는 경우의 retro-reflective fiducial 마커.

Fig. 4. (a) Fiducial markers that are printed easily by a laser print. (b) Invisible markers using a retro-reflector[9] (c) Retro-reflective fiducial markers with a IR light.

Fiducial 마커의 형태는 그림 5에 나타나 있다. 본 논문에서 제안하는 fiducial 마커 기반의 한 대의 카메라를 이용한 SLAM의 장점을 요약하면 다음과 같다.

- 기존의 인공 랜드마크나 초음파를 이용한 실내 위치인식 방법 [9,10]과 달리 사전에 기하학적 정보를 조사하는 사전 교정(calibration)과정이 생략된다.

기존의 초음파를 이용한 실내 위치인식이나 인공 랜드마크의 알려진 기하학적 관계를 통한 위치 추정의 경우 사전에 센서들을 어떻게 설치 할 것인지 정하고 그 정보를 로봇 데이터베이스에 입력을 시켜야 했다. 그리고 로봇은 이를 기반으로 위치 추정을 수행한다. 이러한 경우 구조가 바뀔 때마다 데이터베이스를 일일이 갱신 해야 한다. 이는 상당히 오랜 시간과 노력을 요구하며 곧 비용으로 이어진다. 하지만 본 논문에서 제안하는 방법의 경우 이와 같은 작업은 수행하지 않아도 된다.

- 최소 한 개의 랜드마크가 영상에서 관찰 되더라도 위치 추정이 가능하다.

한 대의 카메라와 한 장의 영상에서 추출된 특징점을 이용하는 SLAM의 경우 하나의 특징점에서 바로 그 특징점의 좌표를 추출해 낼 수 없다. 그 특징점은 여러 시점에서 관찰되어야만 한다. 하지만 본 논문에서 제안하는 fiducial 마커는 한 프레임에서 하나가 관찰 되더라도 바로 랜드마크의 좌표를 추출해 낼 수 있다. 따라서 한 영상 안에서 하나의 랜드마크만 관찰 되더라도 위치인식을 수행 할 수 있으므로 환경의 영향을 덜 받는다. 물론, 다수의 랜드마크가 관찰되는 경우에 비하여 그 정확도는 낮아진다.

- 장치 탑재를 최소화 할 수 있으며 손쉽게 설치 할 수 있다.

[10]의 경우 송/수신기에 전원이 필요하므로 전원 관리 및 배선 문제가 발생한다. 제안한 방법은 랜드마크에 전원을 공급 할 필요가 없으며 또한 한 대의 카메라가 영상을 통하여 SLAM을 수행하기 때문에 별도의 배선이 필요 없다. 제안된 방법은 출력된 랜드마크를 무작위로 설치 하더라도 위치인식 기능을 수행하기 때문에 설치가 쉽다. 게다가 fiducial 마커는 역반사형(retro reflective) 도료나 잉크를 통하여 사람의 눈에 띄지 않도록 설치 될 수 있다 [12]. 그림 4는 역반사형 도료를 이용한 투명 fiducial 마커를 나타내고 있다.

III. Method

1. Fiducial Marker as a Landmark

본 논문에서는 특징점 모델로서 fiducial 마커를 사용 하는 방식을 제안한다. 본 논문에서 사용하는 fiducial 마커는 그림 5와 같은 형태를 가진다 [13].

Fiducial 마커는 한번의 관찰로 3차원 좌표를 알아 내기 위한 사각형 테두리상의 네 꼭지점과 각각의 마커를 식별하기 위한 식별 코드로 구성된다. 4개의 꼭지점은 카메라 좌표계를 기준으로 fiducial 마커의 자세를 추정하는데 필요한 정보를 제공한다. 즉, 3차원 공간상의 자세행렬(pose matrix)을 알아내기 위하여 fiducial 마커상의 4개의 점을 활용한다. 이 네

꼭지점은 배경과 쉽게 구분되어 특징점으로 추출이 용이하고 그 기하학적 관계가 미리 정해져 있어 이를 이용하여 카메라를 기준으로 한 마커 중심의 좌표를 촬영한 한 장의 영상으로부터 구할 수 있다.

식별 코드를 인식하는 방법에는 템플릿 매칭을 이용한 방법 [14]과 디지털 신호처리를 이용한 방법 [11]이 있다. 템플릿 매칭을 이용한 방법은 비트 수에 제한되지 않는 장점이 있으나 인식률이 낮고 오류가 높은 단점이 있다. 디지털 신호처리를 이용한 방법은 대체로 수 비트를 할당 하여 일정한 수 범위 내의 마커를 숫자로서 인식 할 수 있고 오류 정정 코드를 삽입하여 인식률을 높일 수 있다. 본 논문에서는 디지털 신호처리를 이용한 방법을 사용한다.

그 동안 fiducial 마커를 이용한 연구에는 ARTToolKit [14], ARTag [11], ARTToolKitPlus [15]가 있다. 이 연구들은 증강현실 (augmented reality)의 실현을 위하여 카메라의 자세를 추정하는 목적으로 fiducial 마커를 사용하였다. [16]에서는 이러한 fiducial 마커 시스템 간의 성능 우위에 대하여 분석하였다. 증강현실은 한 개 혹은 다수의 fiducial 마커를 사용하여 3차원 객체와 카메라 영상의 시점을 동기화하는 것으로 정의 할 수 있다. 이들 연구는 fiducial 마커를 트래킹(tracking)용도 로만 사용하였다. 따라서 본 논문과 달리 다수의 fiducial 마커에 대하여 전역 좌표계를 기준으로 한 fiducial 마커의 위치를 알아낼 수 없다. 또한 관찰자의 절대위치를 파악할 수 있는 프레임워크를 갖추고 있지 않다. 즉, 2m 내외의 공간에서 3차원 객체의 시점동기를 위하여 fiducial 마커를 사용하였다.

Fiducial marker를 이용하여 위치인식을 수행하고자 한 대표적인 연구로는 [12]이 있다. [12]에서는 다수의 fiducial 마커를 이용하여 실내 위치인식을 시도하였다. 하지만 [12]의 연구는 fiducial 마커의 트래킹에서 발생하는 오차를 확률적으로 해석하지 않았으며 관찰자의 위치는 특정 fiducial 마커를 기준으로 하는 좌표계를 사용하고 있다. 따라서 기준이 되는

fiducial 마커의 측정치에 불확실성이 개입될 경우 모든 위치 인식에 오차가 누적될 수 있다.

본 논문은 fiducial 마커를 이용한 SLAM framework을 제안한다. 기존의 위치인식(localization) 방법은 [12]와 같이 알려진 기하조건을 이용해왔다. 이 같은 방법은 위치인식 방법을 실현하기 위하여 번거로운 측정 작업을 수반할 뿐만 아니라 변경이 용이하지 않다. 또한 기존의 SLAM은 고가의 레이저 스캐너를 이용하는 한편 프레임간의 데이터 연관을 해결하기 어려웠다 [3]. 따라서 움직이는 물체가 존재하는 곳에서 SLAM을 수행하기 어려웠다. 본 논문에서는 이 두가지 측면을 고려하여 혼합한 방법을 제안한다.

Fiducial 마커는 그 생김새와 특징으로 인하여 다양하고 복잡한 배경 영상에 위치하더라도 쉽게 인식이 가능한 장점이 있다. 또한 표면에 인쇄된 디지털 바코드와 유사한 식별코드로 인하여 데이터 연관이 매우 쉬워진다. 기존의 위치인식 방법은 하나의 fiducial 마커를 기준으로 하는 상대좌표로서 관찰자의 위치를 결정하는 한편 확률적 해석 없이 위치를 결정하므로 센서의 오차에 대한 처리가 미비하며 오차가 누적된다. 하지만 본 논문은 SLAM 프레임워크를 fiducial 마커와 결합하고 이에 따른 센서모델을 제안함으로써 fiducial 마커를 Bayesian 추정 기반으로 해석할 수 있도록 한다. 이에 따라 위치 정확도는 높아지며 카메라 센서로 인한 잡음 및 오차를 모델링 하여 줄일 수 있다.

1.1 Gaussianity Test

EKF는 불확실성이 unimodal인 가우시안 분포를 이루어야만 적용 할 수 있다. 따라서 EKF 를 적용하려는 센서가 가우시안 분포를 가지는지 확인할 필요가 있다. 본 논문에서는 EKF의 적용에 앞서 제안한 센서 모델이 가우시안 분포를 이루는지 실험해 보았다.

실험 환경은 그림 6에 나타나 있다. 일정 거리를 물리적으로 설정 한 후 그 거리를 센서를 통하여 관찰하였다. 그리고 이에 대한 히스토그램을 그리고 그 분포를 시각적으로 살폈다. 설정된 거리는 420mm이고 이에 대한 히스토그램은 그




그림 5. 본 논문에서 사용하는 fiducial 마커의 형태 [20]. 검은 사각형틀 안의 문양은 마커의 식별번호를 의미한다.
Fig. 5. The form of fiducial markers [20] that are used in this paper.



그림 6. Gaussianity 검증 실험 환경.
Fig. 6. The experiment environment for verifying gaussianity.




그림 7. Sensor에 대한 오차 히스토그램.

Fig. 7. The error histogram of the sensor used in this paper.

림 7과 같다.

실험 결과 카메라 센서는 가우시안 잡음 분포를 가지고 있었다. 표준편차는 3.8219이고 평균은 0인 unimodal 특성을 가지므로 EKF를 적용 할 수 있다고 판단하였다.

2. Robot and Landmark Models

k 단계에서 로봇의 동적 모델과 랜드마크의 위치에 대한 joint SLAM 벡터를 다음과 같이 정의한다.

$$\mathbf{x}(k+1) = \mathbf{f}(\mathbf{x}(k), \mathbf{u}(k), \mathbf{w}(k)) \quad (1)$$

$$\mathbf{z}(k) = \mathbf{h}(\mathbf{x}(k), \mathbf{v}(k)) \quad (2)$$

상태벡터 $\mathbf{x}(k) \in \mathbb{R}^{m+dn}$ 은 k 번째 step 에서 로봇의 상태 $\mathbf{x}_v(k) \in \mathbb{R}^m$ 과 n 개의 $\mathbf{m}_i \in \mathbb{R}^d$ 인 랜드마크 집합 $\mathbf{m} \in \mathbb{R}^{dn}$ 로 구성된다. 즉,

$$\mathbf{x}(k) \triangleq \begin{bmatrix} \mathbf{x}_v(k) \\ \mathbf{m}(k) \end{bmatrix} = [\mathbf{x}_v(k)^T \quad \mathbf{m}_1^T(k) \quad \cdots \quad \mathbf{m}_n^T(k)]^T \quad (3)$$

이다. 로봇에 대한 입력 벡터는 $\mathbf{u}(k) \in \mathbb{R}^p$ 이며, $\mathbf{w}(k) \in \mathbb{R}^p$ 는 $\mathcal{N}(0, \mathbf{Q}_v)$ 이고 $\mathbf{Q}_v \in \mathbb{R}^{p \times p}$ 이다. 공분산 \mathbf{Q}_v 는 모델링 되지 않은 로봇의 동적 모델과 시스템 잡음을 표현한다. 측정값 \mathbf{z} 에 대한 설명은 Remark 1에 나타나 있다.

함수 $\mathbf{f}: \mathbb{R}^{m+dn} \rightarrow \mathbb{R}^{m+dn}$ 은 로봇의 동적 모델을 표현하는 비선형 식이다. Gaussian random 벡터 $\mathbf{v}(k) \in \mathbb{R}^{dn}$ 은 비선형 측정모델 $\mathbf{h}: \mathbb{R}^{m+dn} \rightarrow \mathbb{R}^{dn}$ 의 부정확성 그리고 측정 잡음을 모델링 한다. $\mathbf{v}(k)$ 는 $\mathbf{R}_m \in \mathbb{R}^{d \times d}$ 의 공분산을 가진다.


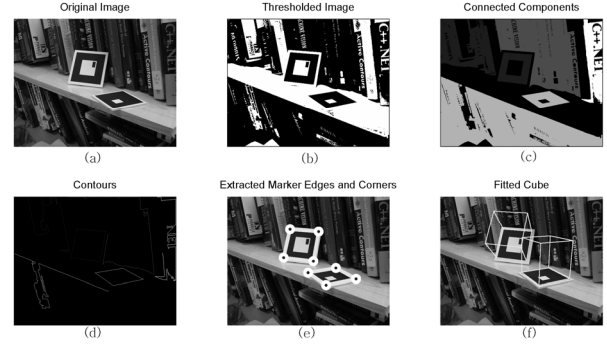


그림 8. Fiducial 마커 좌표계와 카메라 좌표계의 관계.

Fig. 8. The relations between fiducial marker coordinates and camera coordinates.

그림 9. \mathbf{T}_{cm} 을 구하는 과정.Fig. 9. The process of acquiring the \mathbf{T}_{cm} .

SLAM 에서 k 단계 까지 관찰된 모든 랜드마크의 관찰 정보 $\mathbf{z}(k) = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_n\}$ 는 사후추정(a posteriori) 상태 $\hat{\mathbf{x}}_v^+(k)$ 를 추정하기 위하여 사용된다. 함수 \mathbf{h} 는 전역 좌표계를 기준으로 저장된 맵 벡터 \mathbf{m}_i 가 로봇이 이동함에 따라 변하는 로봇 상태벡터 $\mathbf{x}_v(k)$ 에 따라서 관찰된 것으로 예상되는 추정 측정치 $\hat{\mathbf{z}}_i$ 를 예측하기 위하여 사용하는 함수로

$$\mathbf{h} = \begin{bmatrix} \mathbf{h}_1 \\ \mathbf{h}_2 \\ \vdots \\ \mathbf{h}_n \end{bmatrix} \quad (4)$$

와 같다. 즉, 추정 측정치 $\hat{\mathbf{z}}_i$ 는 실제 측정이 이루어지기 전, 로봇의 이동량에 따라 바뀌었을 것으로 예상되는 맵 벡터 \mathbf{m}_i 에 대한, 로봇 기준 좌표계에서의 좌표이다. 카메라를 통하여 실제 관찰한 측정치 \mathbf{z}_i 는 추정 측정치 $\hat{\mathbf{z}}_i$ 와 차이를 보일 것이며 이는 EKF의 Kalman 이득에 곱해져 사후 추정치를 얻게 된다.

3. Measurement Model of Fiducial Marker

본 논문에서 제안하는 fiducial 마커 기반의 SLAM은 한대의 카메라만으로도 3차원 공간상의 특징점의 로봇 좌표계 기준에서의 유클리디안 좌표를 상태의 지연 없이 알아낼 수 있는 장점이 있다. 상태의 지연이 없다는 것은 한 프레임만 가지고도 알아낼 수 있는 것을 의미한다. 즉, 지연이 있다는 것은 여러 프레임을 관찰해야만 유클리디안 좌표를 얻어낼 수 있는 것을 의미한다.

Fiducial 마커를 이용하면 로봇을 기준으로 하는 특징점의 3차원 좌표를 관찰 즉시 알아 낼 수 있다. i 번째 랜드마크에 대한 측정값을 $\mathbf{z}_i(k)$ 라고 하면 $\mathbf{z}_i(k)$ 는 로봇의 위치를 원점으로 하는 로봇 기준 좌표계에서 정의된다. k 단계에서 SLAM 상태벡터 $\mathbf{x}(k)$ 에 포함되어 있는, 전역좌표계를 기준으로 랜드마크 \mathbf{m}_i 의 좌표를 $(x_{m_i}, y_{m_i}, z_{m_i})$, 로봇 좌표를 $(x_v(k), y_v(k), 0)$ 라 하면 $\mathbf{z}_i(k)$ 는 다음과 같은 관계를 갖는다.

$$\mathbf{z}_i(k) = \mathbf{h}_i(\mathbf{x}(k), 0) = \begin{bmatrix} x_{z_i}(k) \\ y_{z_i}(k) \\ z_{z_i}(k) \end{bmatrix} = \begin{bmatrix} \Phi_{11} \\ \Phi_{22} \\ z_{m_i}(k) \end{bmatrix} \quad (5)$$

즉, \mathbf{h}_i 는 전역 좌표계를 기준으로 저장된 랜드마크의 좌표 \mathbf{m}_i 를 로봇 기준 좌표계로 변환해주는 함수이다. 이는 예측

된 로봇 상태를 이용하여 앞으로 측정될 값의 예측치 $\hat{\mathbf{z}}_i$ 를 계산할 때에도 사용된다. 식 (5)에서 Φ_{11}, Φ_{12} 는 다음과 같다.

$$\begin{aligned}\Phi_{11} &= (x_{m_i}(k) - x_v(k)) \cos(\theta(k)) + \\ &\quad (y_{m_i}(k) - y_v(k)) \sin(\theta(k)) \\ \Phi_{22} &= -(x_{m_i}(k) - x_v(k)) \sin(\theta(k)) + \\ &\quad (y_{m_i}(k) - y_v(k)) \cos(\theta(k))\end{aligned}$$

4. Fiducial Marker Tracking System

본 절에서는 fiducial 마커의 좌표를 측정하는 방법과 측정된 좌표가 어떻게 SLAM에 이용되는지 설명한다.

카메라를 기준으로 하는 카메라 좌표계는 (X_c, Y_c, Z_c) 를 좌표로 가지며 fiducial 마커의 중심을 기준으로 하는 fiducial 마커좌표계 (X_m, Y_m, Z_m) 를 좌표로 가진다. 두 좌표계간의 관계는 그림 8에 나타나 있다. Fiducial 마커 좌표계로부터 카메라 좌표계로의 변환행렬 \mathbf{T}_{cm} 은 식 (6)과 같이 정의된다. 이는 3차원 공간상의 회전요소 $\mathbf{R}_{3 \times 3}$ 와 병진 이동요소 $\mathbf{T}_{3 \times 1}$ 로 구성된다. 벡터의 끝에 1을 추가한 것은 계산을 행렬로 표현하기 위한 homogeneous 표현법으로 인한 것이다.

Remark 1: 본 논문에서 제안하는 fiducial 마커 기반의 SLAM 은 로봇의 중심을 기준으로 하는 로봇좌표계에서 fiducial 마커까지의 거리를 측정값 $\mathbf{z}_i(k)$ 로 사용한다. 이 값은 변환행렬 \mathbf{T}_{cm} 에서 병진 이동요소 $\mathbf{T}_{3 \times 1}$ 와 같다.

$$\begin{aligned}\begin{bmatrix} X_c \\ Y_c \\ Z_c \\ 1 \end{bmatrix} &= \begin{bmatrix} R_{11} & R_{12} & R_{13} & T_x \\ R_{21} & R_{22} & R_{23} & T_y \\ R_{31} & R_{32} & R_{33} & T_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} X_m \\ Y_m \\ Z_m \\ 1 \end{bmatrix} \\ &= \begin{bmatrix} \mathbf{R}_{3 \times 3} & \mathbf{T}_{3 \times 1} \\ \mathbf{0}_{1 \times 3} & 1 \end{bmatrix} \begin{bmatrix} X_m \\ Y_m \\ Z_m \\ 1 \end{bmatrix} = \mathbf{T}_{cm} \mathbf{X}_m\end{aligned}\quad (6)$$

그림 9는 좌표 변환 행렬 \mathbf{T}_{cm} 을 구하는 과정을 도시하고 있다. 카메라 좌표계를 기준으로 fiducial 마커의 위치를 기술하기 위해서 변환행렬 \mathbf{T}_{cm} 을 구하는 과정을 요약하면 다음




그림 10. Fiducial 마커의 좌표계. Fiducial 마커는 정사각형이다. Fiducial 마커상의 4개의 꼭지점 값은 Z축의 값이 모두 0인 평면에 위치한다.

Fig. 10. Coordinates of a fiducial marker. Fiducial markers are exact squares. The vertices of fiducial markers are located on x-y plane.

과 같다.

Step 1. 그림 9(a)와 같이 입력된 원본 영상을 그림 9(b)와 같이 이진화 한다.

Step 2. 이진화를 수행한 후에는 마커를 선별하기 위하여 레이블링을 수행한다.

Step 3. 레이블링된 객체에서 마커를 추출한 후에 그림 9(c)와 같이 이진 이미지의 최외곽을 순회하면서 외곽선을 구한다.

Step 4. 추출된 외곽선에서 4개의 꼭지점을 구한다(그림 9(d)).

Step 5. 추출된 4개의 꼭지점은 영상좌표계 (x_c, y_c) 상에서 기술된다. 따라서 식 (7)과 같이 카메라의 내부(intrinsic) 파라미터로 구성된 행렬 \mathbf{P} 의 역변환을 이용하여 카메라 좌표계 (X_c, Y_c, Z_c) 로 변환한다.

Step 6. 카메라 좌표계와 fiducial 마커 좌표계의 관계를 기술하는 \mathbf{T}_{cm} 을 구하기 위해서 식 (9)의 평가 함수를 도입하고 파라미터 집합을 식 (10)과 같이 정의한다.

Step 7. 비선형 최적화 방법중 하나인 Levenberg-Marquardt 방법을 이용하여 비용함수 식 (9)를 최소화 하는 해집합 식 (10)을 구한다. 보통의 경우 4~5회의 반복에서 미리 정한 문턱값 보다 낮아진다. 이는 카메라로부터 한 프레임의 얻는데 걸리는 시간보다 빠르므로 실시간 구현이 가능하다.

카메라의 내부 파라미터는 영상 좌표계 (x_c, y_c) 와 카메라 좌표계의 관계를 기술하는 변환 행렬의 요소이다 [20]. 식 (7)은 영상 좌표계와 카메라 좌표계의 관계를 나타내고 있다.

$$\begin{bmatrix} hx_c \\ hy_c \\ h \\ 1 \end{bmatrix} = \begin{bmatrix} s_x f & 0 & x_0 & 0 \\ 0 & s_y f & y_0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} X_c \\ Y_c \\ Z_c \\ 1 \end{bmatrix} = \mathbf{P} \begin{bmatrix} X_c \\ Y_c \\ Z_c \\ 1 \end{bmatrix}\quad (7)$$

\mathbf{P} 는 사전에 카메라 calibration 을 통하여 알고 있는 변환이다.

그림 10과 같이 fiducial 마커의 네 꼭지점의 좌표는 마커의 중심을 기준으로 각각 $(-w, w)$, (w, w) , $(-w, -w)$, $(w, -w)$ 이다. 이를 $\mathbf{P}_1 = (-w, w, 1)$, $\mathbf{P}_2 = (w, w, 1)$, $\mathbf{P}_3 = (-w, -w, 1)$, 그리고 $\mathbf{P}_4 = (w, -w, 1)$ 로 설정하고 각 fiducial 마커의 네 꼭지점이 2차원 영상에서 관찰되었을 때의 좌표를 $\mathbf{s}_i = (s_{ix}, s_{iy})$ 로 하자. 다음으로, 비선형 최적화 방법에 쓰일 초기치를 구하기 위하여 다음의 행렬을 다음과 같이 설정한다 [17].

$$\begin{bmatrix} \mathbf{P}_1 & 0 & -s_{1x} \mathbf{P}_1 \\ \mathbf{P}_2 & 0 & -s_{2x} \mathbf{P}_2 \\ \mathbf{P}_3 & 0 & -s_{3x} \mathbf{P}_3 \\ \mathbf{P}_4 & 0 & -s_{4x} \mathbf{P}_4 \\ 0 & \mathbf{P}_1 & -s_{1y} \mathbf{P}_1 \\ 0 & \mathbf{P}_2 & -s_{2y} \mathbf{P}_2 \\ 0 & \mathbf{P}_3 & -s_{3y} \mathbf{P}_3 \\ 0 & \mathbf{P}_4 & -s_{4y} \mathbf{P}_4 \end{bmatrix} \begin{bmatrix} R_{11} \\ R_{12} \\ T_x \\ R_{21} \\ R_{22} \\ T_y \\ R_{31} \\ R_{32} \\ T_z \end{bmatrix} = \mathbf{A} \mathbf{b}\quad (8)$$

SVD를 이용하여 \mathbf{A} 를 분해 한 후 얻어진 \mathbf{UDV}^T 중 \mathbf{V} 의 가장 마지막 행은 비선형 최적화시 초기값으로 사용된다. 이것은 즉, 최소 자승 오차를 가지는 해와 같다.

$\mathbf{R}_i = [R_{1i}, R_{2i}, R_{3i}]^T$ 로 정의하였을 때 \mathbf{R}_3 은 $\mathbf{R}_1 \times \mathbf{R}_2$

로 얻어진다. 이는 평면체의 특성으로 인하여 가능하다. 식 (6)에서 Levenberg-Marquardt의 방법을 이용하여 최적화된 회전 변환 $\mathbf{R}_{3 \times 3}$ 과 병진 이동 벡터 $\mathbf{T}_{3 \times 1}$ 를 구하기 위해서 식 (9)와 같은 평가함수를 도입한다.

$$J = \sum_{i=1}^4 \left[\begin{pmatrix} x_c(i) \\ y_c(i) \end{pmatrix} - f \left(\begin{pmatrix} X_m(i) \\ Y_m(i) \\ Z_m(i) \end{pmatrix}, \phi, \varphi, \psi, \mathbf{T}, f, s_x, s_y, x_0, y_0 \right) \right] \quad (9)$$

파라미터 집합은 식 (10)과 같이 정의한다.

$$\mathbf{X} = (\phi, \varphi, \psi, \mathbf{T}) \quad (10)$$

파라미터 집합 식 (10)의 ϕ, φ, ψ 는 회전변환 행렬 $\mathbf{R}_{3 \times 3}$ 를 Rodrigues의 공식을 통하여 파라미터화 된 값이다. 회전변환 행렬 $\mathbf{R}_{3 \times 3}$ 은 9개의 값을 가지지만 실제로는 yaw, pitch, roll (ϕ, φ, ψ)의 3자유도를 가진다. 따라서 Levenberg-Marquardt의 방법을 이용하여 비선형 최적화를 하기 위해서는 3자유도로 파라미터화 한 후 이를 다시 9개의 요소를 가지는 $\mathbf{R}_{3 \times 3}$ 로 바꾸어 주어야 한다.

5. Landmark and Map Representation

5.1 The State Vector and Covariance

k 단계에서의 로봇 상태벡터 \mathbf{x}_k 와 랜드마크 \mathbf{m}_i 의 추정값을 $\hat{\mathbf{x}}$ 라 하고 그 공분산을 \mathbf{P} 라고 표기한다. $\hat{\mathbf{x}}$ 와 \mathbf{P} 는 관찰된 랜드마크에 따라 동적으로 변하는 벡터와 행렬이다. 즉, 랜드마크가 새롭게 관찰되면 $\hat{\mathbf{x}}$ 와 \mathbf{P} 는 이전 크기보다 하나 더 확장된다. 이 행렬들은 다음과 같이 구성된다.

$$\hat{\mathbf{x}} = \begin{bmatrix} \hat{\mathbf{x}}_v \\ \hat{\mathbf{m}}_1 \\ \hat{\mathbf{m}}_2 \\ \vdots \end{bmatrix}, \mathbf{P} = \begin{bmatrix} \mathbf{P}_{xx} & \mathbf{P}_{xm_1} & \mathbf{P}_{xm_2} & \cdots \\ \mathbf{P}_{m_1x} & \mathbf{P}_{m_1m_1} & \mathbf{P}_{m_1m_2} & \cdots \\ \mathbf{P}_{m_2x} & \mathbf{P}_{m_2m_1} & \mathbf{P}_{m_2m_2} & \cdots \\ \vdots & \vdots & \vdots & \ddots \end{bmatrix} \quad (11)$$

공분산 행렬 \mathbf{P} 는 로봇과 랜드마크들 간의 확률 관계를 표현한다. \mathbf{P}_{m_1x} 의 크기가 크다면 랜드마크 \mathbf{m}_1 은 그 측정치에 대한 신뢰도가 낮은 것을 의미한다. 해당 랜드마크 \mathbf{m}_1 은 측정한지 오래 지났거나 적은 횟수로 관찰되었다는 것을 의미한다. 이는 랜드마크의 삭제 및 추가에 중요한 판단 지표가 된다.

로봇 상태벡터 \mathbf{x}_k 는 로봇을 가장 잘 묘사하는 변수들로 구성된다. 일반적으로 널리 쓰이는 two-wheeled 모바일 로봇의 경우 로봇은 2차원에서의 위치 (x, y) 와 방위각 θ 으로 구성된다. 만약, 3차원 공간상에서 움직이는 로봇(e.g., 로봇팔)의 경우 (x, y, z) 와 수평각 및 수직각 (θ, ϕ) 로 구성된다.

6. Motion Model

6.1 Mobile Robot Platform

본 논문에서 대상으로 하는 시스템은 직접 제작한 4개의 바퀴를 가진 모바일 로봇이다. 조향은 전륜 2륜을 이용하여 하며 후륜 2륜은 고정되어 있다. 모델링에 사용된 로봇은 그림 11과 같다.

6.2 Coordinates System

로봇의 최초 위치를 원점($^G\mathbf{O}$)으로 하는 좌표계를 전역 좌표계라 했을 때 그림 12는 로봇 기준 좌표계와 전역 좌표계의 상관관계를 나타낸다. $\mathbf{P}^G = [x_m, y_m]^T$ 는 전역 좌표계 상에서 랜드마크의 좌표이고 $\mathbf{P}^R = [x_{fi}, y_{fi}]^T$ 는 로봇 좌표




그림 11. 본 논문에서 대상으로 하는 모바일 로봇(위: 실체사진, 아래: CAD모델).

Fig. 11 The mobile robot used in this paper(Top: real picture, Bottom: CAD model).

계 상에서 랜드마크의 좌표를 의미한다. 즉, \mathbf{P}^G 는 \mathbf{m}_i 와 대응되고 \mathbf{P}^R 은 \mathbf{z}_i 와 대응된다. 본 논문에서 식 (5)의 함수 $\mathbf{h}(\cdot)$ 은 $\mathbf{P}^G \rightarrow \mathbf{P}^R$ 의 변환에 해당한다.

6.3 Kinematics Model of a Mobile Robot

그림 11의 로봇에 대한 기구학 모델은 식 (12)와 같다. 로봇의 위치는 $(x_v(k), y_v(k))$ 이다. 제어 입력 u 는 속도 V 와 조향각 β 이다. 이 기구학 모델은 칼만 필터의 예측 단계에서 로봇의 위치를 정하기 위해 사용한다.

$$\begin{bmatrix} x_v(k+1) \\ y_v(k+1) \\ \theta(k+1) \end{bmatrix} = \begin{bmatrix} x_v(k) + \Delta V(k) \cos(\theta(k) + \beta(k)) \\ y_v(k) + \Delta V(k) \sin(\theta(k) + \beta(k)) \\ \theta(k) + \Delta V(k) \frac{\sin(\beta(k))}{l} \end{bmatrix} \quad (12)$$

식 (12)에서 Δ, θ, β 는 차례대로 각각 샘플링 시간, 현재 로봇의 방향(heading), 그리고 조향각에 대한 입력이다. l 은 앞바퀴 중심에서 뒷바퀴 중심까지의 거리(wheel base)를 의미한다.




그림 12. 로봇의 좌표 개념도.

Fig. 12. Concept diagram for robot coordinates.




그림 13. EKF의 동작 개념도.

Fig. 13. Concept diagram for applying EKF to the mobile robot.

7. Extended Kalman Filter (EKF) Solution of SLAM Problem

SLAM 문제는 기구학 모델이 알려진 로봇이 미지의 시작 점으로부터 출발하여 특징점(feature)이나 랜드마크를 지나면서 로봇의 위치와 랜드마크의 위치를 동시에 추정하는 것으로 정의할 수 있다. 본 논문에서 특징점이나 랜드마크는 동의어이다. 로봇 내부의 상태만을 이용하여 로봇의 위치를 추정하는 문제를 dead reckoning하는데, SLAM 문제는 기구학 모델에 기반한 dead reckoning과 로봇에 장착된 센서가 외부 환경을 관찰하여 얻어진 얻은 정보를 이용하여 물리적 불확실성을 확률적으로 보정하고자 하는 것이다.

SLAM 문제를 확률적으로 해석하는 것은 센서의 불확실성에 근거한다. 일반적으로 제조된 센서는 정확한 수치값으로부터 일정 범위를 가지는 Gaussian분포를 가진다. 따라서, 이러한 불확실한 센서들의 집합으로부터 타당한 결과치를 예측하는 것은 확률론을 이용하는 것이 적합하다. 확률론을 도입함으로써 하나의 값이 아닌 일정 범위를 일정 오차 내에서 다룰 수 있게 된다. 이러한 확률론에 기반하여 불확실한 값으로부터 의미있는 값을 알아내기 위하여 Kalman 필터가 사용된다. SLAM에서는 비선형 시스템에 대하여 확장된 EKF를 주로 사용한다. 또한 많은 연구들이 EKF를 이용하여

추정 문제를 해결해왔다[2,18-20].

본 논문에서는 로봇과 실세계의 비선형 특성을 다루기 위하여 EKF를 이용한다. EKF를 이용한 SLAM 해법은 두 가지 단계로 이루어진다. 첫번째 단계는 예측(prediction)으로 외부에서 유입된 정보 없이 내부 상태를 갱신하는 것이다. 두번째 단계는 외부에서 유입된 정보를 이용하여 예측 단계에서 커진 오차를 줄이는 갱신(update) 단계이다. 이어지는 7.1, 7.2 절에서는 예측 단계와 갱신 단계에 대하여 자세히 설명한다.

7.1 Prediction

확장 칼만필터를 이용한 SLAM의 가장 처음 단계는 상태 예측이다. 즉, 로봇 기구학과 관찰된 주행거리계 센서를 통하여 현재 상태를 갱신 하는 것이다. 이는 그림 13(a) 단계의 로봇이 제어 입력 $u(k-1)$ 을 통하여 (b) 단계로 움직이는 것을 추정하는 것과 같다. 결과적으로 오차가 존재하는 점선 (b) 로봇의 위치($\hat{\mathbf{x}}^-(k)$)를 현재 상태로 추정하게 된다. 오차는 이때 증가하며 측정값을 이용한 갱신 단계에서 Kalman 이득에 의하여 줄어들게 된다. 예측단계의 수식은 아래와 같다.

$$\hat{\mathbf{x}}^-(k) = \mathbf{f}(\hat{\mathbf{x}}^+(k-1), \mathbf{u}(k-1), 0)$$

$$\hat{\mathbf{z}}^-(k) = \mathbf{h}(\hat{\mathbf{x}}^-(k), 0)$$

$$\mathbf{P}^-(k) = \mathbf{f}_x(k-1)\mathbf{P}^+(k-1)\mathbf{f}_x^T(k-1) + \mathbf{f}_u(k-1)\mathbf{Q}(k)\mathbf{f}_u^T(k-1)$$

$$\mathbf{f}_x(k-1) = \left. \frac{\partial \mathbf{f}}{\partial \mathbf{x}} \right|_{(\hat{\mathbf{x}}^+(k-1), \mathbf{u}(k-1), 0)}$$

$$\mathbf{f}_u(k-1) = \left. \frac{\partial \mathbf{f}}{\partial \mathbf{u}} \right|_{(\hat{\mathbf{x}}^+(k-1), \mathbf{u}(k-1), 0)}$$

$\mathbf{f}_x(k-1) \in \mathbb{R}^{m+dn \times m+dn}$ 이고 $\mathbf{f}_u(k-1) \in \mathbb{R}^{m+dn \times m+p}$ 이다. $\mathbf{Q}(k)$ 는 $\begin{pmatrix} \mathbf{Q}_v & \mathbf{0}_{1 \times dn} \\ \mathbf{0}_{dn \times 1} & \mathbf{0}_{dn \times dn} \end{pmatrix}$ 를 나타낸다. $\mathbf{Q}(k)$ 는 $\mathbb{R}^m \times m$ 의 크기를 가진다.

7.2 Update

예측 단계에서는 예측한 로봇 상태변수 $\hat{\mathbf{x}}^-(k)$ 를 기반으로 측정값의 예측치 $\hat{\mathbf{z}}_i^-(k)$ 를 구했다. 갱신 단계에서는 센서를 통하여 랜드마크의 실제 측정값 $\mathbf{z}_i(k)$ 를 얻어낸 후 $\hat{\mathbf{z}}_i^-(k)$ 와 차이를 비교하여 예측 단계에서 계산된 상태의 오차를 줄인다. 이는 그림 12에서 (b) 단계 점선에서($\hat{\mathbf{x}}^-(k)$) 오차가 줄어든 실선($\hat{\mathbf{x}}^+(k)$)으로 위치를 수정 하는 것과 같다. 마찬가지로 랜드마크의 위치도 $\hat{\mathbf{z}}_i(k)$ (점선)에서 $\mathbf{z}_i(k)$ (실선)으로 이동된다. 만약 로봇이 전진 했다면 랜드마크는 그만큼 다가올 것이다. 만약 예측단계에서 계산한 측정치 추정값 $\hat{\mathbf{z}}_i(k)$ 에 오차가 크게 존재한다면 $\mathbf{z}_i(k) - \hat{\mathbf{z}}_i(k)$ 는 클 것이다. 이러한 정보를 기반으로 예측단계에서 구한 $\hat{\mathbf{x}}^-(k)$ 는 EKF를 통하여 $\hat{\mathbf{x}}^+(k)$ 로 갱신된다.

확장칼만필터를 이용하여 구한 칼만이득 $\mathbf{K}(k)$ 와 측정값의 예측치와 실측치의 차이 $\mathbf{z}_i(k) - \hat{\mathbf{z}}_i(k)$ 는 서로 곱해져 예측 단계에서 구한 $\hat{\mathbf{x}}^-(k)$ 에 더해진다. 이로써 joint SLAM 벡터의 최종 추정치 $\hat{\mathbf{x}}^+(k)$ 가 확정된다. 갱신 단계의 수식은 식 (13)과 같다.

$$\begin{aligned}
\mathbf{K}(k) &= \mathbf{P}^-(k) \mathbf{h}_x^T(k) (\mathbf{h}_x(k) \mathbf{P}^-(k) \mathbf{h}_x^T(k) + \mathbf{h}_v(k) \mathbf{R}(k) \mathbf{h}_v^T(k))^{-1} \\
\hat{\mathbf{x}}^+(k) &= \hat{\mathbf{x}}^-(k) + \mathbf{K}(k) (\mathbf{z}(k) - \hat{\mathbf{z}}(k)) \\
\mathbf{P}^+(k) &= \mathbf{P}^-(k) - \mathbf{K}(k) \mathbf{h}_x(k) \mathbf{P}^-(k) \\
\mathbf{h}_x(k) &= \left. \frac{\partial \mathbf{h}}{\partial \mathbf{x}} \right|_{(\hat{\mathbf{x}}^-(k), 0)} \\
\mathbf{h}_v(k) &= \left. \frac{\partial \mathbf{h}}{\partial \mathbf{v}} \right|_{(\hat{\mathbf{x}}^-(k), 0)}
\end{aligned} \quad (13)$$

8. Map Management

8.1 Landmark Addition

랜드마크는 로봇의 위치를 원점으로 하는 좌표계에서 관찰된다. Laser range finders의 경우에는, 유클리디안 좌표를 바로 알 수 없고 거리나 방위각 등의 형태로 관찰되기도 한다. 만약 측정 함수 \mathbf{h}_i 를 이용하여 측정치가 바로 랜드마크 \mathbf{m}_i 로 역변환 될 수 있다면 joint SLAM 상태벡터 \mathbf{x} 는 다음과 같이 확장된다.

$$\begin{bmatrix} \mathbf{x}_v \\ \mathbf{m}_1 \\ \mathbf{m}_2 \end{bmatrix} \rightarrow \begin{bmatrix} \mathbf{x}_v \\ \mathbf{m}_1 \\ \mathbf{m}_2 \\ \mathbf{m}_3 \end{bmatrix} \quad (14)$$

이것은 예를들면, 2개의 랜드마크가 이미 추가되어 있고 3번째 랜드마크가 관찰된 경우이다. \mathbf{m}_3 의 초기값은

$$\mathbf{m}_3 = \begin{bmatrix} x_v(k) + x_{z_i}(k) \cos(\theta(k)) - y_{z_i}(k) \sin(\theta(k)) \\ y_v(k) + x_{z_i}(k) \sin(\theta(k)) + y_{z_i}(k) \cos(\theta(k)) \\ z_{z_i}(k) \end{bmatrix} \quad (15)$$

와 같이 계산된다. 새롭게 추가된 랜드마크 \mathbf{m}_3 에 대한 covariance는

$$\mathbf{P}_{new} = \begin{bmatrix} \mathbf{P}_{xx} & \mathbf{P}_{xm_1} & \mathbf{P}_{xm_2} & \mathbf{P}_{xx} \frac{\partial \mathbf{y}_i}{\partial \mathbf{x}_v}^T \\ \mathbf{P}_{m_1x} & \mathbf{P}_{m_1m_1} & \mathbf{P}_{m_1m_2} & \mathbf{P}_{m_1x} \frac{\partial \mathbf{y}_i}{\partial \mathbf{x}_v}^T \\ \mathbf{P}_{m_2x} & \mathbf{P}_{m_2m_1} & \mathbf{P}_{m_2m_2} & \mathbf{P}_{m_2x} \frac{\partial \mathbf{y}_i}{\partial \mathbf{x}_v}^T \\ \frac{\partial \mathbf{y}_i}{\partial \mathbf{x}_v} \mathbf{P}_{xx} & \frac{\partial \mathbf{y}_i}{\partial \mathbf{x}_v} \mathbf{P}_{xm_1} & \frac{\partial \mathbf{y}_i}{\partial \mathbf{x}_v} \mathbf{P}_{xm_2} & \frac{\partial \mathbf{y}_i}{\partial \mathbf{x}_v} \mathbf{P}_{xx} \frac{\partial \mathbf{y}_i}{\partial \mathbf{x}_v}^T + \frac{\partial \mathbf{y}_i}{\partial \mathbf{h}_i} \mathbf{R} \frac{\partial \mathbf{y}_i}{\partial \mathbf{h}_i}^T \end{bmatrix} \quad (16)$$

와 같이 갱신된다. 이는 식 (13)으로부터 유도된다.

8.2 Landmark Deletion

랜드마크를 삭제하는 것은 단순히 상태벡터에서 해당 요소를 제거하는 것이다. 만약 3개의 랜드마크 중 2번째 랜드마크가 삭제될 경우는 식 (17)과 같다 [19].




그림 14. 모의 실험에서 사용하는 경로.

Fig. 14. The path used in the simulations.

$$\begin{bmatrix} \mathbf{x}_v \\ \mathbf{m}_1 \\ \mathbf{m}_2 \\ \mathbf{m}_3 \end{bmatrix} \rightarrow \begin{bmatrix} \mathbf{x}_v \\ \mathbf{m}_1 \\ \mathbf{m}_3 \end{bmatrix} \quad (17)$$

Covariance는 식 (18)과 같이 축소된다.

$$\begin{bmatrix} \mathbf{P}_{xx} & \mathbf{P}_{xm_1} & \mathbf{P}_{xm_2} & \mathbf{P}_{xm_3} \\ \mathbf{P}_{m_1x} & \mathbf{P}_{m_1m_1} & \mathbf{P}_{m_1m_2} & \mathbf{P}_{m_1m_3} \\ \mathbf{P}_{m_2x} & \mathbf{P}_{m_2m_1} & \mathbf{P}_{m_2m_2} & \mathbf{P}_{m_2m_3} \\ \mathbf{P}_{m_3x} & \mathbf{P}_{m_3m_1} & \mathbf{P}_{m_3m_2} & \mathbf{P}_{m_3m_3} \end{bmatrix} \rightarrow \begin{bmatrix} \mathbf{P}_{xx} & \mathbf{P}_{xm_1} & \mathbf{P}_{xm_3} \\ \mathbf{P}_{m_1x} & \mathbf{P}_{m_1m_1} & \mathbf{P}_{m_1m_3} \\ \mathbf{P}_{m_3x} & \mathbf{P}_{m_3m_1} & \mathbf{P}_{m_3m_3} \end{bmatrix} \quad (18)$$

실제 구현에서 랜드마크 삭제는 오랫동안 관찰되지 않거나 데이터 연관이 실패 하였을 때 수행한다.

IV. Simulations

본 장에서는 제한한 fiducial 마커를 이용한 SLAM의 성능을 컴퓨터 모의실험을 통하여 평가한다. 모의 실험에서는 그림 14와 같은 90m×80m 크기의 굴곡있는 복도형 경로를 가지는 가상 공간에 대하여 EKF를 이용한 fiducial 마커 기반의 SLAM을 수행한다. 모의 실험에서는 실제 상태를 알 수 있으므로 SLAM을 이용하여 추정된 상태와의 비교를 통하여 의미 있는 결과를 도출 할 수 있다.

실험에서는 카메라의 센서 관찰 범위를 수정하여 field of view(FOV)안에 관찰되는 fiducial 마커의 개수를 변화시키면서 제안된 방법의 견실성(robustness)을 검증한다. 실험은 총 3번의 반복으로 구성된다. 첫 번째 루프에서는 상대적으로 덜 정확한 추정을 하게 된다. 두 번째 루프에서는 이전에 관찰되었던 정보를 기반으로 좀 더 정확한 추정치를 얻을 수 있다. 세 번째 루프에서는 이전 실험 보다 더 정확한 데이터를 얻을 수 있다.

1. Simulation Setup

Fiducial 마커의 위치는 사전에 저장하지 않는다. 다만, 모의실험 프로그램에서 실제 센서의 관찰 범위에 대한 제약을 표현하는 함수에서만 그 정보를 이용한다. 즉, 실제 구현 시와 마찬가지로 로봇이 사전에 랜드마크의 정보를 알 수 없는 것과 같다.

표 1은 로봇의 기구적 제약 조건에 대한 값을 나타낸다. 실제 로봇은 일정 샘플링 시간에 조향 할 수 있는 모터 성능이 정해져 있으며 최대 속도 및 최대 조향각도 정해져 있다.

로봇의 실제 속도는 알 수 없다. 속도는 센서에 의해서(eg, 광학식 엔코더) 측정하게 되는데 이 과정에서 오차가 존재하게 된다. 조향각 또한 마찬가지로 오차를 가지게 된다. 따라서 이러한 부분은 잡음항을 추가하여 모델링 할 수 있다. 속도 및 조향각에 대한 불확실성은 식 (19)와 같이 모델링 된다.

표 1. 로봇의 기구적 제약조건에 대한 파라미터.

Table 1. Parameter that models mechanical constraint of mobile robot.

Parameter	Value	Units
최대 속도	1.1	m/s
최대 조향각	120	도
최대 순간 조향각	60	도
샘플링 시간	0.025	초
Wheel Base	1.5	m

$$Q_v = E[\mathbf{w}\mathbf{w}^T] = \begin{bmatrix} \sigma_v^2 & 0 \\ 0 & \sigma_\theta^2 \end{bmatrix} \quad (19)$$

본 논문에서 $\sigma_v^2 = 0.1$ (m/s)이고 $\sigma_\theta^2 = (1.0 \times \frac{\pi}{180})$ rad 이다. 이 값은 대상 플랜트의 특성으로부터 정할 수 있다.


실제 환경에서 카메라가 한 FOV에서 관찰 할 수 있는 fiducial 마커의 개수는 한계가 있다. 이 갯수는 카메라의 성능이나 렌즈의 사양에 따라 다르다. 마찬가지로 본 논문의 모의실험에서도 이러한 부분을 모델링 한다. 즉, 고의로 관찰 범위를 통제하여 한 샘플링시간 동안 관찰할 수 있는 범위를 제한 한다.

때에 따라 한 화면에 보이는 fiducial marker의 개수는 요구 되는 랜드마크의 개수보다 적어 질 수 있다. 본 장에서는 영상에서 fiducial marker가 1개만 나타날 때에 대한 결과를 이용하여 제안된 방법의 견실성에 대하여 평가한다.


2. Simulation results

2.1 Dead Reckoning

그림 15는 비전 센서가 없이 위치추정을 수행한 것이다. 각 축 오차는 시뮬레이션에서 얻어진 절대 좌표의 자료를 기준으로 한다. 시뮬레이션에서 얻어진 절대 좌표는 EKF를 통




(a) Continuously increasing errors. These data are useless because of big difference from the ground truth data.




(b) The trace estimated from odometer information (dash-dot). There are big differences between estimated trace and ground truth data(dotted).

그림 15. 주행거리계 정보만 이용하여 추정된 결과.


Fig. 15. Estimation results obtained from odometer information.



(a) The trace after rounding once with a camera.



(b) The trace after rounding twice with a camera.



(c) The trace after rounding three times with a camera.

그림 16. 카메라를 센서모델에 포함시켜 SLAM을 수행한 결과.

Fig. 16. SLAM result after including the camera sensor model.

하여 예측한 값이 아닌 식 (12)로 얻어낸 오차가 없는 좌표 값을 의미한다. 그림 15에서 오차가 꾸준히 발산하는 것을 볼 수 있다.

추정치가 약 4m 이상 벗어나 실제 로봇의 위치와 많은 차이를 보인다. 이로서 비전 센서가 없이 주행거리계만으로 위치를 추정하는 것은 불가능하다고 할 수 있다. 실제 환경에서는 마찰력, 미끄러짐 등으로 인하여 같은 효과가 발생한다. 주행거리계만 이용한 dead reckoning은 위치인식 자료로 활용하기 힘든 사례를 보여준다.

2.2 One Fiducial Marker at a Scene

그림 16(a)-(c)는 비전 센서 모델이 추가된 이후 같은 경로를 3번 순회하는 동안의 경로 변화를 나타낸다. 그림 16(a)에서는 목표 경로와 추정 경로가 불일치 하는 부분이 나타난다. 이러한 현상은 그림 16(c)에서는 거의 관찰 되지 않는다. 하나의 카메라 영상에 하나의 fiducial 마커만 보이더라도 추정 오차 평균 0.3m 이내의 위치 인식 수행이 가능하다. 반복적으로 위치 이동을 시도할 경우 정확도는 점차 증가하게 되어 추정오차 평균은 0에 근접한다.

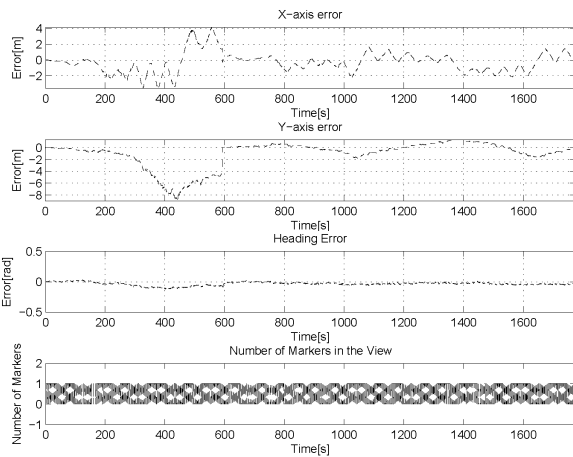




그림 17. 시야에 보이는 fiducial 마커가 1개인 경우의 오차.
Fig. 17. Estimation results with a camera.



(a) The trace after rounding once with two fiducial markers in a frame.



(b) The trace after rounding twice with two fiducial markers in a frame.

그림 18. 한 프레임에 fiducial 마커가 다수 관찰되는 환경에서의 경로 추정 결과.

Fig. 18. SLAM result after including the camera sensor model.

그림 17은 비전 센서를 장착하고 fiducial 마커를 관측하면서 이동했을 때 그림 14의 경로에 대하여 ground truth 자료에 대한 오차 그래프이다. 그림 16(a), (b), (c)는 5m마다 배치된 fiducial 마커와 4m의 관측거리를 가지는 센서 모델에 대한 궤적 그래프이다. 주어진 센서 모델의 경우 시야에 fiducial 마커가 1개 밖에 관측되지 않는다. 한 개의 랜드마크만 가지는 상황은 대부분의 SLAM 연구에서 가정하지 않는 상황이므로 매우 열악한 환경이라 할 수 있다. 실험에서 한 영상에서 관찰된 fiducial 마커의 개수는 그림 17의 최하단 그래프에 나타나 있다.




그림 19. 한 프레임에 fiducial marker가 2개 이상인 경우의 오차 그래프. 최대 오차는 실험이 반복될 수록 감소한다. 또한 평균오차도 관찰 횟수가 늘어날수록 평균이 0에 근접한다.

Fig. 19. Estimation results with more than two fiducial markers in a frame. As the experiments are repeated, the maximum error decreases. Likewise as the number of observation increases, the average of errors goes to 0.

2.3 Two or More Fiducial Marker at a Scene

그림 18(a), (b)는 한 프레임에 fiducial 마커가 2개 이상 나타나는 경우의 경로 궤적을 나타내고 있다. 한 프레임에 fiducial 마커가 두 개 이상 등장하게 되면 정확도가 높아지는 것을 관찰할 수 있다. 또한 오차 그래프 그림 18로부터 fiducial 마커의 FOV에서 등장하는 개수가 많을 수록 추정 정확도가 높아지는 것을 알 수 있다.

V. Conclusion

본 논문에서는 fiducial 마커를 이용하여 확장 칼만필터 기반의 SLAM을 수행하였다. Fiducial 마커는 측정 모델을 간단히 할 뿐만 아니라 시간 지연 없는 랜드마크 추가를 가능하게 하였다. 즉, 기존의 monocular SLAM [2]이 특징점을 여러 시점에서 관찰해야 하나의 특징점을 등록할 수 있는 것과 달리 단 한 장의 프레임만 관측 하더라도 랜드마크로서 fiducial 마커를 등록할 수 있다.

사전에 설치된 랜드마크에 대하여 계측하는 기존 연구 [9]와 달리 본 연구에서 제한하는 랜드마크 모델은 무작위로 배치될 수 있다. 또한 초음파 위성을 이용하는 [10]의 경우 랜드마크에는 별도의 전원이 필요하지만 제안된 방법은 랜드마크가 전원을 필요로 하지 않는다. 따라서 장치 구성이 간단해지고 탑재가 손쉬우며 경제적이다.

기존에는 cross-correlation 연산을 통하여 데이터 연관 문제를 해결하였다. 이는 때때로 잘못된 데이터 연관으로 추정 오차를 크게 하는 원인이 되어왔다. 본 논문에서는 산업계에서 널리 쓰이는 만큼 그 안정성이 확보된 디지털 바코드를 활용하여 데이터 연합 문제에 있어 신뢰성을 높였다.

본 논문에서는 영상을 이용한 SLAM에 있어 신뢰도를 향상시키기 위하여 인공적인 랜드마크를 사용하되 그 기하학적 조건을 사전에 설정할 필요가 없는 새로운 방법을 제안

하였다. 또한 인공적인 랜드마크는 환경에 시각적 영향을 최소화 할 수 있도록 적외선 영역에서 감지되도록 할 수 있다.

본 논문에서 제안한 방법은 가정용 로봇이나 서비스 로봇에 적용되어 낮은 가격에 높은 신뢰도를 가지는 위치추정을 가능하게 할 것이다.

참고문헌

- [1] T. Bailey and H. Durrant-Whyte, "Simultaneous localisation and mapping (slam) : Part ii state of the art," *IEEE Robotics and Automation Magazine*, 2006.
- [2] A. J. Davison, I. Reid, N. Molton, and O. Stasse, "MonoSLAM: Real-time single camera slam," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 29, no. 6, June 2007.
- [3] J. Andrade-Cetto and A. Sanfeliu, "Environment Learning for Indoor Mobile Robots. A Stochastic State Estimation Approach to Simultaneous Localization and Map Building" *Springer-Verlag Berlin and Heidelberg GmbH & Co. K*, 2006.
- [4] A. Davison, "Active search for real-time vision," *Computer Vision*, 2005. ICCV 2005. *Tenth IEEE International Conference on*, vol. 1, pp. 66-73, Oct. 2005.
- [5] G. Desouza and A. Kak, "Vision for mobile robot navigation: a survey," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 24, no. 2, pp. 237-267, Feb 2002.
- [6] M. Betke and L. Gurvits, "Mobile robot localization using landmarks," *IEEE Transactions on Robotics and Automation*, vol. 13, no. 2, pp. 251-263, April 1997.
- [7] I. Shimshoni, "On mobile robot localization from landmark bearings," *IEEE Transactions on Robotics and Automation*, vol. 18, no. 6, pp. 971-976, Dec 2002.
- [8] V. Ayala, J. H. F. Lerasle, and M. Devy, "Visual localization of a mobile robot in indoor environments using planar landmarks," in *Proceedings of the 2000 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 275-280, 2000.
- [9] "StargazorTM," Hagisonic, South Korea, Daejeon. [Online]. Available: <http://www.hagisonic.com/>
- [10] "U-safTM," Korea LPS, South Korea, Pusan. [Online]. Available: http://korealps.co.kr/bbs/products_model.html
- [11] M. Fiala, "Artag, a fiducial marker system using digital techniques," in *Proceedings of the Computer Vision and Pattern Recognition (CVPR'05)*, 2005.
- [12] N. Y., K. M., and Y. N., "Localization of wearable users using invisible retro-reflective markers and an ir camera," in *Proceedings of SPIE Electronic Imaging*, vol. 5664, pp. 563-570, 2005.
- [13] M. Fiala, "Artag revision 1. a fiducial marker system using digital techniques," Institute for Information Technology, Tech. Rep. NRC/ERB-1117, November 2004.
- [14] H. Kato and M. Billinghurst, "Marker tracking and hmd calibration for a video-based augmented reality conferencing system," in *Proceedings of the 2nd International Workshop on Augmented Reality (IWAR 99)*, San Francisco, USA, Oct. 1999.
- [15] W. Daniel and S. Diester, "Artoolkitplus for pose tracking on mobile devices," in *Proceedings of 12th Computer Vision Winter Workshop (CVWW'07)*, 2007.
- [16] M. Fiala, "Comparing artag and artoolkit plus fiducial marker systems," in *IEEE International Workshop on Haptic Audio Visual Environments and their Applications*, Ottawa, Ontario, Canada, 2005.
- [17] T. Okuma, K. Sakaue, H. Takemura, and N. Yokoya, "Real-time camera parameter estimation from images for a mixed reality system," in *Proceedings of 15th International Conference on Pattern Recognition*, vol. 4, pp. 482-486, 2000.
- [18] M. W. M. G. Dissanayake, P. Newman, S. Clark, H. F. Durrant-Whyte, and M. Csorba, "A solution to the simultaneous localization and map building (slam) problem," *IEEE Transactions on Robotics and Automation*, vol. 17, no. 3, pp. 229-241, June 2001.
- [19] A. J. Davison and N. Kita, "Sequential localization and map-building for real-time computer vision and robotics," *Robotics and Autonomous Systems*, vol. 36, no. 4, pp. 171-183, 2001.
- [20] A. J. Davison, "Mobile robot navigation using active vision," Ph.D. dissertation, Department of Engineering Science-University of Oxford, 1998.



임 현

2008년 인하대학교 전자공학 공학사
2008년~현재 인하대학교 대학원 전기공학과 석사과정 재학 중
관심분야는 SLAM, Optimal Estimation, Structure from Motion(SfM), 모바일로봇.



이 영 삼

1997년 인하대학교 전기공학 공학사
1999년 인하대학교 전기공학과 석사
2003년 서울대학교 전기컴퓨터공학부 (박사)
2004년~현재 인하대학교 조교수

관심분야는 임베디드 시스템, 디지털 제어, CACSD(Computer-aided Control System Design) 소프트웨어



양 지 혁

2006년 인하대학교 전자공학 공학사
2006년~현재 인하대학교 대학원 전기공학과 통합과정 재학 중
관심분야는 RCP, Magnetic Levitation, Mobile Robot.



김 진 길

1978년 서울대학교 전기공학 공학사.
1983년 University of Iowa(공학석사)
1985년 University of Iowa(수학석사)
1988년 University of Iowa(공학박사)
1988년~현재 인하대학교 교수

관심분야는 이족 보행 로봇 시스템 제작/개발, 지능제어 시스템 설계, 다족 보행 로봇 시스템 개발