

工學碩士 學位論文

적외선 레인지파인더 센서를 이용한  
이동로봇용 환경지도 작성

**Environmental Map Building for a Mobile Robot  
Using Infrared Range-finder Sensors**

指導教授 河 潤 秀

2002 年 8 月

韓國海洋大學校 大學院

制 御 計 測 工 學 科

金 憲 熙

# 목 차

<b>Abstract</b> .....	iii
<b>제 1 장 서론</b> .....	1
<b>제 2 장 환경지도 작성용 적외선 레인지파인더 센서</b> .....	5
2.1 환경지도 작성용 센서 .....	5
2.2 PB9-01 적외선 레인지파인더 .....	8
2.3 센서의 특성분석실험 .....	10
2.2.1 실험환경 및 방법 .....	11
2.2.2 실험 및 분석결과 .....	12
<b>제 3 장 신경회로망을 이용한 비선형 바이어스오차 보정</b> .....	19
3.1 신경회로망의 개요 .....	19
3.1.1 다층 퍼셉트론 .....	19
3.1.2 Levenberg-Marquardt 알고리즘 .....	20
3.2 비선형 바이어스오차 보정 .....	22
3.2.1 신경회로망의 구조 .....	22
3.2.2 신경회로망의 학습 .....	23
3.2.3 검증실험 .....	26

제 4 장 이동로봇용 환경지도 작성 .....	28
4.1 점유격자지도(Occupancy grids map) .....	29
4.2 확률적 접근 .....	30
4.2.1 베이지안 추론 .....	30
4.2.2 우도(Likelihood) 및 우도율(Likelihood ratio) .....	31
4.2.3 데이터 융합(Data fusion) .....	32
4.3 센서 모델링 .....	33
4.4 지역지도의 생성 .....	37
4.5 전역지도의 갱신 .....	38
제 5 장 실험 및 고찰 .....	40
5.1 대상 로봇시스템 .....	41
5.1.1 주모듈 .....	42
5.1.2 보조모듈 .....	43
5.1.3 소프트웨어 .....	44
5.2 실험환경 .....	46
5.3 결과 및 검토 .....	47
제 6 장 결론 .....	50
참고문헌 .....	52

# **Environmental Map Building for a Mobile Robot Using Infrared Range-finder Sensors**

*Hon-Hui Kim*

*Department of Control and Instrumentation Engineering,  
Graduate School, Korea Maritime University*

## **ABSTRACT**

The use of infrared range-finder sensors in the environmental recognition system for mobile robot has the advantage of low sensing cost compared with the use of other vision sensors, such as laser range-finder and CCD camera. This paper presents a methodology building the high accuracy environmental map using a mobile robot with low cost infrared range-finder sensors. In the map building using an infrared range-finder sensor, the errors due to non-linearity, specular reflection are contained. In this paper, therefore, the error due to non-linearity is compensated using a neural network. The neural network used consists of multi-layer perceptron and Levenberg-Marquardt algorithm is applied to learn it. And also, the random error of readings and the uncertainty of environment are taken into sensor modeling at probabilistic approach. The map is represented by occupancy grid framework and updated by the Bayesian estimation mechanism. The effectiveness of the proposed method is verified through experiments.

# 제 1 장 서 론

이동로봇이 다양한 환경에서 주어지는 목표점까지 자율적으로 이동하기 위해서는 환경에 대한 지도정보가 필요하다[1][2]. 이러한 지도는 주어진 환경을 미리 입력하는 방법이 일반적이나, 사람의 접근이 어려운 방사능 유출지역 등과 같이 위험에 노출된 특수환경에서는 장애물 등의 정확한 위치정보를 사전에 입력하는 것이 쉽지 않다. 또한 로봇의 사용 환경이 시간에 따라 변화하는 경우에는 입력한 위치정보의 수정작업이 불가피하다. 따라서 이동로봇은 임무완수의 효율성을 위해 이러한 위험 지역이나 동적환경 속에서도 자율적으로 이를 인지하여 지도를 형성할 수 있어야 한다[3].

환경지도 작성을 위한 시각센서로 초음파 센서, 레이저 레인지파인더, CCD카메라 등이 일반적으로 사용된다. 레이저 레인지파인더는 넓은 범위의 장애물에 대한 고정도의 각도 및 거리정보를 실시간적으로 제공할 수 있으나 고가의 가격부담이 따른다. 또한 CCD카메라는 방대한 양의 데이터를 처리해야 하는 부담이 있어 실시간성을 보장할 수 없다. 반면 초음파 센서는 시스템 구성이 간단하고 계산과정이 빠르며 센싱비용이 저렴한 이유로 이동로봇용 시각센서로서 주로 이용된다[4][5]. 그러나 초음파 센서를 이용하여 시각시스템을 구성할 경우에는 넓은 지향각으로 인한 방향 부정확성, 경면반사, 다중반사 등의 물리적 특성에 기인한 센싱 오류를 고려해야 한다[6]. 이를 극복하기 위해 둘 이상의 센서를 사용하여 배열위치, 각 센서의 구동주기, 구동주파수 등을 적절하게 조절하는 등

다양한 연구가 진행되고 있다[7][8][9]. 특히 초음파 센서를 이용한 시각 시스템으로 가장 일반적인 형태는 초음파 센서링을 구성하는 것으로, 이는 넓은 범위에 대한 많은 환경정보를 얻음으로써 센싱오류에 대해 어느 정도는 보완책이 될 수 있다[10]. 그러나 이러한 경우, 센싱비용이 증가하게 되며 이웃하는 센서에 대한 간섭오차를 피하기 위해 구동주기를 적절히 조절해주어야 하므로 이에 따른 시간지연과 더불어 전체적인 시스템의 복잡성을 초래한다.

한편 이동로봇의 시각센서를 이용한 환경지도 작성에 관한 방법으로 특징 추출법과 격자식 방법을 들 수 있다. 특징추출에 의한 지도작성은 주어진 환경의 평면(Plane), 구석(Corner), 모서리(Edge) 등을 검출하여 이를 트리(Tree) 등의 형태로 저장하는 방법으로, 특징점에 대한 비교적 정확한 정보를 얻을 수 있으나 이를 이용한 장애물 회피, 경로설정 등의 응용에 어려움이 따른다. 반면 격자식 방법은 주어지는 환경을 이차원 또는 삼차원 격자로 나눈 후 해당되는 셀에 가중치를 부여하여 표현하는 방법으로, 셀의 크기에 따라 정밀성과 계산시간이 결정되는 한계가 있으나 구체적인 환경표현이 가능하여 장애물의 회피, 경로계획 등의 응용에 접근이 용이하다[3][8].

Moravec과 Elfe는 최초로 점유격자방식의 환경지도 작성법을 제안하였다[3][9]. 이들은 초음파 센서의 넓은 지향각으로 인한 방향 부정확성의 오류를 극복하기 위해 확률모델을 세우고 이를 근거로 주위의 환경정보를 표현하였으며, 격자정보의 추정문제에 있어 베이저안 법칙에 근거한 확률 추론법을 적용하였다. 또한 Cho와 Moravec은 센서의 확률모델을 구하는

문제에 있어 경면반사나 다중반사에 따른 센싱오류를 더불어 고려함으로써 비교적 양질의 지도 작성법을 제안하였다[11]. 이는 지도 작성에 있어서 초음파 센서의 물리적 특성에 따른 오류를 보완하는 효과적인 해결책이라 할 수 있으며, 이를 근간으로 하는 다양한 방법들이 제시됨으로써 레이저 레인지파인더와 같은 고가의 비전센서에 비해 저렴한 비용으로 효과적인 환경지도 작성의 구현이 가능해졌다. 그러나 복잡한 환경의 표현 등 고정도를 요하는 작업에 있어서는 여전히 그 한계를 극복할 수 없었다.

이에 센싱비용의 절감과 고정도의 환경지도 작성을 동시에 만족하기 위해서는 초음파 센서의 단점을 보완하면서 레이저 레인지 파인더와 같은 우수한 성능을 가지는 환경인식용 센서에 대한 연구가 절실히 요구되어진다. 이러한 측면에서 적외선 레인지파인더는 염가의 가격으로 구입이 가능하며, 하나의 센서로부터 넓은 범위의 장애물에 대한 방위 및 거리 정보를 동시에 획득할 수 있다. 또한 각도분해능이 비교적 우수하므로 요구되는 조건에 대하여 그 해결책이 될 수 있을 것이다. 그러나 이를 이동로봇용 환경지도 작성에 응용하기 위해 반드시 필요한 센서의 물리적 특성에 대하여 상세히 보고된 바는 많지 않다.

따라서 본 논문에서는 적외선 레인지파인더를 이용한 저비용, 고정도의 이동로봇용 환경지도 작성법을 제안한다. 이를 위한 선행과정으로 센서의 물리적 특성을 분석하고 그 중 환경지도 작성에 부정적 영향을 미칠 수 있는 요인을 찾아 이에 대한 해결책을 제시한다. 또한 지도작성에 필요한 센서의 확률모델과 이를 기반으로 하는 환경지도 작성법을 제안한다. 제

안된 방법에 대한 유효성은 실험을 통하여 검증된다.

본 논문의 구성은 다음과 같다. 제 2장에서는 적외선 레인지파인더를 소개하고 그 물리적 특성을 실험을 통하여 분석함으로써 이동로봇용 환경지도 작성의 응용에 부정적인 영향을 미칠 수 있는 요인을 찾아 기술한다. 제 3장에서는 신경회로망을 이용한 적외선 레인지파인더의 비선형 바이어스오차의 보정법에 대하여 서술하며, 제 4장에서는 대상 센서를 이용한 환경지도 작성법에 대해 논한다. 제 5장에서는 제안된 방법에 대한 유효성을 실험을 통하여 검증을 하며 제 6장에서 결론을 내린다.



## 제 2 장 환경지도 작성용 적외선 레인지파인더 센서

### 2.1 환경지도 작성용 센서

이동로봇용 환경지도 작성은 대개 초음파 센서, 레이저 레인지파인더, CCD카메라 등을 이용하여 단일 또는 복합적으로 구성된 시각시스템을 통해 이루어진다. 본 절에서는 이러한 시각시스템 중에서 고정도의 환경지도 작성을 위해 사용되는 레이저 레인지파인더와, 이에 비하여 정밀성은 떨어지나 저가형의 시각시스템인 초음파 센서링에 대해 살펴 본다.

레이저 레인지파인더는 광원으로 직진성이 우수한 레이저 빔을 이용한 시각시스템으로서 정밀한 거리데이터를 제공한다. 또한 회전가능한 반사경에 의해 빔의 방위각을 변경하는 방법으로, 넓은 범위의 장애물에 대한 형상정보의 획득이 가능하다. 사진 2.1은 환경지도 작성의 용도로 주로 사용되는 SICK사의 레이저 레인지파인더로서 전방 180°에 대하여 0.5° 간격의 각 방위각에서 50m의 측정범위를 갖는 거리데이터를 제공한다. 이를 이용한 환경지도 작성의 일례로 그림 2.1에서 보는 바와 같이 레이저 레인지파인더를 로봇의 전면부에 장착하여 측정 범위내의 장애물에 대한 거리정보를 획득하게 되면, 이들의 좌표변환을 통한 간단한 방법으로 비교적 정밀한 환경지도를 획득할 수 있다. 그러나 레이저 레인지파인더에 의한 환경지도 작성시 타 시각시스템에 비해 상대적으로 무거운 중량과 큰 부피, 설치비용의 증가는 이동로봇에의 응용에 있어 고려되어야 한다.

한편 비교적 저가형의 시각시스템을 구성하기 위한 방법으로 로봇의



사진 2.1 환경지도 작성용 레이저 레인지파인더(SICK series)

Photo. 2.1 Laser range-finder for environmental map building (SICK series)




그림 2.1 레이저 레인지파인더를 이용한 환경지도작성

Fig. 2.1 Environmental map building using laser range-finder

둘레에 초음파 센서를 링구조로 배열한 초음파 센서링 시스템이 이용된다. 사진 2.2는 이를 구성하기 위해 가장 일반적으로 사용되는 폴라로이드사의 6500시리즈 초음파 센서를 나타낸다. 이는 40~1000cm 의 측정범위를




사진 2.2 환경지도 작성용 초음파센서 (폴라로이드 6500시리즈)

Photo. 2.2 Ultrasonic sensors for environmental map building  
(Polalroid 6500 series)

가지며 열린 공간에서의 장애물에 대해서는 비교적 정밀한 거리데이터를 제공하지만, 복잡한 환경에서는 음파의 특성상 다중반사, 경면반사, 넓은 지향각 등에 기인한 측정오류가 필연적으로 동반된다. 따라서 수개의 초음파 센서를 링구조로 함으로써 보다 많은 환경정보를 이용하여 이러한 오류를 극복하고자 하는 등 다양한 연구가 시도되고 있으나 정밀한 환경 지도를 작성하기에는 여전히 한계가 있다. 특히 이웃하는 센서에 대한 간섭오차를 피하기 위해 구동주기나 구동주파수의 등의 조절이 불가피하며 시스템의 복잡성, 설치비용 증가 등의 문제가 따른다. 이러한 관점에서 볼 때 이동로봇용 환경지도 작성을 위해 시스템의 구성이 간단하며 설치비용을 줄일 수 있고, 정밀한 환경정보를 제공할 수 있는 새로운 시각시스템이 절실히 요구되어 진다.

## 2.2 PB9-01 적외선 레인지파인더

본 논문에서 사용되는 적외선 레인지파인더는 HOKUYO사의 PB9-01로 그 외형은 사진 2.3과 같으며  $70 \times 60 \times 120\text{mm}$ 로 비교적 크기가 작고 무게가 가벼우므로 실험용 이동로봇에 쉽게 장착이 가능하다. 신호 발생 원으로 적외선 광을 사용하며 측정거리 레인지가 짧으므로 실내용으로 그 사용이 제한되지만, 타 시각센서와 비교하여 볼 때 하나의 센서로 넓은 범위의 장애물에 대한 각도와 거리정보를 동시에 얻을 수 있으므로 설치 비용을 절감할 수 있는 장점이 있다.

센서의 내부는 그림 2.2과 같으며 적외선 빔의 발광부 및 수광부, 모터 구동부, 신호처리부로 구성되어 있다.



사진 2.3 적외선 레인지파인더 PB9-01

Photo. 2.3 Infrared range-finder PB9-01




그림 2.2 PB9-01의 구조

Fig. 2.2 Structure of PB9-01

하단과 상단에는 각각 적외선 LED와 Photo-detector가 위치해 있으며 그 사이에는 두개의 반사경이 스텝모터의 동축상에 고정되어 있다. 이러한 구조로서 적외선 LED에 의해 870nm의 파장으로 발광되는 적외선은 반사경을 통해 외부로 전달된다. 또한 장애물에 의해 반사된 적외선은 수광부의 반사경을 거쳐 Photo-detector로 전달되며 센서의 출력은 신호처리부에 의해 각 방위각에서의 거리값으로 변환된다. 이때 센서의 계측방향은 스텝모터의 회전에 의한 두 반사경의 방향에 의해 결정되며 모터는 매 160ms마다 162°의 방위각에 대해 91스텝으로 좌우로 회전하게 된다. 표 2.1은 PB9-01의 주요사양을 나타내고 있다. 여기서 PB9-01은 직류전원 24V 입력으로 간단히 동작되어 RS232C방식의 통신을 통해 다른 프로세스와 쉽게 인터페이스 된다.

표 2.1 PB9-01의 사양

Table 2.1 Specifications of PB9-01

Power source	DC 24V
Response time	160ms
Detection distance	10 to 300 cm
Scanning angle	162 °
Interface	RS-232C
Weight	500g

그림 2.3은 PB9-01의 측정범위를 나타내는 것으로서 전방 162°의 방위 각에 대한 거리정보가 한번의 계측으로 얻어지며 거리데이터는 10~300cm의 범위의 값으로 주어진다. 또한 각도 분해능이 1.78°로써 고정도의 환경 정보 획득이 가능하므로 지도작성, 형태인식 등의 용도로 적합하다.

### 2.3 센서의 특성분석실험

일반적으로 효과적인 센서응용을 위해 그 특성을 알아야 한다. PB9-01은 비교적 양질의 정보를 제공하지만 센서고유의 특성으로 인한 물리적 제약이 있을 수 있다. 따라서 본 절에서는 대상센서에 대한 물리적 특성을 실험을 통해 분석한다.




그림 2.3 PB9-01의 탐색범위 및 방위

Fig. 2.3 Scanning range and direction of PB9-01

### 2.3.1 실험환경 및 방법

PB9-01은 162°범위의 방위각에 대해 1.78°의 분해능으로 장애물에 대한 거리데이터를 제공한다. 그러나 센서의 거리데이터는 한 쌍의 발광부와 수광부를 통해 얻어지므로 실험은 임의의 고정된 방위각에 대해 센서 플랫폼으로부터 장애물까지의 거리데이터를 획득하는 것으로 하였다. 그림 2.4는 센서의 특성분석을 위한 실험환경을 나타낸 것으로서 실내의 열린 공간내에 센서가 장착된 로봇을 위치시키고 그 정면에 평판을 두어 그 거리에 해당되는 샘플 데이터를 수집하였다. 이때 센서정면의 방위각에 해당하는 거리데이터만을 추출하였고 평판의 위치는 센서의 최대




그림 2.4 실험환경

Fig. 2.4 Experimental environment

측정가능 범위인 300cm까지 최초 10cm에서 각각 10cm씩 그 위치를 증가시켰으며 각 측정거리에서의 샘플 데이터는 200회씩 수집하였다.

### 2.3.2 실험 및 분석결과

그림 2.5는 PB9-01을 이용한 거리측정 실험결과를 나타낸 것이다. 여기서 X축은 센서 플랫폼과 장애물간의 실제거리, Y축은 실측거리를 나타낸다. 평판을 10cm간격으로 이동시키면서 각 위치에서 받은 200개의 데이터들의 평균을 구하고 이를 실제 측정거리와 비교하였다. 그 결과 측정 데이터들의 평균치의 편향(Bias) 정도가 비선형적으로 존재함을 확인할 수 있다.



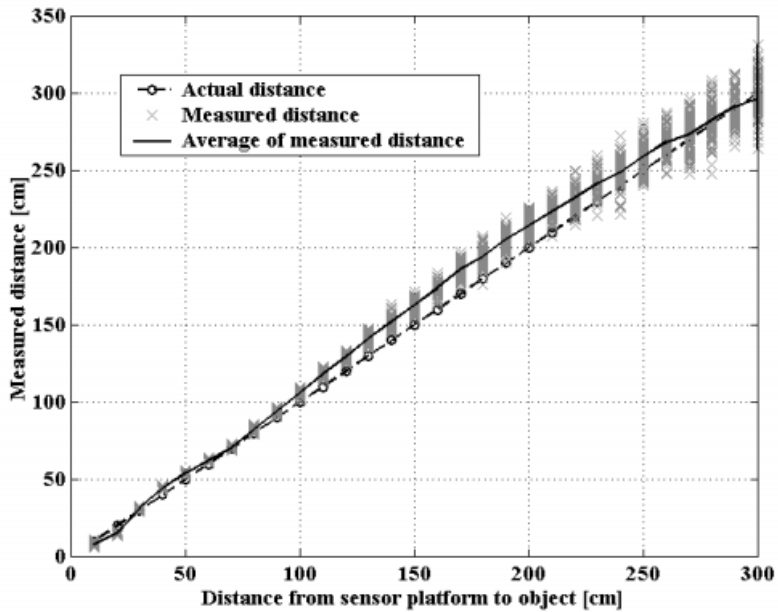


그림 2.5 PB9-01을 이용한 거리측정 실험결과

Fig. 2.5 Results of distance measurement using PB9-01

한편 그림 2.5에서 각 측정거리에서 얻어진 데이터들의 재현성이 측정 거리에 비례하여 떨어지는 성향이 있음을 확인할 수 있다. 따라서 측정 데이터들을 토대로 센서의 특성을 보다 정확히 분석하기 위해 통계적인 해석을 실시하였다. 그림 2.6 - 2.9에서는 각각 측정거리 50cm, 100cm, 200cm, 300cm에서 얻은 표본 데이터들의 평균과 표준편차를 구하고 이러한 추정량을 토대로 가우시안 분포의 확률밀도함수를 정의해 이를 측정 데이터들과 비교하여 나타낸 것이다[4].




그림 2.6 측정데이터의 확률밀도함수 (50cm)

Fig. 2.6 Probability density function of measured data (50cm)




그림 2.7 측정데이터의 확률밀도함수 (100cm)

Fig. 2.7 Probability density function of measured data (100cm)

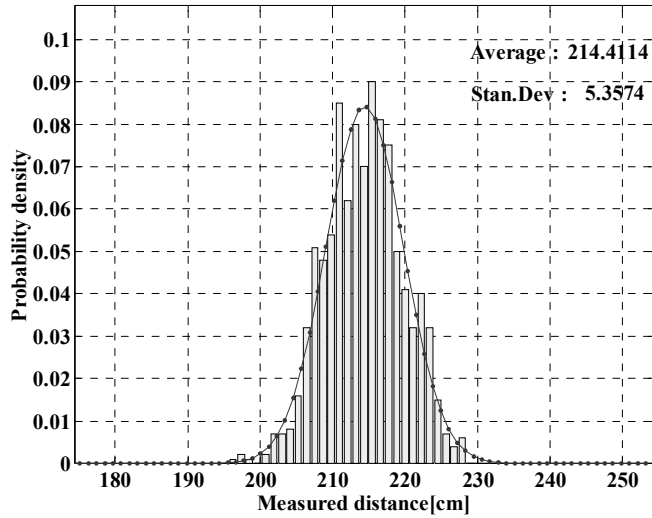


그림 2.8 측정데이터의 확률밀도함수 (200cm)

Fig. 2.8 Probability density function of measured data (200cm)

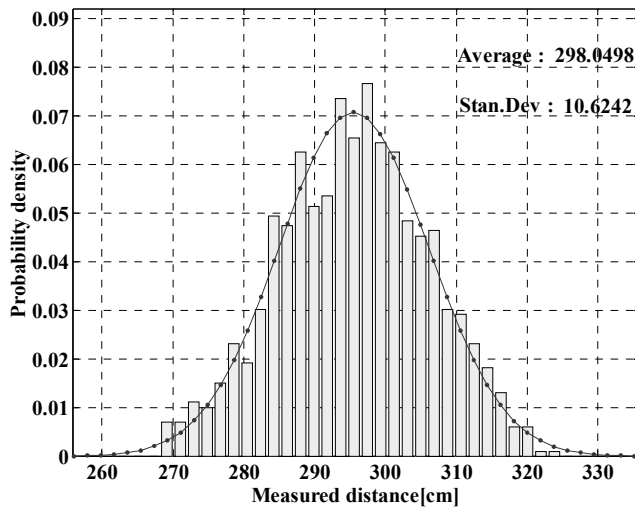


그림 2.9 측정데이터의 확률밀도함수 (300cm)

Fig. 2.9 Probability density function of measured data (300cm)

그림 2.6 - 2.9로부터 각 측정거리에 대한 데이터들의 분포는 이들의 추정량으로 정의된 가우시안 분포의 확률밀도함수와 매우 유사함을 알 수 있다. 한편 측정거리에 대한 데이터 분포의 상관관계를 알기 위하여 전구 간에서 얻어진 데이터들의 평균에 대한 표준편차를 추출하고 이를 이용하여 2차 다항식 회귀곡선으로 근사화하였다.

실험 데이터  $(d_i, \sigma(d_i), i=1, 2, \dots, n)$ 가 주어질 때 이에 적합한 다항곡선은

$$\sigma(d) = a_0 + a_1d + a_2d^2 + \dots + a_nd^n = \sum_{k=0}^n a_k d^k \quad (2.1)$$

라 정의할 수 있으며, 따라서 모든 계수들은 최소자승법에 의해 추정된다.

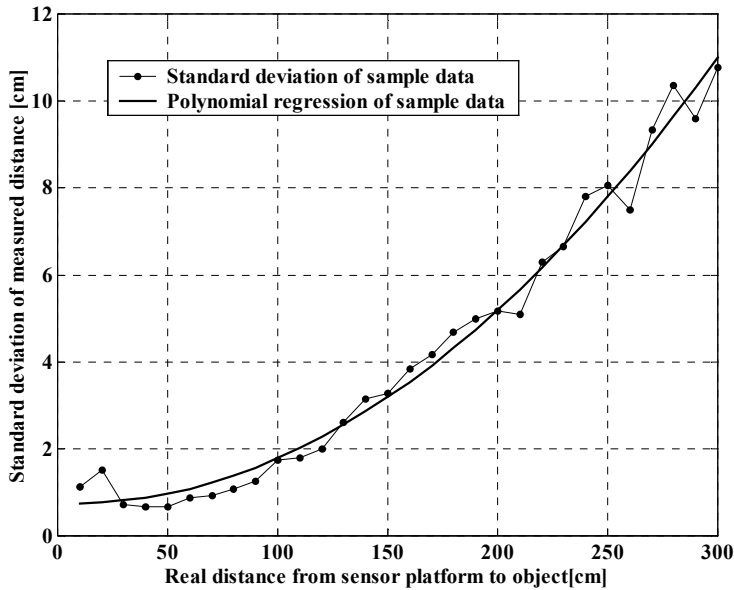


그림 2.10 표본데이터의 표준편차

Fig. 2.10 Standard deviation of sample data

$d = d_i$  를 식 (2.1)의 우변에 대입한 추정값과  $d_i$ 의 차를  $\varepsilon_i$ 라 하면  $n$ 조의 데이터에 가장 적합한 식은

$$Q = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n \left( \sigma(d_i) - \sum_{k=0}^n a_k d^k \right)^2 \quad (2.2)$$

이 최소가 되는 식으로써  $Q$ 를 모든  $a_k$ 에 대해  $\frac{\partial Q}{\partial a_k} = 0$ 을 만족하는 계수  $a_k$ 를 구함으로써 얻어진다. 이를 통해 측정거리  $d$ 에 대하여 추정된 표준편차  $\sigma(d)$ 의 2차 다항식 회귀곡선은

$$\sigma(d) = 0.0001d^2 - 0.0017d + 0.7544 \quad (2.3)$$

로 주어진다. 그림 2.10은 실험데이터들의 표준편차와 이를 토대로 추정된 2차 다항식 회귀곡선을 나타낸다.

이상과 같은 분석결과를 통해 측정 데이터들로부터 센서의 특성을 다음의 두 가지로 요약할 수 있다.

첫째, 표본 데이터들은 평균치에 대하여 가우시안 분포를 따르며 측정 오차의 분산은 거리에 비례하여 증가한다.

둘째, 각 측정거리에서 얻은 데이터들은 실제거리에 대하여 비선형 바이어스 오차를 가진다.

본 논문에서는 대상센서를 실험용 이동로봇에 장착하여 환경지도 작성의 용도로 이용하고자 한다. 그러나 이를 이용하여 고정도의 환경지도를 작성하기 위해서는 앞서 언급한 센서의 특성을 고려한 적절한 신호처리 알고리즘이 필요하다. 센서로부터 수집된 데이터들을 확률적으로 처리할 경우 데이터의 측정횟수가 많아짐에 따라 점진적으로 평균값으로 수렴해 가므로 센서의 측정거리에 대한 오차는 다소 줄일 수 있으나 비선형 특성

에 기인한 오차는 근본적으로 보정될 수 없다.

따라서 본 논문에서는 이러한 센서의 물리적 특성에 기인한 지도작성 오차를 줄이는 방안으로서 확률적 접근을 통한 거리측정 정도의 향상과 더불어 비선형 바이어스 보정에 역점을 두고 있다. 비선형 바이어스의 보정은 실제 보정과정에서 생기는 계산시간을 최소화함으로써 시스템의 실시간성을 만족시킬 수 있어야 한다. 따라서 이를 고려해 학습시간은 다소 소요되지만 실제 적용시 응답이 빠른 신경회로망에 의한 보정법을 제안한다.

# 제 3 장 신경회로망을 이용한 비선형 바이어스오차 보정

## 3.1 신경회로망의 개요

### 3.1.1 다층 퍼셉트론

신경회로망을 구성하는 기본단위인 뉴런은 다양한 형태로 결합하여 하나의 신경회로망을 이룬다. 현재 다양한 구조의 신경회로망이 개발되어 왔으며 다층 퍼셉트론(MLP : Multi-Layer Perceptron)은 그 중 가장 일반적인 형태이다. 또한 MLP에서 주로 사용되는 구조는 외부 입력을 받아들이는 입력층(Input layer), 처리된 결과가 출력되는 출력층(Output layer), 입력층과 출력층 사이에 위치하여 외부로 나타나지 않는 은닉층(Hidden layer)의 3개

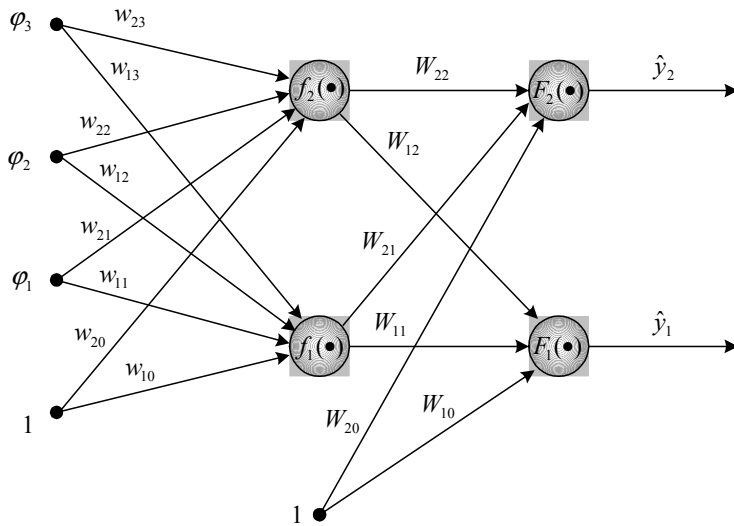


그림 3.1 다층 퍼셉트론

Fig. 3.1 Multi-layer perceptron

층으로 구성되어 진다[13]. 그림 3.1은 이러한 MLP의 구조와 각 파라미터를 나타내고 있으며 MLP의 동작을 수학적으로 표현하면 식 (3.1)과 같다.

$$\hat{y}_i(t) = F_i \left[ \sum_{j=1}^{n_h} W_{i,j} f_j \left( \sum_{l=1}^{n_p} w_{j,l} \varphi_l + w_{j,0} \right) + W_{i,0} \right] \quad (3.1)$$

이때,  $w_{j,l}$  와  $W_{i,j}$ ,  $f_i(\bullet)$  와  $F_i(\bullet)$ ,  $w_{j,0}$  와  $W_{i,0}$  는 각각 입력층과 은닉층, 은닉층과 출력층에 대한 뉴런간의 연결강도, 활성화 함수, 바이어스를 나타내며  $\varphi_l$  는 신경회로망의 입력이다.

신경회로망에서 연결강도의 값을 결정하는 것은 입력과 출력을 연관시키는 방법을 의미하며 이를 학습이라고 한다. 즉 신경회로망에서 학습이라 함은 특정한 응용목적에 적합하도록 뉴런간의 연결강도를 적응시키는 과정이다.

### 3.1.2 Levenberg-Marquardt 알고리즘

본 논문에서는 신경회로망을 학습하기 위해 Levenberg-Marquardt 학습 알고리즘을 사용한다. 식 (3.2)는 학습을 위한 입력패턴을 나타낸다.

$$Z^N = \{[x(t), y(t)], t=1 \dots N\} \quad (3.2)$$

여기서  $x(t)$  는 신경회로망이 입력이고,  $y(t)$  는 목표치이다.

Levenberg-Marquardt 알고리즘은 다음과 같은 평균제곱오차(Mean squared error)를 정의함으로써 신경회로망의 출력과 실제 출력과의 근접성을 평가한다.

$$V_N(\theta, Z^N) = \frac{1}{2N} [y(t) - \hat{y}(t | \theta)]^2 = \frac{1}{2N} \sum_{t=1}^N \varepsilon^2(t, \theta) \quad (3.3)$$



따라서, 신경회로망 학습의 최종 연결강도는

$$\hat{\theta} = \arg \min_{\theta} V_N(\theta, Z^N) \quad (3.4)$$

와 같으며 신경회로망의 학습에서 오차를 최소화하는 업데이트 룰은 다음과 같다.

$$\theta^{(i+1)} = \theta^{(i)} + \mu^{(i)} f^{(i)} \quad (3.5)$$

$\theta^{(i)}$  는  $i$  단계의 파라미터를 나타내며,  $f^{(i)}$  는 탐색 방향,  $\mu^{(i)}$  는 스텝 사이즈를 나타낸다. Levenberg-Marquardt 알고리즘은 Gauss-Newton method 를 근간으로 하고 있는데, Gauss-Newton method는 오차를 최소화하기 위해 다음과 같은 선형 근사화식을 사용한다.

$$\begin{aligned} \mathcal{E}(t, \theta) &= \varepsilon(t, \theta^{(i)}) + [\varepsilon'(t, \theta^{(i)})]^T (\theta - \theta^{(i)}) = \varepsilon(t, \theta^{(i)}) - [\varphi(t, \theta^{(i)})]^T (\theta - \theta^{(i)}) \\ \text{where, } \varphi(t, \theta) &= \frac{dy(t|\theta)}{d\theta} \end{aligned} \quad (3.6)$$

신경회로망의 학습에 있어  $i$ 번째 학습과정에서 Criterion  $V_N(\theta, Z^N)$  을 정의하면,

$$V_N(\theta, Z^N) \cong L^{(i)}(\theta) = \frac{1}{2N} \sum_{i=1}^N \mathcal{E}^2(t, \theta) \quad (3.7)$$

이며,  $\theta = \theta^{(i)}$  일때 Gradient  $G(\theta^{(i)})$  는 다음과 같다.

$$G(\theta^{(i)}) = \frac{dL^{(i)}(\theta)}{d\theta} \Big|_{\theta=\theta^{(i)}} = \frac{1}{N} \sum_{i=1}^N \varphi(t, \theta^{(i)}) [y(t) - \hat{y}(t|\theta^{(i)})] \quad (3.8)$$

또한, Gauss-Newton hessian  $R(\theta^{(i)})$  는 식 (3.9)와 같다.

$$R(\theta^{(i)}) = \frac{d^2 L^{(i)}(\theta)}{d\theta^2} \Big|_{\theta=\theta^{(i)}} = \frac{1}{N} \sum_{i=1}^N \varphi(t, \theta^{(i)}) \varphi^T(t, \theta^{(i)}) \quad (3.9)$$

Gauss-Newton hessian  $R(\theta^{(i)})$  은 양의 반한정이 되며, Gauss-Newton method

는 일차 미분만을 필요로 하므로 구현하기 쉽다는 장점이 있다. 따라서 Gauss-Newton method의 탐색방향과 오차를 최소화하는 업데이트 룰은 다음과 같다.

$$R(\theta^{(i)})f^{(i)} = -G(\theta^{(i)}) \quad (3.10)$$

$$\theta^{(i+1)} = \theta^{(i)} - R^{-1}(\theta^{(i)})G(\theta^{(i)}) \quad (3.11)$$

Levenberg-Marquardt 알고리즘은 Gauss-Newton method의 업데이트 룰식에 파라미터  $\lambda$ 를 첨가하여 다음과 같은 형태를 취한다.

$$[R(\theta^{(i)}) + \lambda^{(i)}I]f^{(i)} = -G(\theta^{(i)}) \quad (3.12)$$

즉  $\lambda$ 의 값이  $\infty$ 에 근접함에 따라 학습알고리즘은 Gradient method 즉, BP알고리즘의 형태가 되며 0에 근접함에 따라 Gauss-Newton method의 형태가 된다. 즉, Levenberg-Marquardt 알고리즘은  $\lambda$  값을 변형해 가며 적절한 탐색방향을 찾게 된다[14][15].

## 3.2 비선형 바이어스오차 보정

### 3.2.1 신경회로망의 구조

그림 3.2는 본 논문에서 사용되는 신경회로망의 구조를 나타낸 것으로 입력층과 출력층의 뉴런수는 각각 1개이며, 2개의 은닉층의 뉴런수는 각각 6개와 2개이다. 은닉층과 출력층은 바이어스를 포함하고 있다. 활성화 함수로 은닉층의 뉴런에 대해서는

$$f^1(n) = f^2(n) = \frac{1 - e^{-n}}{1 + e^{-n}} \quad (3.13)$$




그림 3.2 신경회로망의 구조

Fig. 3.2 Structure of neural network

의 양극성 시그모이드 함수를 사용하였고, 출력층의 뉴런에 대해서는

$$f^3(n) = n \quad (3.14)$$

의 항등함수를 각각 사용하였다. 각각의 활성화 함수로서 조합된 최종 출력은

$$\hat{y} = z_3 = f^3(f^2(f^1(xW_1^T + b_1)W_2^T + b_2)W_3^T + b_3) \quad (3.15)$$

으로 얻어진다.

### 3.2.2 신경회로망의 학습

그림 3.3은 센서의 비선형 바이어스의 보정을 위해 본 논문에서 사용한

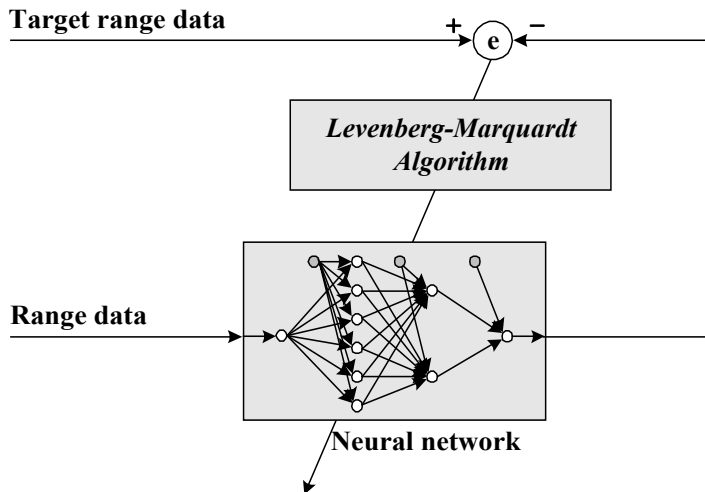


그림 3.3 신경회로망의 학습

Fig. 3.3 Training mechanism of neural network

신경회로망의 학습구조를 나타낸 것이다. 신경회로망의 입력은 그림 2.5에서와 같은 방법으로 얻어진 데이터들의 각 거리별 평균치가 사용되며, 목표치는 센서와 측정대상의 실제거리에 해당된다. 신경회로망의 학습에는 Levenberg-Marquardt 알고리즘이 이용되었으며 학습률은 0.01로 주어졌다. 또한 학습은 출력치와 목표치와의 RMS오차가  $2.5 \times 10^{-5}$  이하가 되면 종료된다.

그림 3.4는 학습과정을 나타낸 것으로, 출력치와 목표치와의 제곱오차의 변화를 나타낸 것이다. 여기서 254회의 반복학습으로 학습이 종료됨을 알 수 있다.

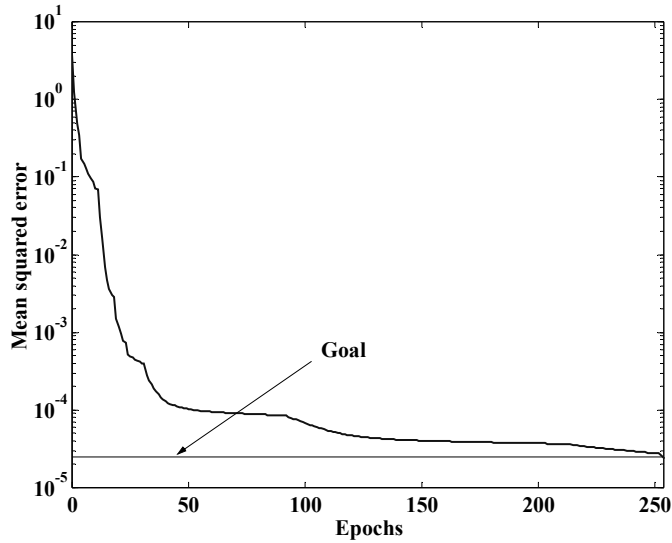


그림 3.4 신경회로망의 학습

Fig. 3.4 Training of Neural network

이와 같은 과정을 통해서 학습이 완료된 신경회로망의 연결 강도는 식 (3.16)로 주어졌다[16].

$$\begin{aligned}
 \mathbf{W}_1 &= \begin{bmatrix} -5.7950 \\ -6.2927 \\ -2.9562 \\ 2.4116 \\ -4.3381 \\ -5.4769 \end{bmatrix}, & \mathbf{b}_1 &= \begin{bmatrix} 18.3913 \\ 16.7640 \\ 6.5854 \\ -2.8336 \\ 2.4960 \\ -1.0804 \end{bmatrix} \\
 \mathbf{W}_2^T &= \begin{bmatrix} 0.1691 & 1.8179 \\ 3.5284 & 0.6239 \\ 0.4716 & -0.3999 \\ -0.1736 & -2.5846 \\ 0.0987 & -0.1048 \\ 0.6648 & -1.6205 \end{bmatrix}, & \mathbf{b}_2 &= \begin{bmatrix} -3.9994 \\ -0.7220 \end{bmatrix} \\
 \mathbf{W}_3 &= [-2.6751 \quad -0.4954], & \mathbf{b}_3 &= 0.1639
 \end{aligned} \tag{3.16}$$

### 3.2.3 검증실험

본 논문에서는 제안하는 방법에 대한 유효성을 검증하기 위한 실험을 행하였다. 그림 3.6은 실험환경을 나타내는 것으로서 좌·우측에 벽면으로 둘러싸인 공간에 PB9-01이 장착된 로봇을 위치시키고 로봇의 정면으로부터 200cm의 거리에 90cm 폭을 갖는 평판을 물체로 두었다.




그림 3.6 실험환경

Fig. 3.6 Experimental environment

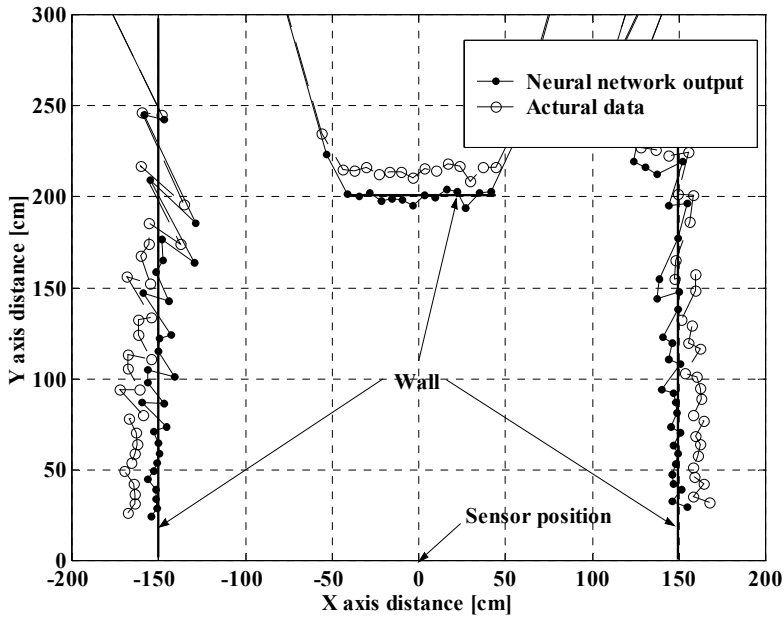


그림 3.7 실험결과

Fig. 3.7 Experimental result

이상과 같은 환경에서의 실험결과는 그림 3.7과 같다. 여기서  $\ominus$  는 센서로부터 받은 보정전의 거리데이터이고  $\bullet$  는 제안한 신경회로망에 의해 보정한 거리데이터이다. 이 결과로부터 보정후의 거리데이터가 실제 환경에 근접해 있음을 알 수 있다. 여기서 센서의 좌·우측의 벽면에서 생기는 측정오차는 센서의 지향각에 의한것으로 여겨진다. 이것은 센서빔의 폭은 적으나 그에 대한 영향이 어느 정도는 존재하고 있음을 의미한다. 그러나 전반적으로 본 논문에서 제안하는 보정방법을 통해 얻어진 데이터들은 실제 환경과 근사함을 알 수 있다.

## 제 4 장 이동로봇용 환경지도 작성

환경지도 작성에 있어서 PB9-01의 측정데이터는 학습된 신경회로망을 통해 보정됨으로써 비선형 바이어스는 제거되지만 측정거리에 비례하여 증가하는 거리 불확실성은 여전히 존재한다. 또한 적외선을 발광원으로 함으로써 생기는 광반사 특성으로 인한 불확실성도 무시할 수 없다. 이에 본 논문에서는 이러한 사항을 고려하여 각각의 셀에 확률가중치를 부여하여 표현하는 점유격자식 환경지도 작성법과 센서의 불확실한 정보를 보완하기 위한 확률모델을 제안한다.

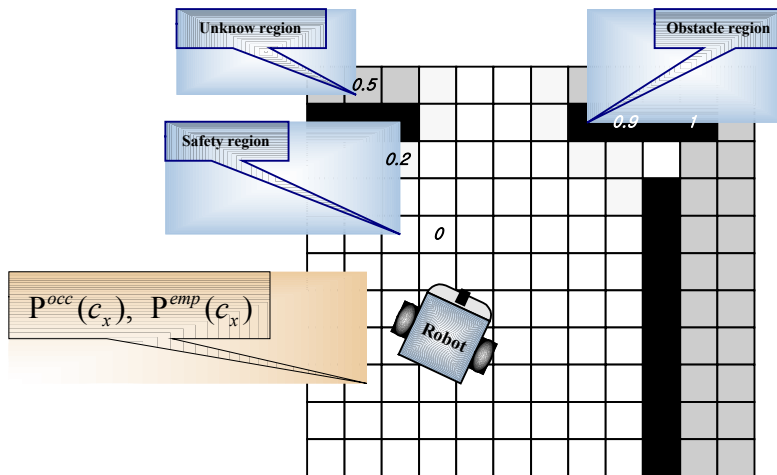


그림 4.1 점유격자지도

Fig. 4.1 Occupancy grids map



## 4.1 점유격자지도(Occupancy grids map)

점유격자지도는 환경이 일정크기의 단위 셀로 구성된 2차원 격자형태로 표현되며 실제의 환경정보는 그 위치에 해당되는 셀의 점유가중치로 주어지게 된다[17]. 그림 4.1은 점유격자지도의 구조를 보여주고 있으며 지도상에 존재하는 로봇은 주어진 격자정보를 이용하여 이동 등의 임무를 수행하게 된다. 이때 각 셀의 점유가중치는 장애물의 존재유무를 판단할 수 있는 기준이 된다.

한편, 점유격자지도의 점유정보는 센서가 장착된 로봇의 위치와 센서의 측정값에 따라 결정되므로 이들로부터의 오차는 지도정보에 절대적인 영향을 미치게 된다[18]. 그러나 로봇의 위치와 센서의 측정값은 시스템적 오차나 다양한 외란으로 인하여 신뢰성이 떨어진다. 따라서 격자지도의 각 셀의 점유가중치를 각각의 독립된 확률변수로 취급하여 0과 1사이의 값을 부여하고 독립된 확률 데이터들을 적절한 방법으로 융합함으로써 불확실한 지도정보를 보완한다. 여기서 임의의 셀  $c_x$ 는 장애물이 존재할 확률  $P^{occ}(c_x)$ 와 존재하지 않을 확률  $P^{emp}(c_x)$ 로 주어지게 되며 두 확률 변수는  $P^{occ}(c_x)+P^{emp}(c_x)=1$ 의 관계가 성립하므로 다음과 같이 각 셀의 점유정보를 결정할 수 있게 된다.

$$\left\{ \begin{array}{l} \text{cell } c_x \text{ is occupied} \\ \quad : \text{if } P^{occ}(c_x) > P^{emp}(c_x) \text{ or } P^{occ}(c_x) > 0.5 \\ \text{cell } c_x \text{ is empty} \\ \quad : \text{if } P^{occ}(c_x) < P^{emp}(c_x) \text{ or } P^{occ}(c_x) < 0.5 \\ \text{cell } c_x \text{ is unknown} \\ \quad : \text{if } P^{occ}(c_x) = P^{emp}(c_x) \text{ or } P^{occ}(c_x) = 0.5 \end{array} \right. \quad (4.1)$$

## 4.2 확률적 접근

본 논문에서는 불완전한 센서의 측정데이터를 이용하여 점유격자지도를 생성하기 위해 크게 두 가지의 과정을 거치게 된다. 이는 센서의 측정치로부터 확률모델을 적용하여 지역지도를 생성하는 과정과 이전의 정보와 새롭게 얻어진 지역지도의 정보를 융합하여 전역지도를 갱신하는 과정이다. 본 논문에서는 이러한 추정과정에 있어 베이저안 법칙(Bayes' theorem)에 근거한 확률 추론법을 이용한다. 또한 센서의 모델링에 있어서 우도 및 우도율을 적용하여 수식을 간략화시키면서 사전정보를 충분히 활용하여 추론과정에 적용한다. 본 절에서는 불완전한 센서데이터의 융합을 위해 필요한 주요확률 이론에 대하여 간략히 살펴본다.

### 4.2.1 베이저안 추론

한 사건  $B$  가 일어났다는 조건하에서 다른 사건  $A$  가 일어날 확률을 조건부 확률(Conditional probability)이라 한다. 이러한 조건하에서는  $B$  가 새로운 표본공간이 되고  $B$  내에서  $A \cap B$  에 있는 근원 사건이 일어날 때  $A$  가 일어날 것이므로  $P(B) > 0$  의 경우에 있어서 조건부 확률을

$$P(A|B) = \frac{P(A \cap B)}{P(B)} \quad (4.2)$$

로 정의한다. 또한 사건  $A_1, A_2, \dots, A_n$  이 표본공간  $S = \{A_1 \cup A_2 \cup \dots \cup A_n\}$  의 한 분할(Partition)이고 각  $i$  에 대하여  $P(A_i) > 0$  이며  $P(B) > 0$  일 때

$$P(A_k|B) = \frac{P(B|A_k)P(A_k)}{P(B)} \quad (4.3)$$

의 등식이 성립하며 이를 베이지 정리라 한다. 이때  $P(B)$  는 전확률의 정리(Theorem of total probability)에 의해

$$P(B) = \sum_{i=1}^n P(B|A_i)P(A_i) \quad (4.4)$$

로 정의된다[19][20].

베이지 정리로부터 사전확률(Priori probability)  $P(A_k)$  및 조건부 확률  $P(B|A_k)$  을 이용하여 사후확률(Posteriori probability)  $P(A_k|B)$  을 추정할 수 있다. 이와 같이 추정하고자 하는 모수를 상수가 아닌 확률변수로 취급하고 이에 대한 사전정보를 확률분포형태로 표현하여 이들 정보를 충분히 활용하고자 하는 추론방법을 베이시안 추론법이라 한다[21].

#### 4.2.2 우도(Likelihood) 및 우도율(Likelihood ratio)

모수(Parameter)의 추정은 확률적 방법과 가설검증의 방법에 의해 가능하다. 확률적 방법은 주로 신뢰성 있는 기대치, 분산, 가우시안 확률밀도 함수 등으로 구성된 확률모델을 전제로 하는 반면, 가설검증의 방법은 현재 일어난 사건에 대한 가능성을 추측하여 이를 검증하는 방법으로 모수의 추정은 확률모델의 추정량을 이용하기 보다는 직접적으로 주어지는 데이터들을 통해 이루어진다[22][23].

관측치  $R$  에 대해 주어지는 가설  $H$  의 우도를  $L(H|R)$  로 정의하면 확률모델  $P(R|H)$  과 다음의 관계를 가진다

$$L(H|R) = cP(R|H) \quad (4.5)$$

이때  $R$  은 주어진 샘플시간에 대하여 정적인 관측값이며  $H$  는 변수,  $c$  는

상수이다.

또한 하나의 관측치  $R$  에 관한 두개의 가설  $H_1, H_2$  의 우도율  $L(H_1, H_2 | R)$  는

$$L(H_1, H_2 | R) = \frac{L(H_1 | R)}{L(H_2 | R)} = \frac{P(R | H_1)}{P(R | H_2)} \quad (4.6)$$

의 관계가 성립하며 통계적 독립인 두 사건  $R_1, R_2$  에 관한 두개의 가설  $H_1, H_2$  의 우도율은

$$L(H_1, H_2 | R_1 \wedge R_2) = \frac{L(H_1 | R_1 \wedge R_2)}{L(H_2 | R_1 \wedge R_2)} = \frac{P(R_1 \wedge R_2 | H_1)}{P(R_1 \wedge R_2 | H_2)} \quad (4.7)$$

이 된다. 이때 통계적 독립인 두 사건에 대하여

$$P(R_1 \wedge R_2 | H_i) = P(R_1 | H_i)P(R_2 | H_i) \quad (4.8)$$

이 성립하므로 식(4.8)를 식(4.7)에 대입함으로써

$$L(H_1, H_2 | R_1 \wedge R_2) = \frac{P(R_1 | H_1) P(R_2 | H_1)}{P(R_1 | H_2) P(R_2 | H_2)} \quad (4.9)$$

을 얻을 수 있다[24].

### 4.2.3 데이터 융합(Data fusion)

점유격자지도에서 임의의 셀에 대한 점유확률을  $P(o)$  라 하고 새로운 정보를  $z$  라 정의하면 사건  $z$  가 발생하고 있다는 가정하에 또다른 사건  $o$  가 발생할 확률은 베이즈 정리에 의해

$$P(o | z) = \frac{P(z | o)P(o)}{P(z | o)P(o) + P(z | \bar{o})P(\bar{o})} \quad (4.10)$$

이 된다. 여기서  $P(\bar{o})$  는 셀의 점유확률  $P(o)$  에 대한 여사건 확률을

나타낸다. 또한  $P(o|z)$ 의 여사건 확률  $P(\bar{o}|z)$ 은 식(4.10)과 유사한 방법으로

$$P(\bar{o}|z) = \frac{P(z|\bar{o})P(\bar{o})}{P(z|\bar{o})P(\bar{o}) + P(z|o)P(o)} \quad (4.11)$$

로 주어진다. 이때 두 확률식을 식(4.6)의 우도율을 적용하여 정리하면

$$L(o, \bar{o}|z) = \frac{P(o|z)}{P(\bar{o}|z)} = \frac{P(z|o)P(o)}{P(z|\bar{o})P(\bar{o})} \quad (4.12)$$

이 된다.

한편 임의의 셀에 대하여 새로운 정보와 이전의 정보를 각각  $z_2, z_1$ 이라 정의하면  $P(o|z_2 \wedge z_1)$ 와  $P(\bar{o}|z_2 \wedge z_1)$ 는 위와 같은 방법으로

$$P(o|z_2 \wedge z_1) = \frac{P(z_2|o \wedge z_1)P(o|z_1)}{P(z_2|o \wedge z_1)P(o|z_1) + P(z_2|\bar{o} \wedge z_1)P(\bar{o}|z_1)} \quad (4.13)$$

$$P(\bar{o}|z_2 \wedge z_1) = \frac{P(z_2|\bar{o} \wedge z_1)P(\bar{o}|z_1)}{P(z_2|\bar{o} \wedge z_1)P(\bar{o}|z_1) + P(z_2|o \wedge z_1)P(o|z_1)} \quad (4.14)$$

이 얻어지며 두 확률식을 적용한 우도율은

$$L(o, \bar{o}|z_2 \wedge z_1) = \frac{P(o|z_2 \wedge z_1)}{P(\bar{o}|z_2 \wedge z_1)} = \frac{P(z_2|o \wedge z_1)P(o|z_1)}{P(z_2|\bar{o} \wedge z_1)P(\bar{o}|z_1)} \quad (4.15)$$

이 된다.

### 4.3 센서 모델링

일반적으로 레인지센서의 모델링은 센서빔의 지향각과 거리에 대한 불확실성을 고려하여 얻어지지만 PB9-01의 경우 빔의 지향각이  $0.95^\circ$ 의 적은 수치이므로 본 논문에서는 센서 모델링에 있어 거리 불확실성만을 고려하여 그 구조를 단순화하였다.




그림 4.2 일차원 배열의 구조

Fig. 4.2 Structure of array type storage

그림 4.2는 임의의 방위각  $\omega$  에 대한 일차원 배열의 격자를 나타낸 것으로, 여기서 각셀의 데이터는 점유확률치로 주어진다. 센서의 확률 모델은 거리측정치  $z$  를 통해 점유영역과 비점유영역으로 나누어 각각 상이하게 주어진다. 즉, 임의의 셀이  $r < z - 2\sigma$  의 조건을 만족하면 비점유 영역으로 간주되며  $z - 2\sigma \leq r \leq z + 2\sigma$  의 조건에 대해서는 점유영역으로 간주된다. 여기서  $r$  은 센서 플랫폼에서 대상 셀까지의 거리를 나타내며 또한  $\sigma$  는 2.3.2절에서 실험을 통해 얻어진 측정데이터에 대한 표준편차의 추정량이다.

한편, 센서는 측정거리에 대한 불확실성을 가지고 있으며 그림 4.3에 나타낸 바와 같이 감지 또는 불감지 확률로 주어질 수 있다[26]. 이를 각각  $p_i^{det}$ ,  $p_i^{fal}$  의 확률변수로 정의하면,  $p_i^{det}$  는 센서와 장애물간의 거리가 멀어질수록 불확실성이 커지게 되며 이를

$$p^{det} = 1 - \left( \frac{r}{R_{max}} \right)^2 \quad (4.16)$$




그림 4.3 센서의 오류가능성

Fig. 4.3 Likelihood of sensor failure

와 같이 나타낸다. 또한  $p^{fal}$  은 장애물의 감지확률에 상수배의 가중치를 부여하여

$$p^{fal} = \alpha \cdot p^{det} \quad (4.17)$$

로 정의한다. 이때 셀  $c_i$  에서 장애물이 감지되어 빔이 멈추게 될 확률  $P(p_i^{halt})$  는  $p_i^{det}$ ,  $p_i^{fal}$  를 셀의 사전확률  $P(o_i)$  에 따른 가중치를 부여함으로써 조합하면

$$P(p_i^{halt}) = P(o_i)p_i^{det} + P(\bar{o}_i)p_i^{fal} \quad (4.18)$$

로 얻어진다.

비점유영역에 대하여 센서의 빔이 멈추는 우도함수는  $P(p_z^{halt})$  과 이의 여사건 확률에 대한 확률곱으로서 식 (4.19)과 같이 나타낼 수 있다.

$$\begin{aligned} P(z) &= \overline{P(p_1^{halt})} \wedge \overline{P(p_2^{halt})} \wedge \cdots \wedge \overline{P(p_{z-1}^{halt})} \wedge P(p_z^{halt}) \\ &= P(p_z^{halt}) \prod_{i=1}^{z-1} \overline{P(p_i^{halt})} \end{aligned} \quad (4.19)$$

이를 특정 셀  $c_z$  에 적용하여  $c_z$  에서 센서빔을 멈추게 할 가능성과 이의

여사건의 가능성에 대한 우도율은 식 (4.20)과 같다.

$$\frac{P(z|o_j)}{P(z|\bar{o}_j)} = \frac{P(p_j^{halt}|o_j) \prod_{i=1}^{j-1} \overline{P(p_i^{halt}|o_j)}}{P(p_j^{halt}|\bar{o}_j) \prod_{i=1}^{j-1} \overline{P(p_i^{halt}|\bar{o}_j)}} \quad (4.20)$$

한편, 점유영역에서의 센서모델에 있어서 측정거리에 대한 확률가중치로 식 (4.21)의 정규분포의 확률밀도함수를 정의한다.

$$p(z, r) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left[-\frac{(r-z)^2}{2\sigma^2}\right] \quad (4.21)$$

이때 센서플랫폼으로부터  $r$ 의 거리에 있는 셀  $c_j$ 가 측정치  $z$ 일 확률을  $p_j^z$ 로 나타내면 센서의 빔이 임의의 셀  $z_j$ 에서 장애물을 감지하여 센서빔을 멈추게 할 우도함수는 다음과 같이 표현될 수 있다.

$$P(z_i) = p^{z_1} P(p_{z_1}^{halt}) \vee p^{z_2} \{P(\overline{p_{z_1}^{halt}}) \wedge P(p_{z_2}^{halt})\} \vee p^{z_3} \{P(\overline{p_{z_1}^{halt}}) \wedge P(\overline{p_{z_2}^{halt}}) \wedge P(p_{z_3}^{halt})\} \vee \dots \vee p^{z_i} \prod_{k=z_1}^{z_i-1} P(\overline{p_k^{halt}}) \wedge P(p_{z_i}^{halt}) \quad (4.22)$$

따라서 특정셀  $c_j$ 에서 센서의 빔이 장애물을 감지하여 빔을 멈추게 할 우도와 이의 여사건에 대한 우도율을 구하면

$$\frac{P(z|o_j)}{P(z|\bar{o}_j)} = \frac{\sum_{k=1}^n p_k^z P(p_k^{halt}|o_j) \prod_{i=1}^{k-1} \overline{P(p_i^{halt}|o_j)}}{\sum_{k=1}^n p_k^z P(p_k^{halt}|\bar{o}_j) \prod_{i=1}^{k-1} \overline{P(p_i^{halt}|\bar{o}_j)}} \quad (4.23)$$

을 얻을 수 있다.

센서의 측정치로부터 비점유영역과 점유영역에 존재하는 각각의 셀에 대하여 식 (4.20)와 식 (4.23)의 센서모델과 각 셀의 사전확률인  $P(o)$ ,  $P(\bar{o})$ 의 정보는 식 (4.12)의 추론과정을 통해 각 셀의 점유가능성에 대한



우도율로 주어지게 된다. 이때 사전확률  $P(o)$  는 이전의 지도 정보로부터 해당 셀들의 평균점유밀도를 구함으로써 결정된다.

또한 우도율과 이에 해당하는 확률값은 식 (4.24)의 관계가 있으며 이를 적용하면 각 셀에 대한 점유확률치로 복귀된다.

$$P(o|z) = \frac{L(o, \bar{o}|z)}{1 + L(o, \bar{o}|z)} \quad (4.24)$$

#### 4.4 지역지도의 생성

이로서 방위각  $\omega$  에 대하여 센서의 확률모델을 적용한 새로운 정보가 생성되었으며 91개의 방위각에 대하여 각각 이를 적용하여 지역지도상에




그림 4.4 지역지도의 생성과정

Fig. 4.4 Process of local map building

맵핑하는 과정을 수행하게 된다. 그림 4.4은 이러한 과정을 나타내는 것이다. 여기서 임의의 방위각  $\omega$  에 대하여 센서모델을 적용하여 얻어진 일차원 배열상에 존재하는 각 셀의 점유가중치는 센서의 위치로부터 방위각  $\omega$  와 셀의 위치로부터 좌표변환과정을 거치고 새롭게 형성된 지역지도상에 맵핑된다. 이때 새로운 지역지도상의 셀들은 사전확률로 각각의 셀에 대한 평균점유밀도인  $P(o)$  가 주어진다. 모든 방위각에 대하여 이러한 맵핑과정이 완료되면 현재의 센서데이터에 대한 지역지도가 형성된다.

#### 4.5 전역지도의 갱신

그림 4.5는 로봇의 위치로부터 주어진 영역에 대한 지도정보의 갱신 과정을 도시한 것으로서 센서의 확률모델을 적용하여 얻어진 지역지도와 이전 지도상에 존재하는 독립된 셀들의 점유정보는 사전확률  $P(o)$  를 통해 베이저안 추론에 근거한 데이터 융합으로 전역지도의 정보는 갱신된다. 이때 식 (4.15)에서 다음의 경우를 고려한다. 특정 셀이 가지는 이전의 점유확률  $P(o|z_1)$  와 새롭게 얻어진 점유확률  $P(o|z_2)$  가 주어지고  $P(o|z_2 \wedge z_1)$  를 구하는 경우에 있어  $z_1$  의 조건을 없는 것으로 간주한다. 이를 적용한 임의의 셀에 대한 점유가능성의 우도율은

$$\frac{P(z_2 | o \wedge z_1)}{P(z_2 | \bar{o} \wedge z_1)} = \frac{P(z_2 | o)}{P(z_2 | \bar{o})} \quad (4.25)$$

으로 주어지며  $z_1$  과  $z_2$  를 통계적 독립이라고 가정하여 식 (4.9)에 적용하면

$$\begin{aligned}
 L(o, \bar{o} | z_1 \wedge z_2) &= \frac{P(o | z_1 \wedge z_2)}{P(\bar{o} | z_1 \wedge z_2)} \\
 &= \frac{P(o | z_1)P(o | z_2)P(\bar{o})}{P(\bar{o} | z_1)P(\bar{o} | z_2)P(o)} = \frac{L(o, \bar{o} | z_1) \times L(o, \bar{o} | z_2)}{L(o, \bar{o})}
 \end{aligned}
 \tag{4.26}$$

를 유도할 수 있다. 식 (4.26)은 다음의 과정을 통해 특정 셀의 점유확률로 복귀된다.

$$P(o | z_1 \wedge z_2) = \frac{L(o, \bar{o} | z_2 \wedge z_2)}{1 + L(o, \bar{o} | z_2 \wedge z_2)}
 \tag{4.27}$$




그림 4.5 전역지도의 갱신과정

Fig. 4.5 Updating process of global map

## 제 5 장 실험 및 고찰

본 논문에서 제안된 방법에 의한 유효성 검증을 위해 실제 환경에 대한 환경지도 작성실험을 행하였다. 실험을 위한 각 파라미터는 다음과 같다.

표 5.1 실험을 위한 파라미터

Table 5.1 Parameters for experiment

Cell size	5×5cm
Global map size	1750×1750 cm
Cell numbers of global map	351×351 EA
Local map size	600×600cm
Cell numbers of local map	121×121 EA

또한 전역지도의 각각의 셀에 대한 점유가중치의 초기값으로서 0.5를 부여하였다. 지도작성은 주어진 환경에 대해서 로봇을 원격조종기로 주행시키면서 얻은 데이터를 이용하여 오프라인으로 작성된다. 이때 로봇의 위치좌표는 독립적으로 구성된 주행시스템에 의해 매 5ms마다 실시간적으로 계산 및 저장됨으로써 환경지도를 작성 등 필요시 이를 참조하도록 하였다. 환경지도 작성실험은 다음과 같은 사항에 주안점을 두고 실시하였다.

첫째, 작성된 환경지도가 실제 환경과 근사한가.

둘째, 센서의 광반사 오류로 인하여 지도정보의 손실이 있는가.

## 5.1 대상 로봇시스템

사진 5.1은 검증실험을 위한 대상 로봇인 KOMA(KOrea MAritime mobile robot)의 실물사진을 나타내고 있다. KOMA는 주모듈과 보조모듈로 나뉘는 기능분산형 로봇시스템(Functionally distributed robot system)이다. 이들 모듈은 RS232C의 통신방식에 의해 상호 데이터의 교환이 가능하다.



사진 5.1 이동로봇 KOMA

Photo. 5.1 Mobile robot KOMA

### 5.1.1 주모듈

주모듈은 맨-머신 인터페이스(Man-machine interface)나 측정 데이터들의 통합(Integration) 또는 융합을 통해 환경지도 작성, 경로계획 등 상위레벨 제어의 목적으로 구성되었다. 사진 5.2는 주모듈의 구조를 나타내며 주프로세서와 전원공급부로 나뉜다. 여기서 주모듈에는 Intel Pentium III 1GHz의 CPU를 기반으로 하고 있는 IEI사의 PCISA-3717EVT의 산업용 컴퓨터가 장착되어 있다. 또한 내장된 ISA, PCI방식의 확장슬롯을 통해 무선 네트워크, 영상처리 등의 기능확장이 가능하다.



사진 5.2 주모듈

Photo. 5.2 Main-module

### 5.1.2 보조모듈

사진 5.3은 보조모듈의 구조를 나타낸 것으로 구동부, 제어부, 전원부의 3부분으로 나뉜다. 로봇은 좌·우 독립적으로 구동되는 구동륜과 두개의 비구동륜을 가짐으로써 방향 전환시 좌·우 구동륜의 속도차에 의해 이루어지는 PWS(Power Wheeled Steering)구조를 가진다. 또한 구동모터의 제어는 PWM(Pulse Width Modulation)방식에 의해 이루어진다[27][28].

환경지도를 작성하는데 있어 로봇위치의 정도는 지도의 질에 직접적인 영향을 미치게 된다. 로봇의 위치는 좌·우 구동륜의 회전각 검출을 통해 이루어지며 이를 위해 1024펄스(Pulse)의 증분형 엔코더센서(Incremental encoder sensor: AUTONICS, E40H6-1024-3-2)가 각 모터의 양 끝단에 부착되




사진 5.3 보조모듈

Photo. 5.3 Sub-module

어 있다. 이러한 구조로 보조모듈은 실시간 처리를 필요로 하는 모터 제어와 센서 구동 및 신호처리를 담당하여 로봇의 경로추종 및 추측항법 등의 작업을 수행하게 된다[29]. 이를 위한 하드웨어로서 486DX-66을 기반으로 하는 AAEON사의 PCM-4335-A11 임베디드 보드(Embedded board)를 이용하였으며 프로그램은 C++언어에 의해 구현되었다. 로봇의 구동전원으로 두개의 ROKET사 12M14-3A의 밧데리를 사용하였고 각각 14AH의 용량을 가지고 있다.

### 5.1.3 소프트웨어

사진 5.4는 Visual C++의해 구현된 환경지도 작성용 소프트웨어의 화면 구성을 나타낸다. 여기서 좌측창은 환경지도 작성과정을 보여주고 있으며




사진 5.4 창의 구성

Photo. 5.4 Configuration of window



우측창에는 로봇의 위치, 사용자에게 의해 주어지는 목표점의 위치, 현재 마우스의 위치정보를 나타내는 창이 차례로 위치해 있다. 로봇은 사용자로부터 마우스나 키보드 등을 통해 이동명령을 받으며 이동을 위해 주모듈이 보조모듈에 내리는 주요명령은 다음과 같다[30].

1. 로봇의 위치( $x_{pos}, y_{pos}, \theta_{pos}$ )요청
2. 주어진 목표점( $x_{ref}, y_{ref}, \theta_{ref}$ )으로의 이동
3. 주행도중 회두각( $\theta_{ref}$ ) 변경
4. 속도변경( $v_{ref}$ ) 및 비상정지

사진 5.5는 이러한 방법을 통해 로봇이 주어진 목표점을 따라 주행하면서 주위의 환경지도를 작성하는 실험장면을 나타낸다.



사진 5.5 환경지도작성 실험장면

Photo. 5.5 Experimental scene of environmental map building

## 5.2 실험환경

그림 5.1은 지도작성을 위한 환경을 나타내고 있다. A에는 사각형 박스가, B에는 센서의 광반사 오류를 유발시킬 철재 캐비닛이 각각 위치하고 있으며, C에는 모양이 일정치 않은 물건들이 불규칙적으로 위치해 있다. 로봇은 시작점에서 출발한 후 출입문을 통과하여 복도와 강의실을 거쳐 다시 시작점으로 돌아오게 된다.




그림 5.1 환경지도 작성을 위한 실험환경

Fig. 5.1 Experimental environment for real world mapping

### 5.3 결과 및 검토

그림 5.2는 환경지도를 작성하는 과정을 나타내는 것인데, 실선으로 나타내어진 외각의 사각형 박스는 지역지도의 영역을 나타낸다. 여기서 로봇은 작은 원으로 표현되고 실선은 로봇의 이동궤적 나타낸다. 또한 로봇정면의 부채꼴모양의 실선들은 적외선 레인지파인더의 측정범위 내에서 장애물을 감지하는 동작을 나타내고 있다.




그림 5.2 환경지도의 작성과정

Fig. 5.2 Process of real world mapping

지역지도에 의해 형성되는 환경정보는 전역지도상에 맵핑되는 과정을 거치며 최종적으로 그림 5.3의 결과를 얻을 수 있었다. 여기서 그림 5.1의 A에 주어진 사각형 장애물의 형태가 제대로 나타나지 않은 것은 로봇에 장착된 센서의 측정범위가 제한되어 있어 한번의 스캔으로 주위의 전영역을 탐지하지 못한 이유로 여겨진다. 그러나 전체적으로 볼 때 실제 실험 환경과 매우 흡사하며 특히 철제 캐비닛이 있는 B영역에서의 정보손실이 거의 없음을 알 수 있다.




그림 5.3 환경지도 작성 결과

Fig. 5.3 Result of real world mapping

이를 통해 B영역에서의 측정데이터로부터 얻은 정보들은 광반사로 인한 측정오류 가능성에 비하여 장애물이 존재할 가능성을 더 많이 가지고 있음을 내포하고 있다. 이는 실제환경에 대하여 본 논문에서 제안한 센서의 확률모델이 타당함을 입증하여 주고 있다.

## 제 6 장 결 론

본 논문에서는 적외선 레인지파인더 센서를 이용한 저비용, 고정도의 환경지도 작성법을 제안하였다. 이를 위하여 본 논문에서는 대상 센서의 특성을 실험적으로 분석한 결과 측정오차는 가우시안 분포를 따르며 거리에 비례하여 증가하고, 측정거리에 따른 비선형 바이어스 오차를 가짐을 알 수 있었다.

따라서 본 논문에서는 이러한 물리적 특성에 기인한 오류를 극복하고 고정도의 환경지도를 작성하기 위한 방법으로 먼저 센서의 비선형 바이어스 오차 보정을 위해 신경회로망 보정법을 제안하였다. 또한 지도작성시 거리 불확실성 및 광반사 특성을 고려하여 센서를 모델링 하였으며 이를 토대로 확률적 방법에 의한 환경지도 작성법을 제안하였고 검증실험 결과 다음과 같은 결론을 얻었다.

첫째, 신경회로망을 통해 보정된 거리데이터는 비선형 특성이 현격히 감소한다.

둘째, 센서의 특성에 따른 불확실성을 고려하여 얻은 센서의 확률모델과 환경지도 작성법을 통해 고정도의 환경지도를 얻을 수 있다.

셋째, 로봇의 이동 경로상에 광반사를 유발할 수 있는 장애물이 존재하는 곳에서도 환경지도의 질은 크게 저하되지 않는다.

따라서 본 논문에서 제안한 적외선 레인지파인더를 이용한 저비용,

고정도의 환경지도 작성법은 향후 이동로봇의 경로계획, 자율이동제어 및 장애물 회피 등의 다양한 연구에 응용이 기대된다.

## 참 고 문 헌

- [1] J. Borenstein, H. R. Everett, and L. Feng, *Where am I? Sensors and Methods for Mobile Robot Positioning*, The University of Michigan, 1996
- [2] P. Mckerrow, *로봇공학, 기술*, 1992
- [3] H. Moravec and A. Elfes, “High Resolution Maps from Wide Angle Sonar”, *Proc. IEEE Int. Conf. On Robotics and Automation*, pp.116-121, 1985
- [4] M. Adams, *Sensor Modeling, Design and Data Processing for Autonomous Navigation*, World Scientific, 1999
- [5] 김현희, 한동희, 하윤수, “초음파 센서를 이용한 이동로봇용 표적 추적 시스템에 관한 연구”, *제어·자동화·시스템공학회*, pp.2938- 2941, 2001
- [6] J. Manyika and H. Durrant-Whyte, *Data Fusion and Sensor Management : A Decentralized Information-Theoretic Approach*, Ellis Horwood, 1994
- [7] M. Abidi and R. Gonzalez, *Data Fusion in Robotics and Machine Intelligence*, Academic Press. Inc, 1992
- [8] A. Howard and L. Kitchen, “Generating Sonar Maps in Highly Specular Environments”, *Proc. of the 4<sup>th</sup> International Conference on Control, Automation, Robotics and Vision*, 1996
- [9] H. Moravec, “Sensor Fusion in Certainty Grids for Mobile Robots”, *AI Magazine, Vol.9, No.2*, pp.61-74, 1988
- [10] T. Yuta and A. Ohya, “A Fast and Accurate Sonar-ring Sensor for a Mobile Robot”, *Proc. IEEE Int. Conf. on Robotics and Automation*, 1999



- [11] H. Moravec and D. W. Cho, “A Bayesian Method for Certainty Grids”, *Working Notes of AAAI 1989 Spring Symposium on Robot Navigation*, pp.57-60, 1989
- [12] R. Brooks and S. Iyengar, *Multi-Sensor Fusion Fundamentals and Applications with Software*, Prentics Hall PTR, 1997
- [13] 오창석, *뉴로컴퓨터*, 내하출판사, 2000
- [14] M. Norgaard, O. Ravn, N. K. Poulsen, and L.K. Hansen, *Neural Networks for Modelling and Control of Dynamic Systems: a practitioner’s handbook*, Springer, 2000
- [15] 김홍복, “유전알고리즘을 이용한 신경 회로망 기반 시스템 식별기의 최적화 설계 및 응용에 관한 연구”, *한국해양대 석사학위논문*, 2002
- [16] H. Demuth and M Beale, *Neural Network Toolbox for Use with MATLAB*, MathWorks, 1997
- [17] 임중환, “초음파센서를 이용한 자율이동로봇의 지도형성, 탐사 및 위치평가”, *포항공대 박사학위논문*, 1993
- [18] G. Dudek and M. Jenkin, *Computational Principles of Mobile Robotics*, Cambridge Univ. Press, 2000
- [19] Z. Peebles, *Probability, Random Variables, and Random Signal Principles*, McGraw-Hill Inc, 1993
- [20] 송문섭, 허문열, *수리통계학*, 박영사, 2002
- [21] 장인식, *베이지추론*, 고려대학교 출판부, 2001
- [22] 진영강, *랜덤변수와 랜덤과정*, 청문사, 2001
- [23] S. Woods, *Probability, Random Processes, and Estimation Theory for Engineers*, Prentics-Hall International, 1994

- [24] J. Mendel, *Lessons in Estimation Theory for Signal Processing, Communication, and Control*, Prentice-Hall International. Inc, 1995
- [25] 김현희, 한동희, 하윤수, “이동로봇용 적외선 레인지파인더센서의 특성분석 및 비선형 바이어스오차 보정에 관한 연구”, *IEEK / KIEE / ICASE 합동 학술 발표회*, pp. 96-99, April 2002
- [26] 김현희, 한동희, 하윤수, “적외선 레인지파인더센서의 확률모델에 근거한 이동로봇용 환경지도작성”, *IEEK / KIEE / ICASE 합동 학술 발표회*, pp. 126-129, 2002
- [27] P. Embree and D. Danieli, *C++ Algorithms for Digital Signal Processing*, Prentice Hall PTR, 1999
- [28] 위용욱, 김현희, 하윤수, 진강규, “RCGA 기반의 모델을 이용한 트레일러형 로봇의 후방경로 추종제어”, *제어·자동화·시스템공학회지 Vol. 7, No. 9*, pp. 717-722, 2001
- [29] 위용욱, 김현희, 한동희, 하윤수, 진강규, “RCGA 기반의 선형모델을 이용한 트레일러형 로봇의 후방경로 추종제어”, *대한전기학회*, pp. 11-17, 2001
- [30] Yun-Su Ha and Shin'ichi Yuta, "Trajectory Tracking Control for Navigation of the Inverse Pendulum Type Self-Contained Mobile Robot", *Int. Journal of Robotics and Autonomous System*, Vol. 17, pp. 65-80, 1996