

## RGB-D 이미지 인텐시티를 이용한 실내 모바일 로봇 장애물 회피

권기현\*, 이형봉\*\*

### Obstacle Avoidance of Indoor Mobile Robot using RGB-D Image Intensity

Ki-Hyeon Kwon \*, Hyung-Bong Lee\*\*

#### 요약

주어진 실내 환경에 위치한 여러 장애물에 대한 정보를 사전에 훈련하고 인식하여 로봇의 인지 능력을 향상시키기 위해 스테레오비전 센서의 RGB-D 이미지에서 인텐시티를 기반으로 일정 거리 안에 있는 장애물을 검출하는 방법을 제시한다. RGB-D 인텐시티 정보에 대해 PCA, ICA, LDA, SVM의 주요 패턴인식 알고리즘을 적용하여 인식률 및 실행시간을 구하고, 여러 패턴인식 알고리즘 중에서 어떤 알고리즘이 인식률 및 실행시간 측면에서 적용이 가능한지를 제시한다. 실험결과, RGB-D 데이터와 인텐시티 데이터를 비교한 결과 정확도면에서는 RGB-D 데이터가 4.2% 높은 인식률을 보였으나 훈련시간은 인텐시티 데이터가 RGB-D 이미지에 비해 LDA의 경우 29%, SVM의 경우 31% 빠르게 처리되었으며 테스트시간은 LDA의 경우 70%, SVM의 경우 33% 빠르게 처리되어 모바일 로봇 장애물 인식에 인텐시티 데이터를 사용하는 것이 정확도면에서도 우수하고 처리 속도 면에서 높은 개선효과가 있다.

▶ Keywords : RGB-D, 인텐시티, 스테레오비전, LDA, SVM, 키넥트

#### Abstract

It is possible to improve the obstacle avoidance capability by training and recognizing the obstacles which is in certain indoor environment. We propose the technique that use underlying intensity value along with intensity map from RGB-D image which is derived from stereo vision Kinect sensor and recognize an obstacle within constant distance. We test and experiment the accuracy and execution time of the pattern recognition algorithms like PCA, ICA, LDA, SVM to show the recognition possibility of it. From the

•제1저자 : 권기현 •교신저자 : 이형봉

•투고일 : 2014. 7. 1, 심사일 : 2014. 8. 25, 게재확정일 : 2014. 10. 7.

\* 강원대학교 전자정보통신공학부(Dept. of Electronics, Information & Communication Engineering, Kangwon National University)

\*\* 강릉원주대학교 컴퓨터공학과(Dept. of Computer Science & Engineering, Gangneung-Wonju National University)

※2014년도 강원대학교 학술연구조성비로 연구하였음(관리번호-220140078)

comparison experiment between RGB-D data and intensity data, RGB-D data got 4.2% better accuracy rate than intensity data but intensity data got 29% and 31% faster than RGB-D in terms of training time and intensity data got 70% and 33% faster than RGB-D in terms of testing time for LDA and SVM, respectively. So, LDA, SVM have good accuracy and better training/testing time to use for obstacle avoidance based on intensity dataset of mobile robot.

▶ Keywords : RGB-D, Intensity, Stereo Vision, LDA, SVM, Kinect

## I. 서 론

지난 수십 년간 로봇 자율 주행에 관한 인공지능 분야의 지속적인 연구를 통해 관련된 많은 문제들이 해결되고 있다. 로봇 자율 주행 성능을 향상시키기 위해 가장 중요한 문제 중의 하나는 로봇이 주변 환경을 이해하는 인지 능력이다. 로봇의 인지 능력은 탐색 자체의 문제뿐만 아니라 탐색지역에 대한 정보의 부재로 인해 더 가중된다.

이러한 문제점을 해결하기 위해 레이저, 초음파, 자외선, 영상 등 다양한 센서들을 사용한 연구가 진행되어 왔으며 Stowers는 스테레오비전 카메라인 마이크로소프트 Kinect 센서가 이동장치에 적용 가능함을 보였다(1-5). Kevin L.은 RGB 이미지에 깊이정보를 부가한 RGB-D를 사용하여 물체의 계층적인 뷰 생성에 대해서 연구하였으며, P. Henry는 실내 환경에서 RGB-D를 3D모델링에 적용하였다(6-7).

Kinect 센서는 적외선 레이저 방출기, 2개의 적외선카메라 그리고 RGB카메라를 가지고 있어서 깊이 이미지와 컬러 이미지를 초당 30프레임의 속도로 취득할 수 있다. 스테레오비전 카메라를 사용하는 장점은 별도의 거리 측정 센서 없이도 물체와의 깊이 정보를 제공할 수 있으며 낮은 조도에서도 잘 동작하므로 실내에서도 응용이 용이하다.

본 논문은 주어진 실내 환경에 위치한 여러 장애물에 대한 정보를 사전에 훈련하고 인식하여 로봇의 인지 능력을 향상시키기 위해, 깊이정보를 가지는, 스테레오비전 센서의 RGB-D 이미지에서 인텐시티를 기반으로 일정 거리 안에 있는 장애물을 검출하는 기법을 제시한다. 이미지 인텐시티는 음영 값을 가지는 2D 이미지보다 깊이 값을 가지는 3D이미지에서 값의 구별이 더 명확해질 수 있으며 RGB-D 이미지 전부를 데이터로 사용하는 경우에 비해 훈련시간 및 테스트 시간이

줄어들어 처리가 용이하다.

RGB-D 이미지 인텐시티의 패턴인식 적용성을 판단하기 위해 주요 알고리즘인 PCA(Principal Component Analysis), ICA(Independent Component Analysis), LDA(Linear Discriminant Analysis) 그리고 SVM(Support Vector Machine)의 알고리즘을 사용하여 RGB 이미지 전체를 입력으로 사용하는 경우에 비해 인텐시티 데이터가 어느 정도 개선이 있는지 인식을 및 실행시간 측면에서 비교한다. 그리고 어떤 알고리즘이 인텐시티 데이터를 사용하여 실내 주변 환경에 있는 주요 사물을 분류 인식하는데 적합하며 실내 모바일 로봇 자율 주행에 적용이 가능한지를 제시한다.

논문의 구성은 2장에서 RGB-D 이미지 인텐시티의 활용성에 대해서 설명하고, 3장에서는 RGB-D 이미지 인텐시티 인식을 위해 사용되는 패턴인식 알고리즘에 대해 기술하였으며, 4장에서는 시스템구현과 RGB-D 데이터와 인텐시티 데이터의 비교 분석한 결과를 설명하고, 5장에서 결론을 맺는다.

## II. 장애물 인식 및 RGB-D 인텐시티

### 2.1 장애물 인식 과정




그림 1. RGB-D 이미지 전처리 및 장애물 인식 과정  
Fig. 1. The Flow of RGB-D Preprocessing and Obstacle Recognition

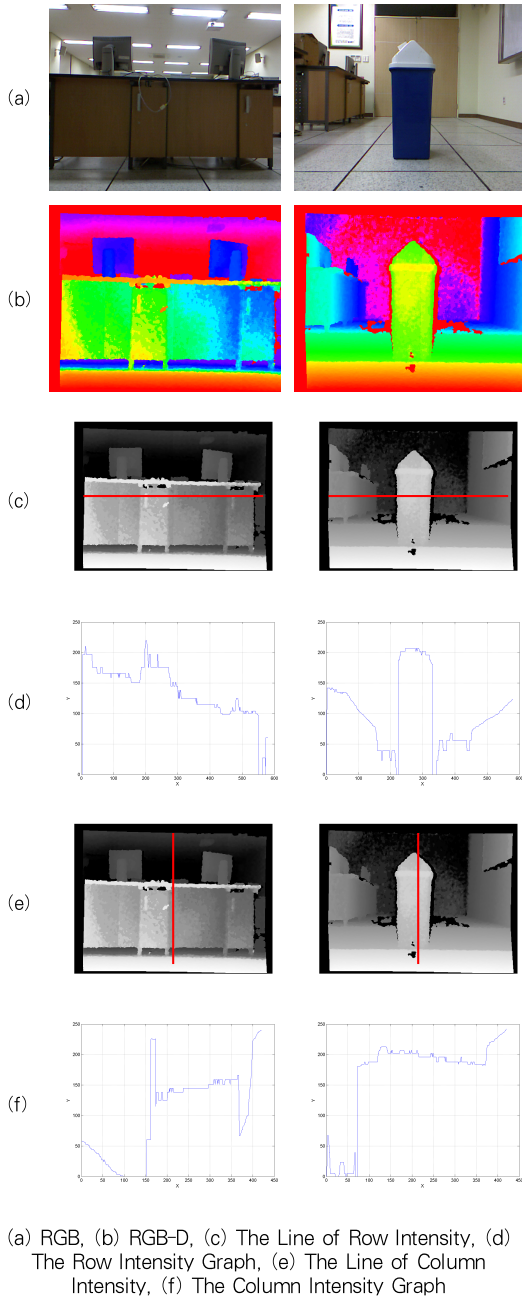


그림 2. RGB-D 이미지에서 구한 인텐시티 그래프  
Fig. 2. The Intensity Plot of RGB-D Image

RGB-D 이미지 전처리 및 장애물 인식 과정은 그림 1과 같다. Kinect에서 구해진 컬러 이미지와 깊이 이미지는 RGB-D 이미지로 변환되고, 편차를 줄이기 위해 Wiener 필터

를 사용하여 잡음을 제거하고 히스토그램 평활화를 거친다. 전처리를 마친 RGB-D 이미지는 깊이 이미지의 한 픽셀에 한 바이트를 할당하고, 0~255 사이의 컬러맵에 대한 인덱스 값을 가지도록 설정하였다. 전처리가 끝난 RGB-D 이미지에서 인텐시티를 구하여 데이터 세트를 만들고 PCA, ICA, LDA, SVM의 패턴인식 알고리즘의 입력으로 사용되어 패턴인식을 수행한다.

## 2.2 RGB-D 인텐시티

로봇이 자율 주행하는 실내 환경에는 다양한 장애물이 있고 각 장애물은 각기 다른 인텐시티를 가지고 있으며 크기 및 폭과 높이에 따라 극복할 수 있는 장애물과 극복할 수 없는 장애물로 구분할 수 있다. 예를 들어, 책상, 박스, 휴지통, 의자 등은 극복할 수 없는 장애물이지만 전기코드나 책 등은 모바일 로봇의 구성에 따라 극복할 수 있는 장애물이 될 수 있다.

RGB-D 이미지의 인텐시티 값은 깊이 이미지의 그레이 수준에 따라 원거리는 낮은 인텐시티를 가지게 되고 근거리는 높은 인텐시티 값을 가지게 된다. 그리고 계단, 벽면, 테이블과 같이 물체가 있는 경우에는 크기 및 굴곡에 따라 인텐시티가 달라진다. 그림 2-(a), (b)는 각각 책상과 휴지통에 대한 RGB, RGB-D 이미지이다. 그림 2-(c)에서 임의의 행의 인텐시티 값을 구하여 그림 2-(d)에 나타낸 것이며 그림 2-(e)에서 임의의 열의 인텐시티 값을 구하여 그림 2-(f)에 나타낸 것이다. 이를 통해 장애물에 따른 인텐시티 값의 변화를 알 수 있다.

주행 환경에 위치한 장애물에 대한 인텐시티 정보를 구하기 위해 인텐시티 맵을 정의하였으며 인텐시티 맵의 라인을 따라 인텐시티 값이 구해진다. RGB-D 이미지 크기는  $500 \times 500$  픽셀이며 인식 알고리즘의 훈련 및 테스트 소요시간을 고려하여 RGB-D 이미지에 대해 40픽셀 간격으로 라인을 배치하였다. 각 라인에 해당하는 인텐시티 값이 데이터 값으로 사용된다. 그림 4-(a)를 통해 장애물의 폭에 대한 인텐시티를 구하고 그림 4-(b)를 통해 장애물의 높이에 대한 인텐시티를 구한다.

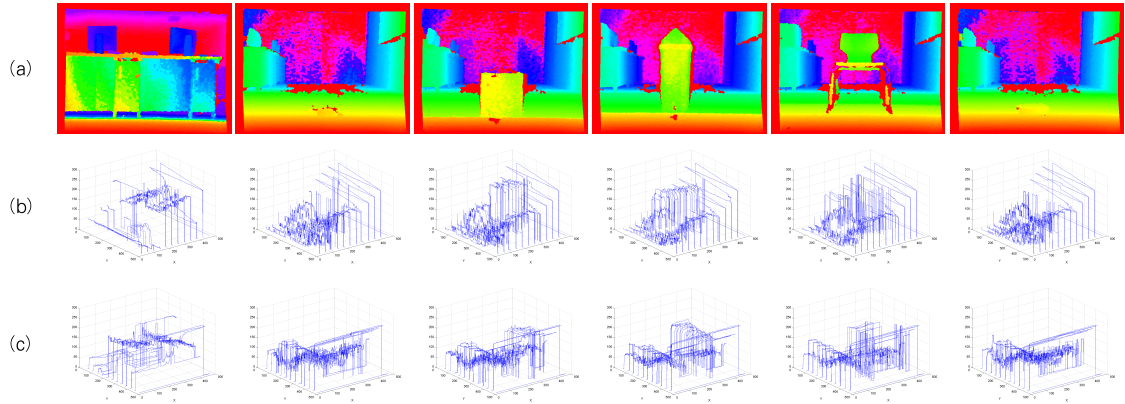


그림 3. (a) RGB-D, (b) 행 인텐시티 그래프, (c) 열 인텐시티 그래프  
 Fig. 3. (a) RGB-D, (b) The Row Intensity Plot, (c) The Column Intensity Plot




그림 4. 장애물 인텐시티 값을 구하기 위한 맵  
 Fig. 4. The Map for the Intensity Values of a Obstacle

### 2.3 RGB-D 인텐시티 그래프

로봇의 장애물 인식을 위한 데이터 세트를 책상, 전기코드, 박스, 휴지통, 의자, 책의 6가지 물체에 대해 근거리 80cm와 원거리 300cm에 두고 각각 20회씩 측정하였다. 결과적으로, 240개의 인텐시티 데이터 매트릭스를 구하였다. 데이터 세트를 거리 구분에 따라 둘로 나누어 120개 데이터 세트 2개를 작성하였다. 그림 3은 80cm 거리에서 취득한 이미지에 대한 인텐시티를 측정한 것으로 (a) RGB-D, (b) 행 인텐시티 그래프 그리고 (c) 열 인텐시티 그래프를 나타낸다.

이들 인텐시티 값은 장애물 인식을 위한 주요 패턴인식 알고리즘의 훈련 데이터 세트로 사용된다. 인텐시티 크기 및 변화에 따라 로봇의 장애물 회피 여부를 판단할 수 있다.

## III. 주요 인식 알고리즘

실내 장애물의 인텐시티에 대한 인식을 수행하기 위해 주요 패턴인식 알고리즘으로 잘 알려진 PCA, LDA, ICA,

SVM의 성능을 도출하고자 한다.

### 3.1 PCA(Principal Component Analysis)

잘 알려진 패턴인식 알고리즘인 고유치(eigen value)를 찾는 문제로 주성분분석(PCA)에 기반을 두고 있다[8].

$$\Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n \tag{1}$$

$$w_k = u_k^T (\Gamma - \Psi) \tag{2}$$

PCA는 모든 데이터 세트에서 유사성을 찾아 차원을 줄이는 방법을 사용한다. M개의 데이터 세트가 있을 때, 이 데이터 세트를 칼럼벡터( $\Gamma_1, \Gamma_2, \dots, \Gamma_M$ )로 표현하고, 평균치(식 1)를 구해, 각 데이터 세트에서 빼면,  $\Phi_i = \Gamma_i - \Psi$ 가 구해지고, 모든 데이터 세트에서 평균값을 뺀 데이터 세트  $A = [\Phi_1 \Phi_2 \dots \Phi_M]$ 가 만들어진다. PCA는 데이터를 잘 표현하는 직교벡터를 찾는 방법으로, 이들 벡터는 공분산  $C = AA^T$ 의 고유벡터가 된다. 고유치 견지에서, 각 데이터 세트는 M개의 의미가 큰 고유벡터  $u_k$ 을 사용하게 되며 가중치(식 2)가 구해진다. 훈련 데이터 세트와 새 데이터 세트의 가중치를 알면, NN(nearest neighbor) 방법을 사용하여 대상을 식별하게 된다. 고유치를 이용한 방법은 단순하고 빠른 장점이 있으나, 포즈, 표현, 조도에 따라 인식률이 낮아지는 문제점이 있다.

### 3.2 ICA(Independent Component Analysis)

PCA와 유사하게, ICA도 입력 데이터 세트의 차원을 줄일 벡터를 찾는 방법이다[9]. 그러나 ICA는 벡터의 직교규격화(orthonormalization)를 필요로 하지 않으므로 데이터 세트 값에서 고차 의존도를 활용할 수 있게 된다. PCA에서 데이터 세트의 1차 통계량인 평균을 빼는 것처럼, ICA도 1차, 2차 통계량을 제거한다. 평균이 제거된 각 데이터 세트는 X에 행 벡터로 저장, 백색화 매트릭스(식 3)와 곱한다. ICA는 여러 데이터 세트가 행벡터로 저장된 매트릭스  $U = WX$ 에서, 통계적으로 독립된 데이터 세트를 찾는 것이다. PCA와 비교하여 U의행은 고유치로 볼 수 있고,  $W^{-1}$ 은 각 데이터 세트의 가중치가 된다. ICA는 입력 데이터 세트의 특성을 보다 잘 반영할 수 있으나, 처리 속도가 느리다.

$$W_z = 2cov(X)^{-1/2} \tag{3}$$

### 3.3 LDA(Linear Discriminant Analysis)

PCA, ICA의 문제점중 하나는 같은 데이터 세트간의 가중치간 거리가, 다른 데이터 세트의 가중치 거리보다 커진다는데 있다. 이 문제를 바로잡기 위한 방법이 Fisherface이며, LDA에 기반을 두고 있다[10]. 이 알고리즘은 클래스 내부의 산포도를 최소화하고 클러스터와 클러스터 사이를 최대화하도록 고안되었다. 클래스간 산란행렬을  $S_B$ , 클래스내 산란행렬을  $S_W$ 라고 하면 최적 투영 공간은 다음 방법으로 구해진다.

$$W_{opt} = \frac{\max |W^T S_B W|}{\max |W^T S_W W|} = [w_1 w_2 \dots w_p] \tag{4}$$

$S_W$ 의 rank(계수)는 커 봐야 N-c이다. 여기에서 c는 훈련 집합 클래스의 수(파일 수)이고, PCA를 사용하여 차원을 줄이는 첫 단계에서 사용된다. 여기에는 많아봐야 c-1개의 고유벡터가 있으므로, 최대 c-1개의 Fisherface가 있게 된다. LDA가 데이터 세트가 적고 잘 분산된 경우 PCA 보다 우수하다고 알려져 있다.

### 3.4 SVM(Support Vector Machine)

최근에, SVM 패턴인식 문제를 푸는데 많은 관심을 받고 있다. SVM은 처음에 이진 분류기로 제안된 것이다. SVM은 간격 또는 거리를 최대화하는 하이퍼플레인을 구하여 지원백

터를 계산한다. SVM은  $x_i \in R^n, i = 1, 2, \dots, N$ 인 N개의 점집합으로 시작한다. 각 점  $y_i$ 는 두 클래스(-1, 1) 중 하나로 표시 된다. 최적 분리 하이퍼플레인은 (식 5)로 정의되고,  $f(x)$ 의 부호는 데이터의 클래스를 결정하게 된다 [11].

$$f(x) = \sum_{i=1}^l \alpha_i y_i x_i \cdot x + b \tag{5}$$

## IV. 구현 및 성능평가

앞의 단계에서 취득한 인텐시티 데이터 세트를 인식 알고리즘에 적용하여 인식을 및 실행시간을 구한다.

### 4.1 실험 환경

인텐시티 기반 장애물 인식을 위해 표 1과 같은 환경에서 실험을 수행하였다.

표 1. 하드웨어 스펙  
Table 1. Hardware Specification

항 목	주요 스펙
Microsoft Kinect	<ul style="list-style-type: none"> <li>Resolution: 640 × 480</li> <li>Frame Rate: 30 fps</li> <li>Sensing Range: 1.2 ~ 3.5m</li> <li>Field of View: Horizontal: 57°, Vertical: 43°</li> <li>Number of Cameras: IR: 2, RGB: 1</li> <li>Intel(R) Core(TM) i7, 3.4GHz</li> </ul>
Mobile Robot	<ul style="list-style-type: none"> <li>CRX10 Mobile Robot</li> <li>크기: 192 × 192 × 79.5 (L × W × H)</li> <li>Atmega128, Atmega88</li> <li>모터 : DC Geared motor/ 30:1 / 12VDC</li> <li>이동속도 : MAX. 1m/s</li> </ul>

RGB, RGB-D 그리고 인텐시티 데이터의 인식 차이점을 도출하기 위해, 근거리 80cm와 원거리 300cm에서 구한 인텐시티 데이터 세트에 PCA, ICA, LDA, SVM의 알고리즘을 적용하고 훈련세트 60%, 시험세트 40%로 설정하여, 두 개의 데이터 세트에 대해 인식을 수행하였다.

우선, 깊이정보가 없는 RGB와 깊이정보를 가지는 RGB-D에 대한 인식을 실험, 비교하고 RGB-D와 인텐시티 데이터 간의 인식을 및 처리 시간을 구해 어떤 조건에서 최적의 응용이 가능한지 제시한다.

### 4.2 RGB, RGB-D의 인식률 비교

RGB와 RGB-D의 인식 차이점을 도출하기 위해 두 데이터 세트에 대해 인식률을 수행한 결과는 그림 5와 같다.




그림 5. RGB와 RGB-D 데이터 세트별 인식률  
Fig. 5. The Accuracy for RGB and RGB-D Dataset

그림 5에서 LDA의 경우는 RGB와 RGB-D가 동일한 인식률을 보였으나, SVM에서 RGB-D가 8.3%더 우수한 인식률을 보였다.

### 4.3 RGB-D, 인텐시티 데이터의 인식률, 처리속도 비교

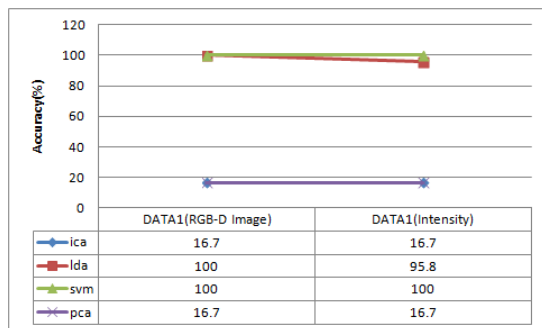


그림 6. RGB-D, 인텐시티 데이터 세트 인식률  
Fig. 6. The Accuracy for RGB-D & Intensity Dataset

RGB-D 이미지가 인텐시티 데이터에 비해 SVM의 경우 동일한 인식률을 보였으나, LDA에서 전체 픽셀과 거리 값을 사용한 RGB-D가 4.2% 높은 인식률을 보였다(그림 6).

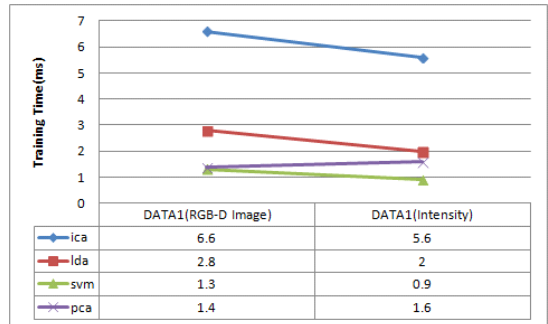


그림 7. RGB-D, 인텐시티 데이터 세트 훈련시간  
Fig. 7. The Training Time for RGB-D & Intensity Dataset

훈련시간은 인텐시티 데이터가 RGB-D 이미지에 비해 LDA의 경우 29%, SVM의 경우 31% 빠르게 처리됨을 알 수 있다(그림 7).




그림 8. RGB-D, 인텐시티 데이터 세트 테스트시간  
Fig. 8. The Testing Time for RGB-D & Intensity Dataset

테스트시간은 인텐시티 데이터가 RGB-D 이미지에 비해 LDA의 경우 70%, SVM의 경우 33% 빠르게 처리됨을 알 수 있다(그림 8).

PCA, ICA는 고유치 고유벡터를 기반으로 패턴인식을 수행하므로 인텐시티 데이터와 같이 여러 방향성이 혼재되어 있는 경우에는 인식률이 낮아지게 된다. 반면, LDA는 데이터 세트가 적고 잘 분산된 경우에 인식률이 높게 나올 수 있으며 SVM은 이진 분류기형태로 수행되기 때문에 분산에 기반을 두지 않아서 높은 인식률을 나타내었다.

장애물을 검사하기 위한 여러 센서를 추가적으로 사용하지 않더라도 LDA, SVM 알고리즘이 저가의 모바일 로봇 자율 주행에 사용이 가능하다는 것을 보여주는 것이다.

## V. 결론

로봇 자율 주행 성능을 향상시키기 위해 가장 중요한 문제 중의 하나는 로봇이 주변 환경을 이해하는 인지 능력이다. 미지 공간의 탐색 문제점은 탐색 자체의 문제뿐만 아니라 탐색 지역에 대한 정보의 부재로 인해 더 가중된다.

스테레오비전 센서는 저가격이면서도 매우 높은 수준의 인텐시티를 얻을 수 있어서 제공되는 탐색지역에 대한 정보를 통해 주변 환경의 장애물을 판단하는데 도움을 줄 수 있으므로 자율 주행에 효과적으로 사용될 수 있다.

로봇 자율 주행에 있어 기술적으로 중요한 점이 주변 환경의 장애물 인식이므로 저가의 시스템에서도 적용이 용이하고 빠른 처리가 가능한 알고리즘을 적용하는 것이 중요하다.

RGB-D 데이터와 인텐시티 데이터를 비교한 결과 정확도면에서는 RGB-D 데이터가 4.2% 높은 인식률을 보였으나 훈련 시간은 인텐시티 데이터가 RGB-D 이미지에 비해 LDA의 경우 29%, SVM의 경우 31% 빠르게 처리되었으며 테스트 시간은 LDA의 경우 70%, SVM의 경우 33% 빠르게 처리되어 인텐시티 데이터를 사용하는 것이 정확도면에서도 우수하고 처리 속도 면에서 높은 개선효과가 있는 것으로 판단된다.

향후연구로, 로봇이 자신의 위치를 찾고 탐색된 지역에 대한 수치지도를 생성하도록 하는 SLAM(Simultaneously Localization and Mapping)과 연동되는 것이 요구된다.

## 참고문헌

- [1] Pravitra, C., Chowdhary, G., Johnson, E., "A compact exploration strategy for indoor flight vehicles," in CDC-ECC, pp.3572-3577, 12-15 Dec. 2011.
- [2] Ruijie He, Prentice, S., Roy, N., "Planning in info space for a quad rotor helicopter in a GPS-denied environment," in ICRA, pp.1814-1820, 19-23 May 2008.
- [3] Grzonka, S., Grisetti, G., Burgard, W., "Towards a navigation system for autonomous indoor flying," in ICRA, pp.2878-2883, 12-17 May 2009.
- [4] Stowers, J., Hayes, M., Bainbridge-Smith, A., "Altitude control of a quadrotor helicopter using


depth map from MS Kinect sensor," in ICM, pp.358-362, 13-15 April 2011.

- [5] Kinect. <http://www.xbox.com/en-us/kinect/> March 2011.
- [6] Kevin L., Liefeng B., Xiaofeng R., and Dieter F., "A Large-Scale Hierarchical Multi-View RGB-D Object Dataset", In ICRA, 2011.
- [7] P. Henry, M. Krainin, E. Herbst, X. Ren, and D. Fox, "RGB-D mapping: Using depth cameras for dense 3D modeling of indoor environments", in ISER, 2010.
- [8] M. A. Turk and A. P. Pentland, "Face Recognition Using Eigenfaces", in IEEE CVPR, pp. 586-591, 1991.
- [9] M. S. Bartlett, J. R. Movellan, and T. J. Sejnowski, "Face Recognition by Independent Component Analysis", IEEE Transactions on Neural Networks, Vol. 13, pp. 1450-1464, 2002.
- [10] P. N. Belhumeur, J. P. Hespanha, and D. J. Kriegman, "Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection", in IEEE TPAMI. Vol. 19, pp. 711-720, 1997.
- [11] B. Heisele, P. Ho, and T. Poggio, "Face Recognition with Support Vector Machines: Global versus Component-Based Approach", in ICCV. Vol. 2 Vancouver, Canada, pp. 688.694, 2001.

## 저 자 소 개



**권 기 현**  
1993: 강원대학교  
전자계산학과 이학사  
1995: 강원대학교  
전자계산학과 이학석사  
2000: 강원대학교  
컴퓨터과학과 이학박사  
1998~2002: 동원대학  
인터넷정보과 교수  
2002~현재: 강원대학교  
전자정보통신공학부 교수  
관심분야: 패턴인식, 미들웨어,  
임베디드 소프트웨어  
Email : kweon@kangwon.ac.kr



**이 형 봉**  
1984: 서울대학교  
계산통계학과 이학사.  
1986: 서울대학교  
계산통계학(전산과학)과  
이학석사.  
2002: 강원대학교  
컴퓨터과학과 이학박사  
1986~1993: LG전자  
컴퓨터연구소 선임  
1994~1998: 한국디지털  
(DEC Korea) 책임  
1999~2003: 호남대학교  
정보통신공학부 조교수  
2004~현재: 강릉원주대학교  
컴퓨터공학과 교수  
관심분야 : 임베디드 시스템,  
센서 네트워크,  
데이터마이닝 알고리즘  
Email : hblee@gwnu.ac.kr