

논문 2010-47SP-4-4

# 마찰계수의 비접촉 추정을 위한 영상정보 활용방법

## ( Utilizing Visual Information for Non-contact Predicting Method of Friction Coefficient )

김 두 규\*, 김 자 영\*, 이 지 흥\*, 최 동 겐\*\*, 권 인 소\*\*

(Doo-gyu Kim, Ja-young Kim, Jihong Lee, Dong-Geol Choi, and In-So Kweon)

### 요 약

본 논문에서는 마찰계수의 비접촉 추정을 위한 영상정보 활용방법을 제안한다. 마찰계수는 이동체의 도로주행 또는 장애물 극복에 있어 매우 중요한 요소이다. 이동체가 이동경로의 마찰계수를 미리 알 수 있다면 이동성향상을 기대할 수 있다. 본 논문의 마찰계수 추정방법은 영상정보를 활용하기 때문에 이동체가 지면과 접촉하기 전에 마찰계수를 추정 할 수 있다는 장점이 있다. 마찰계수의 비접촉 추정을 위한 영상정보 활용방법은 마찰계수측정실험과 물질그룹생성을 포함한 학습단계와 물질그룹 분류과정과 마찰계수 함수 활용을 포함한 마찰계수 추정단계로 구성되어 있으며 물질 조성비를 생성하는 영상처리는 두 단계에 모두 포함된다. 이 과정을 통해 얻은 마찰계수는 무인이동로봇이 이동경로 진입 전에 미끄러움을 판단하여 미끄럼지역을 회피 할 수 있도록 하며, 저속으로 이동이 가능한 경우 미끄럼이 발생하지 않는 적정속도를 계산하는데 활용 가능하다. 본 논문에서 사용한 지형의 마찰계수와 영상정보는 마찰계수 측정실험을 통해 취득하였다. 마찰계수 추정방법을 평가하기 위해 실험지형의 실제 마찰계수와 추정 마찰계수의 차이를 비교하였다.

### Abstract

In this paper, we proposed an algorithm for utilizing visual information for non-contact predicting method of friction coefficient. Coefficient of friction is very important in driving on road and traversing over obstacle. Our algorithm is based on terrain classification for visual image. The proposed method, non-contacting approach, has advantage over other methods that extract material characteristic of road by sensors contacting road surface. This method is composed of learning group(experiment, grouping material) and predicting friction coefficient group(Bayesian classification, prediction function). Every group include previous work of vision. Advantage of our algorithm before entering such terrain can be very useful for avoiding slippery areas. We make experiment on measurement of friction coefficient of terrain. This result is utilized real friction coefficient as prediction method. We show error between real friction coefficient and predicted friction coefficient for performance evaluation of our algorithm.

**Keywords :** Friction Coefficient, Mobile Robot, Path Planning, Bayesian Classification

### I. 서 론

지면의 마찰계수(friction coefficient)는 모든 이동체의 이동성(mobility)에 큰 영향을 미친다고 할 수 있다. 마찰계수의 크기에 따라 미끄러지지 않고 이동 가능한 속도 역시 달라진다. 이동체의 이동성을 높이기 위해 마찰계수를 추정하여 활용하는 연구가 진행되어 왔다<sup>[1]</sup>. 이동체를 사용해 마찰계수를 추정하는 방법은 과거부터

\* 정회원, 충남대학교 BK21 메카트로닉스 사업단  
(BK21 Mechatronics Group at Chungnam National University)

\*\* 정회원, 한국과학기술원  
(Korea Advanced Institute of Science and Technology)

※ 본 연구는 한국과학기술원 국방무인화기술평화연구 센터를 통한 국방과학연구소 연구비 지원으로 수행되었습니다.

접수일자: 2009년9월25일, 수정완료일: 2010년6월22일

연구되어 온 사후 추정 방법과 최근 활발히 연구되는 사전 추정 방법으로 나눌 수 있다.

사후 추정 방법은 이동로봇 견인력 제어를 위해 바퀴 토크의 변화를 이용해 미끄럼(slip)을 최소화 하는 방법<sup>[2]</sup>과 자동차의 견인력 제어를 위해 다양한 센서를 활용하여 마찰계수를 추정하는 방법<sup>[3]</sup>이 대표적이라고 할 수 있다. 예외적인 유사 연구로는 진동을 이용한 물질(material) 분류 방법이 있다<sup>[4]</sup>. 사후 추정 방법의 장점은 지면과 접촉 후 미끄럼이 적게 발생 하도록 바퀴 속도를 조절하여 견인력을 높일 수 있다는 것이다. 하지만 지면과 접촉을 해야만 하기 때문에 미끄러운 지역에서는 이동 불능 상태에 빠질 수 있다는 단점이 있다.

사전 추정 방법은 이동로봇의 경로계획을 위해 영상 정보 중 지형의 모양(geometry) 정보를 추출해 미끄럼을 추정하는 방법<sup>[5]</sup> 등이 있으며 마찰계수 추정에 사용 가능한 지형 분류<sup>[6~7]</sup>가 선행연구 되고 있다. 사전 추정 방법은 지면과 접촉하기 전에 마찰계수 추정을 통해 미끄럼을 판단하여 진입 후 이동 불능 상태가 될 가능성이 큰 지역을 회피 할 수 있다는 장점이 있다. 그리고 주행 속도 계산에 사용 될 경우 최적 속도를 이용해 빠른 이동성을 가질 수 있다.

본 논문에서 제시하는 마찰계수 추정 방법은 새롭게 연구되고 있는 사전 추정 방법으로 영상 정보에서 물질 조성비로 표현되는 물질 정보를 추출해 마찰계수를 추

정한다. 물질 조성비를 사용하여 마찰계수를 학습하기 때문에 단순 물질 분류를 활용하는 것 보다 정확한 마찰계수를 추정 한다는 장점이 있고, 사전 추정 방법이 갖는 장점 역시 가진다. 본 연구는 여러 종류의 물질이 섞여 있는 혼합지형의 마찰계수 추정을 위한 기초 연구라고 할 수 있으며 결과 역시 그러하다.

본 논문은 물질 조성비를 생성하는 영상 전처리(II장), 물질 그룹 생성과 물질 분류(III장), 마찰계수 추정 함수(prediction function)(IV장), 마찰계수 측정 실험과 추정 결과(V장)로 구성된다. 그림 1은 마찰계수 추정 방법을 도식화 한 것이다.

그림 1에서 보여주는 영상 전처리는 학습 단계와 마찰계수 추정 단계에서 모두 사용된다.

## II. 영상 전처리

### 1. Over-segmentation

영상 전처리는 Over-segmentation과 물질 조성비 생성으로 구분 할 수 있다. Over-segmentation은 입력된 지형 영상의 질감을 이용한 분류 방법으로 Leung과 Malik가 소개한 Texton을 사용한다. Texton을 사용하면 색상과 관련 없이 질감을 판단 할 수 있다<sup>[8]</sup>. 그리고 영상의 정확하고 빠른 질감 판단을 위해 Verma 방법을 이용해 Texton Histogram을 만들어 사용한다<sup>[9]</sup>. 영상의 질감 판단 결과는 Felzenszwalb의 방법<sup>[10]</sup>을 이용한 질감의 유사도 판별 과정을 통해 지형 영상을 부분별로 병합(merge)하여 Segment를 생성한다. 그림 2는 Over-segmentation 이전의 지형 영상 정보 건본이다.

그림 3은 그림 2의 Over-segmentation 결과를 보여 준다.

그림 3은 Over-segmentation 결과를 시각적으로 확

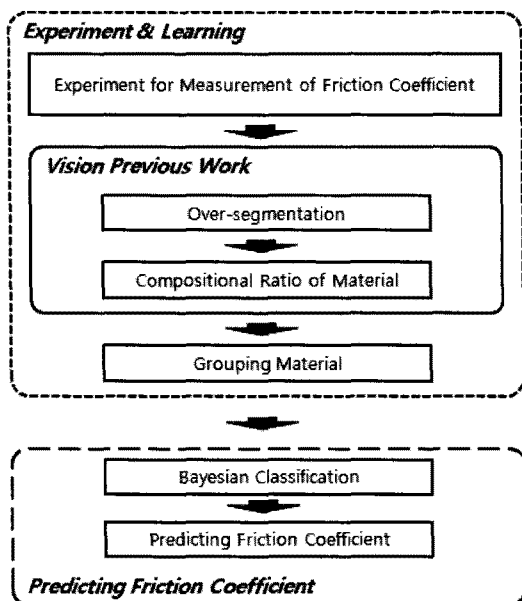


그림 1. 마찰계수 추정 방법 도식화  
Fig. 1. Diagram of Predicting Method of friction coefficient.




그림 2. 지형 영상 정보 건본  
Fig. 2. Sample image of terrain visual information.




그림 3. 지형 영상 정보 건본의 Over-segmentation 결과

Fig. 3. Over-segmentation result of sample image.

인하기 위해 각 Segment 마다 단색을 채워 보여주고 있다. 동일한 색상으로 채워져 있는 각각의 Segment는 같은 물질로 이루어 졌다고 할 수 있다.

2. 물질 조성비 생성

본 논문에서 사용하는 물질 조성비는 각 Segment와 학습 영상 사이의 유사도를 활용해 생성되며 물질 종류 판단 및 마찰계수 추정에 사용된다. 그림 4는 물질 조성비 생성에 사용되는 학습 영상이다.

학습 영상은 6가지 물질(하늘, 흙, 작은 자갈, 자갈, 나무, 아스팔트)로 구성되어 있다. 모든 Segment는 각각 물질 조성비를 가지며 그림 5는 2개 Segment의 물질 조성비를 그래프로 나타내고 있다.

생성된 물질 조성비는 마찰계수 추정 함수와 물질 그룹 생성에 사용될 때 6가지 종류 중 지면의 마찰계수에 영향을 미치지 않는 하늘과 나무가 제외된 데이터를 벡터 형태로 사용한다.




그림 4. 6가지 물질의 학습 영상  
Fig. 4. Learning images of six material.




그림 5. 영상 조각의 물질 조성비 결과 막대그래프  
Fig. 5. Histogram of compositional ratio of material.

III. 물질 그룹 생성 및 분류

1. 물질 그룹 생성

물질은 노면을 구성하는 대표적 물질이라 할 수 있는 흙, 작은 자갈, 자갈, 아스팔트의 물질 조성비를 이용해 각 물질마다 그룹을 생성한다. 식(1) 과 식 (2)은 각 물질 그룹의 평균 벡터와 공분산 행렬을 구한다.

$$\hat{\mu} = \frac{1}{n} \sum_{k=1}^n X_k \tag{1}$$

$$\hat{\Sigma} = \frac{1}{n} \sum_{k=1}^n (X_k - \hat{\mu})(X_k - \hat{\mu})^T \tag{2}$$

여기서,  $X$ 는 실험을 통해 생성한 물질 그룹의 물질 조성비,  $n$ 은 물질 조성비의 개수,  $\hat{\mu}$ 는 물질 그룹의 평균 벡터,  $\hat{\Sigma}$ 는 물질 그룹의 공분산 행렬이다. 계산된  $\hat{\mu}$  과  $\hat{\Sigma}$ 는 베이지안 분류기에서 사용된다.

2. 물질 분류 방법

새로운 지형 영상 정보의 물질 조성비를 활용해 생성 되어 있는 물질 그룹을 선택하기 위해 베이지안 분류기 (Bayesian classification)를 사용한다<sup>[11]</sup>. 식 (3)은 베이 지안 분류기를 보여준다.

$$P(\omega_i | Y, D) = \frac{P(Y | \omega_i, D_i) P(\omega_i | D_i)}{\sum_{j=1}^G P(Y | \omega_j, D_j) P(\omega_j | D_j)} \tag{3}$$

여기서,  $\omega_i$ 는 각 물질 그룹의 식별자(identifier)이고  $\omega_i = (\mu, \Sigma)$ 로 나타낼 수 있다.  $D$ 는 물질 그룹에 속해

있는 물질 조성비,  $Y$ 는 새로운 지형 영상 정보의 물질 조성비,  $G$ 는 물질 그룹의 수이다.  $P(\omega|D)$ 는 사전확률이고,  $P(Y|\omega, D)$ 는 조건부 확률이며 식 (4)로 나타낼 수 있다.

$$P(Y|\omega, D) = \frac{1}{\sqrt{2\pi}^d \sqrt{\det(\Sigma)}} e^{-\frac{1}{2}(D-\mu)^T \Sigma^{-1} (D-\mu)} \quad (4)$$

여기서,  $d$ 는 물질 조성비의 차 원수 이다.

#### IV. 마찰계수 추정

마찰계수 추정에 사용되는 함수는 물질 그룹의 마찰계수 특징을 마찰계수 추정 함수에 반영 할 수 있도록 변수를 생성하는 비용 함수(cost function)와 마찰계수 추정에 사용되는 마찰계수 추정 함수로 이루어진다. 비용 함수는 물질 그룹마다 적용되며 식(5)로 나타낸다.

$$\min \sum_{c=1}^C \sum_{i=1}^N \{F_i - K(x_i, x_c) [b_0^c + b_1^c < x_c, x_i >]\}^2 \quad (5)$$

여기서,  $F_i$ 는 실험을 통해 획득한 물질의 실제 마찰계수이고,  $K(x, x_c)$ 는  $K(x, x_c) = \exp(-\|x - x_c\|^2) / \lambda$ 로 표현되는 가중치 함수이다.  $x_i$ 는 1개의 물질 그룹 내에 존재하는 물질 조성비 이고,  $x_c$ 는 모든 그룹의 물질 조성비 전부,  $N$ 은 1개 물질 그룹의 물질 조성비 수,  $C$ 는 모든 그룹의 물질 조성비 전체의 수이다.  $N$ 과  $C$ 는 Segment의 수로도 설명 가능하다.  $b_0$ 와  $b_1$ 은 마찰계수 특성을 나타내는 변수이고,  $\lambda$ 는 마찰계수 추정 함수의 수용 영역(receptive fields)이다<sup>[12]</sup>.

식 (5)를 통해 각 그룹은 변수  $b_0, b_1, \lambda$ 을 가지게 되고 마찰계수 추정 함수에 사용된다. 식 (6)은 마찰계수 추정을 위한 함수이다.

$$\hat{F}(x) = \sum_{i=1}^N K(x, x_i) (b_0^c + b_1^c < x_i, x >) \quad (6)$$

여기서,  $x$ 는 새롭게 입력된 지형 영상 정보 중 1개의 Segment의 물질 조성비 이고,  $\hat{F}$ 는 추정 마찰계수이다.

#### V. 실험 결과

본 장에서는 영상정보를 활용한 마찰계수 추정 방법을 검증하기 위한 실험 결과를 제시한다.

#### 1. 마찰계수 측정 실험

마찰계수 측정 실험은 추정된 마찰계수와 비교하기 위해 실제 마찰계수를 얻기 위한 실험이다. 마찰계수 측정 실험 장치는 로드 셀(Load Cell)을 이용하였다. 실험 방법은 견인 차량(traction car)과 실험 이동체(experimental vehicle) 사이에 로드 셀을 위치시켜 실험 이동체가 미끄러지는 순간의 힘을 측정 한 후, 실험 이동체의 무게를 고려하여 마찰계수를 계산한다. 실험 결과는 본 연구에서 사용하는 각 지형의 실제 마찰계수로 사용하였다. 영상 정보는 범블비(Bumblebee) 카메라를 사용하여 획득 하였다. 그림 6은 마찰계수 측정 실험 장면을 보내준다.




그림 6. 마찰계수 측정 실험  
Fig. 6. Experiment for measurement of friction coefficient

#### 2. 지형의 그룹화 및 새로운 지형 분류 결과

4 종류 지형(흙, 작은 자갈, 자갈, 아스팔트)에서 마찰계수 측정 실험을 실행하고 본 논문의 III장에서 소개한




그림 7. 물질 그룹 생성에 사용한 지형(흙, 작은 자갈, 자갈, 아스팔트)  
Fig. 7. Terrain information for grouping(Soil, Small Gravel, Gravel, Asphalt).

식 (1)과 식(2)를 이용해 각 물질 그룹의 평균값과 공분산을 구한다. 그림 7은 마찰계수를 추정 했던 지형을 보여준다.

생성된 4개의 물질 그룹은 식 (5)을 이용해 변수  $b_0, b_1, \lambda$ 를 계산한다.

3. 베이지안 분류기를 활용한 물질 분류

새로운 지형 영상 정보는 본 논문 II장에서 소개한 영상 전처리를 통해 Segment를 생성하고 물질 조성비를 만든다. 베이지안 분류기는 생성된 모든 Segment의 물질 조성비와 각 물질 그룹의 평균, 공분산, 물질 조성비를 이용해 각 Segment마다 마찰계수 특징이 유사한 물질 그룹으로 분류한다. 그리고 모든 물질 그룹에 미리 생성해 놓은 변수를 사용해 마찰계수를 추정 한다. 표 1은 그룹 생성에 사용했던 지형 영상정보를 입력 지형 영상으로 설정하였을 때 베이지안 분류 결과와 성능 비교를 위한 최소거리 분류 결과의 확률을 보여주고 있다.

표 1은 물질 그룹 분류 성능을 자체평가하기 위해 그룹 생성에 사용했던 그림 7의 4가지 지형 영상 정보를 새로운 입력으로 가정한 분류 결과로 모든 지형에서 최소거리 분류법 보다 베이지안 분류법이 물질 그룹 분류가 잘 되고 있음을 확인 할 수 있다. 우리는 베이지안 분류법이 최소거리 분류법 보다 좋은 분류법임을 알 수 있다. 분류 확률이 100%가 되지 못하는 이유는 지형 영상 정보 중 경계선 부분의 물질 조성비가 잘못 생성되었기 때문으로 추정된다.

물질 그룹 생성에 사용하지 않은 새로운 지형 영상

표 1. 베이지안 분류 결과와 최소거리 분류 결과의 확률

Table 1. Probability of Bayesian classification result and minimum distance classification result.

		Bayesian Classification	Minimum Distance Classification
Average of Classification on Probability (%)	Soil	96.82	70.45
	Small Gravel	92.72	85.96
	Gravel	97.73	88.4
	Asphalt	90.19	86




그림 8. 새로운 지형 영상 정보

Fig. 8. Vision information of new terrain

표 2. 새로운 지형 영상 정보의 베이지안 분류 결과와 최소거리 분류 결과의 확률

Table 2. Probability of Bayesian classification result and minimum distance classification result of new terrain.

	Bayesian Classification	Minimum Distance Classification
Average of Classification Probability (%)	82.56	61.28

정보인 그림 8을 입력된 지형 영상정보로 설정하여 베이지안 분류법과 최소 거리 분류법의 결과를 표 2에 나타내었다.

표 2의 분류 결과는 표 1과 마찬가지로 베이지안 분류기의 분류 확률이 높은 것을 보여준다. 그리고 표 2의 수치가 표 1에 비해 낮은 이유는 그림 8이 물질 그룹을 생성 할 때 사용했던 영상정보가 아니기 때문에 Segment의 물질 조성비와 물질 그룹간의 유사도가 떨어지기 때문이다. 표 2와 표 1의 수치 차이는 마찰계수 추정 오차에 영향을 미친다.

4. 마찰계수 추정 결과

모든 Segment는 베이지안 분류기에 의해 선택된 물질 그룹에 해당하는 변수를 마찰계수 추정 함수 인 식 (6)에 사용하여 마찰계수를 추정한다. 그림 9는 그림 7에서 보여주는 4가지 지형의 마찰계수 추정 오차와 그림 8의 마찰계수 추정 오차를 그래프로 나타낸 것이다. 오차 계산은 실제 마찰계수에서 추정된 마찰계수를 차감하는 형식을 사용했으며 오차를 합산 할 때는 절대값을 사용하였다.

그림 9는 그림 7의 4개 지형에 비해 그림 8의 새로운 지형의 마찰계수 추정 오차가 큰 것을 보여준다. 이 결

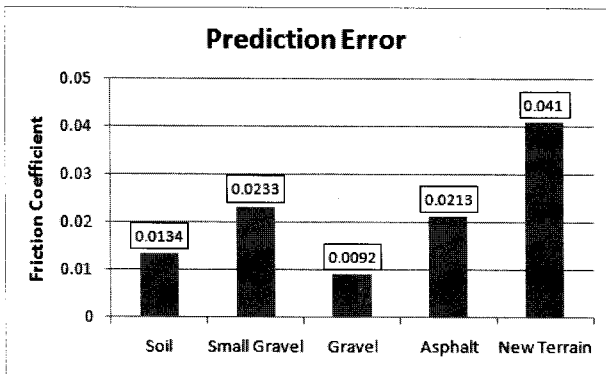


그림 9. 5가지 지형(그림 6, 그림 8)의 마찰계수 추정 오차

Fig. 9. Prediction error of five terrain(fig. 6, fig. 8).

과는 표 2의 결과와 표 1의 결과 차이와 연관 하여 생각 할 수 있다. 그리고 4개 지형의 그래프 중 흙과 자갈에 비해 작은 자갈과 아스팔트의 오차가 큰 것을 확인할 수 있다. 이유는 물질 조성비 생성 과정에서 흙과 자갈은 4가지 물질 중에서 물질 조성비 특성이 뚜렷한 반면 작은 자갈과 아스팔트의 물질 조성비 특성이 흙과 자갈에 비해 서로 비슷한 부분이 있기 때문이다. 이 결과는 표 1의 분류 확률 중에서 작은 자갈과 아스팔트의 분류 확률이 흙과 자갈의 분류 확률에 비해 낮은 것과 연관 지을 수 있다.

그림 9에서 가장 중요한 결과는 새로운 지형의 마찰계수 추정 오차라고 할 수 있으며 그 값은 0.041로 계산되었다. 따라서 오차율이 4.1%이며 이 수치는 기존의 지형정보를 활용한 미끄럼 추정 방법<sup>[4]</sup>에서 제시했던 20%에 비해 15%이상 상승된 수치이다.

## VI. 결 론

본 논문에서는 마찰계수의 비접촉 추정을 위한 영상 정보 활용방법을 제안 하였다. 마찰계수 측정 실험을 통해 측정된 실제 마찰계수를 이용하여 정확한 마찰계수 적용 및 검증을 했으며, 마찰계수 추정 이전에 물질 그룹을 만들고 변수를 생성해 놓아 마찰계수 추정 함수에 마찰계수 특성을 반영 할 수 있도록 하였고, 베이저안 분류기를 사용해 마찰계수 특징이 유사한 물질 그룹을 판단 할 수 있게 하였다. 추정 된 마찰계수는 실제 마찰계수와 오차율이 약 4.1%로 기존의 사전 추정 방법에 비해 작은 것을 확인하였다.

추후 연구로는 다양한 지형에서의 마찰계수 측정을 통해 영상 정보 데이터베이스를 구축하여 다양한 물질

그룹 생성 및 분류가 가능하도록 하는 연구가 있을 수 있다. 또한 분류 확률을 높이고, 마찰계수 추정 오차를 줄이기 위한 연구가 필요하다. 마지막으로 이를 실제 이동체의 경로계획에 활용하기 위해서는 실시간성을 확보하는 것이 무엇보다 중요하다고 할 수 있다.

## 참 고 문 헌

- [1] CHIA-SHANG LIU and HUEI PENG, "Road Friction Coefficient Estimation for Vehicle Path Prediction," *Vehicle System Dynamics*, vol. 25, pp.413-425, 1996.
- [2] P. Lamon, A. Krebs, M. Lauria, and S. Shooter, R. Siegwart, "Wheel torque control for a rough terrain rover," *IEEE International Conference on Robotics and Automation*, pp. 4682-4687, 2004.
- [3] F. Gustafsson, "Slip based tire-road friction estimation," *Automatica: the journal of IFAC, the International Federation of Automatic Control*, vol. 33, no. 6, pp.1087-1099, 1997.
- [4] Christopher A. Brooks and Karl Iagnemma, "Vibration-based terrain classification for planetary exploration rovers," *IEEE Transactions on Robotics*, vol. 21, no. 6, pp.1185-1191, 2005.
- [5] Anelia Angelova, Larry Matthies, Daniel Helmick and Pietro Perona, "Learning and Prediction of Slip from Visual Information," *Journal of Field Robotics*, vol. 24, no. 3. pp.205-231, 2007.
- [6] Paul Jansen, Wannes van der Mark, Johan C. van den Heuvel, Frans C.A. Geroen, "Colour based Off-Road Environment and Terrain Type Classification," *IEEE Conference on Intelligent Transportation Systems*, pp.61-66, 2005.
- [7] 성기열, 광동민, 이승연, 유준, "무인차량 적용을 위한 영상 기반의 지형 분류 기법", *제어.로봇.시스템학회 논문지*, vol. 15, no. 4, pp.372-378, 2009.
- [8] T. Leung and J. Malik, "Representing and Recognizing the Visual Appearance of Materials Using the Three-dimensional Texton," *IJCV* vol. 42, no. 1, 2001.
- [9] M. Varma and A. Zisserman, "Classifying images of materials achieving viewpoint and illumination independence," *European Conference on Computer Vision*, pp.255-271, 2003.
- [10] P. felzenszwalb and D. Huttenlocher, "Efficient Graph based Image Segmentation," *IJCV*, vol. 59, no. 2, pp.167-181, 2004.
- [11] Richard O. Duda, Peter E. Hart and David G. Stork, *Pattern Classification 2nd ed*, Wiley, New York, 2001.

- [12] Sethu Vijayakumar, Aaron D'Souza, and Stefan Schaal, "Incremental Online Learning in High Dimensions," *Neural Computation*, vol. 17, no. 12, pp.2602-2634, 2005.

---

 저 자 소 개
 

---



김 두 규(정회원)  
 2008년 충남대학교 메카트로닉스 공학과 학사 졸업.  
 2010년 충남대학교 메카트로닉스 공학과 석사 졸업.  
 <주관심분야 : 로봇틱스, 경로계획, 로봇설계>



김 자 영(정회원)  
 2008년 충북대학교 기계공학과 학사 졸업.  
 2009년~현재 충남대학교 메카트로닉스 석사 재학중  
 <주관심분야 : 로봇틱스, 지능제어, 로봇제어>



이 지 흥(정회원)  
 1983년 서울대학교 전자공학과 학사 졸업.  
 1985년 한국과학기술원 전기 및 전자공학과 석사 졸업.  
 1991년 한국과학기술원 전기 및 전자공학과 박사 졸업.  
 1994년~현재 충남대학교 메카트로닉스공학과 정교수  
 <주관심분야 : 로봇틱스, 위치추정, 경로계획>



최 등 걸(정회원)  
 2005년 한양대학교 전자컴퓨터 공학과 학사 졸업  
 2007년 한양대학교 제어계측 공학과 석사 졸업  
 2007년~현재 한국과학기술원 로봇학제전공 박사과정 재학중  
 <주관심분야 : 로봇 비전, Computational Camara, 물체 인식, 물체 분류>



권 인 소(정회원)  
 1981년 서울대학교 기계설계학과 학사 졸업  
 1983년 서울대학교 기계설계학과 석사 졸업  
 1990년 Carnegie Mellon Uni. Robotics Institute 박사 졸업  
 1991년~1992년 일본 도시바 중앙연구소 연구원  
 1992년~현재 한국과학기술원 전자전산학부 교수  
 <주관심분야 : 컴퓨터 비전, 3D 비전, 카메라 보정, 물체 인식, 물체 분류, SLAM>