

실외 주행 로봇의 이동 성능 개선을 위한 지형 분류

Terrain Classification for Enhancing Mobility of Outdoor Mobile Robot

김 자 영¹, 이 종 화¹, 이 지 흥[†], 권 인 소²

Ja-young Kim¹, Jong-hwa Lee¹, Jihong Lee[†], In-So Kweon²

Abstract One of the requirements for autonomous vehicles on off-road is to move stably in unstructured environments. Such capacity of autonomous vehicles is one of the most important abilities in consideration of mobility. So, many researchers use contact and/or non-contact methods to determine a terrain whether the vehicle can move on or not. In this paper we introduce an algorithm to classify terrains using visual information(one of the non-contacting methods). As a pre-processing, a contrast enhancement technique is introduced to improve classification of terrain. Also, for conducting classification algorithm, training images are grouped according to materials of the surface, and then Bayesian classification are applied to new images to determine membership to each group. In addition to the classification, we can build Traversability map specified by friction coefficients on which autonomous vehicles can decide to go or not. Experiments are made with Load-Cell to determine real friction coefficients of various terrains.

Keywords: Image Processing, Vision Information, Over-segmentation, Bayesian Classification, Friction Coefficient, Terrain Classification, Traversability Map

1. 서 론

로봇이 행성 탐사, 군사용 정찰 등의 임무를 사람의 조 작 없이 수행하기 위해서는 자율 주행 능력을 갖추고 있어야 한다. 이러한 자율 주행 능력은 다양한 환경에서 로봇이 얼마만큼의 주행성(mobility)을 가지고 있는냐에 따라 달라진다. 따라서 로봇의 자율 주행 측면에서 주행성 향상은 중요한 연구 주제가 되어왔다¹⁾.

다양한 환경에서 로봇의 주행성을 향상시키기 위해 로봇이 어떠한 환경에서 움직이고 있는지 인식하고 판단할 수 있는 알고리즘 연구가 선행되어야 한다. 이러한 알고리즘은 크게 로봇이 지면과 접촉하여 환경을 인식하는 접촉식 방법과 로봇이 특정한 환경에 들어서기 전에 미리 환

경을 인식하고 로봇을 운용하는 비접촉 인식 방법으로 나눌 수 있다.

접촉식 방법으로서 로봇이 움직이는 환경 안에서 지면의 물리적 특성인 마찰계수를 추정하고, 정량적인 마찰계수를 주행성의 판단 기준으로 사용하여 지형을 인식하는 연구가 수행되었다²⁾. 그리고 최대 전단응력을 추정하는 방법³⁾과 자동차의 견인력제어와 관련된 최대 마찰계수 추정연구⁴⁾를 예를 들 수 있다. 그 중에서 최근에 많은 연구가 이루어지고 있는 미끄럼(slip)을 기반으로 한 최대 마찰계수 추정이 대표적이다⁵⁾. 또한 환경의 형상에 기반을 두어 로봇이 이동하는 동안의 진동정보를 학습시켜서 몇몇 주요 지형 환경인 ‘자갈’, ‘모래’, ‘흙’을 인식하는 연구가 수행되었다⁶⁾. 이러한 접촉식 방법을 통한 지형 인식은 로봇의 바퀴가 지면에 접촉하여 접촉된 좁은 영역만을 측정해야 하고 경우에 따라 모래와 같이 유연한 지면의 환경에서 바퀴가 지면에 물이게 되어 바퀴의 지면 잠식 정도를 별도의 카메라를 통해 측정해야 한다. 또한 로봇의 바퀴와 지면과의 접촉은 미끄러거나 갈라진 틈(crack)이 많은 지

Received : Jun. 28. 2010; Reviewed : Aug. 19. 2010; Accepted : Sep. 17. 2010

※ 본 연구는 한국과학기술원 국방무인화기특화연구센터를 통한 방위사업청과 국방과학연구소 연구비 지원으로 수행되었습니다.

† 교신저자 : 충남대학교 메카트로닉스 공학과 교수

¹ 충남대학교 메카트로닉스 공학과

² 한국과학기술원 전자 전산학부

형에서는 로봇이 움직일 수 없는 이동 불능 상태에 빠질 수 있다는 단점을 가지고 있다.

비접촉 인식 방법은 로봇의 바퀴가 지면에 접촉하기 전에 영상 센서를 이용하여 환경을 인식하는 방법이다. 주행 로봇의 경로 계획을 위해 영상 정보 중 지형의 모양(geometry) 정보를 추출해 미끄러움 정도를 추정하는 방법^[7]과 지면의 영상 정보를 바탕으로 지형의 주요한 특성(지면의 거칠기, 경사도, 불연속 지점, 경도 등)을 파악하여 퍼지로지(fuzzy logic) 알고리즘을 이용해 지형 정보 인덱스(traversability index)를 추정한 연구 방법이 있다^[8]. 또한 스테레오 영상(stereo imaginary)을 이용하여 다양한 많은 지형 샘플을 만들고 로봇에 학습 시켜 지형의 미끄러움 정도(slip)를 판단하는 연구가 수행되었다^[9].

이러한 영상 센서를 이용한 비접촉 지형 인식 방법은 카메라에 의한 지면의 영상 정보만을 이용하기 때문에 날씨에 많은 영향을 받는다. 또한 지형의 학습량에 따라 로봇이 운용 중에 지형을 판단하는 판단 정도가 차이가 나며 많은 데이터를 주고, 받는 시스템 처리를 해야 하므로 실시간성에 문제를 갖고 있다.

본 논문에서는 실외 환경에서 자율 주행 로봇의 주행성 향상을 위해 영상 센서를 이용하여 환경을 인식하는 것에 초점을 맞추었다. 본 논문에 제시된 알고리즘은 앞서 설명한 비접촉 지형 인식 방법으로 영상 전처리를 통해 날씨에 따른 조도차이에 의한 영상 인식 오차(error)를 줄인다. 또한 로봇을 운용하기 전에 다양한 지형을 학습 시키고 지형을 그룹화 한 후 실시간 적으로 빠른 분류 성능을 갖기 위해 베이시안 분류(Bayesian classification)방법을 도입하였다. 마지막으로 지형의 미끄러움 정도(slip)를 판단하기 위해 실험을 통해 마찰 계수를 측정하여 지형 분류 결과를 이용, 가동성 지도(traversability map)를 생성하였다.

본 논문에서 2장은 전체적인 지형 분류 알고리즘을 소개 하고, 3장에서는 지형 분류 알고리즘의 성능을 검증한다. 4장에서는 실험을 통한 지형 분류 알고리즘의 결과를 보여주며, 마지막 5장에서는 결론을 도출한다.

2. 지형 분류 알고리즘

본 논문에서 제안하는 지형 분류 알고리즘은 크게 두 단계로 나눌 수 있다. 첫 번째 단계는 로봇이 처음 영상을 접하여 학습하는 훈련 단계이고, 두 번째 단계는 기존의 학

습된 영상을 바탕으로 새로운 지형이 입력되었을 때 새로운 지형이 어떤 지형인지 분류하는 분류단계이다.

그림 1은 전체적인 지형 분류 알고리즘의 흐름을 보여 주고 있다. 그림 1에서 보듯이 첫 번째 단계인 훈련단계에서는 오프라인(OFF-LINE)상에서 학습을 위한 다양한 지형의 영상을 입력하고 입력된 영상의 지형 특징을 분석해 특징에 따른 지형 그룹을 만들어 낸다. 따라서 훈련단계에서는 지형의 특징들을 모아서 그룹을 만들고, 지형의 그룹들을 이용해 로봇이 지형을 판단할 수 있는 판단 기준을 만들어 내는 단계라고 할 수 있다.

두 번째 단계인 지형 분류 단계에서는 온라인(ON-LINE) 상에서 로봇이 자율적으로 다양한 지형을 돌아다니면서 학습되어진 특정한 지형 그룹을 비교 기준으로 하여 가동성 지도(Traversability Map)를 만들어 내는 단계이다. 가동성 지도를 통하여 로봇은 이동 할 수 있는 곳과 이동 할 수 없는 곳을 판단하며 또한 이동 할 수 있는 지형이라도 이동 중에 미끄러짐이 발생하는지 아니면 발생하지 않는지 판단 할 수 있다.

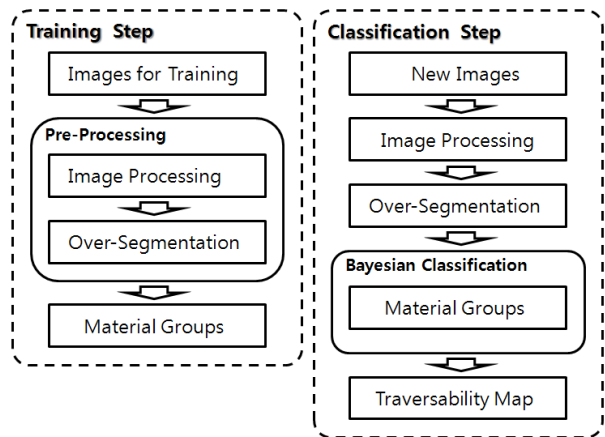


그림 1. 그룹화 및 지형 분류 알고리즘 흐름도

2.1 영상 전처리

본 논문에서 제시한 지형 분류 알고리즘은 영상 정보를 기반으로 하고 있기 때문에 주변 환경에 많은 영향을 받는다. 특히, 날씨 변화에 매우 민감하게 작용하는데 이러한 날씨에 따른 영상 정보의 오류를 개선하기 위해 영상 전처리 방법 중의 하나인 영상 대비 강화 기법(Contrast Enhancement Technique)을 사용한다.

영상 대비 강화 기법(Contrast Enhancement Technique)

은 영상의 명암도 분포가 한쪽으로 치우친 저 대비에 의한 영상 정보의 불확실성을 밝은 영역과 어두운 영역에 대비 향상을 주어 영상을 개선하는 방법으로 본 논문에서는 날씨에 따른 영상의 명암도 차이로 인해 발생하는 지형 분류 오차를 효과적으로 개선하기 위해 영상의 전처리 과정으로서 영상 대비 강화 기법(Contrast Enhancement Technique)을 사용하였다.

그림 2를 보면 알 수 있듯이 그림 2는 저 대비 영상으로서 전체적 이미지가 다소 흐릿하다는 것을 알 수 있다. 실제로 로봇이 그림 2와 같은 영상을 이용하여 안전한 경로를 판단해야 하는 상황에서 영상 정보의 불확실성으로 인해 지형이 어떠한 물질로 이루어져 있는지 구분을 하지 못한다면 로봇은 불안정한 경로를 만들어 낼 수 있다. 따라서 이러한 지형 분류 에러를 개선하기 위해 밝은 색채와 어두운 색채의 대비 격차를 더 멀리 떨어뜨려 영상 이미지의 색채구별을 개선함으로써 좀 더 효과적인 영상 분류 성능을 구현할 수 있다.

그림 3은 영상의 대비 강화 기법을 이용하여 원본 영상을 수정한 이미지이다. 그림 3에서 보듯이 그림 2와 다르게 보다 뚜렷하고 선명한 이미지로 수정된 것을 볼 수 있다.

논문에서 제시된 영상 대비 강화 기법(Contrast Enhancement Technique)은 기존의 영상을 적절한 양수의 대비 값을 선택함으로써 개선된 영상으로 바꿀 수 있다. 대비 값은 0에서 2까지 선택할 수 있고 대비 값을 0으로 선정하여 이미지를 변환하면 전체적인 이미지는 어두운 색채를 띠게 된다. 반대로 대비 값을 2로 선정하여 이미지를 변환하면 전체적인 이미지는 하얀 색채를 띠게 된다.



그림 2. 원본 이미지 (큰 자갈 지형)



그림 3. 수정된 이미지 (큰 자갈 지형)

따라서 논문에서 제시된 지형 분류 알고리즘에 적용하기 위한 최적의 대비 값 선택은 지형 분류의 정확성 향상을 위해 필수적인 사항이다.

그림 4는 최적의 대비 값을 선정하기 위한 알고리즘 흐름도이다. 먼저 영상 이미지가 입력되면 대비 값들을 이용하여 영상을 수정하고 수정된 각 영상을 Over-segmentation 방법을 이용하여 각 영상 이미지의 물질 특징 값들을 추출하게 된다. 추출된 물질 특징 값들의 공분산을 구하여 가장 작은 공분산 값을 찾고, 그 공분산 값을 만들어낸 대비 값을 최적의 대비 값으로 선정한다. 이것은 공분산 값이

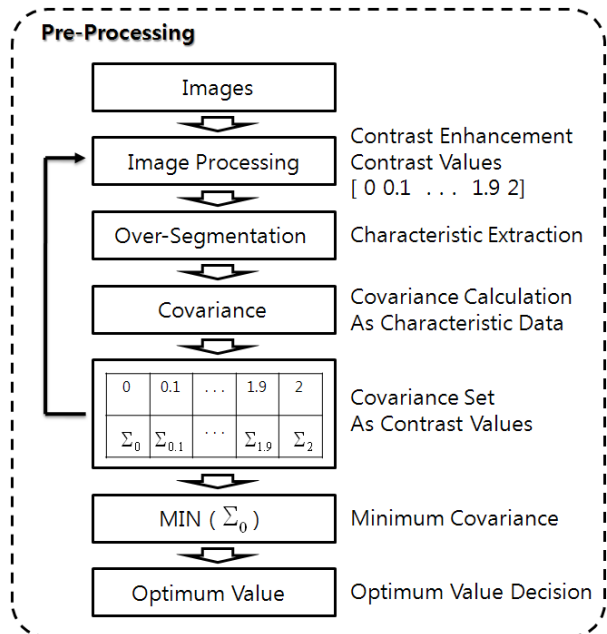


그림 4. 최적 값 선택을 위한 알고리즘 흐름도

최소에 더 가까울수록 수정된 영상 이미지 안의 각 물질들이 더욱 조밀하게 평가되어지는 것을 의미한다. 결국, 최적의 대비 값을 선정하여 영상을 보정함으로써 로봇은 보다 정밀한 영상 정보를 획득할 수 있게 된다.

2.2 지형의 특징 데이터 추출

본 장에서는 영상 이미지 안에서 각 지형의 특징 데이터를 추출 하는 방법을 소개 한다.

지형의 특징 데이터를 추출하기 위해 본 논문에서는 Over-segmentation 방법을 사용한다. Over-segmentation은 입력된 지형 영상의 질감을 이용한 분류 방법으로 Leung 과 Malik가 소개한 Texton을 사용한다. Texton을 사용하면 색상과 관련 없이 질감으로 각 물질을 판단 할 수 있다^[10]. 그리고 정확하고 빠르게 영상의 질감을 판단하기 위해 Verma 방법을 이용해 Texton Histogram을 만들어 사용한다^[11].

영상의 질감 판단 결과는 Felzenszwalb의 방법^[12]을 이용한 질감의 유사도 판별 과정을 통해 지형 영상을 부분별로 병합(merge)하여 각 물질 조각인 Segment를 생성한다.

그림 5는 작은 자갈 지형의 이미지를 나타내고 그림 6은 Over-segmentation 방법에 적용한 결과를 보여준다. 그림 6에서 동일한 색상으로 채워져 있는 각각의 Segment는 같은 물질로 이루어진 것을 의미하며 또한 색상이 다른 Segment라도 각 지형 특징 데이터에 따라 같은 물질로 구별 될 수가 있다.

그림 7은 각 Segment의 지형 특징 데이터의 값을 그래프로 표현한 것이다. 앞서 설명한 것처럼 각 Segment안에



그림 5. 작은 자갈 지형 이미지



그림 6. Over-segmentation 결과 (작은 자갈 지형)

그림 7과 같은 특징 데이터 값이 존재하며 각 물질의 크기 차이에 따라 특정한 물질로 구분된다. 또한 각 물질의 종류는 학습 훈련을 시키는 물질 종류에 따라 달라 질수 있다. 본 논문에서는 6가지 지형(하늘, 흙, 작은 자갈, 큰 자갈, 아스팔트, 숲)을 학습 지형으로 선택하여 훈련단계에서 사용하였다.

다음 장에서 각 Segment의 특징 데이터는 훈련 단계에서의 각 물질에 대한 그룹을 만드는 데 사용되어진다.

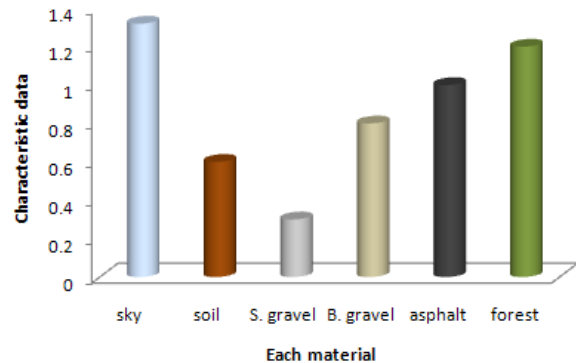


그림 7. 영상 조각(segment)의 특징 데이터 그래프

2.3 그룹화 방법

먼저, 확률론적인 지형 분류 방법을 도입하기 위해서 각 지형의 그룹을 이루는 데이터들은 가우시안 분포를 가지고 있다고 가정한다. 각 그룹은 가우시안 분포를 이루고 있으므로 가우시안 분포의 기준인 평균과 공분산의 값을 계산할 수 있다. 식 (1)은 평균 벡터를 계산하는 식이고 식 (2)은 공분산 행렬을 계산하는 식이다.

over-segmentation 방법으로 추출된 지형의 특징 데이터들을 입력으로 하여 각 지형에 따른 물질 그룹을 생성한다.

$$\hat{\boldsymbol{\mu}} = \frac{1}{n} \sum_{k=1}^n \mathbf{X}_k \quad (1)$$

$$\hat{\boldsymbol{\Sigma}} = \frac{1}{n} \sum_{k=1}^n (\mathbf{X}_k - \hat{\boldsymbol{\mu}})(\mathbf{X}_k - \hat{\boldsymbol{\mu}})^T \quad (2)$$

여기서, \mathbf{X} 는 over-segmentation 방법에 의해 생성된 지형의 특징 데이터, n 은 특징 데이터의 샘플 개수, $\hat{\boldsymbol{\mu}}$ 는 물질 그룹의 평균 벡터, $\hat{\boldsymbol{\Sigma}}$ 는 물질 그룹의 공분산 행렬이다. 계산된 $\hat{\boldsymbol{\mu}}$ 과 $\hat{\boldsymbol{\Sigma}}$ 는 각 지형의 물질 그룹을 형성하고 형성된 물질 그룹은 베이지안 분류기에서 학습된 지형 기준이 되어 새로운 지형을 분류하기 위해 사용된다.

2.4 베이지안 분류기

기준에 학습이 이루어지지 않은 새로운 지형 이미지를 특징한 지형으로 구분 짓기 위하여 베이지안 분류기 (Bayesian classification)를 사용한다^[13]. 식 (3)은 베이지안 분류기를 나타낸다.

$$P(\mathbf{Y}|\boldsymbol{\omega}, \mathbf{D}) = \frac{1}{\sqrt{2\pi}^d \sqrt{\det(\boldsymbol{\Sigma})}} e^{-\frac{1}{2}(\mathbf{D}-\boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{D}-\boldsymbol{\mu})} \quad (3)$$

$$P(\boldsymbol{\omega}_i | \mathbf{Y}, \mathbf{D}) = \frac{P(\mathbf{Y}|\boldsymbol{\omega}_i, \mathbf{D}_i)P(\boldsymbol{\omega}_i | \mathbf{D}_i)}{\sum_{j=1}^G P(\mathbf{Y}|\boldsymbol{\omega}_j, \mathbf{D}_j)P(\boldsymbol{\omega}_j | \mathbf{D}_j)} \quad (4)$$

식 (3)에서, $\boldsymbol{\omega}_i$ 는 각 물질 그룹의 식별자(identifier)이고 $\boldsymbol{\omega}_i = (\boldsymbol{\mu}, \boldsymbol{\Sigma})$ 로 나타낼 수 있다. \mathbf{D} 는 물질 그룹에 속해 있는 지형의 특징 데이터, \mathbf{Y} 는 새로운 지형 영상 정보의 특징 데이터, G 는 물질 그룹의 수이다. $P(\mathbf{Y}|\boldsymbol{\omega}, \mathbf{D})$ 는 사후 확률, $P(\boldsymbol{\omega}|\mathbf{D})$ 는 사전확률, $P(\boldsymbol{\omega} | \mathbf{Y}, \mathbf{D})$ 는 조건부 확률이며 식 (4)로 나타 낼 수 있다. 또한, d 는 지형 특징 데이터의 차원 수이다.

여기서, $P(\mathbf{Y}|\boldsymbol{\omega}, \mathbf{D})$ 의 사후 확률을 계산하는 것은 베이지안 분류기의 핵심이다. 즉, 식 (3)으로 나타내어지는 베이지안 분류기는 학습된 각 지형의 식별자 $\boldsymbol{\omega}_i = (\boldsymbol{\mu}, \boldsymbol{\Sigma})$ 을 기준으로 새로 입력된 지형 이미지의 각 특징 데이터를 사전 확률 $P(\boldsymbol{\omega}|\mathbf{D})$ 과 조건부 확률 $P(\boldsymbol{\omega} | \mathbf{Y}, \mathbf{D})$ 을 통해 확률

적으로 기준이 된 그룹에 얼마나 근접한가를 판단하는 알고리즘이다.

3. 성능 검증

3.1 영상 처리 방법을 이용한 검증

지형 분류 알고리즘의 성능을 검증하기 위하여 지형 분류의 정확성을 확인하였다. 우선 학습 지형으로 그림 8의 4가지 지형 이미지(흙, 작은 자갈, 큰 자갈, 아스팔트)를 사용하였다. 각각의 영상 이미지는 1초당 1프레임으로 입력되는 영상을 10초 동안 입력해 각 지형 당 10프레임씩 전체 40프레임의 영상 이미지를 사용하여 학습 하였다. 각 4가지 지형은 앞서 설명된 것처럼 전처리 과정을 거쳐 over-segmentation 방법에 의해서 지형 특징 데이터가 추출되고 추출된 데이터는 그룹화 방법에 따라 각 물질 그룹(흙, 작은 자갈, 큰 자갈, 아스팔트)으로 그룹화 된다.

지형 분류 알고리즘의 성능을 검증하기 위하여 학습된 지형 이미지를 새로운 지형 이미지라 간주하여 알고리즘에 적용하였다. 입력된 새로운 지형 이미지는 학습되어져 있는 지형이므로 결국 좋은 분류 성능을 보여야 할 것이다. 그림 9와 10은 성능 검증에 사용된 지형 이미지이다. 영상 전처리 과정에 따라 달라지는 지형 분류 성능을 검증하기 위하여 그림 9는 큰 자갈 지형으로서 영상 전처리를 하지 않은 원본 이미지이고 그림 10은 영상 전처리를 이용하여 수정된 이미지이다.



그림 8. 물질 그룹 생성에 사용된 지형

그림 9와 10의 (가)의 이미지를 이용하여 베이지안 분류기를 통해 지형 분류한 결과가 (나)가 된다. 각각의 (나) 그림에서 파란색 영역은 흙, 하늘색 영역은 큰 자갈, 흰색 영역은 작은 자갈, 녹색 영역은 아스팔트 물질로 구분된다. 또한 검은색 영역은 나무숲과 하늘을 판단한 영역이다. 나무숲과 하늘 영역은 로봇이 절대적으로 이동 할 수 없는 지형이므로 검은색으로 구분된다. 그림 9와 10의 (나)를 비교해 보면 그림 9의 결과는 큰 자갈 영역을 하늘색이 아닌 녹색으로 아스팔트 물질이라고 판단하였다. 이것은 영상의 명암도 대비에 따른 자갈과 아스팔트의 색상과 질감 차이를 구별해 내지 못한 결과로서 지형 분류 오류를 보여주고 있다. 하지만 그림 10에서 수정된 이미지를 사용해 지형을 분류한 결과, 대부분을 큰 자갈 지형으로 판단하였다.

분류 성능을 정량적인 방법으로 검증하기 위해 그림 9와 10과 같이 큰 자갈 지형의 이미지(가)에 큰 자갈 물질 영역(다)을 설정하여 이미지 마스크를 만들고 이미지 마스크를 지형 분류가 완료된 이미지(나)에 덮어 물질 영역 안에서의 분류 결과(라)를 확인하였다. 결과적으로 이미지의 각 픽셀(pixel)의 개수를 확인하였을 때 분류 정확도는 원본 이미지를 이용한 방법은 약 6.81%, 수정된 이미지를 이용한 방법은 약 96.55%로서 수정된 이미지를 이용한 방법이 지형을 분류 하는데 있어서 훨씬 더 효과적인 것을 알 수 있다. 결과적으로 이러한 지형 분류 검증을 통해 지형 분류 알고리즘이 좋은 지형 분류 성능을 가지고 있다는 것을 확인하였다.




그림 9. 원본 영상 분류 (큰 자갈 지형)




그림 10. 영상 전처리에 의해 수정된 영상 분류 (큰 자갈 지형)

3.2 주성분 분석법(PCA)을 이용한 검증

주성분 분석법(PCA)을 이용하여 정량적이고 시각적인 성능 검증을 할 수 있다. 주성분 분석법은 높은 차원의 특징 벡터를 중요한 정보를 유지하면서 낮은 차원의 특징 벡터로 변화시킨다.

그림 8에서 각 4가지 지형의 특징 데이터들은 4차원 (흙, 작은 자갈, 큰 자갈, 아스팔트)으로 나뉘어 있으므로 이것을 주성분 분석법(PCA)을 이용하여 2차원으로 변화시킨다. 그리고 2차원화된 지형 특징 데이터를 식 (1)과 식 (2)을 이용하여 평균 벡터와 공분산 행렬을 구하여 각각을 그룹화 한다. 그림 11은 각 지형의 특징 데이터를 이용한 그룹화 결과이고, 표 1은 그림 11의 각 지형 그룹의 평균

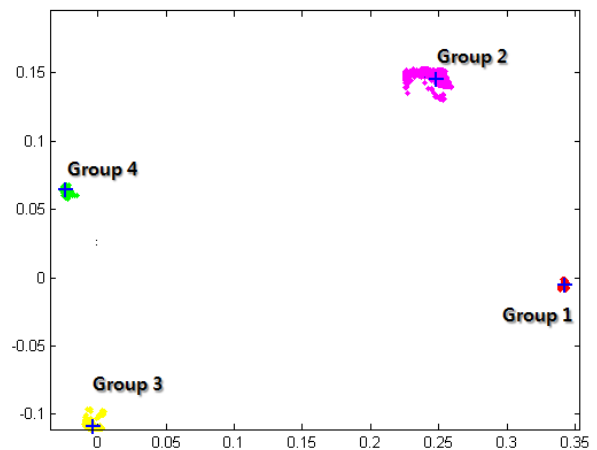


그림 11. 각 지형의 그룹화 결과

벡터와 공분산 행렬을 정량화 한 것이다.

그룹 1은 흙, 그룹 2는 큰 자갈, 그룹 3은 작은 자갈, 그룹 4는 아스팔트의 물질 그룹을 나타낸다. 그림 11에서 보듯이 각 지형의 물질 그룹은 겹치는 부분 없이 적당한 거리를 유지하며 위치하고 있으며 이것은 각 물질의 특징 데이터들이 over-segmentation 방법에 의해 정확하게 추출되고 있음을 의미한다. 또한 그 결과로서 표 1의 평균 벡터와 공분산 행렬에서도 볼 수 있다.

그림 12는 기존에 학습되어있지 않은 지형 이미지를 나타낸다. 그림 13은 그림 12의 지형을 입력하고 지형의 특징 데이터를 over-segmentation 방법에 의해 추출한 뒤 데이터를 그림 11 위에 위치시켜본 것이다. 그림 13에서 지형 특징 데이터들은 그룹 4인 아스팔트 물질 그룹 가까이에서 가장 많이 위치한 것을 볼 수 있다.

베이시안 분류기의 지형 분류 결과를 보면 그룹 1에 15개, 그룹 2에 25개, 그룹 3에 11개, 그룹 4에 78개가 분류

표 1. 각 지형 그룹의 평균 벡터와 공분산 행렬

식별자 ω	평균 μ	공분산 Σ
Group 1 흙 지형	(0.3427, -0.0051)	$\begin{bmatrix} 0.0442 & 0.0069 \\ 0.0069 & 0.2649 \end{bmatrix} \times 10^{-4}$
Group 2 작은 자갈 지형	(0.2482, 0.1456)	$\begin{bmatrix} 0.7834 & -0.1838 \\ -0.1838 & 0.2457 \end{bmatrix} \times 10^{-3}$
Group 3 큰 자갈 지형	(-0.0033, -0.1087)	$\begin{bmatrix} 0.1336 & 0.0422 \\ 0.0422 & 0.1282 \end{bmatrix} \times 10^{-3}$
Group 4 아스팔트 지형	(-0.0235, 0.0641)	$\begin{bmatrix} 0.2390 & -0.1009 \\ -0.1009 & 0.5368 \end{bmatrix} \times 10^{-4}$



그림 12. 새로운 지형 이미지(아스팔트 지형)

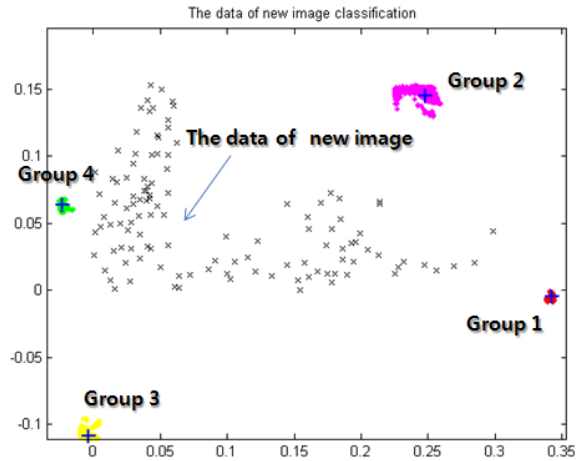


그림 13. 새로운 지형의 특징 데이터

가 되었다. 또한 분류결과를 확률적으로 계산해보면 90.5%의 정확도를 보였다. 결과 적으로 전체적인 지형 분류 알고리즘이 좋은 지형 분류 성능을 갖고 있다는 것을 확인하였다.

4. 실험 결과

4.1 마찰 계수 측정 실험

로봇의 바퀴와 지형의 지면간의 물리적인 값을 확인하기 위하여 마찰 계수를 측정하는 실험을 하였다. 그림 8의 4가지 지형을 마찰 계수 측정 실험에 사용하였으며 측정된 마찰 계수는 지형 분류 알고리즘에 적용하여 가동성 지도를 생성하는데 이용되었다.

그림 14는 마찰계수를 측정하는 실험 장면을 보여주고 있다. 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. 표 2는 측정된 각 지형의 마찰 계수이다. 실험 결과는 본 연구에서 사용하는 각 지형의 실제 마찰계수로 사용하였다. 영상 정보는 범블비(Bumblebee) 카메라를 사용하여 획득 하였다.

표 2. 마찰계수 측정 결과

	흙 지형	작은 자갈 지형	큰 자갈 지형	아스팔트 지형
마찰계수 (μ)	0.9	0.74	0.82	1.2




그림 14. 마찰 계수 측정 실험

4.2 새로운 지형 이미지 분류 결과

그림 15, 그림 16, 그림 17, 그림 18은 기존에 학습되지 않은 새로운 지형 이미지로서 지형 분류 결과를 확인하였다. 그림 15는 흙 지형, 그림 16은 작은 자갈 지형, 그림 17은 큰 자갈 지형, 그리고 그림 18은 아스팔트 지형을 나타낸다. 그림에서 보듯이 환경에 따라 약간의 지형 분류 차이를 보였다. 그림 15에서 햇빛에 의한 그림자는 어두운 색상으로 이러한 환경적 요인은 지형 물질이 흙임에도 불구하고 아스팔트 물질 영역이라는 분류 결과를 보였다. 결과적으로 그림 15, 그림 16, 그림 17, 그림 18의 지형 분류 결과에서 볼 수 있듯이 약간의 환경적 요인을 제외하고는 전반적으로 신뢰할 수 있는 분류 결과를 보였다.



그림 15. 흙 지형 분류 결과



그림 16. 작은 자갈 지형



그림 17. 큰 자갈 지형




그림 18. 아스팔트 지형

4.3 가동성 지도 생성

그림 19는 그림 18에서의 지형 분류 결과를 4.1장에서 측정된 각 지형의 마찰 계수를 적용하여 가동성 지도를 생성한 것이다. 그림 19에서 검정색 부분은 자율 주행 로봇이 갈 수 없는 하늘과 숲을 나타낸다. 진한 파란색 부분은 마찰 계수가 가장 높은 아스팔트 지역을 나타내고 진한 보라색은 큰 자갈, 옅은 보라색은 흙을 나타낸다. 결과적으로 그림 19의 가동성 지도를 통해 자율 주행 로봇이 갈 수 있는 지역과 갈 수 없는 지역을 먼저 판단 할 수 있고, 또한 갈 수 있는 지역이라도 지면의 마찰 계수에 따라 로봇의 바퀴 속도나 로봇의 자세를 어떻게 유지 할 것인지를 결정지을 수 있게 한다.




그림 19. 가동성 지도

5. 결론

본 논문에서는 영상 정보를 활용하여 자율 주행 로봇의 이동성을 개선하기 위한 지형 분류 알고리즘을 연구하였다. 영상의 전처리 과정을 통해 이미지를 보정하고 보정된 영상 이미지를 over-segmentation 방법을 이용하여 지형의 특징 데이터를 추출하였다. 추출된 지형 특징 데이터는 가우시안 분포를 갖는 그룹을 생성하기 위해 사용되었다. 이렇게 생성된 그룹들은 베이지안 분류기에 적용되어 새로운 영상 이미지를 특정한 물질 그룹으로 분류 할 수 있었다. 결과 적으로 마찰 계수 측정 실험을 통해 측정된 마찰 계수를 이용해 가동성 지도를 생성하여 자율 주행 로봇의 이동성을 개선 할 수 있는 방법을 제안하였다.

본 연구의 향후 과제는 지형 분류 알고리즘의 모든 시스템을 실시간적으로 운용할 수 있는 방법을 찾는 것이다. 처음 로봇이 다양한 지형을 학습할 때 학습은 오프라인(OFF-LINE)상에서 이루어지므로 추후에는 온라인(ON-LINE)상에서 로봇이 다양한 지형을 이동하면서 자율적으로 학습하는 자동 학습 기능을 갖게 하는 것이 필요하다.

참고문헌

- [1] H.D. Choi, C.k. Woo, S.H.Kim, Y.K.Kwak, S.J.Yoon, "Independent traction control for uneven terrain using stick-slip phenomenon; application to a stair climbing robot," Autonomous robots, Vol.23 No.1, pp.3-18, 2007
- [2] 강현석, 곽윤근, 최현도, 정해관, 김수현, "주행로봇 제어를 위한 힘지의 최대마찰계수 추정", 제어.로봇.시스템학회 논문지, Vol.14, No.10, pp.1062-1071, 2008
- [3] Iagnemma, K.Kang, S. Shibly, H. and Dubowsky, S., "Online terrain parameter estimation for wheeled mobile robots with application to planetary rovers," IEEE transactions on robotics, Vol.20, No.5, pp.921-927, 2004
- [4] 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
- [5] W. Hwang, and B. Song, 2000, "Road condition monitoring system using, tire-road friction estimation," Proceedings of AVEC 2000, Ann Arbor, Michigan, pp.437-442, August 22-24
- [6] 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
- [7] 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
- [8] A. Howard and H. Seraji, "Vision-based terrain characterization and traversability assessment," journal of robotic systems, Vol.18, No.10, pp.577-587, 2001
- [9] 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
- [10] T. Leung and J. Malik, "Representing and Recognizing the Visual Appearance of Materials Using the Three-dimensional Texton," IJCV Vol.42, No.1, 2001
- [11] M. Varma and A. Zisserman, "Classifying images of materials" achieving viewpoint and illumination independence, European Conference on Computer Vision, pp.255-271, 2003
- [12] P. felzenszwalb and D. Huttenlocher, "Efficient Graph based Image Segmentation," IJCV, Vol.5, Eff, No.2, pp.16e,81, 2004
- [13] Richard O. Duda, Peter E. Hart and David G. Stork, Pattern Classification 2nd ed, Wiley, New York, 2001.



김 자 영

2008 충북대학교 기계공학과
(공학사)

2009~현재 충남대학교 메카트
로닉스공학과 석사 과정

관심분야: 로봇틱스, 지능 제
어, 로봇제어

E-mail : jaya@cnu.ac.kr,



이 종 화

2007~현재 충남대학교 메카트로닉스 공학과 학사과정
관심분야: 메카트로닉스 시스템, 센서
E-mail : cnu-ljh@nate.com



권 인 소

1981 서울대학교 기계설계학과 (공학사)
1983 서울대학교 기계설계학과 (석사)
1990 Carnegie Mellon Uni. Robotics Institute (박사)
1991~1992 일본 도시바 중앙연구소 연구원
1992~현재 한국과학기술원 전자 전산학부 교수
관심분야: 컴퓨터 비전, 3D 비전, 카메라 보정, 물체 인식, 물체 분류, SLAM



이 지 홍

1983 서울대학교 전자공학과 (공학사)
1985 한국과학기술원 전기 및 전자공학과 (석사)
1991 한국과학기술원 전기 및 전자공학과 (박사)
1994~현재 충남대학교 메카트로닉스 정교수
관심분야: 로봇틱스, 위치추정, 경로계획
E-mail : jihong@cnu.ac.kr