

무인차량 적용을 위한 영상 기반의 지형 분류 기법

Vision Based Outdoor Terrain Classification for Unmanned Ground Vehicles

성기열, 곽동민, 이승연, 유준*
(Gi-Yeul Sung, Dong-Min Kwak, Seung-Youn Lee, and Joon Lyou)

Abstract : For effective mobility control of unmanned ground vehicles in outdoor off-road environments, terrain cover classification technology using passive sensors is vital. This paper presents a novel method for terrain classification based on color and texture information of off-road images. It uses a neural network classifier and wavelet features. We exploit the wavelet mean and energy features extracted from multi-channel wavelet transformed images and also utilize the terrain class spatial coordinates of images to include additional features. By comparing the classification performance according to applied features, the experimental results show that the proposed algorithm has a promising result and potential possibilities for autonomous navigation.

Keywords : terrain classification, wavelet transform, texture feature, spatial coordinate feature, neural network, unmanned ground vehicles

I. 서론

최근 미국을 비롯한 선진국을 중심으로 무인차량(UGV: unmanned ground vehicles)의 자율주행 기법에 대한 연구가 활발하게 진행되고 있다. 특히 군사용으로 사용되는 무인차량의 경우 도심지의 포장로뿐만 아니라 굴곡이 있는 비포장로 및 수풀이 있는 거친 야지지형에서도 주행이 가능하여야 한다. 이와 같은 야지환경에서 무인차량의 자율주행에 있어 효과적이고 안전한 주행을 위해서 장애물 탐지와 지형 분류가 중요한 요소로 많은 연구가 진행되어 왔다[1-3]. 특히 서로 다른 지형 특성에 대해 차량의 안정성을 확보할 수 있는 최적 속도를 결정하거나, 최적의 주행 경로를 설정하는데 지형 분류가 중요한 요소로 작용한다. 즉, 무인차량이 현재 주행 중인 지형에 대한 정보(자갈길, 진흙길, 포장로 등)를 알 수 있으면 무인차량은 안전성을 고려하여 현재 지형에 대한 최적의 주행속도를 결정할 수 있으며, 무인차량 전방의 경로 상에 주행 가능한 긴 풀이 존재하는 경우 장애물 탐지 결과만 이용한다면 장애물로 판정되어 불가피하게 경로를 변경해야 하지만, 지형 분류기법을 통해 분류된 지표면 정보를 활용할 수 있다면 주행 경로의 변경 없이 효과적인 임무 수행이 가능할 것이다.

야지환경에서 지형분류를 위하여 라이다, 근거리 레이더, CCD 또는 IR 등 다양한 센서들이 활용될 수 있다. 이와 같은 센서들은 각기 장·단점이 있으나, 특히 군사용 임무를 수행하는 경우 라이다나 레이더는 능동적인 특성으로 인해 적에게 쉽게 노출될 수 있는데 비해 CCD 센서는 수동적인 특성을 가지고 있어 전략적으로 유용하게 사용할 수 있으므로 CCD 센서를 이용한 영상 기반의 지형분류 기법에 대

한 많은 연구가 이루어지고 있다. CCD 센서를 이용한 영상 기반의 지형분류에 사용되는 대표적인 특징으로는 색상특징이나 질감특징이 있다.

R. Manduchi[1]와 P. Bellutta[2] 등은 흙/바위, 녹색 풀 및 마른 풀 등의 지형 클래스에 대해 색상특징을 이용한 지형 분류 기법을 소개하였다. 조명 변화에 대한 영향을 보상하기 위해 다양한 환경 조건하에서 학습 데이터를 획득한 후, 각각의 지형 클래스별로 가우시안 혼합모델(GMM: Gaussian Mixture Model)을 생성하고, 최우도기법(ML: Maximum Likelihood)을 이용하여 지형분류를 수행하였다. 시험을 통하여 영상 기반의 지형분류에서 색상 정보가 매우 효과적인 특징으로 이용될 수 있음을 입증하였다. 그러나 흙과 마른 풀 클래스들 사이에는 색상특징의 구분이 뚜렷하지 않아 정확하게 분류되지 않는 것으로 나타났다. 색상특징을 이용한 지형분류의 또 다른 기법은 P. Jansen 등[4]에 의해 소개되었는데, 그들은 유사한 환경 조건하에서 획득된 영상들은 색 공간에서의 픽셀 분포 또한 유사하다는 가정을 하였다. 이들도 GMM에 기반한 ML 분류기를 적용하였으며, 환경 조건의 변화에 대한 영향을 줄이기 위해 유사한 환경 상태를 갖는 학습용 영상 집합을 삭별하고, 각각의 영상 집합에 대해 독립적으로 지형 클래스별 색상 모델을 생성하였다. 입력 영상에 대해 유사한 환경상태의 GMM을 이용하여 하늘, 숲, 잔디, 모래, 자갈 등으로 지형 클래스를 분류하였으며, 서로 다른 환경 조건들이 존재하는 영상에 대해 개선된 지형분류 결과를 얻었다. 그러나 숲과 하늘 사이의 경계 영역이나 그림자 영역 등에서 오분류가 발생하였다.

이와 같이 야외 환경에서 영상의 색상특징만을 이용한 지형분류는 기후, 조명 및 대기 조건과 같은 환경 요인으로 인해 어려운 문제로 알려져 있으며, 이러한 단점을 극복하기 위해서는 색상특징 외에 다른 특징들을 추가적으로 사용하거나 색상특징과 융합하여 사용할 필요가 있다.

* 책임저자(Corresponding Author)

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

성기열, 곽동민, 이승연 : 국방과학연구소

(addsky@add.re.kr/imis@add.re.kr/lee_sy@add.re.kr)

유준 : 충남대학교 전자공학과(jlyou@cnu.ac.kr)

한편, R. Castano 등[5]은 질감특징을 이용한 지형분류 기법을 소개하였는데, Gabor 필터뱅크를 사용하여 질감특징을 추출하고, 두 가지 다른 형태의 분류기를 구현하여 각각의 성능을 평가하였다. 첫 번째 분류기는 질감특징의 확률분포 함수에 대한 GMM을 생성하고, ML 분류기를 적용하였다. 각각의 지형 클래스에 대한 학습은 expectation maximization 알고리즘을 사용하였다. 두 번째 분류기는 영상의 국부적인 영역에 대한 marginal 히스토그램 특징을 통계적 특성으로 표현하였다. 분류기는 학습 집합에서 기 분류된 클래스에 대한 국부 히스토그램의 평균과 주어진 히스토그램 특징 사이의 거리가 최소화되는 클래스로 분류한다. 그러나 영상에서 크기와 방향에 따라 변화하는 질감특징을 추출하기 위해서는 필터의 개수가 증가되어야 하며, 특징 추출시의 연산 량이 증가되어 수행시간이 길어지는 단점이 있다.

본 논문에서는 CCD 센서를 이용한 영상기반의 지형분류에 있어서 색상특징만을 이용한 분류기법의 단점을 극복하기 위해 색상과 질감 정보를 동시에 고려한 지형분류 기법을 소개한다. 실시간 응용을 고려하여 영상에 대한 리프팅(lifting) 기반의 이산 웨이블릿 변환(DWT: Discrete Wavelet Transform)을 통하여 색상 및 질감특징을 추출하고, 신경망 분류기를 적용하였다. 또한 분류 성능 향상을 위해 영상 내에서 지형 클래스의 위치 정보를 추출하여 추가 특징으로 사용하였다. 야외 환경에서 획득된 지형 영상에 대해 실험을 수행하였으며, 동일한 시험영상에 대해 색상특징만을 이용한 GMM 기반의 ML 분류기법 결과와 분류 성능을 비교하였다.

II 장에서는 제안된 알고리즘의 수행 단계별 주요 내용을 설명하고, III 장에서는 실험내용 및 결과분석을 기술하고, 마지막으로 IV 장에서 결론과 향후 연구방향을 제시한다.

II. 본론

본 논문에서 제안하는 지형분류 알고리즘은 학습 데이터에 대해 오프라인에서 수행되는 학습단계와 시험영상에 대해 온라인으로 처리되는 수행단계로 구분되는데, 그림 1과 같이 입력영상에 대한 색 공간 변환과 DWT 변환을 하는 전처리, 전처리된 영상에 대한 특징 추출, 신경망을 이용한

학습 및 분류, 결과에 대한 후처리의 절차로 수행된다.

학습단계에서는 본 연구에서 고려한 분류 대상 지형인 하늘, 자갈, 흙, 포장로, 잔디, 금의 6가지 클래스에 대한 신경망의 학습을 위하여 사전에 획득된 영상집합으로부터 각 클래스별로 200개씩의 16×16 픽셀 크기를 갖는 학습용 칩 영상을 이용한다. 특징 추출을 위하여 각각의 칩 영상에 대해 RGB 색 공간에서 Lab 색 공간으로 변환 후 DWT 변환을 수행한다. 학습용 칩 영상의 추출 시 지형 클래스가 위치하는 공간 정보를 특징으로 적용하기 위해 동일한 클래스가 분포하는 다양한 영역으로부터 고르게 추출하였다.

수행단계에서는 입력영상에 대해 색 공간 변환 및 DWT 변환을 수행하고, 입력영상을 16×16 픽셀 크기의 블록으로 구분하였을 때 각 블록 영역에 해당하는 특징을 추출하여, 신경망을 이용한 분류 및 블록 제거를 위한 후처리의 절차를 수행한다. 각 단계에 대한 상세한 설명은 다음과 같다.

1. 전처리

1.1 색 공간 변환

전처리 단계에서는 환경변화에 강인하고, 양호한 분류성능을 나타내는 특징을 추출하기 위해 입력 영상으로부터 색 공간 및 특징 영역에 대한 변환을 수행한다. 다양한 색 공간에 대해 색상 및 질감 특징을 동시에 고려한 기존의 연구 결과[6]를 바탕으로 특징분류에 우수한 성능을 나타내는 Lab 색 공간을 적용하였으며, 변환된 색 공간에서 각각의 채널별 영상에 대해 Daubechies 기저함수[7]를 이용한 2 단계 DWT 변환을 수행하였다.

1.2 웨이블릿 변환(discrete wavelet transform)

웨이블릿 변환 방법의 기본 개념은 임의의 함수를 시간-주파수 영역에서 동시에 국부성을 갖는 웨이블릿 기저함수의 선형결합으로 표현하는 것이다. 웨이블릿 변환에서 기저함수들은 원형 웨이블릿 함수 $\psi(x)$ 의 확장 및 천이에 의해 생성된다. 웨이블릿 변환의 일반적인 수식은 다음과 같이 정의된다.

$$\psi_{a,b}(x) = \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right) \quad (1)$$

여기서, a 는 스케일 변수이고, b 는 천이변수이다. $\psi(x)$ 는

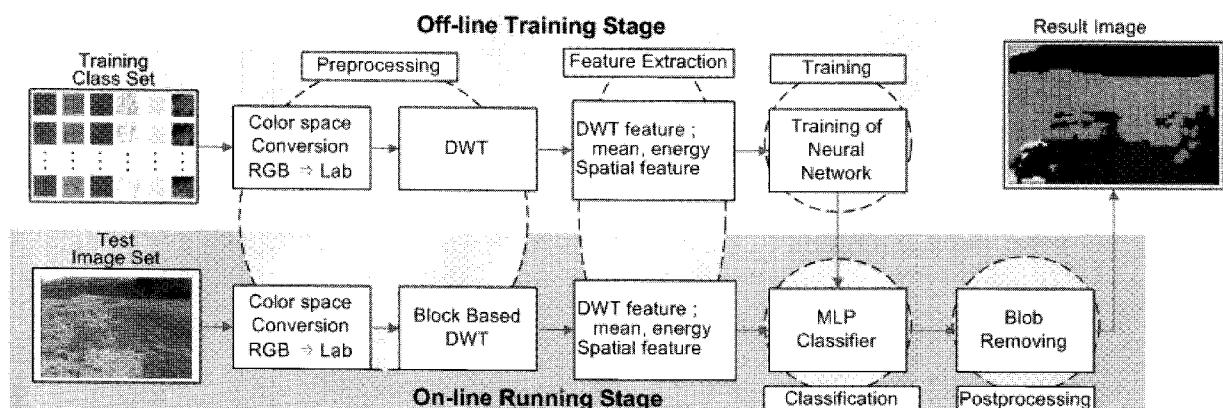


그림 1. 알고리즘 수행 순서도.

Fig. 1. Flow chart of the proposed algorithm.

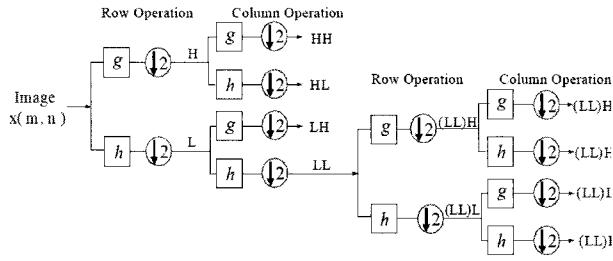


그림 2. 2단계 웨이블릿 변환을 위한 분석 필터뱅크.

Fig. 2. Analysis filter bank of 2-level discrete wavelet transform.

$a < 1$ 이면 폭이 작은 고주파 웨이블릿으로 신호의 고주파 성분 분해에 이용되고, $a > 1$ 이면 폭이 넓은 저주파 성분 분해에 이용된다. 영상에 적용을 위해 수평·수직 방향으로 분할하여 저대역 통과필터와 고대역 통과필터를 컨볼루션 연산을 통해 수행시킨 후 다음 샘플링 함으로서 크기가 다른 분할된 부대역들을 얻을 수 있고, 그들로부터 영상 정보를 추출 할 수 있다. 그림 2는 2단계 DWT를 위한 분석 필터뱅크로 웨이블릿 변환을 위한 영상의 분할(analysis bank)을 나타낸다.

한편, 고속의 웨이블릿 변환을 위해 고안된 리프팅 웨이블릿 변환 (LWT: Lifting Wavelet Transform) 기법은 2세대 웨이블릿 변환이라고도 한다[8]. 기존의 웨이블릿 변환은 저대역 통과필터 및 고대역 통과필터를 사용하여 대역별 컨볼루션 연산을 수행하므로 많은 연산시간과 별도의 메모리가 필요하지만, LWT는 사다리구조(ladder structure)를 사용하여 컨볼루션 연산이 없이 웨이블릿 변환이 가능하므로 연산시간이 단축되고, 또한 in-place 연산으로 메모리 효율성의 극대화 및 기존 웨이블릿 변환에서의 경계선 영역 문제를 해결한 알고리즘이다. 본 논문에서는 Daubechies 4-tap 기반의 LWT를 사용하였다. 4-tap 기반의 LWT는 다음과 같이 유도할 수 있다.

$$h(z) = h_0 + h_1 z^{-1} + h_2 z^{-2} + h_3 z^{-3} \quad (2)$$

$$g(z) = -h_3 z^2 + h_2 z^1 - h_1 + h_0 z^{-1} \quad (3)$$

여기서, 계수 h_0, h_1, h_2, h_3 는 다음과 같다.

$$\begin{aligned} h_0 &= \frac{1 + \sqrt{3}}{4\sqrt{2}}, & h_1 &= \frac{3 + \sqrt{3}}{4\sqrt{2}} \\ h_2 &= \frac{3 - \sqrt{3}}{4\sqrt{2}}, & h_3 &= \frac{1 - \sqrt{3}}{4\sqrt{2}} \end{aligned} \quad (4)$$

위 식을 polyphase matrix로 표현하면 식 (5)와 같고, 식 (5)의 polyphase matrix의 인수분해는 식 (6)과 같다.

$$P(z) = \begin{bmatrix} h_0 + h_2 z^{-1} & -h_3 z^1 - h_1 \\ h_1 + h_3 z^{-1} & h_2 z^1 + h_0 \end{bmatrix} \quad (5)$$

$$P(z) = \begin{bmatrix} 1 & -\sqrt{3} \\ 0 & 1 \end{bmatrix} \begin{bmatrix} \sqrt{3} + 1 & 0 \\ \frac{\sqrt{3}}{4} + \frac{\sqrt{3}-2}{4}z^{-1} & 1 \end{bmatrix} \begin{bmatrix} 1 & z \\ 0 & 1 \end{bmatrix} \begin{bmatrix} \frac{\sqrt{3}+1}{\sqrt{2}} & 0 \\ 0 & \frac{\sqrt{3}-1}{\sqrt{2}} \end{bmatrix} \quad (6)$$

polyphase matrix는 unitary이므로 $P(z)$ 또는 $\tilde{P}(z)$ 로 표현 가능하다. 따라서 $\tilde{P}(z)$ 의 analysis polyphase matrix는 다

음과 같이 주어진다.

$$\tilde{P}\left(\frac{1}{z}\right)^t = \begin{bmatrix} \frac{\sqrt{3}+1}{\sqrt{2}} & 0 \\ 0 & \frac{\sqrt{3}-1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} 1 & 0 \\ z^{-1} & 1 \end{bmatrix} \begin{bmatrix} 1 & \frac{\sqrt{3}}{4} + \frac{\sqrt{3}-2}{4}z \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 \\ -\sqrt{3} & 1 \end{bmatrix} \quad (7)$$

x_{2l} 을 s_l , x_{2l+1} 을 d_l 이라 두면, 수식 (7)의 순방향 LWT의 구현은 다음과 같다.

$$\begin{aligned} d_l^{(1)} &= x_{2l+1} - \sqrt{3}x_{2l} \\ s_l^{(1)} &= x_{2l} + \frac{\sqrt{(3)}}{4}d_l^{(1)} + \frac{\sqrt{3}-2}{4}d_{l+1}^{(1)} \\ d_l^{(2)} &= d_l^{(1)} + s_{l-1}^{(1)} \\ s_l &= \frac{\sqrt{(3)}+1}{\sqrt{2}}s_l^{(1)}, \quad d_l = \frac{\sqrt{(3)}-1}{\sqrt{2}}d_l^{(2)} \end{aligned} \quad (8)$$

역방향 LWT는 순서와 부호를 바꾸어 구현할 수 있다. 본 논문에서는 특징 추출을 위해 순방향 LWT만을 구현하였으며, 구현된 순방향 4-tap LWT 스텝은 그림 3과 같고, 그림 4는 2단계 LWT 결과 영상을 나타낸다.

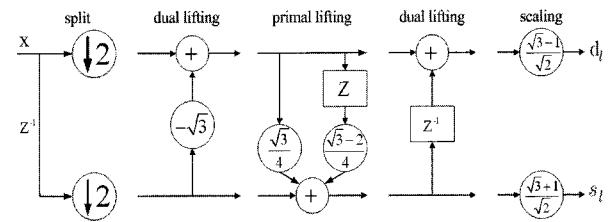


그림 3. 4-tap 리프팅 웨이블릿 스텝.

Fig. 3. 4-tap lifting wavelet steps.

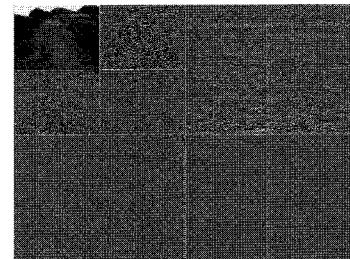


그림 4. 2단계 리프팅 웨이블릿 변환 영상.

Fig. 4. Image of 2-level lifting wavelet transform.

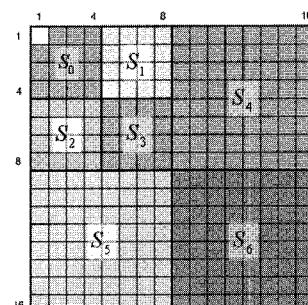


그림 5. LWT 변환 영역 (16x16 블록).

Fig. 5. LWT space (16x16 block).

2. 특징추출

2.1 LWT 영역의 특징추출

2단계 LWT 변환 영상에 대해 그림 5와 같이 16×16 픽셀 크기의 블록 영역으로 구성한 후 각 부대역별 웨이블릿 계수들의 평균과 에너지 값을 특징 벡터로서 추출한다. 그림 5에서 S_0 는 2레벨의 (LL)LL 부대역을, $S_1 \sim S_3$ 은 각각 2레벨의 (LL)HL, (LL)LH, (LL)HH 부대역을, $S_4 \sim S_6$ 은 각각 1레벨의 HL, LH, HH 부대역을 의미한다. i 번째 부대역 계수들에 대한 웨이블릿 평균(M^i)과 에너지(En^i)는 각각 식 (9), (10)을 이용하여 구할 수 있다[9]:

$$M^i = \frac{1}{N} \sum_{j=0}^{N-1} |c_j^i|, \text{ where, } i \in \{S_0, S_1, \dots, S_6\} \quad (9)$$

$$En^i = \frac{100}{En_{total}} \sum_{j=0}^{N-1} (c_j^i)^2, \text{ where, } En_{total} = \sum_{i=0}^{K-1} \sum_{j=0}^{N-1} (c_j^i)^2 \quad (10)$$

여기서, N 은 각 부대역의 웨이블릿 계수의 총 개수이며, K 는 부대역의 총 개수이다. c_j^i 은 i 번째 부대역의 j 번째 계수, En_{total} 은 전체 부대역의 총 에너지를 나타낸다.

웨이블릿 에너지는 Lab 각 채널별로 잡음 특성을 포함한 S_3 과 S_6 부대역을 제외한 5개의 부대역에 대해 계산하였고, 웨이블릿 평균은 S_0 , S_4 , S_5 의 3개 부대역에 대한 Lab 각 채널로부터 추출하였다. 또한 S_0 부대역의 평균은 높은 값의 DC 성분이 신경망의 학습에 미치는 영향을 줄이기 위해 0.1의 가중치를 곱하여 적용하였다. 각 채널별 특징벡터는 식 (11)과 같이 5개의 웨이블릿 에너지와 3개의 웨이블릿 평균으로 구성된다. Lab 채널별 특징벡터를 각각 F_L , F_a 및 F_b 라고 하면, Lab 3채널에 대해 추출된 24차원의 특징벡터는 식 (12)와 같다.

$$F_{CH} = [0.1M^0, M^4, M^5, En^0, En^1, En^2, En^4, En^5] \quad (11)$$

$$F = \text{trans}[F_L \ F_a \ F_b] \quad (12)$$

2.2 공간좌표 특징추출

영상에서 각 지형 클래스가 위치하는 공간좌표는 특정 클래스를 구분하는데 유용한 정보가 될 수 있다. 따라서 현재 처리되는 국부 블록의 중심점 좌표를 공간좌표 특징으로 적용하였다. 학습 단계에서 임의의 표본 영상에서 각 클래스별 학습 칩 영상을 추출할 때, 칩 영상의 중심좌표를 동시에 추출하였다. 그림 6은 추출된 학습 칩의 지형 클래스별 공간상의 분포를 나타낸다. 그림 6에서 영상 내에서 각 클래스들이 위치하는 공간상의 세로 값들은 특정 클래스별로 뚜렷한 차이를 나타내므로 이를 통해 각각의 클래스가 영상 내에서 분포하는 위치가 서로 다르다는 것을 알 수 있다. 웨이블릿 변환을 통하여 추출한 특징에 공간좌표 특징이 추가된 26차원의 특징벡터는 식 (13)과 같다.

$$F = \text{trans}[F_L \ F_a \ F_b \ X/640 \ Y/480] \quad (13)$$

여기서, X 및 Y 는 현재 처리되고 있는 블록의 중심 좌표 값이다.

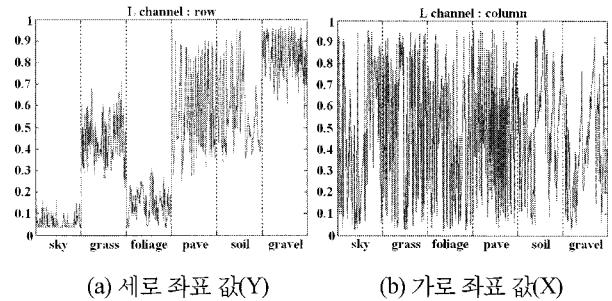


그림 6. 학습용 칩 영상의 지형 클래스별 공간 분포 특성.

Fig. 6. Spatial distribution of terrain class of training chips.

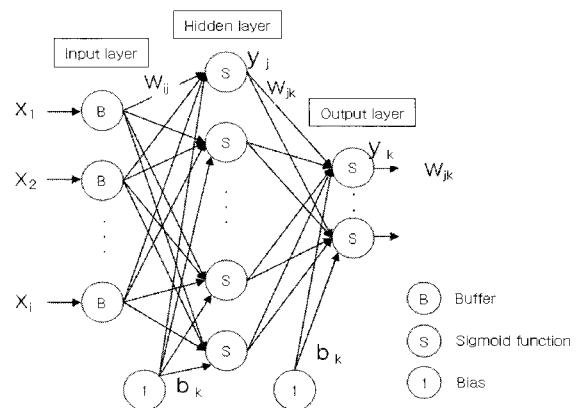


그림 7. 신경망 모델.

Fig. 7. The neural network model.

3. 분류기

분류기로 사용되는 신경망(neural net)은 특징들 사이에 비선형 특성이 포함되어 있거나 또는 불확실한 정보가 많이 포함되어 특징값을 모델로 표현하기 어려운 경우 효과적으로 사용될 수 있다. 신경회로망에는 많은 종류가 있지만 본 논문에서는 일반적으로 널리 사용되는 역전파 알고리즘을 적용하였다.

3.1 학습

역전파 알고리즘은 오차함수의 기울기가 감소하는 기울기 감소법(gradient descent method)을 이용한다. 신경회로망 시스템은 초기에 중간 가중치를 임의로 설정하며, 현재 클래스의 특징점에 대해 출력값을 계산하고, 원하는 출력값과 비교하여 오차가 작아지는 방향으로 초기 가중치를 조절한다. 이와 같이 역전파 알고리즘을 이용한 신경망의 학습은 출력 오차가 최소가 되도록 다음과 같은 과정의 반복을 통하여 중간 가중치를 변경시켜 최적화한다.

$$\begin{aligned} w_{jk}(t+1) &= w_{jk}(t) + \Delta w_{jk} + \alpha(w_{jk}(t) - w_{jk}(t-1)) \\ b_j(t+1) &= b_j(t) + \Delta b_j + \alpha(b_j(t) - b_j(t-1)) \\ w_{ij}(t+1) &= w_{ij}(t) + \Delta w_{ij} + \alpha(w_{ij}(t) - w_{ij}(t-1)) \\ b_k(t+1) &= b_k(t) + \Delta b_k + \alpha(b_k(t) - b_k(t-1)) \end{aligned} \quad (14)$$

여기서, w_{jk} 및 w_{ij} 는 각 레이어 사이의 가중치 값이며, b_j 및 b_k 는 바이어스의 가중치이다. Δw_{jk} , Δw_{ij} 는 가중치의

변화율이며, α 는 모멘텀 계수이다. 은닉층의 개수와 노드 수는 오차를 최소화할 수 있도록 시험을 통하여 결정하였는데, 은닉층의 개수는 2개로 정하였고 각각 18개 및 12개의 노드를 가지며, 출력층의 노드 수는 분류 대상 클래스 수와 같도록 설계하였다. 학습률은 0.5로 설정하였으며, 모멘텀 계수는 0.7로 설정하였다. 결합강도의 초기값은 랜덤 함수를 이용하여 -0.5~0.5의 범위에서 발생하도록 하였다.

신경망의 입력 데이터는 다음의 두 가지 측면을 고려하여 정규화할 필요가 있다. 첫 번째로 각각의 입력 데이터가 신경망 학습에 미치는 중요도는 동일하도록 해야 하며, 시그모이드형 전달함수가 조속히 포화상태에 빠지는 것을 방지하기 위해서이다. 두 번째로 출력값은 출력 전달함수가 가질 수 있는 범위에 포함되어야 하나 변환되지 않은 데이터는 해당 범위에서 대응되지 않을 수도 있다. 입력 데이터를 정규화하는 방법으로 선형변환 및 z-점수 변환 방법 등이 있다. 본 논문에서는 선형변환을 사용하여 각 입력 변수의 값을 정규화하였다. 학습 데이터는 각 클래스에 대한 침영상을로부터 추출한 식 (13)의 특징벡터를 이용하였으며, 학습 결과 오차가 10^{-5} 이하로 수렴하는 것을 확인하였다.

3.2 분류 수행

분류 수행단계는 입력 영상으로부터 추출된 특징벡터를 이용하여 분류 결과를 계산하는 과정으로서 교사학습 단계에서의 전처리 및 특징추출 과정은 동일하므로 특징벡터의 차원을 고려하여 2개의 은닉층과 노드 바이어스를 갖는 다층퍼셉트론(MLP: Multi-Layer Perceptron)을 사용하지만, 학습 결과로부터 생성된 신경망 파라미터를 이용하여 입력 특징을 구분한다. 신경망의 입력은 학습 결과인 가중치 파라미터와 입력영상의 특징벡터로 구성되고, 출력은 입력영상의 픽셀이 속하는 지형 클래스의 분류 결과가 된다. MLP의 수행 과정은 그림 8과 같다[10].

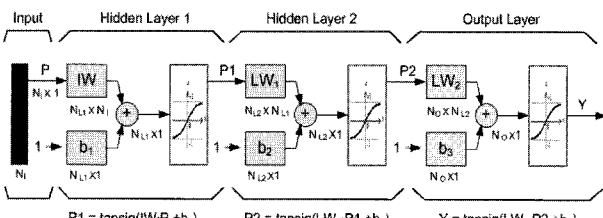
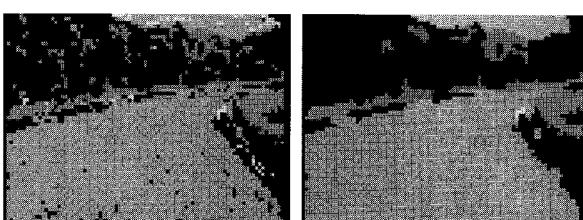


그림 8. MLP의 수행 과정.

Fig. 8. Running process of MLP.



(a) 분류결과 영상

(b) 블록제거 영상

그림 9. 레이블링 및 블록 제거를 통한 후처리.

Fig. 9. Post-processing by image labeling and blob removing.

4. 후처리

상기 과정을 통하여 분류된 결과 영상은 색상 및 질감의 불균일성, 클래스 경계영역에서의 불명확한 특징 등으로 인해 오분류된 블록들이 존재한다. 이와 같은 오분류된 블록을 본 논문에서는 블록(blob)으로 정의하고, 후처리 단계에서 그레이 톤별 영상 레이블링 기법을 이용한 블록 제거를 수행한다. 일반적으로 이진(binary) 영상에 대해서는 팽창(dilate), 침식(erode), 열기(open), 닫기(close) 등의 형태론적 처리를 사용한 레이블링 기법들이 있으나, N개의 클래스로 분류된 N-ary 결과 영상의 경우에는 직접적인 적용이 어렵다. 따라서 분류 결과 영상에 대한 후처리는 씨드 확산법을 이용한 N-ary 영상 레이블링을 적용하였다. N-ary 영상 레이블링 알고리즘은 씨드 확산에 따른 상, 하, 좌, 우, 4방향으로 연결된 성분들을 동일한 영역으로 레이블링하는 방법으로 이진 영상의 레이블링 알고리즘을 확장한 것이다[11]. N-ary 영상에 대한 레이블링이 완성되면, 공간적인 크기를 기준으로 제거할 블록들을 결정한다. 제거 대상 블록들은 해당 블록의 고립 영역을 포함하는 최소 사각형 내에서 가장 큰 영역의 클래스로 대체된다. 그럼 9는 MLP의 출력인 분류결과 영상과 블록들이 제거된 후처리 영상을 나타낸다.

III. 실험 및 결과

실험을 위해서 다양한 지형 클래스를 포함하는 야자지형으로부터 영상을 획득하였으며, SONY사 XC-555 컬러 CCD 카메라를 이용하였다. 획득된 영상은 640×480 의 픽셀 해상도로 초당 30 프레임씩 실시간 디지털 저장장치에 저장된다. 저장된 영상 프레임 중에서 랜덤하게 선택된 100개의 영상으로부터 클래스별 200개씩의 학습용 침 영상 및 10개의 시험영상을 추출하였다. 시험영상에 대해 제안된 기법을 적용하여 실험을 수행하였으며, 제안된 방법의 개선된 성능을 확인하기 위하여 동일한 시험영상에 대해 색상특징을 이용한 분류기법을 적용한 실험결과와 비교하였다. 색상특징을 이용한 분류는 클래스별 학습용 침 영상의 색상특징

표 1. 적용 특징에 따른 분류 성능 비교.

Table 1. Comparison of classification performance(percentage) for different feature vectors.

순번	색상 및 질감특징 (LWT + MLP)	색상특징 (GMM + ML)
1	86.2	92.7
2	80.0	83.7
3	71.7	59.7
4	86.7	32.4
5	82.0	71.6
6	84.5	83.5
7	58.5	41.0
8	65.2	66.6
9	89.3	56.2
10	86.9	79.3
평균	79.1	66.7

Original Image	Ground Truth	Classification Results	
		LWT + MLP	GMM + ML

그림 10. 실험 결과(지형 클래스별 색상 코드: 하늘-하늘색, 숲-파란색, 잔디-녹색, 자갈-노란색, 흙-갈색, 포장로-회색, 기타-검은색).

Fig. 10. Experimental results(color code : sky blue-sky, dark blue-foliage, green-grass, yellow-gravel, dark brown-soil, gray-pavement, black-outlier).

에 대해 GMM을 생성하고, 시험영상을 16×16 픽셀 크기의 블록 단위로 분할하여 ML 분류기를 적용하였다. 또한 알고리즘의 정량적인 성능 평가를 위해 시험영상에 대한 ground truth를 수작업으로 생성하였다. 분류 성능은 수작업 영상과 분류 결과 영상을 픽셀 단위로 비교하여 계산하였다.

10장의 시험영상에 대한 분류 성능은 표 1과 같고, 시험 영상과 ground truth를 포함한 분류 결과 영상은 그림 10에 나타내었다. 표 1에서 제안된 분류기법의 결과는 색상특징 기반의 GMM 및 ML을 적용한 분류 결과에 비해 평균 약 12% 정도 향상된 성능을 나타냄을 알 수 있다.

그림 10에서 첫 번째 열은 입력된 시험영상을 나타내며, 두 번째 열은 분류결과의 평가를 위해 수작업으로 생성된

ground truth 영상이다. 세 번째 열은 LWT 특징을 이용한 분류결과이고, 네 번째 열은 색상특징만을 이용한 분류결과이다. 1, 2번 영상의 경우와 같이 색상 분포가 비교적 균일한 잔디 클래스를 많이 포함하는 시험영상에 대해서는 색상특징 기반의 분류결과가 양호한 성능을 나타내지만, 그 외의 영상에 대해서는 LWT 특징을 적용한 분류결과가 전반적으로 더 좋은 성능을 나타내었다. 특히 4, 9번 영상과 같이 동일한 클래스이지만 그림자 등으로 인한 밝기의 차이가 있는 영역에서는 LWT를 통한 색상 및 질감 특징을 동시에 적용함으로서 성능이 향상됨을 알 수 있다.

IV. 결론

무인차량의 효율적인 자율주행을 위한 영상기반의 지형 분류기법에 대한 기존의 연구내용은 주로 영상의 색상 정보를 이용하였으나, 색상 정보만을 이용한 경우에 대한 단점을 극복하기 위해 영상의 색상과 질감 특징을 동시에 고려한 효과적인 지형 분류기법을 제시하였다. 입력영상으로부터 색상 및 질감 특징을 추출하기 위해 리프팅 웨이블릿 변환을 이용하였으며, 지형 클래스들이 영상에서 위치하는 공간정보를 추가적인 특징으로 이용하였다. 제안한 알고리즘의 타당성을 검증하기 위해 야외 환경에서 획득한 영상에 대해 실험을 수행하였으며, 색상특징만을 적용한 분류 결과와의 정량적인 비교를 통해 제안된 방법에 의해 야외 영상에서의 지형 클래스들을 효과적으로 분류할 수 있음을 입증하였다.

본 연구에서는 학습에 사용되지 않은 물이나 인공적인 구조물과 같은 outlier 클래스에 대해서는 고려하지 않았으나, 향후에는 이와 같은 outlier 클래스를 포함한 분류기법에 대한 연구가 추가로 수행되어야 할 것이다. 또한 환경조건에 강인하고 신뢰성 있는 분류결과를 얻기 위해서는 다양한 환경 조건하에서 획득된 영상에 대한 추가적인 실험이 필요하다. 그리고 분류 성능의 향상을 위해 서로 다른 특징을 이용한 분류결과의 융합 또는 특징간의 융합을 이용한 분류기법에 대한 연구도 필요할 것으로 판단된다.

참고문헌

- [1] R. Manduchi, A. Castano, A. Talukder, and L. Matthies, "Obstacle detection and terrain classification for autonomous off-road navigation," *Autonomous Robot* 18, pp. 81-102, Springer Science, 2005.
 - [2] P. Bellutta, R. Manduchi, L. Matthies, K. Owens, and A. Rankin, "Terrain perception for demo III," *Intelligent Vehicles Conference*, 2000.
 - [3] A. L. Rankin, C. F. Bergh, S. B. Goldberg, P. Bellutta, A. Huertas, and L. H. Matthies, "Passive perception system for day/night autonomous off-road navigation," *SPIE Conf. of Autonomous Vehicles*, 2005.
 - [4] P. Jansen, W. van der Mark, J. C. van den Heuvel, and F. C. A. Groen, "Colour based off-road environment and terrain type classification," *Proc. of the 8th Int'l IEEE Conf. on Intelligent Transportation Systems*, Vienna,

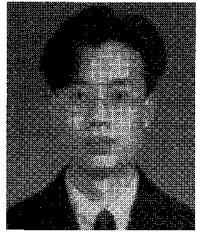
- Austria, Sep. 2005.
- [5] R. Castano, R. Manduchi, and J. Fox, "Classification experiments on real-world texture," *Workshop on Empirical Evaluation in Computer Vision*, Kauai, HI, Dec. 2001.
- [6] G. Y. Sung, D. M. Kwak, D. J. Kim, and J. Lyou, "Terrain cover classification based on wavelet feature extraction," *Int'l Conf. on Control, Automation and Systems*, Seoul, Korea, Oct. 2008.
- [7] I. Daubechies, *Ten Lectures on Wavelets*, Society for Industrial and Applied Mathematics, 1992.

- [8] I. Daubechies and W. Sweldens, "Factoring wavelet transforms into lifting steps," *Journal of Fourier Analysis and Applications*, vol. 4, no. 3, pp. 247-269, 1998.
- [9] M. Misiti, Y. Misiti, G. Oppenheim, and J. M. Poggi, "Wavelet Toolbox User's Guide," MathWork Inc.
- [10] "Neural Network Toolbox," MathWork Inc.
- [11] Y. Shima, T. Murakami, and M. Koga, "A high speed algorithm for propagation-type labeling based on block sorting of runs in binary images," *Proc. 10th International Conference on Pattern Recognition*, vol. 1, pp. 665-665, 1990.



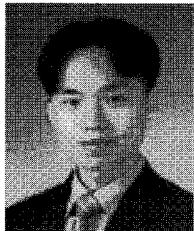
성기열

1989년 경북대학교 전기공학과 졸업.
1991년 동 대학원 석사. 2007년 3월~
현재 충남대학교 박사과정 재학 중.
1991년 2월~현재 국방과학연구소 연구
원. 관심분야는 영상신호처리, 컴퓨터
비전 및 패턴 인식.



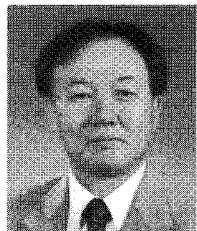
곽동민

1997년 경북대학교 전자공학과 졸업.
1999년 동 대학원 석사. 2003년 동 대
학원 박사. 2004년 2월~현재 국방과학
연구소 연구원. 관심분야는 적외선 영
상처리, 패턴 인식 및 분류.



이승연

2003년 충남대학교 학사 및 2005년 동
대학원 석사졸업. 제어전공. 2005년 2
월~현재 국방과학연구소 연구원. 관심
분야는 EO/IR 영상처리, 패턴 인식 및
분류.



유준

1978년 서울대학교 전자공학과(공학사).
1980년, 1984년 한국과학기술원 전기전
자공학과(공학석사, 공학박사). 1984년
9월~현재 충남대학교 전기정보통신공
학부 교수. 1989년 2월~1990년 2월 미
쉬건 주립대학교 객원 교수. 1993년 12
월~1994년 2월 독일 후라운호퍼 생산공학 및 자동화(IPA)
연구소 방문연구원. 1997년 2월~1998년 2월 캘리포니아 주
립대학교(데이비스) 객원교수. 관심분야는 산업공정제어, 센
서신호처리, IT 기반 로봇, 항법시스템.