

## 야지 자율주행을 위한 환경에 강인한 지형분류 기법

### Robust Terrain Classification Against Environmental Variation for Autonomous Off-road Navigation

성 기 열\*      유 준\*\*  
Gi-Yeul Sung      Joon Lyoo

#### Abstract

This paper presents a vision-based robust off-road terrain classification method against environmental variation. As a supervised classification algorithm, we applied a neural network classifier using wavelet features extracted from wavelet transform of an image. In order to get over an effect of overall image feature variation, we adopted environment sensors and gathered the training parameters database according to environmental conditions. The robust terrain classification algorithm against environmental variation was implemented by choosing an optimal parameter using environmental information. The proposed algorithm was embedded on a processor board under the VxWorks real-time operating system. The processor board is containing four 1GHz 7448 PowerPC CPUs. In order to implement an optimal software architecture on which a distributed parallel processing is possible, we measured and analyzed the data delivery time between the CPUs. And the performance of the present algorithm was verified, comparing classification results using the real off-road images acquired under various environmental conditions in conformity with applied classifiers and features. Experiments show the robustness of the classification results on any environmental condition.

Keywords : Unmanned Ground Vehicles(무인차량), Terrain Classification(지형분류), Wavelet Transform(웨이블릿 변환), Neural Network(신경망), Environment Sensor(환경센서)

#### 1. 서론

무인차량의 효율적인 자율 주행을 위해서는 이동 경로의 지형에 대한 적절한 분류와 분류된 지형에 따른

차량제어가 필요하다. 특히 야외 환경에서 무인차량의 효과적인 기동제어를 위해서는 지형 형상 인지, 지표면 분류 및 장애물 탐지가 필수적이다. 이에 따라 다양한 센서를 활용하여 지형에 대한 형태를 분류하고 인지하는 기법들이 연구되었으며, 라이다나 레이더, 영상 센서(CCD, IR) 등이 많이 활용되고 있다. 특히 영상 센서는 사람의 시각과 유사한 정보를 얻을 수 있고, 낮은 가격에 경량으로 제작이 가능하며, 저 전력을 소모하므로 널리 사용되고 있다. 영상 기반의 지형분

† 2010년 6월 15일 접수~2010년 8월 6일 게재승인

\* 국방과학연구소(ADD)

\*\* 충남대학교(Chungnam National University)

책임저자 : 유준(jlyou@cnu.ac.kr)

류에 사용되는 대표적인 특징으로 색상과 질감 특징이 있으며, 이러한 특징을 적용한 영상 기반의 지형분류 기법들이 소개되었다. 현재까지 연구된 대부분의 지형 분류기는 CCD 센서로부터 획득된 컬러 영상에서 지형 영역에 대한 색 분포를 가우시안 혼합 모델(GMM : Gaussian Mixture Model)로 표현하고, 베이지안 분류기<sup>[1,2]</sup> 또는 최우도기법(ML : Maximum Likelihood)<sup>[3]</sup> 등을 이용하여 분류하는 방법이었다. 이러한 방법들은 고속으로 동작하지만, 색 분포만을 사용하기 때문에 대기변화에 의한 색상 변화, 조도 변화 등에는 매우 취약하다. 이러한 단점을 보완하기 위해 Gabor 필터 기반 질감특징을 적용한 지형분류기법<sup>[4]</sup>도 연구되었으나, 방향과 크기에 따라 변화하는 질감특징을 추출하기 위해 다수의 필터 뱅크를 활용하여야 하므로 과도한 연산 시간이 소요되어 실시간 구현에 적합하지 않다.

본 논문에서는 무인차량의 효율적인 야지자율주행에 적용 가능한 지형분류기로서 분류 성능의 향상 및 처리속도 개선에 중점을 둔 알고리즘과 하드웨어 구조를 제안한다. 컬러 CCD 센서로부터 획득된 지형영상의 웨이블릿 변환 영역에서 추출된 특징을 이용한 교사학습 방식의 신경망 분류기인 다층퍼셉트론(MLP : Multi Layer Perceptron)을 적용하였으며, 동일한 웨이블릿 특징에 대해 SVM(Support Vector Machine) 분류기를 적용한 경우와 그 결과를 비교하였다. 또한 입력영상의 색상 특징에 대한 GMM 기반 ML 분류기를 적용한 시험을 수행하여 적용 특징에 따른 분류 성능을 비교하였다. 환경변화에 강인한 지형분류를 위하여 환경 정보를 활용한 계절, 시간, 조도, 습도 등의 환경 조건별로 학습을 수행하여 각각의 분류기에 해당하는 학습 파라미터를 구축하였다. 임의의 환경 조건에서 야지 지형영상의 분류를 위해서 획득된 환경정보에 따라 환경조건을 식별하고 최적의 학습 파라미터를 선택하도록 하였다. 또한 지형분류 알고리즘의 실시간 구현을 위한 병렬처리 구조의 하드웨어를 설계하여 알고리즘의 수행시간을 측정하였으며, 적용 특징과 분류기 조합에 따른 분류 성능 및 처리시간을 비교하기 위하여 실 야지영상에 대한 실험을 수행하였다.

## 2. 지형분류 알고리즘

교사학습 방식의 분류기는 오프라인 학습단계와 시험영상에 대한 온라인 수행단계로 구분되는데, 오프라

인 학습을 위하여 환경조건 별로 사전에 획득된 영상 집합으로부터 각 클래스별로 200개씩의 16×16 픽셀 크기를 갖는 학습용 칩 영상을 추출한다. 본 논문에서 고려한 분류 대상 지형은 하늘, 숲, 잔디, 자갈, 흙, 포장로의 6가지 클래스이며, 학습용 칩 영상의 추출 시 지형 클래스가 위치하는 공간 정보를 특징으로 적용하기 위해 동일한 클래스가 분포하는 다양한 영역으로부터 고르게 추출하였다<sup>[5]</sup>. 학습용 칩 영상에 대한 전처리 및 특징 추출이 완료되면, 각각의 분류기에 대한 학습 결과 파라미터를 저장한다. 수행단계에서는 선택된 분류기에 따라 필요한 학습 파라미터를 읽어온 후, 입력영상에 대해 색 공간 변환을 수행하고, 입력영상을 16×16 크기의 블록으로 구분하였을 때 각 블록 영역에 해당하는 색상 및 웨이블릿 특징을 추출하여, MLP, SVM 및 GMM-ML 분류기를 선택적으로 적용하고, 후처리 과정으로 고속 레이블링 기반의 블럽 제거 기법을 이용하여 최종결과를 전시한다. Fig. 1은 제안한 알고리즘의 수행 순서도이다.

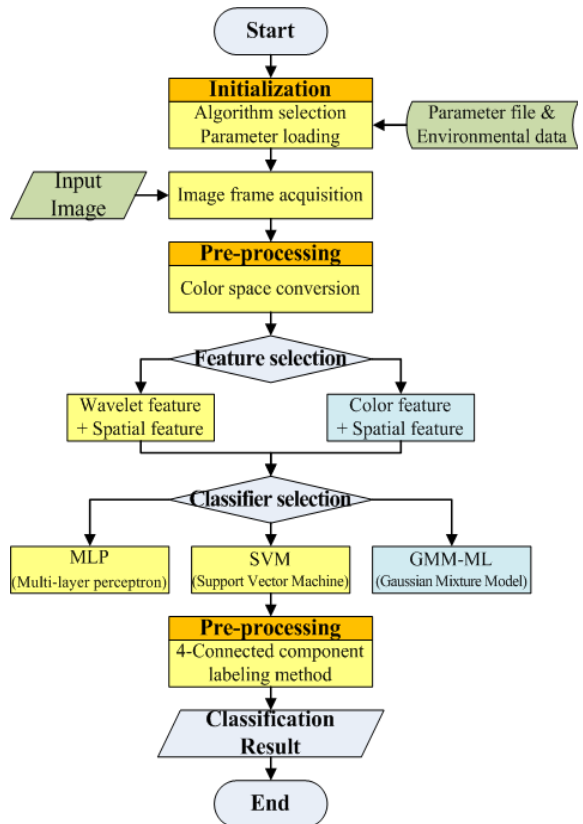


Fig. 1. 지형분류 알고리즘 수행 순서도

가. 전처리(Pre-processing)

전처리 단계에서는 환경변화에 강인하고, 양호한 분류성능을 나타내는 특징을 추출하기 위해 입력 영상으로부터 색 공간 변환을 수행한다. CCD 카메라의 입력 RGB 값은 CIE-Lab, HSI, YUV 등 다양한 색 공간으로 변환이 가능하지만, 색 공간에 따른 분류성능에는 큰 차이가 없으므로<sup>[5]</sup>, 구현 시 처리시간이 빠른 YUV 색 공간으로 변환하였다.

나. 특징추출(Feature Extraction)

1) 웨이블릿 특징 추출

웨이블릿 영역에서 특징 추출을 위해 YUV 색 공간으로 변환된 영상의 각 채널에 대해 Daubechies<sup>[6]</sup> 기저함수를 이용한 2단계 웨이블릿 변환을 수행하고, Fig. 2와 같이 웨이블릿 영역에서의 16×16 픽셀 크기의 블록을 구성하였다. 특징벡터를 추출하기 위해 각각의 부대역에 대한 웨이블릿 평균 및 에너지를 계산한다.  $i$  번째 부대역 계수들에 대한 웨이블릿 평균( $M^i$ )과 에너지( $En^i$ )는 각각 식 (1), (2)를 이용하여 구할 수 있다<sup>[7]</sup>.

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

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




Fig. 2. 2단계 웨이블릿 변환 영상 및 웨이블릿 변환 영역에서의 16×16 블록 구성

여기서,  $N$ 은 각 부대역 별 웨이블릿 계수의 총 개수이고,  $K$ 는 부대역의 총 개수이다.  $c_j^i$ 는  $i$  번째 부대역의  $j$  번째 계수이고,  $En_{total}$ 은 총 에너지이다. 잡음 특성을 많이 포함하고 있는  $S_3$ 와  $S_6$  부대역을 제외하 나머지 5개 부대역으로부터 각 채널에 대해 웨이블릿

에너지를 추출하였고, 웨이블릿 평균은 각 채널의  $S_0, S_4, S_5$  부대역으로부터 추출되었다.  $S_0$  부대역의 평균은 신경망에 미치는 바이어스 영향을 감소시키기 위해 0.1의 가중치를 곱해서 적용하였다.

2) 색상 특징 추출

색상 특징은 GMM 기반의 분류에 적용하기 위해 입력된 영상을 16×16 픽셀 크기의 블록으로 분할한 후 각 블록의 평균값을 특징으로 추출한다. 학습 단계에서는 클래스별 학습용 칩 영상에서 추출된 색상 특징을 이용하여 GMM을 구성하는데, 이때 EM(Expectation Maximization) 알고리즘을 이용하여 최적 학습 파라미터를 도출한다<sup>[8]</sup>.

3) 공간좌표 특징 추출

지형 클래스 별로 추출된 학습용 칩에 대한 영상 내에서 공간 분포를 살펴보면, 각 지형 클래스 별로 영상의 세로 방향으로 위치하는 공간적 분포의 차이가 있으므로, 영상 내에서 각 지형 클래스가 위치하는 공간좌표는 어떤 클래스와 다른 클래스들을 구분하기 위한 유용한 정보가 될 수 있음을 알 수 있다<sup>[5]</sup>. 따라서 현재 처리되고 있는 국부 블록의 중심점을 공간좌표 특징으로 적용하였다. 학습 단계에서는, 임의의 표본 영상들로부터 학습용 칩을 추출할 때 각 칩 영상의 중심좌표를 동시에 추출하였다.

다. 분류기 적용

야지지형 분류를 위해 본 연구에서는 색상 특징과 공간좌표 특징을 이용한 GMM-ML 분류기와 웨이블릿 특징과 공간좌표 특징을 이용한 MLP 및 SVM 분류기를 적용하였다.

1) 색상 특징의 GMM 기반 ML 분류기<sup>[8]</sup>

GMM은 주어진 표본 데이터 집합의 분포를 복수 개의 가우시안 확률밀도 함수의 합으로 모델링하는 방법이며, 식 (3)과 같이 나타낼 수 있다.

$$p(x|\theta) = \sum_{i=1}^M p(x|\omega_i, \theta_i) P(\omega_i) \quad (3)$$

여기서,  $p(x|\omega_i, \theta_i)$ 는 데이터  $x$ 에 대하여  $\omega_i$  번째 성분 파라미터  $\theta_i$ 로 이루어진 확률 밀도함수이고,  $P(\omega_i)$

는 혼합 가중치( $\alpha_i$ )이며, 확률 밀도함수가 가우시안 분포이면  $\theta_i = (\mu_1, \mu_2, \dots, \mu_M, \sigma_1, \sigma_2, \dots, \sigma_M, \alpha_1, \alpha_2, \dots, \alpha_M)$  이 된다. GMM의 학습단계에서는 EM 알고리즘을 사용하여 각 혼합 성분 가우시안들의 파라미터를 추정하며, 수행단계에서는 입력영상의 국부 블록에 대해 추출된 특징벡터와 클래스별 학습 파라미터를 기반으로 각 클래스별 가우시안 확률값을 구하고, 식 (4)의 ML 분류기를 적용하여 가장 큰 값을 갖는 클래스로 해당 블록을 분류한다.

$$ML(F) = \operatorname{argmax} \sum_{i=1}^c w_i^c \mathcal{N}(\mu_i^c, \sigma_i^c) F \quad (4)$$

2) 웨이블릿 특징 기반의 MLP 분류기<sup>[5]</sup>

본 논문에서 사용된 MLP 분류기는 1개의 입력층과 2개의 은닉층, 그리고 1개의 출력층으로 구성된다. 학습단계에서는 교차 학습방법인 오차 역전파법을 이용하여 가중치 변수들을 계산한다. 은닉층의 노드 수는 오차를 최소화하기 위해서 몇 가지의 수를 변경하여 시험하였고, 그 결과 첫 번째 은닉층은 18개의 노드, 두 번째 은닉층은 12개의 노드를 가지도록 설계하였다. 결합강도의 초기값은 랜덤함수를 사용하여 -0.5~0.5의 범위에서 발생하도록 하였다. 또한 입력 데이터를 정규화 함으로써 신경망 학습에 미치는 중요도가 동일하도록 하였다.

3) 웨이블릿 특징 기반의 SVM 분류기<sup>[9]</sup>

SVM 분류기는 통계적 학습 이론에 기반을 둔 2 클래스 분류 방법으로서, 특징 공간(feature space)에서 주어진 클래스 간의 마진을 최대로 하는 최적분류초평면(OSH : Optimal Separating Hyperplanes)을 구하는 것이다<sup>[10]</sup>. 이 때 최적의 초평면은 식 (5)의 최적화 문제의 해로부터 구할 수 있다.

$$\begin{aligned} \operatorname{Min} \quad Q(w) &= \frac{1}{2} \|w\|^2 \\ \operatorname{subject to:} \quad & y_i(w^T x_i + b) \geq 1 \quad \text{for } i=1, \dots, m \end{aligned} \quad (5)$$

그러나 SVM은 구조적으로 이진 분류기라는 단점을 가지고 있어서 다중 클래스 분류가 요구되는 응용 분야에 적용이 쉽지 않다. 따라서 이를 해결하기 위해 다수의 SVM들을 조합하여 학습시키는 방법들을 활용하고 있다<sup>[11]</sup>. 그리고 초평면이 비선형인 경우에는

Kernel 트릭을 사용하여 특징 공간에서 선형 분리가 가능하도록 한다. 본 논문에서는 웨이블릿을 통하여 추출한 특징들을 일대다(One against All) SVM을 적용하여 학습시켰으며, 학습을 위한 툴로는 LibSVM<sup>[12]</sup>을 사용하였다.

라. 후처리

이상의 과정을 통하여 분류된 결과 영상은 색상 및 질감의 불균일성, 클래스 경계영역에서의 불명확한 특징 등으로 인해 오분류된 블록들이 존재한다. 이와 같은 블럽(blobs) 들은 씨드 확산법을 적용한 multi-level 영상 레이블링 및 블럽 제거 방법을 이용하여 후처리된다. multi-level 영상 레이블링 알고리즘은 기본적인 2진 영상의 레이블링 알고리즘을 확장시킨 씨드 확산법에 의한 4방향 연결 성분 레이블링이다<sup>[13]</sup>. 연결 성분에 대한 영역 레이블링 결과로부터 고립영역의 크기에 따라 제거할 블럽들을 결정한다. 이러한 블럽들은 고립 영역을 포함하는 최소 직사각형 내에서 가장 많은 픽셀수를 갖는 클래스로 변경된다.

3. 환경 센서 정보를 활용한 학습 파라미터 DB 구축

영상 기반의 야지 지형 분류에서 웨이블릿 특징을 적용하여 국부적인 색상이나 조명의 변화에 강인한 알고리즘을 구현할 수 있지만<sup>[5]</sup>, 야지환경에서의 계절에 따른 지형의 변화나 영상의 전체적인 조도 변화 등의 영향을 고려하지 못하여 제한된 환경에서만 지형분류를 수행하거나, 무인차량의 주행 직전에 해당 환경에 적합한 학습 파라미터를 다시 추출해야 하는 문제가 발생할 수 있다. 따라서 본 논문에서는 오프라인 학습단계에서 학습용 영상 획득 시에 환경 센서를 이용하여 환경 조건별로 학습 파라미터를 추출하였으며, 수행단계에서 임의의 환경 조건에서 무인차량이 주행을 할 때 환경 센서를 이용하여 현재의 환경 조건과 가장 유사한 조건에서의 학습 파라미터를 선택하여 다양한 환경변화에 강인한 지형분류 결과를 산출하도록 하였다. 환경 센서로는 영상의 특징에 영향을 미칠 수 있는 환경 요소의 파악을 통하여 GPS 센서(계절 및 시간), 조도센서, 습도센서를 적용하였고, 계절, 시간, 조도 및 습도에 따라 환경 조건별로 상태를 구분하기 위해 각 센서의 출력값의 범위에 따라

이산화, 코드화하였다.

Table 1은 각 환경 센서로부터 획득된 출력값을 이산화하는 방법을 나타낸다. Table 1에서 알 수 있듯이 GPS 센서를 통해 획득된 날짜와 시각 정보를 이용하여 4 계절을 구분하였고, 각 계절별로 오전, 오후, 야간의 시간대를 다르게 설정하였다. 따라서 GPS를 통해 얻어진 시각 정보는 계절과 시간에 따라 0, 1, 2, ..., A, B의 12 단계로 구분된다. 조도센서를 통해 얻어진 조도정보는 Lux에 따라 L(Low), M(Middle), H(High)의 3 단계로 구분하였고, 습도센서를 통해 얻어진 습도정보는 %에 따라 L(Low), M(Middle), H(High), U(Very High)의 4 단계로 구분하였다.

Table 1. 환경 센서 출력값에 따른 코드 구분

GPS		조도(Lux)	습도(%)
봄 (3~5월)	0 : 오전(06~12)	L : 0~30000 M : 30000~70000 H : 70000~∞	L : 0~60 M : 60~75 H : 75~85 U : 85~100
	1 : 오후(12~19)		
	2 : 야간(19~06)		
여름 (6~8월)	3 : 오전(05~12)		
	4 : 오후(12~20)		
	5 : 야간(20~05)		
가을 (9~11월)	6 : 오전(06~12)		
	7 : 오후(12~19)		
	8 : 야간(19~06)		
겨울 (12~2월)	9 : 오전(07~12)		
	A : 오후(12~18)		
	B : 야간(18~07)		

이와 같이 환경 센서별로 이산화된 환경 정보를 이용하여 획득시점에 따라 다양한 환경 조건에 해당하는 학습용 샘플 영상을 획득하였으며, 각각의 환경 조건별로 지형분류를 위한 학습 파라미터 DB를 구축하였다. 무인차량이 주행하는 시점의 지형영상이 입력되면, 환경 센서에 의한 정보를 이용하여 환경조건을 판단하고, 동일한 환경조건에서 학습된 파라미터 파일을 선택하여 현재 지형을 분류하게 된다. 현재 환경에 맞는 파라미터가 없을 경우를 대비하여 Table 2와 같이 대체 우선순위에 따른 파라미터 선택 테이블을 제작하여 계절, 시간, 조도, 습도에 따라 현재 요구되는 파라미터와 가장 유사한 환경의 학습 파라미터의 선택이 가능하도록 하여 지형분류 오류를 최소화하도록

하였다. 환경 정보에 따른 대체 파라미터는 다음의 절차에 따라 선택한다. 먼저 Table 2의 검색 순위에 따라 GPS의 시간 정보를 기준으로 계절 및 시간에 대한 코드를 결정하고 해당 파라미터를 검색하는데, 계절에 따른 지형 변화의 영향이 가장 클 것으로 판단되어 동일한 계절의 시간 정보에 대해서만 대체가 가능하도록 하였다. 다음은 검색된 학습 파라미터 파일 중에서 조도 정보를 기준으로 대체 가능 코드 순서에 따라 파라미터를 검색하고, 마지막으로 습도 정보에 대한 코드를 결정하고 적용할 파라미터를 선택한다. 예를 들어, 현재의 GPS 시각정보가 '0'(봄, 오전) 상태인 경우 최우선 순위는 동일한 상태인 '0'이 되고, '0'에 해당하는 파라미터가 없을 경우 다음 우선순위인 '1'에 해당하는 파라미터(봄, 오후)를 찾게 된다. 다음은 GPS 정보의 우선순위에 따라 검색된 학습 파라미터 파일 중에서 조도 정보의 우선순위에 따른 파라미터를 검색하며, 마지막으로 습도 정보의 우선순위에 따라 최종적으로 가장 유사한 환경조건의 학습 파라미터 파일을 선택한다.

Table 2. 학습 파라미터 선택을 위한 우선순위

구분	상태 코드	대체 가능 코드	검색순위
계절/ 시간	0(봄/오전)	0 → 1	1
	1(봄/오후)	1 → 0	
	3(여름/오전)	3 → 4	
	4(여름/오후)	4 → 3	
	6(가을/오전)	6 → 7	
	7(가을/오후)	7 → 6	
	9(겨울/오전)	9 → A	
	A(겨울/오후)	A → 9	
조도	L(Low)	L → M → H	2
	M(Middle)	M → L → H	
	H(High)	H → M → L	
습도	L(Low)	L → M → H → U	3
	M(Middle)	M → L → H → U	
	H(High)	H → M → U → L	
	U(Very high)	U → H → M → L	

#### 4. 하드웨어 설계

##### 가. 하드웨어 구조

알고리즘의 실시간 구현을 위한 하드웨어는 분류 알고리즘을 수행하는 프로세서보드, 외부 장치와 연동되어 제어명령 입력과 분류결과 출력 기능을 수행하는 주제어보드, 입력영상의 획득을 위한 영상획득보드, 보드 간 대용량 데이터의 고속 송수신을 위한 고속통신보드 등으로 구성되며, 알고리즘의 고속 처리와 영상데이터의 원활한 송수신이 가능한 구조로 설계하였다.

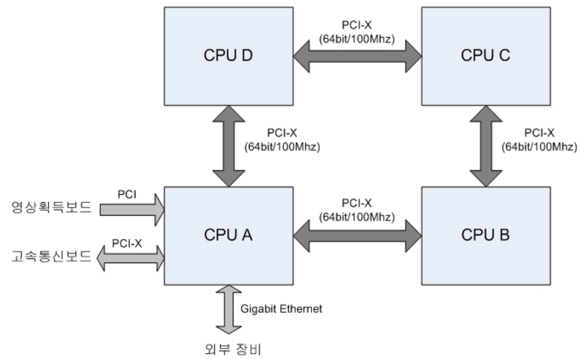


Fig. 4. 프로세서보드 구성도

##### 1) 프로세서보드

프로세서보드는 4개의 PowerPC 7448 CPU로 구성된 Curtiss Wright사의 Champ-AV-IV 보드를 적용하였으며, 보드 내부 Quad-Core CPU의 효율적인 활용을 위해 각 CPU간 데이터 전송시간 측정과 분석을 통하여 분산형 병렬처리가 가능하도록 최적화 구현하였다. 프로세서보드는 디지털 영상을 입력 받아 분류 알고리즘을 수행한 후, 그 결과를 주제어보드로 전송하는 역할을 한다. 각 프로세서는 최대 6.4Gbps의 로컬버스로 연결되어 있어 프로세서 간 대용량 데이터 송수신이 원활하다. 프로세서보드의 형상 및 구성도는 각각 Fig. 3 및 Fig. 4와 같다. Fig. 4에서 프로세서보드의 CPU A는 PCI-bus를 통하여 영상획득보드와 연결되어 디지털 영상을 획득하고, PCI-X bus를 통하여 고속통신보드와 연결되어 지형분류 결과를 전송하는 기능을 수행한다. CPU A에서 획득한 영상데이터는 PCI-X bus를 통하여 CPU B, C, D로 순차적으로 전송되며, CPU B, C, D에서는 각각 입력 받은 영상 데이터에 대하여 분류 알고리즘을 수행한다. 각각의 수행결과는 다시 PCI-X bus를 통하여 CPU A로 전송된다.



Fig. 3. 프로세서보드 형상

##### 2) 주제어보드

주제어보드는 프로세서보드와 동일한 하드웨어를 적용하였으며, 외부 장치와 연동되어 환경정보 및 제어명령을 입력받고, 지형분류 결과를 출력하는 기능을 수행한다. CPU A는 고속통신보드와 연동되어 프로세서보드에서 수행한 지형분류 결과를 전송 받아 Gigabit Ethernet을 통하여 외부 장치로 전송한다. 또한 외부 장치로부터 전송된 환경정보와 운용/통제명령을 받아 프로세서보드로 전송하기도 한다. 주제어보드의 CPU B, C, D는 후처리 및 결과 융합 기능의 추가 등 분류 알고리즘의 성능 개선을 고려한 확장성을 확보하였다.

##### 3) 영상획득보드

영상획득보드는 PMC(PCI Mezzanine Card) 형태로 프로세서보드에 장착된다. CCD 센서로부터 RS-170A 형식의 아날로그 영상신호를 입력받아 640×480(Pixels) 해상도의 24bit, R:G:B=8:8:8 또는 Y:Cb:Cr=8:8:8 디지털 픽셀 데이터로 변환한 후 PCI-bus(66Mhz, 32bit)를 통하여 프로세서보드로 전송하는 기능을 수행한다.

##### 4) 고속통신보드

고속통신보드는 주제어보드와 프로세서보드 간의 대용량 데이터의 고속 송수신 기능을 담당한다. 데이터 송수신 능력은 최대 500MB/sec이며, peer to peer 형태로 연결되어 있다. 또한 보드 간 수신라인과 송신라인이 분리되어 있어, 데이터 송수신이 자유로운 장점이 있다. 고속통신보드는 영상획득보드와 마찬가지로 주제어보드 및 프로세서보드에 PMC 형태로 각각 장착된다.

##### 나. 데이터 송수신 및 알고리즘 처리 시간 측정

프로세서보드에서의 데이터 처리시간 측정을 위해



여 640×480×4byte×30Hz의 입력영상 데이터와 80×60×1byte×5Hz의 분류 결과 데이터를 가정하고, 프로세서 보드에서 제공하는 소요시간 측정 함수를 사용하여 데이터 송수신 소요시간을 측정하였다. 분류 결과의 갱신 주기는 5Hz, 즉 5Frame/sec 처리를 가정하였으며, 이는 분류 알고리즘의 처리시간이 단축되면 증가가 가능하다. 1 프레임의 영상데이터(640×480×4byte)에 대한 CPU 간 입력영상 데이터 송수신 흐름과 소요시간 측정결과를 각각 Fig. 5와 Table 3에 나타내었다.

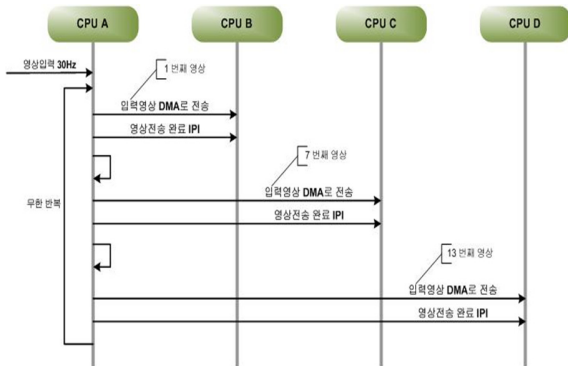


Fig. 5. CPU 간 입력영상 데이터 송수신 흐름도

Table 3. CPU 간 데이터 송수신 속도측정

송신 CPU	수신 CPU	측정시간
CPU A	CPU B	6.693msec
CPU A	CPU C	7.486msec
CPU A	CPU D	6.704msec

CPU 간의 데이터 송수신 속도 측정 결과를 바탕으로 프로세서보드의 각 CPU에서 분류 알고리즘 처리를 위해 확보할 수 있는 시간을 계산하였고, 그 결과를 Fig. 6에 나타내었다. CCD 영상센서에서 입력되는 영상은 30Hz이며, 분류 알고리즘의 결과 영상은 5Hz로 출력되므로 CPU A에서는 5Hz로 입력영상 프레임을 캡처하여 CPU B, C, D로 순차적으로 전송한다. 영상데이터의 CPU 간 전송시간을 최대 10msec로 하였을 때, CPU B, C, D에서 확보할 수 있는 분류 알고리즘 처리시간은 최대 560msec임을 확인할 수 있다. 고속통신보드를 사용한 보드 간의 영상데이터(640×480×4byte) 송수신 소요시간의 10회 측정결과 평균값은 7.527msec로 대용량 데이터의 보드 간 송수신이 매우

빠르게 실행되며, 이를 통하여 향후 분류결과와의 융합 등 알고리즘의 확장을 고려할 수 있다.

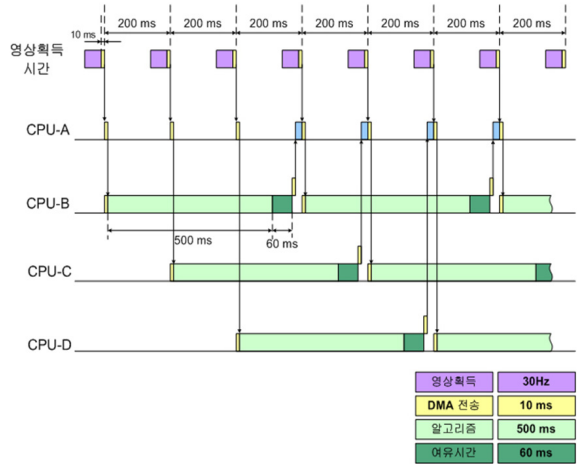


Fig. 6. 프로세서보드 데이터 처리 흐름도

### 5. 실험 및 결과

본 논문에서 제안한 지형 분류 알고리즘과 하드웨어에 대한 성능 검증은 위하여 SONY사의 XC-555 컬러 CCD 카메라를 상용차량에 장착하여 야지 지형을 주행하면서 환경 조건별로 영상을 획득하였다. 획득된 영상은 환경센서 정보를 이용하여 Table 1의 코드 구분에 따라 10종의 환경상태로 구분하였으며, 각각의 환경 조건에 대해 임의의 영상 프레임을 100 장씩 추출하였다. 추출된 영상으로부터 각 클래스별로 200개씩의 학습용 칩 영상을 추출하였으며, 적용 특징과 분류기 조합에 따른 학습 파라미터를 계산하였다. 적용 분류기 및 특징은 Table 4와 같다. Table 4에서 WM(Wavelet mean), WE(Wavelet energy) 및 XY는 각각 웨이블릿 평균, 에너지 및 공간좌표 특징을 의미하며, CM(Color mean)은 국부블록의 색상 평균을 의미한다.

Table 4. 적용 분류기 및 특징벡터

분류기	특징 벡터	분류기 구성
MLP	WM, WE, XY	2-hidden layer, Biased MLP
SVM	WM, WE, XY	RBF Kernel SVM
GMM-ML	CM-GMM, XY	Maximum Likelihood

오프라인에서의 학습과정을 통하여 환경 조건에 대한 분류기별 학습 파라미터를 구축하였으며, 학습 조건과 동일한 환경 조건에서의 적용 특징 및 분류기에 따른 분류 성능 비교를 위하여 각각의 환경 조건별 샘플 영상으로부터 10장씩의 테스트 영상을 선택하였다. 모든 테스트 영상에 대해 분류 정확도의 정량적인 비교를 위한 Ground truth 영상을 수작업으로 작성하였다. Table 5는 각 환경조건에 대한 적용 분류기별 10장의 시험영상에 대한 분류 정확도와 각 분류기별 전체적인 분류성능을 나타낸다. Table 5에서 전체적인 분류성능은 웨이블릿 특징과 공간특징을 이용한 MLP 분류기를 적용한 경우에 가장 높게 나타났으며, GMM-ML 분류기를 적용한 경우 색상 특징만을 적용하였으므로 계절에 따라서 분류성능의 편차가 심함을 알 수 있다. 적용 특징과 분류기 조합에 따른 CPU 별 평균 수행시간을 알아보기 위해 여름철 오후, 즉 4ML의 환경조건에서 획득된 5장의 시험영상에 대한 알고리즘 별 수행시간을 측정하였다. 프로세서보드의 CPU별 알고리즘 수행시간은 GMM-ML 분류기를 적용한 경우에 114msec로 가장 빠르며, SVM 분류기의 처리시간이 254msec로 가장 많이 소요됨을 알 수 있다. 따라서 Fig. 6과 같은 프로세서보드의 데이터 처리 구조에서 CPU A에서의 입력영상 프레임 획득 주기를 GMM-ML의 경우 15Hz, MLP의 경우 10Hz 까지 증가시킬 수 있으므로 분류결과의 출력 주기도 동일하게 증가될 수 있다.

또한 학습 파라미터가 없는 환경 조건에서의 시험영상이 입력될 경우 Table 2의 환경 정보별 우선순위에 따른 대체 파라미터를 선택함으로써 임의의 환경 조건에서도 최적의 분류성능을 나타내는지 확인하기 위하여 '08.10.28 오후'에 획득된 입력 영상 10장에 대한 실험을 수행하였다. 알고리즘은 학습 파라미터 DB에서 영상 획득 당시의 환경 조건에 해당하는 7HL의 파라미터를 적용해야 하지만, 해당 파라미터가 없는 경우, 우선순위에 따라 6ML에 해당하는 학습 파라미터를 적용하게 된다. 대체 파라미터가 적용된 실험 결과는 Fig. 7과 같으며, 비교를 위해 획득 당시의 환경조건인 7HL의 파라미터를 적용한 결과를 함께 나타내었다. Fig. 7에서 알 수 있듯이 학습 파라미터가 없는 환경 조건의 영상에 대해서도 환경 정보별 우선순위에 따른 대체 파라미터를 적용함으로써 급격한 분류 결과의 감소 없이 최적의 분류 성능을 나타냄을 확인하였다.

Table 5. 분류기별 지형분류 정확도(%)

획득일시	환경 조건	MLP	SVM	GMM-ML
08.10.27 오후	7LL	79.1	75.8	59.5
08.10.28 오전	6ML	76.0	76.4	73.2
08.10.28 오후	7HL	78.5	76.0	78.0
08.12.17 오전	9ML	73.1	72.9	80.7
08.12.17 오후	AML	76.9	76.9	76.1
09.01.20 오후	ALL	75.7	70.5	77.5
09.03.18 오후	1LL	76.2	75.5	72.0
09.03.19 오전	0LH	80.4	71.8	78.8
09.05.20 오후	1LL	85.3	79.6	76.9
09.07.22 오후	4ML	89.7	90.4	84.0
평균 분류 정확도(%)		79.1	76.6	75.7
CPU별 평균 수행시간(ms)		199	254	114

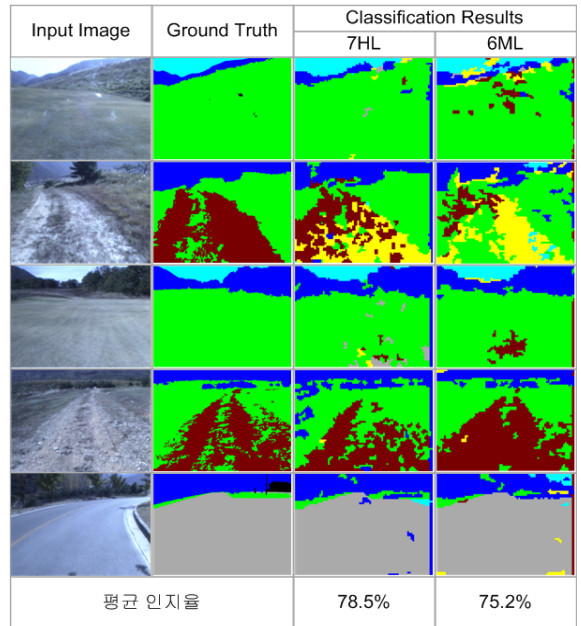


Fig. 7. 대체 파라미터 선택에 의한 분류 결과

## 6. 결론

본 논문에서는 무인차량의 자율주행에 적용을 위하



여 CCD 영상에 대한 야지 지형분류 기법을 제안하였다. 색상 정보를 이용한 야외 영상의 지형분류 단점을 극복하기 위해 웨이블릿 특징과 공간좌표 특징을 적용하고, 환경 센서를 활용한 환경 조건별 학습 파라미터 DB를 구축하여 해당 환경 조건에 대해 최적의 학습 파라미터를 선택하여 환경변화에 강인한 지형분류기를 제안하였다. 또한 알고리즘의 실시간 구현을 위한 분산형 병렬처리가 가능한 하드웨어 구조를 설계하였다. 제안한 알고리즘의 성능 확인을 위하여 색상 특징 기반의 GMM-ML 분류기와 웨이블릿 특징 기반의 SVM 분류기를 동일한 하드웨어에 구현하였으며, 실 야지 영상을 이용한 실험을 통하여 적용 특징과 분류기 조합에 따른 지형분류 결과 및 알고리즘 수행 속도를 비교하였다. 학습 환경과 동일한 환경에서의 실험에서 제안한 알고리즘에 의한 지형분류 결과가 가장 양호하였으며, 제시된 하드웨어에서의 알고리즘 수행시간 측정결과 출력의 갱신 주기는 10Hz까지 가능함을 확인하였다. 또한 학습 파라미터가 없는 환경조건의 입력 영상에 대한 실험을 통하여 우선순위에 따른 대체 파라미터를 선택함으로써 분류기 성능 감소를 최소화할 수 있음을 확인하였다. 향후 실제 무인차량의 기동제어 시스템에 적용을 위해서 다양한 야외 환경조건에 대한 추가적인 학습 파라미터의 확보와 고성능의 하드웨어 및 고속의 영상처리용 라이브러리 등을 적용하여 분류 알고리즘의 성능 개선과 함께 안정성과 신뢰성 향상을 위한 연구가 필요할 것으로 판단된다.

## Reference

- [1] R. Manduchi, A. Castano, A. Talukder, 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, A. Rankin, "Terrain Perception for Demo III", *Intelligent Vehicles Conference*, 2000.
- [3] Paul Jansen, Wannes van der Mark, Johan C. van den Heuvel, Frans 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, September 13~16, 2005.
- [4] Rebecca Castano, Roberto Manduchi, Justin Fox, "Classification Experiments on Real-World Texture", *Workshop on Empirical Evaluation in Computer Vision*, Kauai, HI, Dec. 2001.
- [5] G. Y. Sung, D. M. Kwak, D. J. Kim, J. Lyou, "Terrain Cover Classification Based on Wavelet Features and Neural Network", *International Conference on Control, Automation and Systems*, 2008.
- [6] Ingrid Daubechies, *Ten Lectures on Wavelets*, Society for Industrial and Applied Mathematics, 1992.
- [7] M. Misiti, Y. Misiti, G. Oppenheim, J. M. Poggi, "Wavelet Toolbox User's Guide", MathWork Inc.
- [8] 양동원 외, "GMM 기반의 지형분류기법 연구", 제4회 국방정보 및 제어기술 학술대회, 2008
- [9] 성기열 외, "Support Vector Machine 기반 지형분류 기법", *대한전자공학회 논문지*, 제45권 SC편 제6호, pp. 55~59, 2008.
- [10] V. Vapnik, *Statistical Learning Theory*, John Wiley & Sons, New York, 1998
- [11] C. W. Hsu and C. J. Lin., "A Comparison of Methods for Multi-class Support Vector Machines", *IEEE Trans. on Neural Networks*, Vol. 13, pp. 415~425, 2002.
- [12] C.-C. Chang and C.-J. Lin, *LIBSVM : a Library for Support Vector Machines*, Software Available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>, 2001.
- [13] S. Y. Lee, D. M. Kwak, G. Y. Sung, D. J. Kim, "Modified Component-Labeling Algorithms Applied to Grayscale Images", *International Conference on Control, Automation and Systems*, 2008.