

## 랜덤 포레스트와 칼라 코렐로그램을 이용한 도로추출

# Road Extraction Based on Random Forest and Color Correlogram

최지혜, 송광열, 이준웅\*  
(Ji-Hye Choi<sup>1</sup>, Gwang-Yul Song<sup>1</sup>, and Joon-Woong Lee<sup>1</sup>)

<sup>1</sup>Chonnam National University

**Abstract:** This paper presents a system of road extraction for traffic images from a single camera. The road in the images is subject to large changes in appearance because of environmental effects. The proposed system is based on the integration of color correlograms and random forest. The color correlogram depicts the color properties of an image properly. Using the random forest, road extraction is formulated as a learning paradigm. The combined effects of color correlograms and random forest create a robust system capable of extracting the road in very changeable situations.

**Keywords:** road extraction, color correlogram, random forest, mono vision

### I. 서론

본 논문은 교통영상으로부터 차량이 주행할 수 있는 도로를 추출하기 위한 단안비전시스템을 제안한다. 포장로이건 비포장로이건 도로영상의 외양에 큰 변화를 야기시키는 노면의 색과 재질의 다양성으로 인해 도로를 단안영상으로부터 강인하게 추출하는 것은 어려운 문제이다. 포장로의 재질인 아스팔트나 시멘트는 동일한 광원하에서도 다른 칼라 특성을 보인다. 대부분의 포장로는 차로의 경계를 나타내는 백선표식으로 구획화되어 있지만, 이러한 표식이 없는 경우도 많다. 비포장로 역시 노면의 재질이나 색이 다양하다. 더구나 도로는 포장로/비포장로 상관없이 날씨, 조명, 그림자, 주변물체, 바퀴자국 등과 같은 요인들에 의해서도 영향을 받는다.

컴퓨터비전에 의한 도로추출은 스테레오 비전을 이용한 연구가 대부분이다[1-3]. 스테레오비전은 대개 정합(matching) 과정에서 얻은 시차(disparity)나 거리 데이터를 이용하여 차량이 주행할 수 있는 길(path)을 추출한다. 그러나 이러한 시스템은 3차원 데이터 산출이라는 장점이 있지만, 비용이 많이 들고, 시간소요가 크며, 특히 질감(texture)이 없는 영역에서 오류를 낳는 시차계산에 의존하는 점이 단점이다. 도로는 질감이 적은 영역의 전형적인 예이므로 시차를 기반으로 하는 스테레오 비전은 자주 오류를 낳는다.

단안비전에 의한 도로추출 연구는 알려진 바가 거의 없다. 도로영상에 관한 대부분의 단안비전연구에는 차선 정보추출 시스템[4,5]이나 차량검출 시스템[6]이 많지만, 이런 시스템들은 차량이 주행할 수 있는 도로추출과는 직접적인 관련성이 없다. 차선관련 시스템들은 차선표식과 같은 특별한 특징의 존재에 의존한다. 그러나 도로상태는 시간이 지남에 따라 그러한 표식이 퇴화되고, 정체구간에서는 표식이 가려져 보이지 않기도 하므로 차선정보조차 검출이 어려워진다. 더욱이

이런 시스템들은 차로가 구획화되어 있지 않은 도로에서는 적용할 수도 없다. 차선검출과 차량검출이 동시에 수행된다고 가정해 도로검출에는 한계가 있다. 그 이유는 도로상의 장애물이 차량만 있는 것도 아니고, 차량조차도 형태나 자세, 크기가 다양하므로 단안비전에 의해 차량검출도 완벽하게 이루어지지 않고 있다[6].

DARPA 그랜드 챌린지의 운전자 없는 자율차량경쟁에서 사막의 흙 길을 식별하는 비전시스템들이 도입되었는데, 그들 대부분은 차량들이 남긴 바퀴자국과 같은 패턴을 활용하였다[9-12]. 이러한 인위적인 패턴들이 길 위에 존재하지 않으면 이 시스템들은 길 식별에 실패했다. 더구나 이 시스템들은 포장로에는 적용할 수도 없다.

이러한 상황에서 본 논문에서는 스테레오비전보다 상대적으로 비용이 적은 단안비전을 채용하여 차량이 주행할 수 있는 도로를 식별하는 시스템을 제안한다. 제안된 시스템의 첫 단초는 칼라 코렐로그램(color correlogram)이다. 그 이유는 칼라 코렐로그램은 색의 분포뿐만 아니라 색의 국부적인 공간정보까지 포함하는 특징으로 알려져 있기 때문이다[13,14]. 칼라 히스토그램도 널리 사용되지만, 색의 공간관계는 표현하지 못한다. 그러나 도로를 추출하는 데에 칼라 코렐로그램의 적용은 도로와 비도로 사이에 색의 차이가 존재한다는 가정을 전제로 한다.

본 논문의 두 번째 단초는 학습패러다임이다. 실행속도와 신뢰도 향상을 피하기 위해 도로 추출문제를 칼라 코렐로그램으로 표현된 영상을 통해 학습 형식으로 모형화한다. 이 접근법은 도로 추출에 필요한 많은 계산부하를 학습단계로 넘긴다. 따라서 실행시(runtime) 도로추출 속도와 신뢰도 향상을 피할 수 있다. 논문에서 학습전략은 많은 이진 트리(tree)로 이루어진 앙상블(ensemble) 분류기로 알려진 랜덤포레스트(random forest, RF) [15,16]를 토대로 확립된다. RF는 다클래스(multi-class) 분류문제를 다룰 수 있고, 학습이 빠르고 쉬우며, 분류율이 높다. A. Bosch 등[17]은 영상분류문제에 있어서 RF는 SVM이나 뉴럴네트워크에 비해 학습이나 실행시간이 매우 짧고 정확도는 거의 같다고 밝히고 있다. 궁극적으로 논문에

\* 책임저자(Corresponding Author)

논문접수: 2011. 1. 25., 수정: 2011. 2. 27., 채택확정: 2011. 3. 14.

최지혜, 송광열, 이준웅: 전남대학교 산업공학과(시스템자동화연구소)

(say7779@hanmail.net/skyclas@nate.com/joonlee@chonnam.ac.kr)

※ 이 논문은 2010년도 전남대학교 학술연구비 지원에 의하여 연구되었음.

서 제안된 시스템은 칼라 코렐로그램과 통합된 RF기반의 학습방법에 의해 단안비전에 의한 도로추출을 실현한다.

논문의 구성은 다음과 같다. II 장은 제안된 시스템의 개요를 논하고, III 장은 칼라 코렐로그램에 의한 영상의 표현을 소개한다. IV 장은 도로추출방법을 설명하며 V 장에서 실험결과 그리고 VI 장에서 결론을 맺는다.

**II. 제안된 시스템의 개요**

제안된 시스템은 일반적인 학습패러다임처럼 학습과 실행이라는 두 절차로 된 체계로 모형화된다. 학습절차는 그림 1에 보인 것처럼 세 단계로 이루어진다. 1) 많은 도로, 비도로 영상으로 학습집합 준비, 2) 집합내의 각 영상의 칼라 코렐로그램 형성, 3) 구축된 칼라 코렐로그램을 입력으로 하여 RF기반의 도로, 비도로 분류기 구축이 그것이다. 도로 추출 실행단계에서는 영상이 입력되면 이 영상을 동일한 크기의 작은 패치들로 나누고, 각 패치를 칼라 코렐로그램으로 표현하여 학습단계에서 구축한 분류기에 넣어 이 패치가 도로 패치인지 비도로 패치인지 분류한다.

**III. 영상 표현**

$n$ -차원의 벡터인 칼라 코렐로그램은 칼라영상의 특징을 묘사하는 기법이다. 이러한 칼라 코렐로그램을 도로추출에 사용하려면 다음 두 절차가 필요하다. 1)칼라공간  $C$ 의 양자화로  $C$ 를  $m$ 개의 레벨  $c_1, c_2, \dots, c_m$ 로 분할한다. 2)분할된 칼라레벨을 빈(bin)으로 하여 칼라 코렐로그램을 구축한다.

**1. 칼라공간 선택과 양자화**

많은 칼라공간들이 칼라영상 묘사에 사용되어 왔다. RGB 칼라공간도 그 중에 하나인데, RGB 공간은 사람이 색을 감지하는 동일한 방법으로 모델링 되지도 않고 색이 밝기와 연결되어 있어서 조명변화에 민감하다[14]. 논문에서는 조명의 영향을 줄이며 색감(color tone)의 효과를 높이기 위해 HSV (hue, saturation, value) 공간을 택하여 이 가운데 색조 H와 채도 S를 사용한다.

칼라 양자화는 그림 2에 보인 것처럼 H와 S를 각각 8영역으로 나누어 총 64개의 칼라 요소를 형성한다. H와 S의 범위는 각각  $0^\circ \sim 360^\circ$ 와  $[0, 1]$ 이다. 이에 따라 영상  $I$ 의 칼라는 64레벨  $c_1, c_2, \dots, c_{64}$ 로 양자화된다.




그림 2. H와 S의 64레벨 양자화.

Fig. 2. Quantization of hue and saturation into 64 colors.

**2. 칼라 코렐로그램 구축**

영상  $I$ 의 칼라 코렐로그램은 Huang [13]의 정의를 토대로 구축한다.  $p = (x, y) \in I$  인 픽셀의 칼라  $C(p)$ 가  $c$ 인 집합을  $I_c = \{p | C(p) = c\}$ 로 놓는다.  $I$ 의 임의의 두 픽셀  $p_1 = (x_1, y_1)$  과  $p_2 = (x_2, y_2)$  의 거리를  $|p_1 - p_2| = \max\{|x_1 - x_2|, |y_1 - y_2|\}$ 로 정의한다. 그리고  $1 \sim n$ 까지의 정수의 집합을  $[n] = \{1, 2, \dots, n\}$ 라 하자. 이 때 한 쌍의 칼라  $c_i$ 와  $c_j$ ,  $i, j \in [m]$ 에 대한 칼라 코렐로그램은 다음과 같이 확률로 정의된다.

$$\gamma_{c_i, c_j}^k = P[p_2 \in I_{c_j} \mid |p_1 - p_2| = k, p_1 \in I_{c_i}] \quad (1)$$

여기에서  $k$ 는 거리이다. 칼라 코렐로그램의 확률 정의는 크기 불변(size invariant)성을 가지므로 크기가 변하는 영상에 영향을 받지 않는다. 영상  $I$ 의 칼라 코렐로그램은 특정  $k$ 에 대한  $I$ 내의 칼라 쌍들에 의해 색인이 된  $m \times m$ 행렬이 된다.

본 논문에서 칼라를 64레벨로 정하였으므로 식 (1)의  $m$ 은 64이다. 따라서 칼라 코렐로그램은  $64 \times 64$ 행렬이 되며 4096개의 요소를 가진 1차원의 특징벡터로 취급된다.  $\gamma_{c_i, c_j}^k$ 는 어떤 영상내에서 칼라가  $c_i$ 인 픽셀이 주어졌을 때 그 픽셀로부터  $k$ 만큼 떨어진 거리에 있는 어떤 픽셀의 칼라가  $c_j$ 인 확률이 된다. 파라미터  $k$ 는 코렐로그램이 사용되는 응용예에 따라 적절히 선택된다.

칼라 코렐로그램은 영상의 칼라 특성을 상세히 묘사하므로 칼라 코렐로그램에 포함된 정보는 다음 장에서 소개될 도로, 비도로 분류기 구축과정에서 활용된다.

**IV. 도로 추출**

제안할 도로추출 시스템은 준비된 학습영상들로부터 구축된 칼라 코렐로그램들과 실행시 획득한 입력영상들로부터 구축된 칼라 코렐로그램들을 짝짓는 문제로 보고, 이 문제를 RF를 사용한 학습기반의 분류문제로 공식화한다.

**1. 학습 데이터**

학습기반의 분류에서 학습 집합은 분류될 클래스들의 대표적인 샘플들을 포함한다. 이런 맥락에서 도로와 비도로의 학습 집합은 그림 3에 보인 바와 같이 다양한 칼라 영상으로부터 샘플 영상을 취하여 구성한다. 취하는 샘플영상의 크기는 모두 같고, 샘플이 도로 또는 비도로인지는 학습전에 미리 정해준다. 그림 3에서 사각형들은 샘플을 취할 영역으로 흰 사각형은 도로의 샘플이고, 검은 사각형은 비도로의 샘플

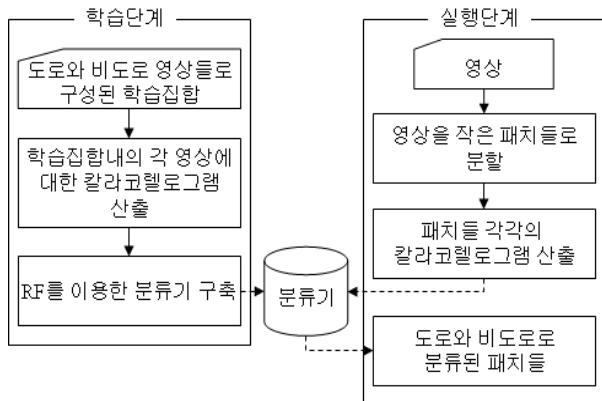


그림 1. 제안된 시스템의 구성도.  
Fig. 1. Configuration of the proposed system.




그림 3. 학습집합 준비.  
Fig. 3. Preparation of training set.

이다. 학습집합내의 각 샘플 영상을 묘사할 칼라 코렐로그래를 식 (1)에 의해 구축하여 1차원 벡터로 저장한다.

2. RF

RF는 일련의 이진 트리(binary tree)들로 구성된 분류기이다. RF내의 각각의 트리는 학습하는 동안에 동일한 입력을 받아 확률분포를 가진 동일한 형태의 추정값을 출력한다. RF의 최종 의사결정은 RF내의 트리들의 추정치에 의존한다. 따라서 트리들의 수와 트리 형성 방법은 RF 분류기의 정확성을 좌우한다.

그림 4에 보인 트리  $T_i$ 의 각 노드(node)는 뿌리(root) 노드에서 잎(leaf) 노드에 다다를 때까지 좌우로 분기되고 분기된 노드에 연결된다. 즉, 트리의 내부 노드는 그림 5에 보인 것처럼 간단한 테스트를 통해 분류되어야 할 데이터 공간  $S$ 를 부공간  $S_1$ 과  $S_2$ 로 분할한다. 하위 노드에서  $S_1$ 이나  $S_2$ 는  $S$ 가 되고 이  $S$ 가 다시  $S_1$ 과  $S_2$ 로 분할된다. 논문에서 특징 공간은 학습집합내의 샘플영상들의 칼라 코렐로그래들로 구성되는데, 이 특징공간이 데이터 공간  $S$ 이다. 잎 노드들에는 분류할 클래스들의 학습데이터로 계산된 사후확률분포가 붙는다. 내부 노드에서의 테스트와 잎 노드의 사후확률분포는 분류기를 구축하는 학습단계의 트리성장 과정에서 결정된다. 그리

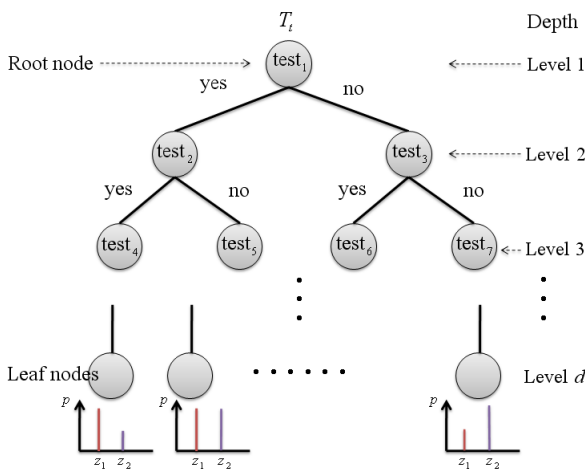


그림 4. 트리의 구조와 트리에 저장된 정보.  
Fig. 4. Structure of a tree and its stored information.

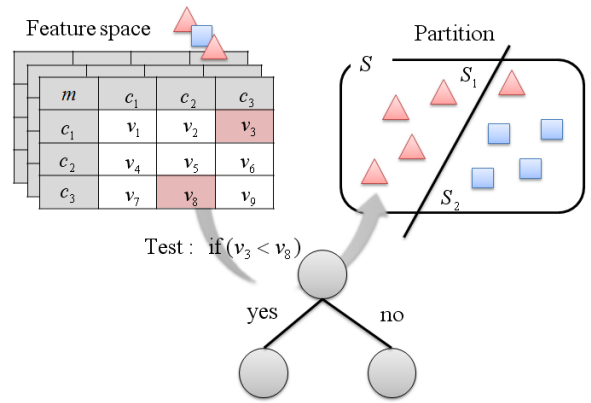


그림 5. 트리의 내부 노드내에서 테스트에 의한 데이터 집합  $S$ 의 분할.  
Fig. 5. Partition of the data set  $S$  by a test within an internal node.

고 이들은 나중에 분류기 실행시(runtime)에 새로운 입력벡터를 분류할 때 사용된다.

RF내의 많은 트리들은 각각의 트리가 데이터 공간  $S$ 에 대해 다른 분할(partition)을 낳도록 성장한다. RF내에  $M$ 개의 트리  $T_1, \dots, T_M$ 이 있다고 하자. 이들  $M$ 개의 트리들의 반응값들은 단일 트리에서 얻은 것보다 더 좋은 분류율이 얻어지도록 결합된다. 즉, 분류기 실행시에 새로운 특징벡터가 모든 트리들에 입력되어 각 노드에 저장되어 있는 테스트에 의해 하위의 좌 또는 우 노드로 보내진다. 최종적으로 이 특징 벡터가 도착된 잎 노드들에 붙어 있는 확률분포들의 합을 구하고, 이 합의 최빈값(mode)에 해당된 클래스가 이 특징 벡터가 속할 클래스가 된다. 이를 수학적으로 정리하면 다음과 같다. 클래스들의 집합  $Z = \{z_i\}, i = 1, \dots, K$  일 때, 데이터 공간  $S$ 에 속한 어떤 특징벡터  $\mathbf{v}$ 의 실제 클래스를  $Y(\mathbf{v})$ 라고 하자. 잎 노드들은  $P_{(t, \mathbf{v})}(Y(\mathbf{v}) = z)$  인 사후확률들을 가지고 있다. 여기에서  $I(t, \mathbf{v})$ 는 특징 벡터  $\mathbf{v}$ 가 도달한 트리  $T_i$ 의 잎 노드이며, 사후확률  $P$ 는 학습집합에 속해 있는 특징벡터들 가운데 잎 노드  $l$ 에 떨어진 모든 특징 벡터들의 수량에서 클래스가  $z$ 인 특징벡터들이 차지하는 비율로 정해진 것이다. 특징벡터  $\mathbf{v}$ 의 클래스의 결정은 다음과 같다.

$$\hat{Y}(\mathbf{v}) = \arg \max_i \sum_{i=1}^M P_{(t, \mathbf{v})}(Y(\mathbf{v}) = z_i) \quad (2)$$

여기에서  $M$ 은 트리들의 수량이다. 본 논문에서 다루는 문제는 클래스의 수는 도로와 비도로 이렇게 둘이므로 집합  $Z$ 의  $K$ 는 2이다.

그림 6은 이와 같은 분류과정의 예를 보인 것이다. 이 예에서 우리는 식 (2)에 의해 최대 확률을 갖는 클래스  $z_2$ 를 벡터  $\mathbf{v}$ 의 클래스로 선정한다.

3. 트리의 성장

RF의 트리들의 수를  $M$ , 각 내부 노드들에서 테스트 선정을 위한 질문 회수를  $r$ , 그리고 트리의 깊이를  $d$ 라 놓자. 하나의 트리는 엔트로피 주도의 재귀적인 분할에 의해 성장한다. 트리 성장과정의 가장 큰 부분은 내부 노드들의 테스트 선정이 차지한다. 주어진 학습집합의 최적의 분리를 목적으로 테스트 조건들이 랜덤하게 선정되는 과정을 거친다. 분리

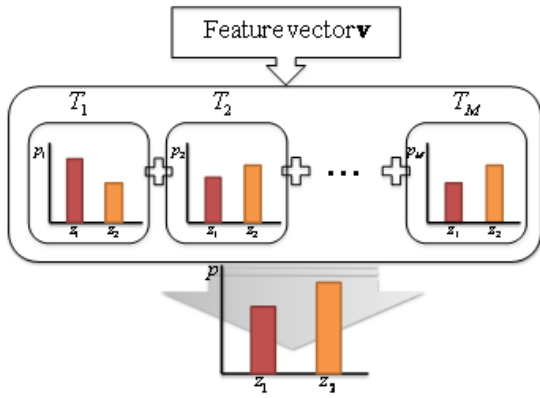


그림 6. 분류기 실행시 특징벡터의 분류.

Fig. 6. Classification of a feature vector at runtime.

효율은 정보내의 기대이득(expected gain)으로 평가된다. 어떤 노드에서 주어진 테스트에 따라 집합  $S$ 를 여러 부분집합들  $S_j$ 로 분할함으로써 생기는 이득은 다음과 같이 계산된다.

$$\Delta E = -\sum_i \frac{|S_i|}{|S|} E(S_i) \quad (3)$$

여기에서  $|S|$ 는 집합의 크기를 나타내고  $E(S_i)$ 는 샤논의 엔트로피(Shannon entropy)  $-\sum_{j=1}^K p_j \log_2(p_j)$ 이다. 이 때  $j$ 는 클래스의 번호이고  $K$ 는 클래스의 수량이며  $p_j$ 는  $S_i$ 안에서 클래스  $j$ 에 속한 샘플들의 비율이다. 일반적으로 각 부분집합은 다른 클래스에 속한 샘플들을 가지고 있다. 만약에  $S_i$ 의 모든 샘플들이 동일 클래스에 속하면  $E(S_i)$ 는 0가 되어  $\Delta E$ 는 최대가 되지만, 반면에 모든 클래스가 동일 비율로 되어 있다면 엔트로피는 가장 크며  $\Delta E$ 는 최소가 된다. 따라서 테스트 선정을 위한 질문들의 집합  $Q = \{q_1, \dots, q_r\}$ 에서  $\Delta E$ 를 최대로 하는 질문을 선정하여 저장한다. 테스트를 선정하는 과정이 앞 노드가 아닌 각 노드에서 그 노드에 떨어진 학습 샘플들만 가지고 수행된다. 뿌리 노드에서 시작된 트리 성장의 재귀적 과정이 현 노드가 너무 작은 샘플을 받거나 주어진 깊이  $d$ 에 도달하면 멈춘다. 여기에서 트리 성장을 멈추게 하는 샘플 수는 10으로 정했다.

본 논문에서 노드들에서 수행되는 테스트들은 노드에 도달된 특징벡터의 요소들 가운데 임의로 두 개의 요소  $v_i$ 와  $v_j$ 를 취해 다음과 같이 그 둘의 차이를 비교하는 간단한 것들이다.

$$E(v_i, v_j) = \begin{cases} \text{if } v_i < v_j & \text{go to the left child node} \\ \text{otherwise} & \text{go to the right child node} \end{cases} \quad (4)$$

이 테스트로 어떤 내부 노드에 도달된 특징벡터들의 집합  $S$ 가 그림 5에 보인 것처럼  $S_1$ 과  $S_2$ 로 분할된다. 그리고 식 (3)에 의해 이 두 부분집합으로 이득이 계산된다. 그 노드에서  $S$ 의 분할과 이득 계산은 질문집합  $Q = \{(i, j), \dots, (i, j)\}$ 에 따라  $r$ 번 수행된다. 질문집합내의  $i$ 와  $j$ 는 벡터  $v$ 의 요소들의 색인, 즉 칼라 코렐로그램의 빈(bin)번호이다. 트리 성장과정 동안 각 노드의  $Q$ 는 다르고 식 (2)의 이득을 최대로 하는 조합  $i$ 와  $j$ 가 승자로 뽑혀 저장이 된다.

V. 실험결과


제한된 시스템은 차량의 실내에 설치된 카메라에 의해 획득된 320x240 크기의 다양한 칼라영상에 대해 평가가 이루어졌다.

1. 칼라 양자화


이 절은 칼라 코렐로그램 구축에 사용된 칼라 레벨의 결정에 대해 평가한 것이다. 그림 7은 그림 7(a)에 보인 흙길에서 취득된 영상에 대해 적용된 결과다. 색조와 채도를 각




(a) Road image



(b) Color correlogram of 16 colors



(c) Color correlogram of 64 colors




(d) Color correlogram of 144 colors

그림 7. 도로영상에 대한 칼라 양자화 효과.

Fig. 7. Color quantization effect for a road image.





(a) Original image (b) Classification of road and non-road

그림 8. 포장로와 비포장로 영상으로 구성된 학습집합.

Fig. 8. Training set by paved and unpaved road images.

각 4, 8, 12등분으로 나누고 이들 각 분할 수준에 대해 칼라 코렐로그램을 구축하는 실험을 실시했다. 16레벨로 양자화된 칼라로 형성된 칼라 코렐로그램은 그림 7(b)에 보인 것처럼 칼라 쌍에 대한 정보 재현이 약했고, 칼라 축소효과 또한 컸다. 64레벨로 양자화된 칼라로 형성된 칼라 코렐로그램은 그림 7(c)에 보인 것처럼 칼라 쌍에 대한 정보를 적절히 재현했다. 마지막으로 144레벨로 양자화된 칼라로 형성된 칼라 코렐로그램은 그림 7(d)에 보인 것처럼 육안으로 식별이 안 될 만큼 자세한 정보를 보였고, 큰 메모리도 요했다. 이러한 결과를 바탕으로 칼라 양자화에서는 64레벨을 선택한 것이다.

2. 학습집합의 준비

학습집합은 분류기를 구축하는 트리성장 과정에서 사용된다. 논문에서는 그림 8과 같이 영상의 소실점 아래 부분을 10×10 픽셀의 크기로 균등 분할한 후 분할된 패치 각각을 사람이 도로와 비도로로 분류하여 학습집합을 준비하였다. 영상에서 흰색 사각형은 도로로 설정된 패치이고 검은 사각형은 비도로로 설정된 패치이다. 학습집합에 도로와 비도로의 다양한 샘플이 들어갈 수 있도록 그림 8과 같이 비포장로, 간이터널 안쪽, 포장로 영상 등 다양한 영상을 이용하였다. 이 때 사용된 영상은 약 50프레임이며, 이 가운데 40프레임 정도가 비포장로 영상이었다. 그 이유는 비포장로의 노면이 더 다양했고, 촬영된 영상도 비포장로가 많았기 때문이다.

3. RF의 파라미터 결정

트리의 수  $M$ ; 각 노드에서 테스트 선정을 위한 질문 횟수  $r$ ; 트리의 깊이  $d$ 를 최적인 것들로 선정하기 위해 학습집합을 가지고 많은 실험을 수행하였다.

$r$ 과  $d$ 는 고려하는  $r$ 과  $d$ 에 맞추어 트리 1개를 생성하고 학습집합에 속한 샘플들의 분류 정확도를 평가하여 결정한다. 표 1은  $r$ 과  $d$ 에 따른 분류결과를 표시한 것이다. 표 1을 통해 알 수 있듯이  $d$ 가 커지고  $r$ 이 커지면 분류의 정확도가 높아진다. 그러나 일정한 깊이 이상이 되고 질문횟수가 일정 횟수 이상이 되면 정확도가 더 이상 높아지지 않고 수렴하였다.

표 1의 결과에 따라 질문횟수  $r$ 은 1600회로 설정하였고,

표 1.  $r$ 과  $d$ 에 따른 분류 정확도.

Table 1. Classification accuracy according to  $r$  and  $d$ .

$d$	$r$				
	100	400	900	1600	2500
3	0.7769	0.8088	0.7753	0.8398	0.8484
4	0.8009	0.8620	0.8857	0.8613	0.8554
5	0.8611	0.8599	0.8633	0.9022	0.9065
6	0.8219	0.8941	0.8765	0.9104	0.9118
7	0.8656	0.8826	0.9065	0.9129	0.8961

표 2. 트리의 수에 따른 분류 정확도.

Table 2. Classification accuracy according to the number of trees.

$M$					
1	2	3	4	5	6
0.9104	0.9244	0.9364	0.9324	0.9587	0.9511

트리의 깊이  $d$ 는 과적합(overfitting)을 막고 학습의 속도를 높이기 위해서 수렴이 시작되는 값인 6으로 설정하였다.

트리의 수  $M$ 은 앞에서 선택한  $r$ 과  $d$ 값을 이용하여 트리를 여러 개 생성하여 RF를 구축하고 정확도를 구한 후 결정한다. 실험결과는 표 2와 같다. 표 2에 보인 바와 같이  $M$ 이 증가할수록 정확도가 높아지다가 5개부터 일정한 값으로 수렴하였다. 따라서  $M$ 은 5로 설정하였다.

4. 분류기의 평가

학습집합 준비 때와 마찬가지로 영상의 소실점 아래 부분을 10×10 픽셀의 크기로 균등 분할한 후, 각 패치를 64레벨의 칼라코렐로그램으로 표현하여 학습단계에서 구축한 분류기에 넣으면 분류기가 도로와 비도로로 분류한다. 그림 9에 보인 실험결과에서 흰색 사각형은 도로로 분류된 것이고 검은 사각형은 비도로로 분류된 것이다. 그림 9(a)는 비포장로에서 행한 실험결과이고 그림 9(b)는 포장로에서 행한 실험결과인데, 그림 9의 우측 열에 보인 것처럼 분류기가 포장로, 비포장로 상관없이 도로를 성공적으로 추출한 것을 알 수 있다. 그림 9(a)의 비포장로에서 밝기나 색이 조금씩 변하여도 도로를 잘 분류하는 것을 볼 수 있다. 특히 네 번째 영상에서 보인 간이 터널 안에서도 도로의 밝기값이 크게 변하는데도 도로가 잘 분류됨을 알 수 있다. 그림 9(b)의 두 번째 영상과 네 번째 영상에 있는 과속방지턱이나 횡단보도 영역도 도로로 성공적으로 분리된 것을 볼 수 있다.

표 3은 일련의 연속된 영상에서 랜덤으로 10프레임의 영상을 대상으로 분류기가 출력한 결과를 사람이 결정한 것과 비교하여 제안된 시스템의 성능을 평가한 결과이다. 표 3에서 False Negative rate은 (도로 패치가 비도로로 분류된 패치수)/(도로 패치수)이고, False Positive rate는 (비도로 패치가 도로로 분류된 패치수)/(비도로 패치수)이며, 정확도(accuracy)는 (정확히 분류된 도로 패치수+정확히 분류된 비도로 패치수)/(도로 패치수+비도로 패치수)이다.

총 100프레임의 영상의 분류결과는 약 93.18%의 정확도를 보였다. 그리고 CPU는 Core 2 Duo E8400이고 RAM은: 2GB인 PC에서 320×240영상을 초당 40장을 처리하였다.

시스템의 오분류는 10×10의 작은 영역의 컬러패턴을 가지고 분류하는 데서 비롯된 것이 많다. 그림 10(a)의 위쪽 사각



(a) Images of off-road and classification result



(b) Images of paved road and classification result


그림 9. 분류기 적용 결과.

Fig. 9. Classification results by classifier.

표 3. 분류 정확도.

Table 3. Classification accuracy.

Frame No.	False Negative Rate	False Positive Rate	Accuracy (%)
1	27/260	0/112	92.7
2	4/311	2/61	98.4
3	12/310	4/62	95.7
4	27/309	10/63	90.1
5	17/308	1/64	95.2
6	36/279	5/105	89.3
7	15/271	4/113	95.1
8	22/190	6/194	92.7
9	47/299	15/73	83.3
10	28/315	5/57	91.1



(a) Original image



(b) Classification result of road and non-road

그림 10. 오분류 분석.

Fig. 10. Analysis of misclassification.

형은 비도로로 패치의 컬러패턴으로 아래쪽 사각형의 도로의 컬러패턴과 유사하여 도로로 오분류된 경우이다. 하지만 그림 10(b)의 분류결과에서 도로와 비도로의 경계가 확실히 구분되었기 때문에 무인차량이 갈 수 있는 길을 결정하는 데 이 오분류가 크게 영향을 주지는 않았다.

### VI. 결론

본 논문은 포장로/비포장로 관계없이 영상으로부터 도로를 추출할 수 있는 단안비전시스템을 제안하였다. 칼라 코렐로그램과 RF를 통합함으로써 도로인식 문제를 학습 패러다임으로 확립하였고, 이를 통해 단안비전으로도 도로를 추출할 수 있음을 보인 것이 논문의 큰 기여라고 할 수 있다. 칼라 코렐로그램은 단순한 칼라특징임에도 도로와 비도로를 적절하게 묘사하였다. 학습기반의 시스템은 계산이 요구되는 많은 부분을 학습단계에 넘김으로써 도로추출을 초당 40프레임 이상 처리하는 실시간 수준으로 행하였다.

제안된 시스템은 비도로를 도로로 판정하는 오류나 도로를 비도로로 판정하는 오류를 낳기도 했다. 특히 비도로의



질감이 약하고 칼라가 도로와 유사한 부분이 오류의 원인이 되었는데 이러한 오류를 극복하기 위해서는 단안비전 시스템과 능동형 센서의 융합처리를 도입할 필요가 있다.

### 참고문헌

- [1] R. Labayrade, D. Aubert, and J. P. Tarel, "Real time obstacle detection in stereovision on non flat road geometry through "v-disparity" representation," *IEEE Intelligent Vehicle Symposium*, pp. 646-651, 2002.
- [2] K. Y. Lee, J. W. Lee, and N. Houshang, "A stereo matching algorithm based on top-view transformation and dynamic programming for road-vehicle detection," *Int. J. of Control, Automation, and Systems*, vol. 7, no. 2, pp. 221-231, 2009.
- [3] H. Badino, R. Mester, T. Vaudrey, and U. Franke, "Stereo-based Free Space Computation in Complex Traffic Scenarios," *IEEE Southwest Symposium on Image Analysis and Interpretation*, pp. 189-192, 2008.
- [4] D. A. Pomerleau and T. Jochem, "Rapidly adapting machine vision for automated vehicle steering," *IEEE Expert Intelligent Systems and Their App.*, pp. 19-27, April 1996.
- [5] J. W. Lee and U. K. Yi, "A lane-departure identification based on LBPE, Hough transform, and linear regression," *CVIU*, vol. 99, pp. 359-383, 2005.
- [6] G. Y. Song and J. W. Lee, "Detection of road vehicles based on a multistage combination of edge features and horizontal symmetry of a monocular image," *Journal of Institute of Control, Robotics and Systems*, vol. 14, no. 7, pp. 679-688, 2008.
- [7] J. Crisman and C. E. Thrope, "SCARF: A color vision system that tracks roads and intersections," *IEEE Trans. Robot Automat.*, vol. 9, pp. 49-53, 1993.
- [8] T. Kalinke, C. Tzomakas, and W. Von Seelen. "A texture-based object detection and an adaptive model-based classification," *Proc. IEEE Int'l Conf. Intelligent Vehicles*, pp. 143-148, 1998.
- [9] Y. Alon, A. Ferencz, and A. Shashua. "Off-road path following using region classification and geometric projection constraints," *CVPR*, pp. 689-696, 2006.
- [10] D. Lieb, A. Lookingbill, and S. Thrun, "Adaptive road following using self-supervised learning and reverse optical flow," *Proc. Of Robotics: Science and Systems*, 2005.
- [11] H. Dahlkamp, A. Kaehler, D. Stavens, S. Thrun, and G. Bradski, "Self-supervised monocular road detection in desert terrain," *Proc. of Robotics: Science and Systems*, 2006.
- [12] C. Rasmussen, "Grouping dominant orientation for ill-structured road following," *CVPR*, pp. 470-477, 2004.
- [13] J. Huang, S. Kumar, M. Mitra, W.-J. Zhu, and R. Zabih, "Image indexing using color correlogram," *Proc. of IEEE Conf. on CVPR*, pp. 193-233, 1997.
- [14] T. Ojala, M. Rautiainen, E. Matinmikko, and M. Aittola, "Semantic image retrieval with HSV correlogram," *Proc. 12th Scandinavian Conf. On Image Analysis*, Bergen, Norway, pp. 620-627, 2001.
- [15] V. Lepetit and P. Fua, "Keypoint recognition using randomized trees," *PAMI*, vol. 28, no. 9, pp. 1465-1479, 2006.
- [16] Y. Amit and D. Geman, "Shape quantization and recognition with randomized trees," *Neural Computation*, vol. 9, no. 7, pp. 1545-1588, 1997.
- [17] A. Bosch, A. Zisserman, and X. Munoz, "Image classification using random forests and ferns," *ICCV*, pp. 1-8, 2007.



**최지혜**

2007년 전남대학교 산업공학과(공학사). 2010년 전남대학교 산업공학과(공학석사). 관심분야는 지능형안전차량, 차량자율주행, 컴퓨터비전.



**송광열**

2007년 전남대학교 산업공학과(공학사). 2009년 전남대학교 산업공학과(공학석사). 2010년~전남대학교 산업공학과 박사과정. 관심분야는 지능형안전차량, 차량자율주행, 컴퓨터비전, 패턴인식.



**이준웅**

1984년 전남대학교 산업공학과(공학사). 1986년 KAIST 산업공학과(공학석사). 1997년 KAIST 자동차 및 설계공학과(공학박사). 1986년~2000년 기아자동차 연구소 및 현대기아연구개발본부 전자개발센터 근무. 2000년~현재 전남대학교 산업공학과 교수. 관심분야는 지능형안전자동차, 차량자율주행, 컴퓨터비전, 센서퓨전.