

3차원 Co-occurrence 특징을 이용한 지형분류

論文

52D-1-7

Terrain Classification Using Three-Dimensional Co-occurrence Features

陳汝廣^{*} · 偶東玟^{**} · 李揆元^{***}
(Mun-Gwang Jin · Dong-Min Woo · Kyu-Won Lee)

Abstract – Texture analysis has been efficiently utilized in the area of terrain classification. In this application features have been obtained in the 2D image domain. This paper suggests 3D co-occurrence texture features by extending the concept of co-occurrence to 3D world. The suggested 3D features are described using co-occurrence histogram of digital elevations at two contiguous position as co-occurrence matrix. The practical construction of co-occurrence matrix limits the number of levels of digital elevation. If the digital elevation is quantized into the number of levels over the whole DEM(Digital Elevation Map), the distinctive features can not be obtained. To resolve the quantization problem, we employ local quantization technique which preserves the variation of elevations. Experiments has been carried out to verify the proposed 3D co-occurrence features, and the addition of the suggested features significantly improves the classification accuracy.

Key Words : terrain, co-occurrence, 3D, classification

1. 서 론

텍스처(texture)분석은 컴퓨터 영상 해석에서 영상 분할, 압축, 부품의 외관 검사 등 많은 분야에서 광범위하게 적용되는 중요한 연구 분야이다. 최근에는 항공 또는 위성 영상으로부터 지형을 분류하는 지형인식 분야에서 특히 유용하게 이용되고 있다. 이러한 응용은 지리정보시스템에 대한 자원 관리, 환경보전, 군사상의 측면에서 매우 중요시되고 있다.

텍스처는 일반적으로 2차원 영상에서 픽셀값 변화의 공간적인 분포, 혹은 구조적인 패턴으로 알려져 왔다.[1,2,3,4] Tamura[1]는 텍스처의 속성을 6가지(coarseness, contrast, directionality, line-likeness, regularity, roughness)로 정의하였다. 이러한 속성을 반영하는 텍스처 특징으로 co-occurrence 특징[5], MRF(Markov Random Field) 특징[6], Garbor 특징[7], Fractal 특징[8] 등이 대표적이다. Ohanian[9]은 이러한 특징들에 대한 인식률 비교를 통해 지형분류와 같은 응용분야에서는 co-occurrence 특징이 가장 우수함을 보고한 바 있다.

전통적인 텍스처 분석은 2차원 정보만을 이용한다는 한계를 갖고 있다. 그러나 이러한 문제점은 3차원 지형 모델을 생성하여 극복할 수 있다. 3차원 지형 모델을 이용하여 3차원 텍스처 특징을 사용하는 것은 지형분류의 인식률을 개선

할 수 있다. 따라서 본 논문에서는 일반적으로 지형분류에 가장 우수하다고 알려진 co-occurrence 특징 추출 기법을 3차원 지형 모델인 수치고도지도(Digital Elevation Map)에 적용하는 방법을 제안하였다.

Co-occurrence 특징 추출을 위해 co-occurrence 행렬을 현실적으로 구성하기 위해서는 수치고도지도를 여러 단계로 양자화 하는 것이 필요하다. 2차원 영상에서는 히스토그램 평활화 방법을 이용하여 양자화 하더라도 텍스처 정보가 손실되지 않으나, 수치고도지도의 경우는 양자화 간격이 클 경우 대부분의 텍스처 정보를 잃게 된다. 따라서 본 논문에서는 실제적인 3차원 co-occurrence 특징 추출을 위해 지역 양자화 기법을 채용하였다. 채용된 기법에 의해 단지 8개의 단계로서 양자화 하더라도 3차원 텍스처 정보를 얻을 수 있다.

본 논문의 구성은 다음과 같다. 2장에서는 3D co-occurrence 특징 및 이의 추출 과정을 설명 하였으며, 3장에서는 사용된 신경망 분류기를 구성하였다. 4장에서는 실제 지형 데이터에 대한 실험을 수행하고 분석 하였으며, 5장에서는 결론을 맺는다.

2. 3D co-occurrence 텍스처 특징

현재의 지형 인식 기술은 주로 2차원 흑백 영상으로부터 텍스처 정보를 추출하여 이용하는 방법이 일반적이다. 이러한 전통적인 텍스처 분석법은 2차원 정보만을 이용한다는 한계가 있다. 이러한 한계를 극복하기 위해 항공 및 위성 영상에 스테레오 정합 기법을 적용하여 3차원 지형 모델을 생성하고, 생성된 지형 모델에서 3차원 텍스처 특징을 추출한다.

* 準會員：明知大學 情報工學科 碩士課程

** 正會員：明知大學 情報工學科 教授 · 工博

*** 正會員：大田大學 情報通信工學科 助教授 · 工博

接受日字：2002年 6月 4日

最終完了：2002年 10月 1日

2.1 DEM구성

본 논문에 채용된 스테레오 정합기법은 HR(Hierarchical Resampling)[11], NSSR (Narrow Search Subpixel Registration)[12], NCC(Normalized Cross-Correlation)[12,13] 등을 이용하여 구성되었다.

그림 1은 2개의 겹쳐진 영상으로부터 수치고도지도를 구하는 시스템의 전체적인 구성도이다. 먼저 기준영상 $I^F(i, j)$ 와 목표 영상 $I^G(i, j)$ 을 $I^F(i, j) \cong I^G(i + D(i, j), j)$ 와 같이 x축으로 1차원만 탐색하여 정합할 수 있도록 epipolar sampling이 수행된다.

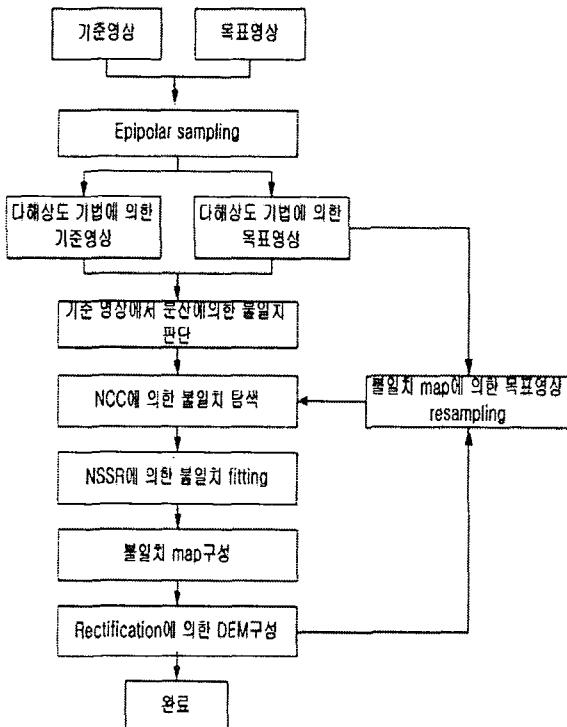


그림 1 DEM생성 시스템 구성도

Fig. 1 DEM create system diagram

다 해상도 기법은 영상의 해상도를 역 피라미드의 형태로 줄여서 해상도가 가장 낮은 영상에서부터 정합하여 해상도가 가장 좋은 영상까지 변환하며 불일치를 결정하는 방법이다. 이러한 계층적 방법을 구현하기 위해 영상 중의 하나가 정합되기 전에 그 영상간의 저해상도 불일치가 없도록 다시 샘플링 한다.

스테레오 정합을 위한 정합 점수(match score)는 NCC(Normalized Cross-Correlation)를 사용한다. NCC는 일반적으로 $(2m+1) \times (2n+1)$ 윈도우에서 식(1)과 같이 정의된다. 식(1)에서 d 는 탐색 범위 내의 값을 갖는다.

$$\rho(i, j, d) = \frac{\sum_{\eta=-m}^m \sum_{\xi=-m}^m I^F(i + \xi, j + \eta) \cdot I^G(i + \xi + d, j + \eta)}{\sigma^F(i, j) \sigma^G(i + d, j)} - N \frac{\mu^F(i, j) \mu^G(i + d, j)}{\sigma^F(i, j) \sigma^G(i + d, j)} \quad (1)$$

여기서 $N=(2m+1) \times (2n+1)$ 이고, 일차, 이차 모멘트 μ 와 σ 는

식(2)과 같다.

$$\mu(i, j) = \frac{1}{N} \sum_{\eta=-m}^m \sum_{\xi=-m}^m I(i + \xi, j + \eta) \quad (2)$$

$$\sigma(i, j) = \sqrt{\sum_{\eta=-m}^m \sum_{\xi=-m}^m [I(i + \xi, j + \eta) - \mu(i, j)]^2}$$

정합 점수로부터 정확한 불일치를 추정하기 위해 NSSR을 사용한다. 이는 정수로 나타나는 정합 단계에서 구해진 정합치를 연속함수로 피팅하여, 불일치 값을 연속함수의 최적화 값으로 결정한다. 일반적으로 연속함수의 형태는 포물선이나 가우시안이 사용된다.

최종적으로 구하여진 불일치 지도를 이용하여 교정단계를 거치게 된다. 이 단계는 삼각측량법을 이용하여 불일치 지도의 값으로부터 모든 실세계 격자점에 대해 수치고도지도로 변환하는 과정이다.

2.2 3D co-occurrence 텍스처 특징 추출

수치고도지도로부터 3차원 텍스처 특징 추출은 Haralick[14]에 의해 제안된 co-occurrence 텍스처 특징 추출방법을 채용하였다. Co-occurrence 특징은 계조도의 공간적인 의존도를 쉽게 계산할 수 있는 특징을 갖고 있다. 영상에서 계조도 i 와 다른 계조도 j 가 지정된 각도와 거리 d 에 의해 떨어진 경우로 나타나는 횟수의 행렬로서 co-occurrence 행렬은 정의된다. 이러한 co-occurrence 행렬은 거리뿐만 아니라 이웃한 화소사이의 각도에도 의존한다. 일반적으로 화소의 거리와 45° 간격으로 양자화된 각도를 이용하여 4개의 행렬 ($0^\circ, 45^\circ, 90^\circ, 135^\circ$)을 만든다. 이 행렬은 화소 a 와 그 이웃한 화소 b 가 각도 θ 를 이루고 a, b 가 영상 위에 모두 있을 때 화소 a 는 i , 화소 b 는 j 로 되어 $P_{ij\theta}(\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ)$ 로 다시 표현된다. 이 행렬로부터 ASM, CON, ENT의 특징을 정의하게 된다.

ASM은 영상의 균일성을 측정 한다. 텍스처의 균일성을 나타내는 ASM은 도로와 같은 평평한 면에서 크게 나타난다.

$$f_{1\theta} = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} P_{ij\theta}^2 \quad (3)$$

CON는 영상에 나타나는 대조 또는 부분적인 변화를 나타낸다. 변화가 많은 곳에서 큰 값으로 나타나는 값인 CON은 숲과 같이 굴곡이 심한 경우 크게 나타난다.

$$f_{2\theta} = \sum_{n=0}^{G-1} n^2 \sum_{|i-j|=n} P_{ij\theta} \quad (4)$$

ENT는 복잡한 정도를 측정한다. ENT의 계산은 정보량의 수식과 동일하여 아래 식과 같이 나타난다. ENT는 복잡하고 예측 불가능한 곳을 반영한다.

$$f_{3\theta} = - \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} P_{ij\theta} \ln(P_{ij\theta}) \quad (5)$$

여기서 G 는 영상의 경우엔 영상의 양자화 단계 수를 나타낸다. Co-occurrence 행렬은 $G \times G$ 의 크기를 갖게 되며, 영상안

의 화소의 개수보다 작은 요소들의 수를 가져야만 한다. 보통 G의 값으로 8을 선정하는 경우가 많은데 이때는 영상이 8단계로 양자화 되며 co-occurrence 행렬은 8x8 크기를 가진다. 실제로 영상의 경우에는 8정도의 값으로 양자화 되더라도 의미 있는 영상을 만들 수 있다.

3차원 co-occurrence 텍스처 특징을 구하는데 있어서 현실적으로 가장 큰 문제점은 수치고도의 양자화이다. 수치 고도의 경우는 8단계로 양자화 한다면 각 단계간의 고도차가 너무 커서 지형의 굴곡에도 불구하고 평평한 영역으로만 특징 값이 나올 수밖에 없다. 따라서 지역 내의 수치 고도 값에 의해 양자화를 하는 지역 양자화 기법을 이용하였다. 그럼2에서와 같이 각 지역 내의 수치 고도들을 하나의 평면으로 피팅하여 이 평면과의 편차를 양자화하여 양자화에 따른 정보 손실을 최소화하였다. 식(6)에서 Z는 수치고도, x 와 y는 수치고도지도에서의 위치좌표를 나타낸다. 식(6)에 해당 지역의 수치고도의 값을 대입하여 행렬식으로 정리한 것이 식(7)이다.

$$z = ax + by + c \quad (6)$$

$$\begin{vmatrix} z_1 \\ z_2 \\ \vdots \\ z_n \end{vmatrix} = \begin{vmatrix} x_1 & y_1 & 1 \\ x_2 & y_2 & 1 \\ \vdots & \vdots & \vdots \\ x_n & y_n & 1 \end{vmatrix} \begin{vmatrix} a \\ b \\ c \end{vmatrix} \quad (7)$$

$$Z = Ax$$

$$X = A^{-1}Z \quad (8)$$

식(11)을 통해 평면의 방정식을 완성할 수 있다. 완성된 식을 이용하여 지역 내의 수치고도의 값 z와 평면의 방정식상의 수치고도의 값 z의 차 $d = z - z$ 를 양자화에서의 입력 값으로 사용한다.

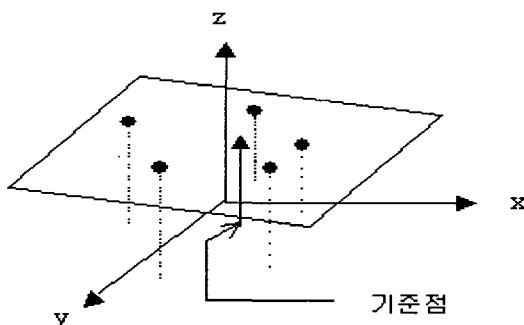


그림 2 지역 양자화 기법

Fig. 2 Local quantization technique

3. 신경망 분류기

본 논문에서는 텍스처 특징을 이용한 지형 분류를 위해 신경망이 사용되었다. 채용된 신경망 알고리즘은 Back-Propagation Neural Net[15]이다. BP(Back-Propagation)는 일반적으로 입력단, 은닉단, 출력단으로 구성된다. 각 단은 다수의 뉴런으로 구성되고 일반적으로 그림3과 같은 구조를 갖는다. BP의 일반적인 알고리즘은 다음 같다.

각 입력뉴런($X_i, i = 1, \dots, n$)에서 입력 신호 x_i 를 받아서 은닉 단으로 전달하면, 각 은닉 뉴런 Z_j 에서 출력 값은 구하여 다음 단으로 전달한다.

$$Z_j = f(Z_{in_j}), \quad Z_{in_j} = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (9)$$

전달된 은닉뉴런의 출력 값은 출력 뉴런에서 입력 값이 된다. 각 출력뉴런 Y_k 의 출력 값은 식(13)으로 구한다.

$$Y_k = f(Y_{in_k}), \quad Y_{in_k} = w_{ok} + \sum_{j=1}^p Z_j w_{jk} \quad (10)$$

각 출력뉴런의 오차정보를 구한다.

$$\delta_k = (t_k - Y_k) f'(Y_{in_k}) \quad (11)$$

각 은닉뉴런의 오차정보를 구한다.

$$\delta_j = \delta_{in_j} f'(Z_{in_j}), \quad \delta_{in_j} = \sum_{k=1}^m \delta_k w_{jk} \quad (12)$$

구한 오차정보를 이용하여 weight의 갱신 식을 구한다.

$$\Delta w_{jk} = \alpha \delta_j Z_j \quad \Delta v_{ij} = \alpha \delta_j x_i \quad (13)$$

각 weight를 갱신한다.

$$w_{jk}(new) = w_{jk}(old) + \Delta w_{jk} \quad (14)$$

$$v_{ij}(new) = v_{ij}(old) + \Delta v_{ij}$$

오차 값이 원하는 수준 이하가 될 때까지 위의 순서를 반복 한다.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (15)$$

x_i 입력 값 t_k 목표 값

α 학습율 $f(x)$ 활성화 함수

δ_k 출력뉴런에서의 오차정보

δ_j 은닉뉴런에서의 오차정보

Z_j 은닉뉴런 j의 결과 값

y_k 출력뉴런 k의 결과 값

v_{0j} 은닉뉴런 j의 bias

v_{ij} 은닉뉴런 j 와 입력뉴런 i의 weight

w_{ok} 출력뉴런 k의 bias

w_{jk} 출력뉴런 k와 은닉뉴런 j의 weight

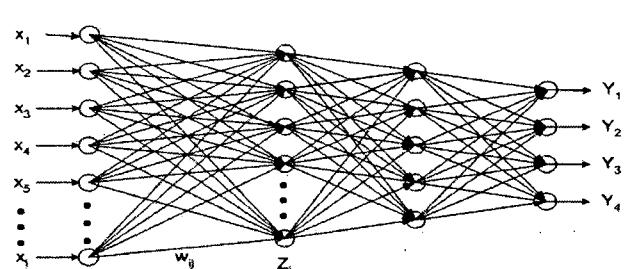


그림 3 Back-Propagation net의 일반적 구조

Fig. 3 structure of Back-Propagation net

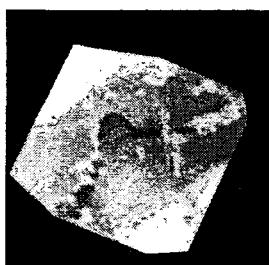
각 입력에 대한 출력 값과 목표 값의 차로 구한 에러 값이 원하는 범위에 들 때까지 훈련 학습을 반복한다.

4. 실험과정 및 결과

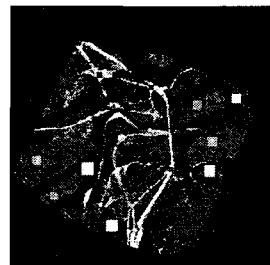
이 실험은 주어진 디지털 영상 데이터를 숲, 초지, 길, 그림자(foliage, grass covered ground, bare ground, shadow) 네 부분으로 분류하는 것을 목적으로 한다. 실험 그룹은 2차원 특징을 이용한 A, 2차원 특징과 명암도 특징을 이용한 B, 2차원 특징과 3차원특징을 이용한 C, 그리고 2차원 특징과 3차원 특징, 명암도 특징모두를 이용한 D 이렇게 4개의 그룹으로 실행 한다.

그림 4는 실험에 이용한 데이터들이다. 실험의 첫 단계는 신경망의 훈련학습에 필요한 데이터의 추출로서, 훈련학습에 필요한 데이터를 그림5와 같은 co-occurrence특징 데이터에서 숲, 초지, 길, 그림자에 해당하는 부분의 데이터를 추출한다. 추출된 데이터의 양은 각 class의 1%이며 총 픽셀의 수는 60,833픽셀이다. 그림 4.(b)는 훈련학습에 쓰인 데이터를 추출한 영역을 보여주고 있다. 목표 값은 ground truth에서 훈련 학습 데이터와 같은 영역을 뽑아서 사용한다.

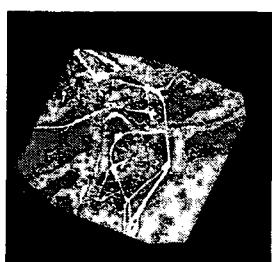
두 번째로 신경망의 훈련 학습을 실행한다. 각 실험 그룹 A, B, C, D에 대해 신경망 분류기가 구성된다. 각각의 실험 그룹은 입력의 수가 다르므로 신경망 구조 또한 같지 않으며 훈련학습은 여러가 최소가 될 때까지 계속된다. 실험에 사용한 신경망은 입력 뉴런의 수는 실험 그룹에 따라 A는 12개, B는 13개, C는 24개, D는 25개이며 은닉단의 수 2개, 각각의 은닉단의 뉴런의 수는 15, 5개이다. 그리고 출력뉴런의 수는 4개이며, 학습율 $\alpha = 0.2$ 이다.



(a) DEM



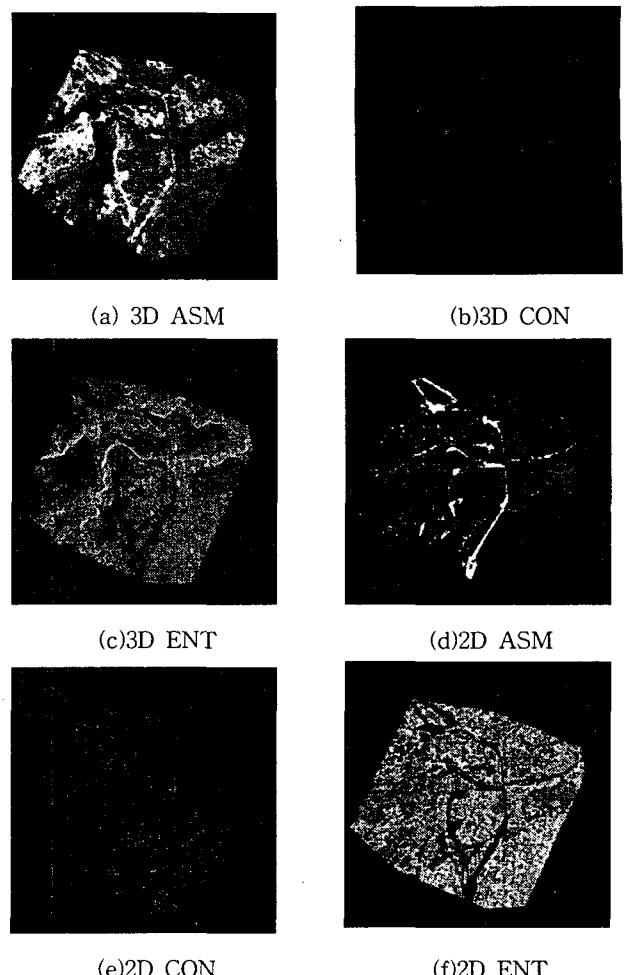
(b) 훈련데이터



(c) ground truth

그림 4 실험 데이터

Fig. 4 Experiment Data

그림 5 Co-occurrence 특징들 ($p_{ij\theta}, \theta = 0^\circ$)Fig. 5 Co-occurrence features ($p_{ij\theta}, \theta = 0^\circ$)

세 번째로 각 훈련 학습된 신경망을 이용하여 인식 결과를 얻는다. 출력뉴런은 그 순서대로 길, 초지, 숲, 그림자를 대표하며, 가장 큰 값을 갖는 출력뉴런이 해당 입력 패턴에 대한 결과가 된다.

실험 결과를 보면 2차원의 co-occurrence 특징만을 이용한 실험 A에서는 숲에 대한 인식률이 상당히 높은 반면 다른 영역의 인식율의 현저히 낮다. 실험 B는 실험 A에 명암도 데이터를 추가한 실험으로 실험 A와 비교하면 숲에 대한 인식률은 다소 낮아졌지만 다른 세 영역의 인식률이 급격히 향상되었음을 알 수 있다. 실험 C는 3차원 co-occurrence 데이터와 명암도 데이터만을 이용한 것으로 실험 B와 비교했을 때 실험 C의 인식률이 실험 B보다 1.55%높게 나타난다. 이것으로 2차원의 텍스처 특징보다 3차원의 텍스처 특징이 좀더 많은 정보를 제공함을 알 수 있다. 하지만 실험 C에서는 실험 B보다 그림자의 인식률이 39% 낮다. 실험 D는 전반적으로 모든 영역에서 고른 인식률을 보인다. 실험 C에서 문제가 되었던 그림자 영역에 대한 인식률도 27%정도 향상되었다.

실험 결과를 분석해 보면 2차원 co-occurrence 데이터만을 이용한 실험에서는 숲의 인식률이 높게 나타나고, 명암도 데이터는 그림자와 길에 대한 인식률에 많은 영향을 줌을

알 수 있으며, 3차원 co-occurrence 텍스처 특징은 그림자, 초지, 숲에 대한 인식률에 영향을 줄 수 있다.

표 1 ANN classifier에 의한 분류실험 결과 분석표(단위: 1000 pixels)

Table 1 Experiment Result with ANN classifier

ground truth	(total)	실험 그룹 A			
		그림자	초지	숲	길
그림자	(41.8)	0.258	0.778	2.768	3.799
초지	(683.0)	0.319	1.569	0.787	1.284
숲	(1018.6)	27.687	661.416	1007.673	82.590
길	(193.4)	13.553	19.243	7.343	105.73
total	(1936.8)	41.817	683.006	1,018.571	193.403
		정확하게 분류된 픽셀의 총수: 1115.23			
		전체적인 분류 정확도: 57.58%			
ground truth	(total)	실험 그룹 B			
		그림자	초지	숲	길
그림자	(41.8)	26.193	0.707	9.187	6.602
초지	(683.0)	0.149	567.594	219.001	34.121
숲	(1018.6)	14.656	94.550	784.581	1.238
길	(193.4)	0.805	20.155	5.735	151.422
total	(1936.8)	41.803	683.006	1,018.504	193.383
		정확하게 분류된 픽셀의 총수: 1529.79			
		전체적인 분류 정확도: 78.99%			
ground truth	(total)	실험 그룹 C			
		그림자	초지	숲	길
그림자	(41.8)	9.826	1.905	20.204	1.528
초지	(683.0)	0.109	492.786	100.706	13.638
숲	(1018.6)	31.881	147.978	884.771	3.791
길	(193.4)	0.001	26.008	13.961	172.475
total	(1936.8)	41.817	668.677	1,019.642	191.432
		정확하게 분류된 픽셀의 총수: 1559.858			
		전체적인 분류 정확도: 80.54%			
ground truth	(total)	실험 그룹 D			
		그림자	초지	숲	길
그림자	(41.8)	20.936	0.522	3.968	0.156
초지	(683.0)	0.009	513.964	69.458	26.371
숲	(1018.6)	20.872	139.353	939.035	3.710
길	(193.4)	0.0	29.167	6.11	163.166
total	(1936.8)	41.817	683.006	1,018.571	193.403
		정확하게 분류된 픽셀의 총수: 1637.101			
		전체적인 분류 정확도: 84.52%			

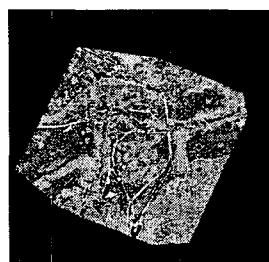
실험 그룹:

A = 12개의 2차원 co-occurrence 특징

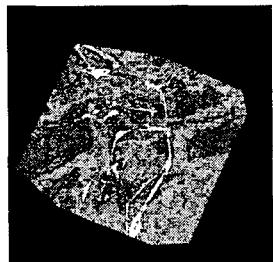
B = A + 명암 특징

C = 12개의 3차원 co-occurrence 특징과 명암 특징

D = A + C



(a) 실험B의 결과



(b) 실험D의 결과

그림 6 실험결과 (실험 그룹 B 와 D에서)

Fig. 6 Experiment Result (experiment group B and D)

특히 그림 6의 실험 결과를 보면 2차원 co-occurrence 특징과 명암도를 적용한 결과에서는 길이라 판단되어야 할 부분에서 그림자로 판단되는 부분이 많이 있음을 알 수 있다. 그러나 3차원 co-occurrence 특징을 추가한 그림 b)에서는 길 부분의 인식이 현저하게 높아졌음을 알 수 있다. 이는 2차원 특징과 명암도 특징만으로는 길과 그림자의 구분이 어렵다는 것을 보여 준다.

5. 결 론

본 논문에서 제안한 3차원 co-occurrence 텍스처 특징은 지형 분류에서 2차원 co-occurrence 텍스처 특징이 제공하지 못했던 지형에 대한 추가 정보를 제공함으로써 지형 인식의 인식률이 향상되었음을 알 수 있다. 실험 B와 실험 D의 비교에서 3차원 co-occurrence 특징을 이용한 실험 C의 인식률이 B보다 1.55% 높은 것으로 증명 할 수 있다. 2차원과 3차원의 co-occurrence 특징과 명암도 특징을 이용한 실험 D의 결과로 한 영역으로 치우치는 문제를 해결 할 수 있음을 알 수 있다.

감사의 글

본 연구는 한국과학재단 목적기초연구(R01-2002-000-00336-0) 지원으로 수행되었음.

참 고 문 헌

- [1] H. Tamura, S. Mori, and T. Yamawaki, "Textural Features Corresponding to Visual Perception," IEEE Trans. on Systems, Man, and Cybernetics, Vol. 8, pp. 460-473, 1978.
- [2] R. Haralick, "Statistical and Structural Approaches to Texture," Pro. IEEE, Vol. 67, pp. 786-804, 1979.
- [3] L. Van Gool, P. Dewaele, and A. Oosterlinck, "Texture Analysis Anno 1983," Computer vision, Graphics, and Image Processing, Vol. 29, pp. 336-357, 1985.
- [4] M. Tuceryan and A. Jain, "Texture Analysis," In The Handbook of Pattern Recognition and Computer Vision, C. Chen, L. Pau, and P. Wang, edg. World Scientific Publishing Co., pp. 235-276, 1993.

- [5] R. Haralick, K. Shanmugam and I. Dinstein, "Texture features for image classification," IEEE Trans. on Sys. Man Cybern. SMC-3, pp. 610-621, 1973.
- [6] R. Dubes and A. Jain, "Random field models in image analysis," j. Appl. Statist. Vol. 16, pp. 131-164, 1983.
- [7] F. Campbell and J. Robson, "Application to Fourier analysis to the visibility of gratings," Physiology, Vol. 197, pp. 551-566, 1968.
- [8] P. Kube and A. Pentland, "On the imageing of fractal surfaces," IEEE Trans. on. Pattern Anal. Mach. Intell., vol. 10, pp. 704-707, 1988.
- [9] P. Ohanian and R. Dubes, "Performance evaluation for four classes of textural features," Pattern Recognition, vol. 25, no. 8. pp. 819-833, 1992.
- [10] M. J. Hannah, "A system for digital stereo image matching," Photogrammetric Engineering and Remote Sensing, Vol. 55, No. 12, pp. 1765-1770, 1989. 12.
- [11] S. Tanimoto and T. Pavlidis, "A hierarchical data structure for picture processing," Comput. Graphics and Image Processing, vol. 4, no. 2, pp. 104-119, 1975.
- [12] H. Schultz, "Terrain Reconstruction from Widely Separated Images," Proc. SPIE, Vol. 2486, pp. 113-123, 1995.
- [13] M. Sonka, V. Hlavac and R. Boyle, "Image processing, analysis, and machine vision," International Thomson Pub. Co. Vol. 2, pp. 190-194, 1999.
- [14] R. M. Haralick and L.G. Shapiro, "Computer and robot vision Vol. II," Addison-Wesley Pub. Co. pp. 357-361, 1993.
- [15] Laurene Fausett, "Back-Propagation Neural Net," In Fundamentals of Neural Networks, Prentice Hall, pp. 289-333

저 자 소 개



진 문 광(陳 汶 廣)

2001년 명지대 공대 제어계측공학과 졸업. 2001년 ~ 현재 동 대학원 제어공학과 제학.



우 동 민(偶 東 攻)

1958년 2월 6일생. 1980년 연세대 공대 전자공학과 졸업. 1982년 동 대학원 전자공학과 졸업(석사). 1987년 미국 Case Western Reserve University 전기공학과 졸업(공박). 1987년~1990년 LG산전(주) 연구소 선임 연구원. 1997년~1998년 미국 University of Massachusetts 객원 연구원. 1990년~현재 명지대 공대 정보공학과 교수.



이 규 원(李 揭 元)

1986년 연세대학교 전자공학과 졸업. 1988년 동 대학원 전자공학과 졸업(석사). 1998년 동 대학원 전자공학과 졸업(공박). 1988년~1989년 LG산전(주) 연구원. 1989년 9월~2000년 2월 한국전자통신연구원 선임연구원. 2000년 3월 ~현재 대전대학교 정보통신공학과 조교수.