

# Stochastic 모형을 이용한 영상 simulation

정명희<sup>1)</sup>

## 개요

주어진 영상은 그것에 대하여 가정된 모형의 한 샘플로 간주될 수 있다는 관점은 그 영상과 유사한 특성을 갖는 많은 영상을 만들 수 있게 해주고, 이렇게 생성된 영상들은 개발된 모형을 평가하고 입증하거나 실험 결과에 대한 신뢰성을 검토하는데 이용된다. 이를 위해서는 주어진 영상에서 관찰되는 stochastic 특성을 설명하는 모형에 기초한 시뮬레이션이 필요하다. 본 연구는 영상에서 관찰되어지는 특성을 설명하는 계층적 stochastic 모형을 개발하고 이 모형에 따른 영상 시뮬레이션에 그 초점을 맞추고 있다.

개발된 모형은 주어진 영상에서 관찰되는 특징에 대한 포괄적 이해에 기초를 두고 있다. 먼저, 영상에서 관찰되는 거시적 특성인 지역형성이 Markov Random Field를 이용해서 모형화되었고 다음으로는 각 지역 내부의 continuous radiance field가 (1)개개의 화소가 i.i.d.되었다는 가정과 (2)이웃하는 화소들이 서로 연관되어 있다는 두개의 다른 가정에 입각해서 모형화되었다. 이러한 모형이 종합되어, 결국 다중분광영상이 시뮬레이션된다.

## 1. 서론

어떤 이미지가 주어졌을 때, 이것은 그 이미지에서 관찰되는 stochastic process가 실현된 한 결과로 가정되어 질 수 있다. 이 주어진 이미지로부터 stochastic process의 변수가 추정되어지고, 이를 이용하여, 잠재적인 상태를 대변하는 다량의 샘플 scene을 생성해낼 수 있다. 이렇게 생성된 샘플들은 가정된 모형아래서 같은 특성을 갖는다고 여겨지며 모형개발에 필요한 실제 데이터와는 달리 개발된 모형을 평가하고 입증하거나 실험 결과에 대한 신뢰성을 검토하는데 중요한 역할을 한다. 또한 시뮬레이션은 임의로 특성을 변화시켜 여러 가지 시나리오에 따른 실험도 가능하게 해준다. 이런 목적을 위해서는 주어진 영상에서 관찰된 stochastic 특성을 설명하는 모형에 입각한 시뮬레이션이 필요하다.

이 연구는 landscape scene에서 관찰되어지는 process를 특징화하는 stochastic 모형을 개발하여 다채널 영상을 시뮬레이션함으로써 원격탐사영상을 이용하여 개발된 landscape 시뮬레이션 모형과 기타 다양한 영상처리 알고리즘을 위해 일

반적인 방법론을 제공해 주는 것을 주된 목적으로 한다. 제안된 모형은 이미지의 통계적인 특성에 대한 포괄적인 이해에 바탕을 두고 있는데, 이는 특성을 계층적으로 접근함으로써 가능하게 된다. scene을 이해하는 관점은 연구자마다 다를 수 있지만 일반적으로 landscape scene은 크게 다양한 모양과 크기의 지역으로 구성되어 있고 이들 각 지역은 나름대로의 고유한 특성을 가지고 있다. 지역은 보통 class라 불리는데 호수나 산림지역과 같은 것이 그 예이다. 이러한 이중적인 특성은 대부분의 생태학적 연구에서 중요시되고 있기 때문에 본 연구는 이 점에 초점을 두고 있다.

먼저, 실제적인 지역형성을 위해서는 모형에서 공간적 연속성이 강조되어야 한다. Markov Random Field는 화소간의 상호 의존적 관계를 탐구하여 공간적 인접성을 강조하고 있으므로 region process의 모형으로 적합하다. 이를 위해 화소들의 공간적 clustering을 특징화하는 Gibbs distribution이 이용되는데, 변수에는 지역의 모양과 방향에 대한 정보가 함축되어져 있다.

다음은 각 지역 고유의 continuous radiance field의 특징을 모형화하는 것인데, 이는 두 가지 다른 관점에서 접근되었다. 첫번째는 화소값이 각 지역에 따라 i.i.d.(independently and identically distributed)되었다는 가정 아래, multivariate Gaussian mixture distribution을 이용하여 일반적으로 noise가 입혀진 random field가 모형화되었다. 두번째 접근에서는 화소간의 가능한 상호 연관성이 고려되었다. 이에 따라 모형에서는 채널간의 correlation뿐 아니라 채널내의 correlation까지 고려되고 있는데, 이는 Gaussian Markov Random Field를 이용하여 실현되었다. 이들 지역내 통계적 특성은 지역형성 모형과 함께 다중분광영상을 만들게 된다. 개발된 알고리즘은 시뮬레이션된 이미지로 테스트된 후, 원격탐사데이터인 TM데이터에 적용되었다.

## II. stochastic 시뮬레이션 모형

### 2.1 지역형성 시뮬레이션

앞의 서론 부분에서도 언급되었듯이 region process는 scene의 상위 특성으로 이를 모형화하기 위해 먼저 scene random field  $X$ 를 유한  $N \times N$  lattice에 정의한다.  $X = \{X_i, 1 \leq i \leq N^2\}$ 는 scene에 존재하는 class 값 ( $A = \{0, 1, 2, \dots, G-1\}$ )중 하나를  $X_i(\omega) = x_i = k$ 와 같이 취한다. 이렇듯,  $\omega$ 는  $N \times N$  lattice를 단순히  $G$ 개의 class로 나누는 것과 같다. 이 단계에서는 공간적으로 분포된 화소들 간의 상호작용을 고려하면서,  $X$ 가 공간적으로 인접해있는 이웃 화소들에(일차 혹은 이차 이웃)대해

Markovian이라는 가정 하에 다음과 같은 Gibbs distribution이[5] 이용된다.

$$P(X = \omega) = \frac{1}{Z} e^{-U(\omega)} \quad (1)$$

where

$$U(\omega) = \sum_{c \in \mathcal{Q}} V_c(\omega) \quad \text{energy function}$$

$$V_c(\omega) = \quad \text{potential function}$$

$$Z = \sum_{\omega} e^{-U(\omega)} \quad \text{partition function}$$

여기서 T는 전체적으로 Gibbs energy를 최소화시키는 simulated annealing schedule로 포함되었다. 화소들이 공간적으로 의미 있게 뭉치도록 하기 위해서는 적절한 clique function을 선택해야 하는데, 여기에서는 다음과 같은 clique function이 선택되었다:

(1) 단일 화소의 clique function

$$V_c(\omega) = \alpha_k \quad \text{if } x_i \text{ in } c \text{ is equal to } k, \text{ where } k \in A = \{0, 1, 2, \dots, G-1\} \quad (2)$$

(2) 화소 상호간의 clique function

$$V_c(\omega) = \begin{cases} -\beta_{dir,k} & \text{if all } x_i \text{ in } c \text{ are equal to } k \text{ and } c \text{ is "dir" type clique} \\ \beta_{dir,k} & \text{otherwise} \end{cases} \quad (3)$$

변수  $\alpha_k$ 는 화소들의 각 지역 타입별 비율을 조정하고,  $\beta_{dir,k}$ 는 k class타입 지역의 dir방향으로의 clustering을 조절한다. 각 class들이 유사한 공간적 특성을 가지고 있다면 상호간 clique function은  $\beta_{dir}$ , dir=hor, ver, ne, nw로 단순화될 수 있다.

region process를 시물레이션하기 위해서는 주어진 이미지의 class map으로부터 모형의 변수들이 평가되어야 한다. 식 (2)과 (3)으로부터 평가되어야 할 최대변수의 수는  $(G+4 \times G)$ 인데 이는 이미지크기에 따라 상당히 커질 수 있다. normalizing function때문에 변수 평가는 Gibbs distribution의 어려운 문제중의 하나인데, 여기서는 Least Square Error Method [1]가 이용되었다. 이렇게 평가된 변수들에 의한 시물레이션은 주어진 class map과 통계적으로 유사한 이미지들을 생성해낸다.

## 2.2 각 지역의 통계적 특성에 대한 모형

계층적 모형의 하위 단계는 각 지역의 continuous radiance field의 통계적 특성을 모형화해서 다채널 이미지를 만들어 내는 것이다. 다중분광영상은 풍부한 채널간 correlation뿐 아니라 화소간의 공간적 correlation을 갖고 있는데, 이런 것들이 모형에서 고려되어야 한다. 두 가지 다른 가정에 입각해서 이에 접근해볼 수 있다. 먼저, 화소 벡터가 서로 i.i.d하다고 가정해 볼 수 있는데, 이 모형에서는 채널간 correlation만이 고려될 수 있다. 다음은 이웃하는 화소 벡터들 간에 서로 연관되어 있다고 보는 관점인데, 여기서는 채널간 correlation뿐 아니라 채널내 화소 벡터들간의 correlation이 동시에 고려될 수 있다.

### 2.2.1 Multivariate Gaussian mixture model

각 지역내의 자연적 변이는 두 개의 서로 독립적인 process, 즉 지역 타입에 따른 process와 noise process의 통합된 결과로 간주된다. 이렇듯 지역내 통계적 특성에 대한 random field  $Z=\{Z_i\}$ 는 다음과 같은 합으로 표시될 수 있다.

$$Z_i = F(X_i) + \epsilon_i \quad (4)$$

$F(X_i)$ 는 class에 따른 process에 대응되는 함수인데, 이것은 실제 데이터에 의해 결정되어진다. 이를 위해 다양한 통계 분포들이 고려될 수 있지만, 본 연구에서는 multivariate Gaussian mixture distribution이 이용되었다. noise random field,  $E=\{\epsilon_i\}$  또한 Gaussian random field로 가정되는데, 따라서 이들이 통합된 random field  $Z=\{X, E\}$ 는 다음과 같이 나타낼 수 있다.:

$$Z_i \sim N(\mu_k, \Sigma_k) \text{ if } X_i = k \quad (5)$$

$\mu_k=(\mu_{k1}, \mu_{k2}, \dots, \mu_{kp})$ 는 p-다중 채널의 mean vector이다.  $\Sigma_k$ 는 그것의 covariance matrix이다. 이것의 시뮬레이션은

$$N(\mu, \Sigma) = A \cdot N(0, I) + \mu$$

에 의한다. 여기서,  $A$ 는  $AA^T = \Sigma$ 이고 cholesky decomposition에 의해 구해진다. 이 분포에 대한 변수들의 평가는 EM 알고리즘을 이용하여 얻어질 수 있다.

### 2.2.2 continuous Markov Random Field Model

화소들 간의 공간적 상호작용을 고려하는 continuous random field는 texture분

석이나 이미지복구와 같은 많은 응용분야에서 이미지 모형에 성공적으로 이용되고 있다 [2,4]. 이 모형에서는 채널간 correlation뿐 아니라 이웃하는 화소들 간의 통계적 의존도가 동시에 고려되고 있으므로 다중분광영상 분석에 적합하다. 본 연구에서는 Gaussian Markov Random Field (GMRF)가 이용되는데, 이 모형에서는 화소값들이 jointly Gaussian분포를 갖고, correlation이 이웃하는 화소들간의 통계적 의존도를 나타내는 변수들에 의해 조절되고 있다. p개의 채널을 위한 모형은 다음과 같이 정의된다.

$$z(s) = \sum_{r \in N_s} \Theta_r z(s+r) + e(s) \quad s \in S \quad (6)$$

여기서,  $z(s)$ 와  $z(s+r)$ 은 각 위치  $s$ 에서의 화소 벡터와 그의 이웃벡터를 나타내며  $\Theta_r$ 은 공간적 상호작용을 반영하는 변수집합이다.

$$\Theta_r = \begin{pmatrix} \theta_{r11} & \theta_{r12} & \cdots & \theta_{r1p} \\ \theta_{r21} & \theta_{r22} & \cdots & \theta_{r2p} \\ \vdots & & & \\ \theta_{rp1} & \theta_{rp2} & \cdots & \theta_{rpp} \end{pmatrix}$$

$e(s)$ 는 noise 벡터를 의미한다. 따라서 식 (6)는 각 화소의 값이 이웃하는 화소들의 선형함수의 값에 noise가 입혀진 값이라는 것을 의미한다. noise  $\{e(s)\}$ 는 covariance matrix  $\Sigma$ 를 갖는 zero mean Gaussian 벡터이고 다음과 같은 correlation 구조를 갖는다.:

$$E(e(s)e(r)) = \begin{cases} \Sigma & s=r \\ -\Theta_{s-r}\Sigma & (s-r) \in N_s \\ \mathbf{0} & \text{otherwise} \end{cases} \quad (7)$$

이웃하는 화소들의 집합  $N_s$ 는 대칭적이고, 밴드 내와 밴드간의 공간적 상호작용을 고려할 수 있도록 선택되어야 한다.  $N_s$ 에 대한 예로 그림 1에서 2차 이웃구조가 보여지고 있다.  $\theta_{ijk}$ 는 밴드  $j$ 와 밴드  $k$ 사이의  $i$  타입(수직, 수평, 대각선 방향 등)의 공간적 상호작용을 나타내는 변수이다.




그림 1. GMRF에서 화소의 아차 이웃들

다중분광영상이 주어졌을 때 이와 같은 특성의 이미지를 시뮬레이션하기 위해서는 모형의 변수들이 주어진 영상으로부터 평가되어야한다. 본 연구에서는, 계산적으로 효율적인 평가 체계로 다음과 같은 pseudolikelihood,

$$L = \prod_{s \in S_f} P(z(s)|z(s+r), r \in N_s) \\ = \prod_{s \in S_f} \frac{1}{(8\pi^3 |\Sigma|)^{1/2}} \exp\left\{-\frac{1}{2} \left(z(s) - \sum_{r \in N_s} \Theta_r z(s+r)\right)^T \Sigma^{-1} \left(z(s) - \sum_{r \in N_s} \Theta_r z(s+r)\right)\right\} \quad (8)$$

를 최대화하는 Least Square Estimate가 이용되다 [4]. 식 (7)에서  $S_f = S - S_B$ 는 이미지 가장자리에 있는 화소들  $S_B$

$$S_B = \{s; s \in S \text{ and } (s+r) \notin S \text{ for at least one } r \in S_f\}$$

을 뺀 내부 화소들을 나타낸다. 식 (8)을 최대화하기 위해 도함수들을 풀면 다음과 같은 해를 얻을 수 있다.

$$\Sigma^* = \frac{1}{M_s} \sum_{s \in S_f} \left( z(s) - \Theta^{*T} q(s) \right) \left( z(s) - \Theta^{*T} q(s) \right)^T \quad (9)$$

$$\Theta^* = \left[ \sum_{s \in S_f} q(s) q(s)^T \right]^{-1} \left( \sum_{s \in S_f} q(s) z(s)^T \right)$$

$$\begin{aligned}
 & \begin{pmatrix} \theta_{\eta 11} & \theta_{\eta 12} & \cdots & \theta_{\eta 1p} \\ \theta_{\eta 21} & \theta_{\eta 22} & \cdots & \theta_{\eta 2p} \\ \vdots & & & \\ \theta_{\eta p1} & \theta_{\eta p2} & \cdots & \theta_{\eta pp} \\ \theta_{r_2 11} & \theta_{r_2 12} & \cdots & \theta_{r_2 1p} \\ \theta_{r_2 21} & \theta_{r_2 22} & \cdots & \theta_{r_2 2p} \\ \vdots & & & \\ \theta_{r_2 p1} & \theta_{r_2 p2} & \cdots & \theta_{r_2 pp} \\ \vdots & & & \\ \theta_{r_n 11} & \theta_{r_n 12} & \cdots & \theta_{r_n 1p} \\ \theta_{r_n 21} & \theta_{r_n 22} & \cdots & \theta_{r_n 2p} \\ \vdots & & & \\ \theta_{r_n p1} & \theta_{r_n p2} & \cdots & \theta_{r_n pp} \end{pmatrix} \\
 & = \begin{pmatrix} z_1(s+\eta) - z_1(s-\eta) \\ z_2(s+\eta) - z_2(s-\eta) \\ z_3(s+\eta) - z_3(s-\eta) \\ \vdots \\ z_1(s+r_n) - z_1(s-r_n) \\ z_2(s+r_n) - z_2(s-r_n) \\ z_3(s+r_n) - z_3(s-r_n) \end{pmatrix} \\
 & q(s) = \text{col}\{z(s+r) - z(s-r), \quad r \in N_s\}
 \end{aligned}$$

Gibbs sampler와 유사한 GMRF sampler를 이용하여 위에서 구해진 변수들을 갖는 이미지가 생성되고 이것이 지역형성 시뮬레이션에서 얻어진 class map위에 입혀지게 되어 다중분광영상이 만들어지게 된다.

### III. 결과 및 고찰

개발된 알고리즘은 합성이미지를 이용하여 테스트되었는데, 그 성과는 시각적으로뿐만 아니라 수치적으로 평가되었다. 상위 단계의 class map으로 실현된 몇 개의 샘플이 <그림 2>에서 보여지고 있는데, 이들 이미지 크기는 모두 256x256이고 Gibbs sampler에 의해 얻어졌다. Gibbs sampler외에도, Chen 알고리즘이나 Metropolis 알고리즘에 의해서도 이미지는 시뮬레이션될 수 있다[3]. 각 class의 비율이 정해져 있다면 매 시뮬레이션 단계마다 화소가 서로 교환되는 Metropolis 알고리즘이 좋은 선택이 될 수 있다.

T는 annealing 변수로 이용되었는데, 시뮬레이션 과정에서 T는  $T_k = c/\log(k+1)$ ,  $k=1, \dots, K$ , ( $k$ 는 루프의 반복횟수,  $T_k$ 는  $k$  번째 loop에서의 온도)의 cooling schedule에 따라 변화한다. <그림 3>은 Metropolis 알고리즘을 이용하여, 반복 횟수에 따라 생성되는 이미지 변화를 보여주고 있다. <그림 4>와 <표 1>에서는 알고리즘이 시각적으로뿐만 아니라 평가된 변수 값과 주어진 값과의 비교로 테스트되었다. 주어진 변수를 가지고 (a)를 얻은 후 그 이미지로부터 다시 변수를 평가하여 수치적으로 변수들이 비교되었는데, 이들 두 값들은 비슷하고 유사한 특징을 가지고 있다. 다시 평가된 변수를 가지고 시뮬레이션하여 (b)를 생성했다. 이들 두 이미지 모두 class 2의 북동 방향 clustering을 조정하는 변수가 음수 값

을 갖음으로서 북동 방향으로 화소가 응집되는 것이 억제되었고 상대적으로 그 반대 방향인 북서쪽 방향으로의 clustering이 유도되었다.

<그림 5>는 multivariate Gaussian mixture distribution에 의한 feature generation결과를 보여주고 있다. 지정된 변수에 의한 mixture distribution의 샘플을 생성한 후 EM 알고리즘에 의해 변수들을 평가하였고 이렇게 얻은 변수를 가지고 다시 mixture distribution의 샘플을 만들어 두 histogram을 비교해 보았다. 두 샘플은 유사한 분포를 가지고 있고 분포의 꼬리 부분의 변이는 mixture model에 의해 잘 설명되고 있다. <그림 6(a)>는 <표 2>에서 지정된 변수를 가지고 GMRF를 이용하여 feature generation한 결과이다. Least Square Estimate 값이 테이블 2에서 지정된 변수 값과 비교되었는데, 둘이 유사한 값과 특성을 갖고있음을 알 수 있다. 평가된 값에 의해 생성된 feature(b) 역시 북서쪽 방향으로 형성된 특성을 가지고 있다. 이 모형에서는 화소간의 공간적 상호관계가 고려되기 때문에 i.i.d를 가정한 모델에서는 설명될 수 없는 contextual information이 포함될 수 있다.




그림 2 class map 예제들




그림 3. annealing schedule에 따른 이미지 변화




그림 4. 지정된 이미지와 합성된 이미지 비교



- Stochastic 모형을 이용한 영상 simulation -




그림 5. Gaussian모형을 이용한 지정된 변수와 평가된 변수의 분포비교






그림 6. 지정된 변수(a)와 평가된 변수(b)로 합성된 이미지 비교




(a) Belize지역의 TM이미지



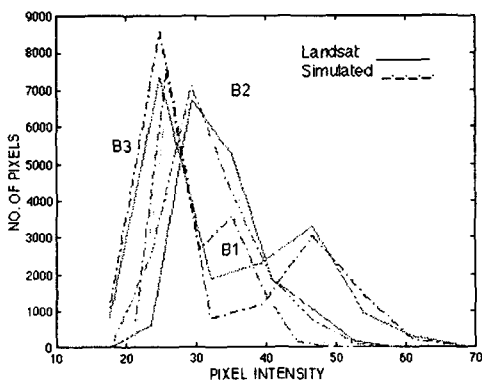
(b) Class Map



(c) 합성된 class map




(d) Gaussian모형에 의해 합성된 이미지



(e) 지정된 데이터(a)와 합성된 데이터(b)의 분포비교



(f) GMRF모형에 의해 합성된 이미지



(g) 지정된 데이터(a)와 합성된 데이터(f)의 분포비교

그림 7. Belize데이터의 시뮬레이션 과정

- Stochastic 모형을 이용한 영상 simulation -

		$\beta_{hor}$	$\beta_{ver}$	$\beta_{ne}$	$\beta_{nw}$
(a)	class 1	0.70	0.70	0.70	0.70
	class 2	0.70	0.70	-0.70	0.70
	class 3	0.70	0.70	0.70	0.70
(b)	class 1	0.51	0.54	0.50	0.71
	class 2	0.71	0.72	-0.32	0.52
	class 3	0.37	0.18	0.60	0.54

표 1. 변수 비교

<p>(a) <math>\mu = (106.66, 45.39, 90.19)</math></p> $\Sigma = \begin{pmatrix} 3.608 & 0.540 & 0.009 \\ 0.540 & 0.900 & 0.023 \\ 0.009 & 0.023 & 2.356 \end{pmatrix}$ $\Theta_1 = \begin{pmatrix} 0.428 & 0.037 & -0.030 \\ 0.040 & 0.267 & 0.016 \\ -0.023 & -0.003 & 0.071 \end{pmatrix}$ $\Theta_2 = \begin{pmatrix} 0.227 & 0.012 & 0.020 \\ -0.065 & 0.053 & 0.074 \\ 0.050 & 0.039 & 0.094 \end{pmatrix}$ $\Theta_3 = \begin{pmatrix} -0.169 & -0.030 & -0.003 \\ -0.006 & 0.020 & 0.032 \\ 0.022 & 0.023 & 0.057 \end{pmatrix}$ $\Theta_4 = \begin{pmatrix} 0.021 & -0.004 & -0.017 \\ 0.025 & 0.061 & 0.056 \\ -0.023 & 0.021 & 0.087 \end{pmatrix}$	<p>(b) <math>\mu = (105.89, 44.65, 89.50)</math></p> $\Sigma = \begin{pmatrix} 3.378 & 0.394 & 0.028 \\ 0.394 & 1.032 & 0.023 \\ 0.028 & 0.023 & 2.235 \end{pmatrix}$ $\Theta_1 = \begin{pmatrix} 0.410 & 0.039 & -0.019 \\ 0.086 & 0.271 & -0.020 \\ -0.036 & -0.006 & 0.062 \end{pmatrix}$ $\Theta_2 = \begin{pmatrix} 0.236 & -0.020 & 0.037 \\ -0.137 & 0.045 & 0.081 \\ 0.059 & 0.053 & 0.096 \end{pmatrix}$ $\Theta_3 = \begin{pmatrix} -0.172 & -0.021 & 0.019 \\ -0.013 & 0.029 & 0.018 \\ 0.037 & 0.028 & 0.044 \end{pmatrix}$ $\Theta_4 = \begin{pmatrix} 0.022 & -0.005 & -0.021 \\ 0.050 & 0.098 & 0.041 \\ -0.023 & 0.031 & 0.083 \end{pmatrix}$
--	---

표 2. <그림 6>의 지정된 변수와 평가된 변수의 비교

그림	변수	평가된 변수값
Class map(b)	$(\beta_{hor}, \beta_{ver}, \beta_{ne}, \beta_{nw})$ $(\alpha_1, \alpha_2, \alpha_3)$	(0.46, 0.47, 0.15, 0.19) (-0.024, -0.02, 0.0)
합성된 class map(c)	$(\beta_{hor}, \beta_{ver}, \beta_{ne}, \beta_{nw})$ $(\alpha_1, \alpha_2, \alpha_3)$	(0.46, 0.47, 0.15, 0.19) (-0.024, -0.02, 0.0)

표 3. 지역형성의 변수 비교

다음은 원격탐사데이터에 적용된 알고리즘의 결과이다. <그림 7(a)>는 1994년 Belize지역 TM이미지의 128x128 subset으로 enhanced true color(r-band3, g-band2, b-band1) 이미지다. 뚜렷한 세 개의 class가 관찰되는데, 녹색부분은 산림지역을, 연보라색은 저습지 지역을, 밝은 부분은 습한 지역을 각각 나타내고 있다. 이에 대응되는 class map(b)는 region-based classification에 의해 얻어졌

고 이로부터 지역형성 모형의 변수들이 평가되었다.<표 3(a)> 이 변수들을 가지고 통계적으로 유사한 땅을 class map을 만들 수 있는데, 그 중 한 예가 (c)에 주어져 있다. 다음으로는 지역내부의 특성을 모형화하고 시뮬레이트하기 위해 각 지역으로부터 취해진 샘플로부터 본문에서 설명한 모형들의 변수가 평가되었고 통계적으로 유사한 특성을 가진 지역 내부가 생성되었다. (d)는 multivariate Gaussian mixture distribution 모형의 결과인데 (e)의 주어진 이미지와의 분포 비교에서도 알 수 있듯이 화소의 통계적 분포는 원래 이미지와 비슷하나 단순화된 결과가 얻어졌다. 그 이유는 주어진 이미지에서 보듯이 화소들이 서로 공간적 관계를 갖고 있는데, 이 모형에서는 i.i.d되었다고 가정되어 있어 공간적 correlation이 고려될 수 없었다. (f)는 공간적 correlation을 고려하는 GMRF 모형의 결과이다. 여기서는 채널 내에서와 채널 간의 correlation이 모두 고려되었기 때문에, 지역 내부의 변이가 더 잘 표현되었고 화소의 분포(g) 또한 유사하다. 여기서 샘플의 중요성이 강조될 수 있는데 이는 샘플에 나타난 특성만이 모형에서 변수화되어 시뮬레이트되기 때문이다. 이것이 주어진 데이터와의 편차의 한 원인이 된다.

#### IV. 결론

본 연구는 다중분광영상에서 관찰되어지는 stochastic 특성을 모형화하고 이 모형을 이용하여 주어진 이미지와 통계적으로 유사한 이미지들을 생성해 내는데 그 초점을 두었다. 현재의 자연적 landcover는 여러 가지 요소들-기후, 지형, 지진이나 화재 같은 자연적 현상과 인간의 영향 등등-의 복잡한 상호작용의 결과이기 때문에, landscape는 단일 모델에 의해서는 설명될 수 없다. 본 연구의 범주 역시 이와 같은 맥락에서, 그림과 같이 자세한 landscape가 아니라 대부분의 생태학 연구가 관심을 갖는 지역형성과 지역의 고유 특성에 초점을 맞추었다. 이를 기반으로 보다 세부적 특성은 적절한 계층적 접근에 의해 모형화될 수 있다. 연구의 결과 얻어지는 이미지들은 자연 환경을 모니터하고 관리하기 위한 multitemporal landscape 시뮬레이션 모델의 시작점을 제공할 것이다.

**- 참고서적 -**

1. H. Derin and H. Elliot, "Modeling of segmentation of noisy and textured image using Gibbs random field, " IEEE Trans. Pattern Anal. Machine Intell., Vol.PAMI-9, pp. 39-55, 1987.
2. I. M. Elfadel, and A. L. Yuille, Mean-Field Theory for Grayscale Texture Synthesis Using Gibbs Random Fields, SPIE, Vol. 1569, pp. 248-259.
3. R. C. Dubes and A. K. Jain, "Random field models in image analysis," Journal of Applied statistics, Vol. 16, No. 2, pp. 131-164, 1989.
4. R. Kashyap and R. Chellappa, "Estimation and Choice of Neighbors in Spatial-Interaction Models of Images," IEEE Trans. on Information Theory Vol. IT-17, No. 1, pp. 60-72.
5. S. Geman and D. Geman, "Stochastic Relaxation, Gibbs Distribution, and the Bayesian Restoration of Images," IEEE Trans. Pattern Anal. Machine Intell., PAMI-6, pp. 721-741, 1984.