

건물 형태 발생을 위한 3차원 선소의 계층적 군집화

Hierarchical Grouping of Line Segments for Building Model Generation

한지호*, 박동철**, 우동민*, 정태경*, 이윤식**, 민수영**

Jiho Han*, Dong-Chul Park**, Dong-Min Woo*, Taikyeong Jeong*,
Yunsik Lee**, Soo-Young Min**

Abstract

A novel approach for the reconstruction of 3D building model from aerial image data is proposed in this paper. In this approach, a Centroid Neural Network (CNN) with a metric of line segments is proposed for connecting low-level linear structures. After the straight lines are extracted from an edge image using the CNN, rectangular boundaries are then found by using an edge-based grouping approach. In order to avoid producing unrealistic building models from grouping lined segments, a hierarchical grouping method is proposed in this paper. The proposed hierarchical grouping method is evaluated with a set of aerial image data in the experiment. The results show that the proposed method can be successfully applied for the reconstruction of 3D building model from satellite images.

요 약

위성 영상에서 건물형태를 발생하기위한 새로운 접근방식이 본 논문에서 제안되었다. 제안된 알고리즘은 낮은 수준의 선소들을 연결하고 유사한 개체들을 군집화하기 위해 선소 측정함수가 적용된 신경망이다. 제안된 신경망은 윤곽선 영상에서 추출된 윤곽선들을 군집화 목적으로 사용된다. 본 논문에서는 3차원 선소의 오류에 의한 군집화 결과의 비현실적 건물모델의 발생을 근원적으로 차단하기위하여, 높이 정보를 이용한 계층적 군집화를 제안하였다. 제안된 새로운 거리척도의 신경망과 군집화를 통해 성공적인 건물모델의 재구성을 실험으로 보여주었다.

Key words : Data Clustering, Clustering algorithm, Satellite image, Line segment

1. 서론

위성영상의 분석에서 건물 탐지는 지리학 정보 체계, 구조적 계획, 그리고 환경 조사등 많은 특정의 용도

들에 사용되는 매우 중요한 작업이다. 그러나 위성영상의 복잡성과 다양성 때문에 수많은 어려움을 만나게 되는 것이 불가피하다. 위성영상에서 건물들을 인식하는 여러 방법들은 건물 탐지를 위해 경계선을 찾고, 높이정보를 요구한다[1]-[3]. 높이 정보는 한 장면에 대한 여러 장을 이미지들의 조합에 의하여 얻을 수 있다. 또한 Synthetic aperture radar (SAR) airborne systems 또는 airborne light detection and ranging (LIDAR) measurement과 같은 방법들이 사용되기도 한다[4]. 그룹화 또는 경계선검출에 대한 여러 가지 접근법들은 하나의 이미지로부터 얻어진 이차원 특징들을 기반으로 건물을 탐지한다[5]-[7]. 일반적으로 이러한 접근법들은 선소의 분석이나 형성

*명지대학교 전자공학과
(Dept. of Electronics Engineering, Myong Ji University)
**전자부품연구원 시스템반도체연구본부
(System IC R&D Division, KETI)

★ 교신저자 (Corresponding author)

※본 연구는 2010년 교육과학기술부의 재원으로 한국연구재단(2010-0009655) 및 2011년 지식경제부산업원천기술개발사업의 지원(10040191)을 받아 수행된 연구임.

接受日:2012年03月07日, 修正完了日: 2012年 04月 01日

掲載確定日: 2012年 04月 17日

관계를 기반으로 높이 정보와 지붕에 대한 추론, 가설, 검증하는 단계들을 제시한다. 이러한 단계들의 필요조건은 건물의 높이, 그림자, 조도의 방향등을 가지는 유용한 정보를 포함하는 것이다. 하지만 이러한 단편적인 방법들은 위성영상의 복잡성 때문에 여전히 정확성에 제한이 있다. 본 논문은 위성영상에서 건물 모델의 재구성을 위하여, 높이정보에 따른 선소 데이터의 계층적 군집화로 영상의 잡음을 감소시키고 정확도를 향상시키는 건물모델의 구성을 위한 방안을 사용하였다.

본 논문에서는 위성영상 데이터에서 건물 재구성을 위하여, 3차원 선소의 군집화를 효율적으로 수행하기 위한 중심신경망을 제안하였다. 제안된 군집화 알고리즘은 오류가 있는 선소들을 완벽한 직선으로 연결하기 위해 중심신경망과, 선소들을 위해 특별히 구성된 선분할 측정함수를 결합하였다. 선소를 위한 측정함수는 하나의 선형적 구조에 속한 주어진 두 선소의 유사도 측정을 위해 처음 이용되었다. 비슷한 선소들을 직선의 구조로 연결하기 위한 그룹화 작업을 위해 중심신경망이 실행되고 그 후, 얻어진 결합된 직선들이 경계선형태를 기초로 건물들이 담지된다. 이진 낮은 수준의 원래의 선들이 건물 형태를 위한 사각의 경계선을 획득하기 위해 그들의 지형적인 특징들을 기초에 두어 가까운 윤곽으로 그룹화 된다는 말이다.

본 논문은 다음과 같이 구성되어 있다. 논문의 II장은 선소 측정함수와 중심신경망의 간단한 요약, 그리고 선소를 연결하기 위한 선소 측정함수와 중심신경망의 결합을 설명하고 건물의 사각형태 구조를 재구성하기 위한 경계선들의 연결 작업, 데이터의 계층적 군집화 전략에 대해 설명한다. III장에서는 제안된 방법의 성능을 평가하기 위하여, 실험에 사용된 위성영상 데이터와 실험 결과를 제시하며, IV장에서는 결론을 내린다.

II. 선소간 거리척도 기반의 중심신경망

1. 선소간의 거리척도

Nacken[8]은 선분을 위해 특별히 구성된 측정함수를 소개하였는데, 이 함수는 하나의 예지 이미지에서 선분들 사이의 동질성과 독립성을 측정하는 것으로,




Fig. 1. Definition of line metric

그림 1. 선소의 정의

두 목표 사이의 거리뿐만 아니라 선소들의 길이, 각도등 다른 특징 차이들도 근거로 삼았고 복잡한 특징들을 가지는 구조들을 비교하는데 이점이 있다.

그림 1에서 주어진 두 선분, u_0 와 u 사이의 유사도 추정을 위한 이웃 함수의 정의는 다음과 같다.

$$f(u_0, u) = G_{\sigma_{angle}}(\theta - \theta_0) \times G_{\sigma_{lengthwidth}}(R_{\theta_0}^{-1}(x - x_0, y - y_0)) \quad (1)$$

위 식에서 사용되는 계수는 다음과 같다.

- * 방향(각도)의 차이, $\theta - \theta_0$
- * 수평 방향의 두 segment의 중점 사이의 거리, $x - x_0$
- * 한 선소와 다른 선소의 수직 방향 중점 사이의 거리, $y - y_0$

또한, 위치 벡터 성분을 위한 가우시안 함수는 $G_{\sigma}(x)$ 이고 변위 벡터를 위한 가우시안 함수는 $G_{\sigma_x, \sigma_y}(x, y)$ 이다. R_{θ_0} 는 θ 의 회전각이다. 이 식에서 변위각의 표준편차와 중점간의 거리가 모두 선소들의 길이와 관계되어진다고 가정한다. 짧은 선소의 벡터는 긴 선소보다 잡음일 확률이 더 높고, 선소 간의 거리는 긴 선소에 대해 멀어지는 것이 허락된다.

2. 중심 신경망(CNN)

중심신경망[9]은 고전적인 k-means[10]에 기초한 무감독 경쟁 학습 알고리즘으로 입력된 데이터 벡터의 중심 값을 찾는 군집화 알고리즘이다. 중심신경망은 승자 뉴런과 패자 뉴런의 정의를 처음으로 도입하여 빠르고 안정된 수렴속도를 보여주었다. epoch (K)에서 주어진 데이터 x_i 가 있을 때, 승자뉴런은 x_i 와 최소 거리에 있는 뉴런이고 패자 뉴런은 epoch(K-1)에서 승자뉴런이었지만 epoch(K)에서는 승자뉴런이 아




Fig. 2. Example of connected line segments (a) input data, (2) output data
 그림. 2 CNN을 이용한 선소 연결에서 (a) 입력영상, (b) 출력영상

닌 뉴런이다. 중심신경망은 현재의 데이터를 위한 뉴런의 상태가 전 epoch와 비교하여 변화가 있을 때만 가중치를 갱신한다.

현재 epoch가 n , 하나의 입력 벡터가 x 로 일 때, 중심신경망의 승자뉴런 j 와 패자뉴런 i 의 가중치 갱신식은 다음과 같이 정의 된다.

$$w_j(n+1) = w_j(n) + \frac{1}{N_j+1}[x(n) + w_j(n)] \quad (2)$$

$$w_i(n+1) = w_i(n) + \frac{1}{N_i-1}[x(n) - w_i(n)] \quad (3)$$

여기서, $w_j(n)$ 과 $w_i(n)$ 은 각각 승자뉴런과 패자뉴런의 가중치 벡터를 각각 나타낸다.

중심신경망은 군집화와 무감독 경쟁학습에 사용될 때 SOM(Self-Organizing Map)과 k-means같은 기존의 알고리즘보다 학습률을 위해 미리 요구되는 값이나 군집화를 위한 총 학습 반복수를 요구하지 않는 장점을 가지며, SOM같은 기존의 알고리즘들이 초기 결정값에 따라 수렴하지 않는 결과들을 보여주는 동안 빠르고 안정적으로 최준적의 해에 수렴한다[9][11].

3. 선소간의 거리에 기반한 중심 신경망

본 논문에서는 중심신경망을 사용하여 끊어진 선소들을 긴 직선으로 대체하는 접근법을 이용한다. 기존




Fig. 3. Example of rectangles found by the proposed method (a) line segments, (2) output rectangles
 그림.3 제안된 방법으로 찾아진 사각 경계선 예시 (a) 선소 데이터, (b) 사각형 출력

의 중심신경망을 선소들을 연결하기위한 군집화 알고리즘으로 이용하기 위해, 기존의 중심신경망에서 가중치 벡터와 입력된 벡터의 거리를 측정하기 위해 사용되었던 거리척도 대신 위에서 설명한 선분할 측정 함수를 사용한다. 즉, 군집 w_i 와 선소 u 사이의 거리는 다음과 같이 정의된다.

$$d(u, w_i) = 1/f(u, w_i) \quad (4)$$

$f(u, w_i)$ 는 기본적인 선분할 측정 함수로 수식(1)에서 정의되었다.

중심신경망의 학습으로 얻어진 영상에서 하나의 선소로 표현되는 것이 각각의 군집이며, 이 군집화 알고리즘의 최종목적은 작은 선들을 연결하여 하나의 긴 선분으로 만드는 것이다. 결과적으로, 각 군집은 어떤 특정한 위치들을 가져야하고 각 특징은 아래에서 설명된 것 같이 개별적인 갱신 순서를 따라야 한다.

평균거리 :

$$w_{avg_{l_i}}(n+1) = w_{avg_{l_i}}(n) + \frac{1}{n_i+1}[x_{avg_{l_i}}(n) - x_{avg_{l_i}}(n)] \quad (5)$$

$$w_{avg_{l_j}}(n+1) = w_{avg_{l_j}}(n) - \frac{1}{n_j-1}[x_{avg_{l_j}}(n) - x_{avg_{l_j}}(n)] \quad (6)$$

여기서 $w_{avg_{l_i}}(n)$ 과 $w_{avg_{l_j}}(n)$ 는 승자뉴런과 패자뉴런 각각의 평균길이를 나타낸다. N_i 와 N_j 는 각각 군집i와 군집 j에 속하는 현재 데이터의 개수이다.

각 선소들이 가지고 있는 각도에 대한 특징의 갱신 식은 식 (7)과 (8)에서와 같이 표현되고, 여기서 $w_{avg_{\theta_i}}(n)$ 와 $w_{avg_{\theta_j}}(n)$ 는 각각 승자뉴런과 패자뉴런의 있는 곳을 나타낸다. 선소들의 정보는 새로운 선소 군집이나 직선을 생성하는데 사용된다. 분할 처리는 각 선소 군집의 오차가 기준 값보다 작을 때까지 계속 된다.

평균 각도 :

$$w_{avg_{\theta_i}}(n+1) = w_{avg_{\theta_i}}(n) + \frac{x_{avg_{l_i}}(n)[x_{avg_{\theta}}(n) - w_{avg_{\theta_i}}(n)]}{N_i \times w_{avg_{\theta_i}}(n) + x_{avg_{l_i}}(n)} \quad (7)$$

$$w_{avg_{\theta_j}}(n+1) = w_{avg_{\theta_j}}(n) - \frac{x_{avg_{l_j}}(n)[x_{avg_{\theta}}(n) - w_{avg_{\theta_j}}(n)]}{N_j \times w_{avg_{\theta_j}}(n) - x_{avg_{l_j}}(n)} \quad (8)$$


학습이 완료된 후 영상에서 직선을 나타내는 선소 군집들이 얻어지고, 하나의 군집에 속한 모든 선소들을 선형 구조로 연결한다. 이 경우, 생성된 직선은 위에서 제시된 평균 각도를 방향으로 가지게 되고, 선소 군집의 선소들 중 가장 우측과 가장 좌측이 서로 연결된다. 학습의 결과로 연결된 선소들의 예제가 그림 2에 제시되었다.

III. 계층적 군집화 알고리즘


1. 경계선 검출

위의 과정을 통해 연결된 긴 직선들과 원래의 선들을 기초로 건물의 경계선을 생성하기 위해 몇 가지의 규칙을 이용한다. 즉, 어떤 두 선소가 한 쌍의 평행한 모서리 형태로 통합되고, 주변의 다른 선소들이 다른 모서리의 형태를 갖추기 위해 탐색되어 점차적으로 사각형의 형태를 갖추게 된다. 하나의 사각형은 서로 평행한 한 쌍의 선소와 그것에 수직인 다른 한 쌍의 선소로 형성되어야 한다는 특징에 기반하며, 이렇게 조합된 사각형은 건물의 지붕과 대응되고 지붕 인식을 위해 사용될 수 있다. 즉,

단계1) 각 선소 군집에 평행한 선소 분류. 각 선소 군집에 속하는 평균 각도에 의해 다른 군집과 분류 된다.



(a)



(b)

(c)

Fig. 4. Satellite image and edge images (a) original image, (b)2D edge image, (c) 3D edge image

그림 4. 위성영상과 추출된 에지 영상 (a) 원본영상, (b) 2D 에지영상, (c) 3D 에지 영상

단계2) 같은 평행 군집에 속한 선소들의 짝을 조사.

- ① 두 선소 사이의 거리는 각 선소의 길이를 초과할 수 없다.
- ② 하나의 경계로 겹쳐진 후 다음 단계에서 선소 결합을 위한 후보자가 될 수 없다.

단계3) 현재 선소 군집과 수직을 이루는 다른 선소 군집들을 찾는다. 현재의 선소들과 찾은 선소들은 직각이 되어야 하며 반드시 두 개의 평행선에 관계되어진 영역에 존재해야 한다.

단계4) 단계3에서 사용 된 선들은 사용이 제약된다.

단계5) 단계4에서 결정 된 선소 군집의 후보들은 사각형 경계선의 형태로 각각 두 평행선과 두 수직선 사이의 중점을 찾고 이웃한 선소들은 직각을 이루어야 한다. 수직한 네 번째 모서리가 없을 때, 두 평행선 사이의 끝점을 연결하여 사각 형태에 상응하는 직선을 그린다.

2. 계층적 군집화 알고리즘

그림 4의 위성영상에서 스테레오 매칭으로 얻어진 3차원 선소 정보는 상당히 복잡하고 잡음 요소가 많아, 있는 그대로 선소 군집화를 수행할 경우 매우 심




그림 5. 추출된 3D 에지 영상의 높이정보 (a) 3D 에지영상 (b)높이에 따른 선소의 분포도
Fig. 5. Extracted height information (a) 3D edge image, (b) height distribution of line segment

심각한 군집화의 오류가 발생할 수 있다. 특히 높이 정보에 대한 오류는 주변의 지형, 그림자의 영향을 받아 발생하기 쉽고, 또 이러한 영향은 건물의 검출 및 재구성을 방해하는 주요 요인이 된다. 즉, 지붕의 높이는 기본적으로 지표면보다 높은 위치에 있고, 선소의 높이에 관한 잡음정보는 지표면의 물체 또는 건물의 그림자에 의해 주로 발생되므로, 그림 5에서 보여지는 바와 같이 3차원 선소의 데이터를 높이에 관한 히스토그램의 분포를 이용하여, 쉽게 잡음 선소를 제거할 수 있다.

이를 효율적으로 이용하여 3차원 선소를 보다 정확히 군집화 할 수 있는 계층적 군집화 방법이 제안되었다. 선소는 X,Y,Z 좌표의 시작점과 끝점으로 표현할 수 있는데, 히스토그램을 구하기 위해 각 선소의 높이의 중점 값을 이용한다.

전체 3차원 선소들의 높이에 따른 히스토그램을 작성하면 지표면, 또는 정해진 높이 이하의 물체와 그 이상의 영역을 쉽게 확인 할 수 있는데, 높은 위치의 에지정보로부터 차례로 문턱값을 잡아 3차원 선소를 군집화 하는 방법이다. 이렇게 선소데이터를 먼저 분류하고, 학습을 시키게 되면, 잡음의 간섭에 의해 잘못 생성되는 사각형을 줄이고 보다 신뢰할 수 있는 결과를 얻을 수 있다.

IV. 실험 및 결과

위성영상을 이용하여 제안된 방법을 평가하기 위한 실험들이 수행되었다. 한 지역의 위성영상에 에지검

출 알고리즘을 사용하여 다른 모양과 높이의 많은 건물들을 포함하고 있는 1024×1024크기의 에지 이미지를 얻었다. 그러나 그림 6에서 나무들이나 길처럼 건물들을 간섭하고 있는 다른 많은 목표물들이 있다는



그림 6. 입력 위성영상
Fig. 6. Input satellite image




그림 7. 추출된 에지 이미지
Fig. 7. Extracted edges




그림 8. CNN의 군집화결과
Fig. 8. Clustering results with the CNN




그림 9. 추출된 사각형들
Fig. 9. Extracted rectangles

것을 알 수 있다. 결과적으로, 끊어진 선들은 물론 잡음 요소들도 많이 가지게 되어 결과 이미지는 상당히 복잡하다. 그림 7의 에지이미지에는 총 1148개의 선분이 존재한다. 그림 7에서의 건물 인식 문제를 해결하기 위해 우리의 제안된 방법을 사용하였다. 첫 단계로 끊어진 선들을 연결하기 위해, 본 논문에서 제안하는 선분할 함수와 결합한 중심신경망 알고리즘을 수행한다.

군집화 동작은 이웃한 경계선에 같은 선형구조의 선소들이 없다고 간주될 때까지 계속된다. 그림 8에서처럼 이 과정 후에 대부분의 끊어져있던 선들이 완벽하게 연결되었고, 총 961개의 선분이 존재한다.

이 결과는 선분할 함수와 결합한 중심신경망이 노이즈로 간주될 수도 있는 끊어진 선들(전체 윤곽선의 16.3%)을 알맞게 제거해 주었다는 것을 보여준다. 다음단계는 추출한 직선들을 흐릿한 사각형의 모양에서 점차 뚜렷한 사각형 모양으로 그룹화하는 것이다. 이 단계는 본문 2장의 내용을 따르며 결과는 그림 9에

주어진다. 0.67의 정밀 검출비를 가지며, 100개 정도의 사각형이 검출되었다. 추출된 건물의 외곽선들은 높이와 그림자 정보를 이용한 3-D처리에 적용하기 위한 기초적 정보를 제공한다.

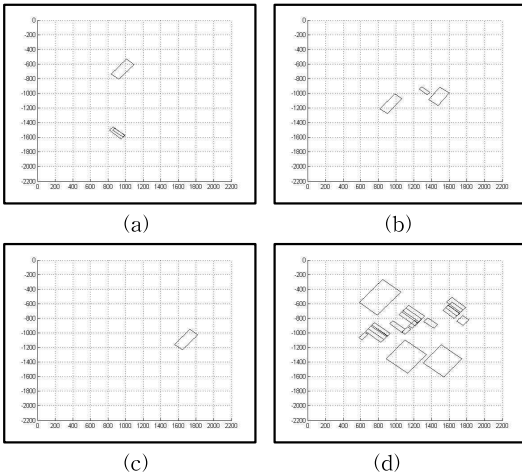


Fig. 10. Extraction of rectangles w.r.t. height information
 그림 10. 데이터의 높이에 따른 사각 경계선 추출.
 (a) 17-18m (b) 15-17m (c) 2-15m (d) 지표면

이제 건물의 검출 결과를 정확히 보여주기 위하여, 비교적 적은 구역의 데이터를 이용한 실험을 통해, 시각적으로 결과를 확인 할 수 있도록 하였다. 그림 4-(a)의 영상에 대하여, 에지를 추출하고, 위의 과정과 같이 제안된 중심신경망을 적용하여, 추출된 선소들을 군집화하여 나온 그림 5-(a)의 3차원 선소정보 데이터에 대해, 선소의 높이 분포도인 그림 5-(b)를 구하고, 이 분포도를 이용하여 높은 높이부터 문턱값을 정하여 선소들을 나누고, 높이가 비슷한 개별 그룹에 대하여 군집화와 사각형 발생을 수행한 결과가 그림 10에 나타나 있다. 여기서 20m 이상의 데이터는 원래의 영상에서 추출된 3D 선소는 일정부분 존재하지만, 원래의 영상에서 건물들이 존재하는 지역이 산중턱이기 때문에 건물과는 관계없는 정보이다.

실험을 통해, 제안된 계층적 군집화 알고리즘은 부정확한 건물 형태의 발생을 최대한 억제하면서, 실제 건물모델을 효율적으로 발생시킬 수 있음을 알 수 있다. 그림 11에서 청색으로 보이는 것은 실제의 건물이고, 검은색의 선으로 이루어진 사각형은 지표면에 위치한 건물이 아닌 사각형 형태의 윤곽선이다. 아마도 수조 또는 지표면에 파놓은 구조물로 추측된다.

그림 11의 (a), (b)에서 볼 수 있듯이 제안하는 계층적 데이터 군집화를 이용하지 않는 경우에는 지표면상의 에지와 건물의 에지성분이 결합하여, 건물을 지표면으로 인식하는 오류를 가지는 사각 건물형태를 구성하는 문제가 종종 발생함을 확인 할 수 있다.

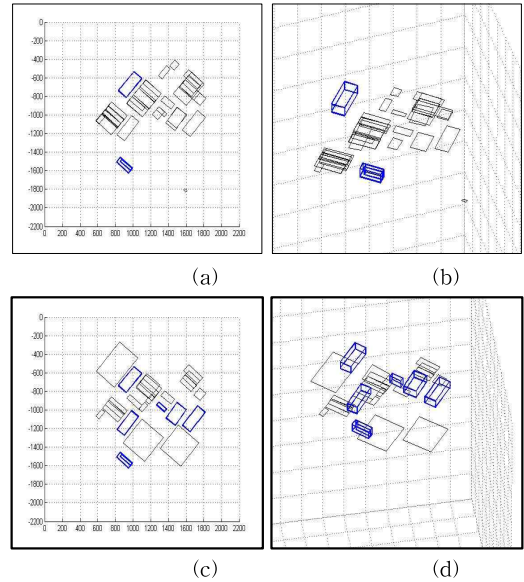


Fig. 11. Reconstructed buildings with hierarchical clustering
 (a)17-18m height (b)3-D rendering (c)all buildings
 (d)reconstructed buildings
 그림.11.계층적 군집화에 의한 건물 발생결과 (a) 17-18m 이 건물 (b) 3-D 발생 (c) 전체건물 (d)전체건물

V. 결론

위성영상에서 사각형태의 경계선을 추출하기 위한 새로운 접근법이 본 논문에서 제시되었다. 제안된 접근법은 에지 검출 알고리즘으로부터 얻어진 에지 이미지에 존재하는 끊어진 선소들을 연결하기 위하여, 새로이 제안된 중심신경망을 사용하는 것이다. 본 논문에서 새로이 제안된 중심신경망은 기존의 중심신경망에 선분할 함수를 거리도구로 사용하는 것으로, 에지 이미지의 끊김이 많은 선들을 감소시키고, 보다 정확한 건물의 윤곽을 위한 사각 형태의 경계선을 검출할 수 있다. 또한 원래의 선들이 사각의 형태를 갖추기 위해 점차적으로 연결되는 계층적구조의 군집화를 통해 더욱 안정적이고, 잡음을 제거하여 신뢰성 높은 결과를 얻을 수 있었다. 향후의 연구에서는,

그림자에 대한 처리방법을 고려하는 3-D 검증 작업에 의해 더욱 정확한 사각의 경계선을 얻을 수 있을 것이다.

참고문헌

[1] O. Henricsson, "The role of color attributes and similarity grouping in 3-d building reconstruction," *CVIU*, 2(72), pp. 163-184, Nov 1998

[2] 우동민, 박동철, 호하이느웬, 김태현, "중심신경망을 이용한 3차원 선소의 군집화에 의한 위성영상의 3차원 건물모델 재구성," *한국원격탐사학회 논문지*, 27(2), pp. 121-130, 2011

[3] Z. Kim and R. Nevatia, "Automatic description of complex buildings from multiple images," *CVIU*, 1(96)6, pp. 60 - 95, 2004

[4] S. Noronha and R. Nevatia, "Detection and modeling of buildings from multiple aerial images," *IEEE Tr. on PAMI*, 5(23), pp. 501 - 518, 2001

[5] O. Simonetto and R. Garello, "Rectangular building extraction from airborne radar images," *IEEE Tr. on GRS*, 10(43), pp. 2386 - 2395, 2005

[6] A. Katartzis and Sahli, "A stochastic framework for the identification of building rooftops using a single remote sensing image," *IEEE Tr. on GRS*, 1(46), pp. 259 - 271, 2008

[7] C. Lin and R. Nevatia, "Building detection and description from a single intensity image," *CVIU*, Vol 2, no. 72, pp. 101 - 121, 1998

[8] P. F. M. Nacken. "A metric for line segments.", *IEEE Trans on Pattern Analysis and Machine Intelligence*, Vol 12, no. 15, pp. 1312 - 1318, 1993.

[9] D. C. Park. "Centroid neural network for unsupervised competitive learning," *IEEE Tr. on Neural Networks*, 2(11), pp. 520-528, 2000

[10] C. Darken and J. Moody, "Fast adaptive k-means clustering. Some empirical results.", *Proc. of IJCNNs*, Vol 2, pp. 2:238-242, 1990

[11] D. C. Park and Y. Woo. "Weighted centroid neural network for edge reserving image compression." *IEEE Tr. on Neural Networks*, Vol 12, pp. 1134 - 1146, 2001

[12] D.-C. Park, O.-H. Kwon, J. Chung, " Centroid

Neural Network with a Divergence Measure for GPDF Data Clustering," *IEEE Tr. on Neural Networks*, 19(6), pp.958-970, 2008.

저 자 소 개

한 지 호 (학생회원)



2011년 : 명지대학교 정보공학과 졸업 (공학사)
 2011년 3월~현재 : 명지대학교 대학원 전자공학과 석사과정
 <주관심분야> 신경망, 영상처리, 신호처리.

우 동 민 (정회원)



1980년 : 연세대학교 전자공학과 졸업 (공학사)
 1982년 : 연세대학교 대학원 전자공학과 (공학석사)
 1987년 : 케이스웨스턴대학교 대학원 전기공학과 (공학박사)
 1990년 3월~현재 : 명지대학교 전자공학과 교수
 <주관심분야> 영상해석, 위성영상처리

박 동 철 (정회원)

전기전자학회 논문지 15권 3호 참고

정 태 경 (정회원)

전기전자학회 논문지 15권 3호 참고

이 윤 식 (정회원)

전기전자학회 논문지 15권 3호 참고

민 수 영 (정회원)

전기전자학회 논문지 15권 3호 참고