

크기에 강인한 인공물 추출 방법

손길호^o 김상희 이용웅
국방과학연구소

khson@add.re.kr falcon@add.re.kr lyw4638@add.re.kr

Scale-invariant man-made structure extraction algorithm

Kil-Ho Son^o Sang-Hee Kim Yong Woong Lee
Agency of Defense Development

요 약

이 논문에서 크기의 변화에 강인한 인공물 추출 알고리즘을 제안한다. 인공물은 크기 및 카메라 센서의 특성에 따라 영상에 다양한 크기로 나타난다. 이 논문은 이러한 크기 변화에 강인한 인공물 추출 방법을 제안한다. 우선 LoG(Laplacian of Gaussian)를 이용하여 최적의 크기를 찾아낸다. 이를 이용하여 우리는 이웃한 정보를 포함할 수 있는 MAP-MRF(Maximum A Posterior - Markov Random Field) 레이블링(Labeling) 방법을 기반으로 인공물 추출을 위한 비용함수를 제안하였다. 인공물은 서로 근처에 존재하기 때문이다. 여기서 정보 비용함수(Data cost function)는 방향 히스토그램(Orientation histogram)을 이용하여 정의하였고, 스무딩 비용함수(Smoothing cost function)는 ICM(Iterated Conditional Modes)을 이용하여 정의한다. 최종적으로 이 알고리즘을 위성영상에 적용하여 알고리즘의 성능을 증명한다.

1. Introduction

이 논문은 크기의 변화에 강인한 인공물 추출 알고리즘을 제안한다. 여기서 인공물영역 이라 함은 영상에 직선, 코너(Corner), Y 정션(Junction) 등이 존재하는 영역이다.(그림 1) 이러한 인공물 검출 알고리즘은 많은 영역에 적용될 수 있다. 영상을 해석할 때나, 검출(Detection)문제에도 활용될 수 있다. 또한 로봇의 경로를 지정 주거나, 감시 시스템에도 적용될 수 있다.



그림 1. Man-made structure

인공물은 직선으로 이루어졌다는 것을 감안한다면 기존의 직선을 찾는 line linking 방법 등을 이용하여 직선을 찾고 이를 이용하여 인공물을 찾을 수 있다. 하지만 외곽선이나 직선의 경우 영상의 잡음에 따라 변화가 심하다. 또한 코너도 인공물의 대표적인 특징이므로 해리스(Harris) 코너 등을 이용하여 코너를 찾은 후 인공물을 찾을 수 있다. 하지만 이러한 경우 코너가 되는 점(Point)는 찾아주지만 전체적인 영역을 찾아주지는 못한

다. 따라서 이러한 한계를 이겨내는 강인하게 인공물을 찾아내는 알고리즘이 필요하다.

이러한 연구는 대표적으로 Kumar et. al.[1]에 의해 연구되어왔다. [1]은 영상에서 사각형의 영역으로 영상을 분할하고 이 분할된 영역이 인공 구조물 인지 자연 물인지를 구분해내는 방법론을 제시하였다. 그림2 (a)처럼 $f(\text{Node})$ 에 영향을 미치는 숨겨진 요인(x^n)을 가정하고 그 숨겨진 요인 위에 또 다른 숨겨진 요인(x^{n-1})이 있음을 가정하는 식으로 요인의 계층구조를 정의 하였다. 학습데이터의 각 $f(\text{Node})$ 에서 14 차원의 특징 점(Feature)를 뽑고, 최대 예상(Expectation Maximization)방법을 사용하여 인공물을 8개의 가우시안(Gaussian)으로 모델링(Modeling)한다. 이를 이용하여 실험데이터의 가능성 확률(Likelihood probability)을 구하고, 메시지 전달(Belief propagation)알고리즘과 예상 최대 방법을 이용하여 노드간의 관계를 구하였다. 그리고 마지막으로 메시지 전달방법을 이용하여 $f(\text{Node})$ 의 최종 인공물일 확률을 추정함으로써 그림2 (b)와 같이 인공 구조물을 구분해 낼 수 있다. 이렇게 [1]에서는 문맥적 정보(Contextual information)를 사용하여 합리적으로 인공물을 추출하는 방법을 제안하였다. 하지만 이러한 방법은 구현하기 어려울 뿐만 아니라 특징 점(Feature)의 차원(Dimension)이 14차원이므로 학습을 위한 다량의 학습 데이터가 필요하다라는 단점이 있다. 또한 인공물은 크기 및 카메라

센서 특성에 따라 인공물은 영상에 다양한 크기로 생성 되는데 이에 대한 해결책을 제시해 주지 않는다.

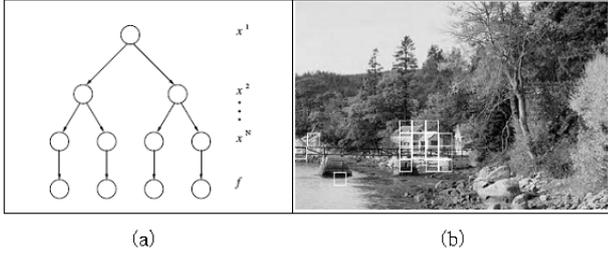


그림 2. Previous works of man-made structure detection

(a)Graphical model, (b) Final result

이에 이 논문에서는 소량의 학습데이터를 이용하여 크기 변화에 강인하게 인공물을 추출하는 방법을 제안한다.

2. MRF-MAP(Markov Random Field - Maximum a Posterior)

본 논문에서는 인공물을 찾기 위해 문맥적 제약을 한다. 건물이나 도로 등의 인공물 영역은 서로 이웃해 있기 때문이다. 이러한 문맥적 정보를 얻기 위해 MRF-MAP기반의 비용함수를 정의하고 이 함수가 최소값을 만족하는 경우를 찾아 인공물영역을 찾아낸다.

주어진 영상에 대해, 인공물 추출문제는 각 영역마다 인공물인지 아닌지를 구분하는 분류문제라 할 수 있다. Y

를 관찰되는 정보라(Observed data)하자. $Y = (y_m)_{m=1}^M$

로 표현되며, y_m 은 m번째 영역의 정보이다. 각 영상

영역에서 이에 대응되는 분류결과가 $X = (x_m)_{m=1}^M$,라

고 주어졌다. 여기서 $x_m = \{0,1\}$ 이다. 이때 MRF-MAP를 기반으로 한 비용함수는 다음과 같다.[4]

$$-\ln P(X | Y) \propto \sum_i^M \alpha(y_i, x_i) + \sum_i^M \sum_j^{N(i)} \beta(x_i, x_j) \quad (1)$$

결과적으로 Posterior 확률의 최대값을 찾는 것은 식 (1)의 최소값을 찾는 것과 같다. 우리는 식(1)의 첫 번째 항(Term)을 정보 비용함수 (Data cost function) 이라 하고, 두 번째항(Term)을 스무딩 비용함수 (Smoothing cost function)라 한다. 이 두 항목을 정의함으로써 인공물을 찾기 위한 비용 함수가 정의된다.

2.1. Data cost function

인공물 영역이란 앞에서 정의했듯 직선, 코너, Y 정션 등이 존재하는 영역이라 볼 수 있다. 이러한 영역의 경우 방향 히스토그램(Orientation histogram)이 한 방향이나 두 방향에서 정점을 이루게 된다. 방향 히스토그램에서 가장 큰 값을 중심으로 빈(Bin)값을 이동 시키면 그림4와 같은 결과를 가져오게 된다. 따라서 각 방향 히스토그램의 빈은 각 영역의 특징 점(Feature)이 되며, 이러한 특징 점은 인공물을 특징을 정확히 표현하고 있다. 따라서 이러한 특징 점을 이용하여 정보 비용함수를 정의 할 수 있다. 그 과정은 다음과 같다.

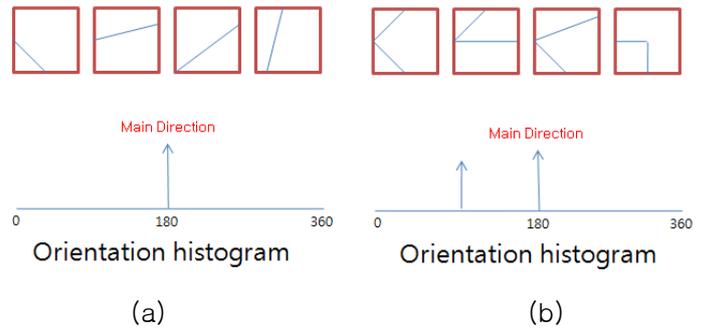


그림 3. Orientation histogram representation of man-made structure

(a) Orientation histogram in a line region

(b) Orientation histogram in a corner region

우선 각 영상을 가우시안(Gaussian)으로 컨볼루션(Convolution) 하여 영상의 잡음(Noise)을 제거 한한 후 학습을 데이터를 다음과 같이 저장한다.

$$E'_\delta = \frac{\sum_{i=1}^{\Delta} K((\delta-i)/h)E_i}{\sum_{i=1}^{\Delta} K((\delta-i)/h)} \quad (2)$$

E'_δ 을 히스토그램의 (Histogram) δ^{th} 빈(Bin)의 크기라 하고 Δ 을 빈의 총 개수라 한다면 커널(Kernel)을 이용하여 스무딩(Smoothing)을 한다. 여기서 커널의 밴드워스(Bandwidth)는 h이며, 커널은 대칭이며, 양수 함수이다.

학습데이터로부터 인공물과 자연물의 데이터를 식 (2)와 같이 저장하고 조명에(Illumination)강인하게하기 위해 정상화(Normalization)를 한다. 가장 가까운 이웃

(Nearest neighborhood)을 찾아 정보 비용함수를 정의한다. 즉 정보 비용함수는 다음과 같다.

$$\alpha(y_i, x_i) = \|O(y_i) - O(D_{x_i})\| \quad (3)$$

여기서 $O(y_i)$ 은 i 영역에서 관측된 회전 히스토그램이며, $O(D_{x_i})$ 는 x_i 인 경우의 저장된 회전 히스토그램을 뜻한다.

하지만 이러한 정보 비용함수의 경우, 저장되어있는 정보가 많으면 많을수록 결과를 만드는데 시간이 오래 걸린다는 단점이 있다. 따라서 본 논문에서는 저장되는 정보를 줄이기 위해 자기학습방법(Self training)방법을 제안한다.

Self training

우선 저장된 방향 히스토그램 정보를 자기 자신과 비교한다. 다시 말해, 만약 인공물이라 저장된 정보가 자연물 정보와 가장 유사함을 보이면 오류(Outlier)라 규정하고 제거한다. 반대로 자연물이라 저장된 정보가 인공물 정보와 가장 유사함을 보이면 오류라 규정하고 제거한다. 그 후 저장된 방향 히스토그램을 K 개로 무리를 짓고(Clustering) 이 각 무리를 대표하는 정보만을 취해, 저장되는 정보의 양을 줄인다.

2.2. Smoothing cost function

본 논문에서는 인공물의 문맥적 정보를 얻기 위해 ICM (Iterated Conditional Mode)[3]을 적용하여 스무딩 비용함수를 정의한다. ICM의 기본 아이디어는 그림 4와 같다. 인공물이라 약하게 판정 내려진 영역의 주위에 자연물 영역이 많으면, 인공물 영역은 자연물로 바뀌게 되는 반면 강하게 인공물이라고 판정 내려진 영역에는 주위에 자연물 영역이 많아도 결정이 바뀌지 않는다. 다시 말해 ICM은 포텐셜(Potential) 함수를 다음과 같이 정의함으로써 주위정보를 얻는다.

$$\sum_j^{N(i)} \beta(x_i, x_j) = \sum_j^{N(i)} \mu x_i x_j \quad (4)$$

여기서 μ 는 i 와 j 의 상호작용상수(Interaction parameter)이고 $x_i \cdot x_j = \{0,1\}$ 이다.

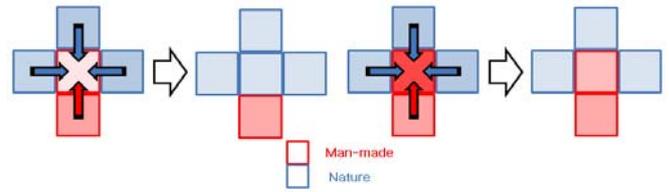


그림 4. Iterated conditional mode algorithm

3. Automatic scale selection

인공물은 센서의 특성 및 인공물의 크기에 따라 다양한 크기로 영상으로 형성된다. 이러한 경우 인공물인지 아닌지를 판단하는 것이 어렵게 된다. 크기가 변하면 크게 2가지 정도의 문제점이 생긴다.

첫 번째 패치가 일정한 경우 크기가 바뀔 때 따라 인공물이 포함되는 정도가 달라진다. 크기가 작아지면 작아질수록 패치가 포함하는 영역이 커지기 때문에 회전 히스토그램은 무작위로(Random) 변하게 되고 따라서 인공물로 분류되기 힘들다.

두 번째로 인공물이 카메라와 멀어지면 CCD의 해상도 오차 및 대기와 렌즈에 의한 오차가 커지기 때문에 그림과 같이 회전 히스토그램의 에러가 증가하게 된다. 인공물의 크기가 줄어들면 줄어들수록 인공물의 픽셀 기울기(Gradient)에 오차가 생기는 것을 확인 할 수 있다. 방향 히스토그램을 비교해 보면 같은 인공물에서 얻은 영상이라도 다르다는 것을 확인 할 수 있다.

이러한 문제점을 해결하기 위해 우선 자동으로 스케일을 찾아내는 방법을 이용한다.[5] 이 방법을 이용하여 가장 적합한 크기를 찾아내고 이에 따라 패치의 크기를 결정한다. 그리고 인공물의 크기가 줄어들수록 생기는 오차를 없애기 위해 기울기를 구할 때(Gradient) 좀 더 멀리 있는 이웃을 이용하여 기울기를 구한다.

4. 실험 결과 및 분석

우선 학습영상을 CCD카메라를 이용하여 그림 4와 같이 각각 3장의 인공물, 자연물 영상을 얻었다. 이 영상으로 80330개의 패치(Patch)를 얻었다. (그림 5)

하지만 이렇게 많은 학습 패치로는 시간이 오래 걸리므로 자기 학습법을 통해 각각 10개의 대표되는 패치로 줄였다. 대표되는 패치의 히스토그램은 그림 6과 같다.



그림 5. Training data

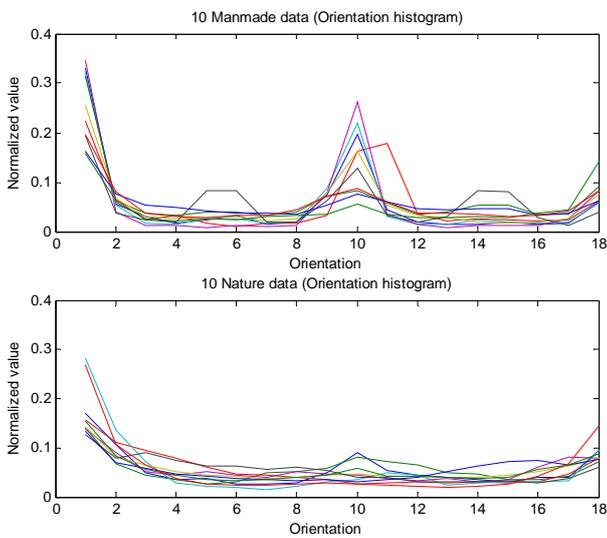


그림 6. Orientation histogram

위 그림을 보면 알 수 있듯이 인공물의 방향 히스토그램은 1개 또는 2개의 의 최고점을 가지거나 3개의 최고점을 가지는 것을 볼 수 있다. 이는 인공물은 선분이나 코너 Y 정션등이 존재하기 때문이다. 반면 자연물의 경우 임의로(Random) 방향 히스토그램이 생성되는 것을 볼 수 있다.

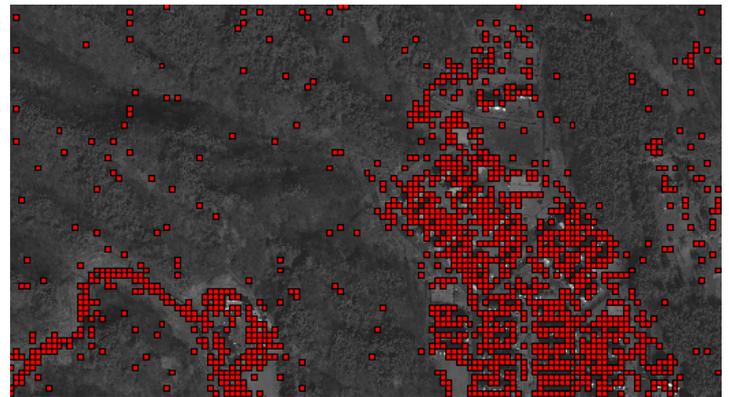
본 논문에서 제안하는 방법을 증명하기 위해 Quick Bird 위성으로부터 전송받은 영상에 대해 언급한 방법을 적용하였다. Quick Bird 영상 중 한 개의 주파수 대역만을 저장한 (Panchromatic) 영상을 실험하였다. 실험 영상은 한 픽셀 당 평균 0.751m의 GSD(Ground Sample Distance)이며 이 위성영상은 기하학적으로 변(Geometrical correction)은 하지 않았고, 방사적 보정(Radiometric correction)은 행한 후의 영상이다.

패치의 크기는 작으면 작을수록 더욱 자세하게 분할되기 때문에 좋지만 너무 작을 경우 패치 내에서 얻을 수 있는 정보가 부족하여 결과가 부정확해 진다. 이 논문에서

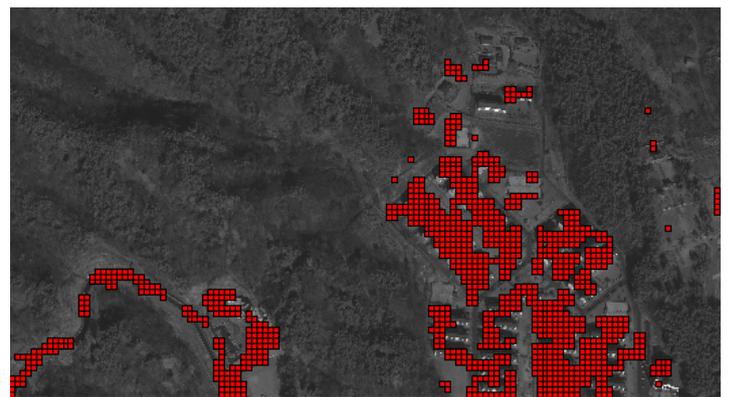
는 12*12 픽셀(Pixel)의 패치로 구분하였다. 앞에서 제시한 패치의 크기를 자동으로 정하는 방법은 아직 구체적으로 구현되지 않았다. 상호작용 상수 μ 는 0.1 로 하였다.



(a) Input image



(b) Data cost function



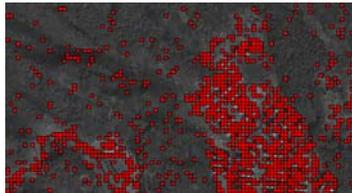
(c) Smoothing cost function

그림 7. Original image results

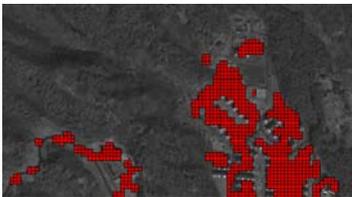
그림 7. (a)는 887*1596 크기의 위성영상이다. 그림 7. (b) 는 정보 비용함수만을 이용하여 얻은 결과이다. 붉은 색 사각형이 인공물로 판명 된 것이다. 중간 중간에 잘못 레이블이 되어있는 것도 있지만 인공물을 찾는 경향성은 보이고 있다. 그림 7. (c) 는 스무딩 비용함수를 이

용하여 얻은 결과물이다. 합리적인 결과를 보여주고 있다.

우리는 우리가 제안한 방법이 크기의 변화에도 강인한지에 대해 실험을 하기 위해 앞의 영상을 절반의 크기인 443*798 크기로 영상을 작게 변환 후 제안한 방법을 적용하였다. 이때 패치의 크기는 8*8 픽셀(Pixel)로 수정하였다.



(a) Data cost function



(b) Smoothing cost function

그림 8. Small image results

그림 8의 결과를 보면 알 수 있듯이 영상의 크기가 줄어들어도 인공물 검출에는 큰 영향을 미치지 않는 것을 볼 수 있다. 이에 우리가 제안한 알고리즘이 크기의 변화에 강인하게 인공물을 찾을 수 있음을 알 수 있다. 결과에 대한 오차는 표 1과 같다. 표1에서 볼 수 있듯 합리적인 결과를 보임을 알 수 있다.

요한 것은 적당한 패치의 크기를 찾는 것이 관건이라 하겠다. 작은 패치의 크기는 정보의 양이 너무 작아 오류를 만들고, 큰 패치는 너무 많은 정보로 인해 오류를 만들며, 영상의 인공물을 자세하게 구분하지 못하게 한다. 우리는 이렇게 패치의 크기를 자동으로 찾는 방법으로 [5]의 방법을 이용할 것이다. 이를 이용하여 효과적인 패치의 크기를 찾는 것이 앞으로 과제라 하겠다.

Reference

[1] S. Kumar, "Man-Made Structure Detection in Natural Images using a Causal Multiscale Random Field", in *Proceedings of the IEEE International Conference on Computer Vision*, 2003.
 [2] S. Kumar, "Discriminative random fields for modeling spatial dependencies in natural images", *Advances in Neural Information Processing Systems, NIPS 16*, 2004.
 [3] J. Besag, "On the statistical analysis of dirty pictures", *Journal of the Royal Statistical Society*, 1986.
 [4] Stan Z. Li, *Markov random field modeling in image analysis*, Springer-Verlag, pages 11-16, 2001
 [5] Lindeberg, T. "Feature detection with automatic scale selection", *International Journal of Computer Vision*, 1998.

	False alarm	Missing alarm
Original images	1.1%	5.2%
Small images	1.3%	5.5%

표 1. False alarm and missing alarm

5. 결론

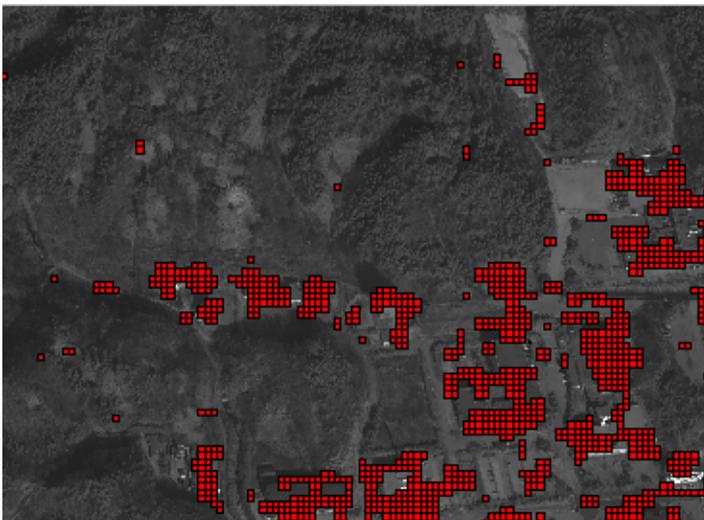
우리는 크기에 강인한 인공물 검출 알고리즘 제안하였다. 인공물은 인공물의 크기 CCD 센서와의 거리 등으로 인해 영상에 다양하게 형성된다. 우리 알고리즘은 이러한 변화에도 불구하고 강인하게 인공물을 찾아내고 있음을 확인 할 수 있었다. 하지만 이 알고리즘에서 가장 중



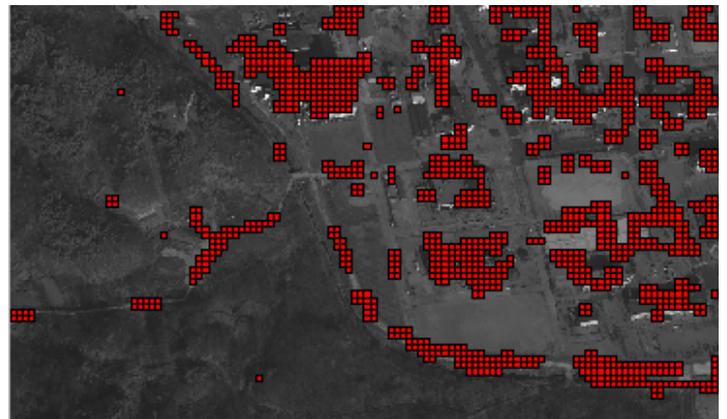
(a) Original image



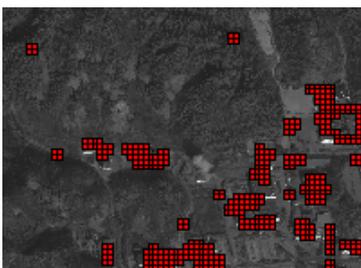
(d) Original image



(b) Man-made detection results (Scale : 10 pixel)



(e) Man-made detection results (Scale : 10 pixel)



(c) Man-made detection results in small images
(Scale : 8 pixel)



(f) Man-made detection results in small images
(Scale : 8 pixel)

그림 9. Final results