

가중치 특징 벡터를 이용한 질감 영상 인식 방법

정수연, 곽동민, 윤옥경, 박길홍

경북대학교 전자공학과

Texture Classification by a Fusion of Weighted Feature

Su-yeon Jung, Dong-min Kwak, Ock-kyung Yoon, Kil-houm Park

Dept. of Electronics, Kyungpook National Univ.

E-mail : jinny00@palgong.knu.ac.kr

요약

최근 영상 검색(retrieval)과 분류(classification)에서 질감 특징(texture feature)을 이용한 연구들이 활발하게 진행되고 있다. 본 논문에서는 효율적인 질감 특징 추출을 위해 명암도 상호발생 행렬법(gray level co-occurrence matrix)과 웨이블릿 변환(wavelet transform)을 이용하여 질감의 특징을 추출한 후 특징의 중요도에 따라서 가중치를 부여하는 방법을 제안한다. 이렇게 추출된 가중치 대표 벡터들을 기반으로 베이시안 분류기(Bayesian classifier)를 통해 임의의 질감을 인식하였다.

1. 서 론

영상에서 질감이란 성질 혹은 형태가 비슷한 기본요소(primitive)들로 구성된 부분을 의미한다. 질감 영상 해석(analysis)은 인간 시각(human vision), 컴퓨터 비전(computer vision), 형태 인식(pattern recognition)등에 효과적이므로 공장 자동화, 의료 영상 처리(biomedical image processing), 원거리 감지(remote sensing), 반도체 및 금속의 표면검사, 항공사진으로부터의 지형의 추출, 산림 분포의 구분, 기계부품의 분류 등의 여러분야에서 광범위하게 사용된다.^[1]

오랜 기간 동안 질감 해석과 분류, 분할(segmentation) 방법에 대해 많은 연구가 있어 왔다. 그러나 이러한 노력에도 불구하고 질감 해석 방법은 영상 처리 분야에서 그 중요성에 비해 어려운 방법으로 인식되고 있다.

질감 특징 추출 방법은 구조적 접근법(structural approach), 통계적 접근법(statistical approach), 공간

주파수 해석법(spatial frequency analysis)의 세가지로 나눌 수 있다. 구조적 접근법에는 형태학적 연산을 이용한 질감인식법 등이 있으며 통계적 접근법에는 Tamura 방법, 명암도 상호발생 행렬법, 질감 에너지법(texture energy), 질감 스펙트럼법(texture spectrum), 명암도 차이법(gray level difference), 선길이 통계법(run length statistics), 프랙탈 특징법(fractal feature) 등이 있고, 공간 주파수 해석법에는 Gabor 필터, 웨이블릿 변환법 등이 있다. 이 중 명암도 상호 발생 행렬법과 웨이블릿 변환법이 인식률에서 좋은 결과를 보이는 것으로 알려져 있다.^[1]

명암도 상호 발생 행렬은 전체 영상에 대한 통계적인 방법을 사용하기 때문에 영상의 크기가 작은 경우에는 영상의 특징을 제대로 나타내지 못하게 되고, 큰 영상일 경우에는 수행시간이 길어지는 단점을 가진다.

본 논문에서는 명암도 상호 발생 행렬을 간단히 소개하고 단점을 보완하기 위한 방법을 제안한다. 사용된 방법은 명암도 상호 발생 행렬법으로 추출된 특징벡터의 각 특징별 중요도에 따라 알맞은 가중치를 부여하는 것이다. 이 방법에서는 질감 영상의 특성에 따라 특징마다 다른 가중치가 부여되므로 가중치 특징 벡터는 각 질감마다 고유한 값을 가지는 질감의 대표 벡터로 사용될 수 있게 된다. 이 방법은 작은 영상에서도 좋은 결과를 보인다. 또한, 더욱 높은 인식률과 빠른 수행시간을 위해 웨이블릿 특징과 명암도 상호 발생 행렬의 특징을 조합하여 사용하였다. 추출된 대표 벡터는 베이시안 분류기에서 임의의 질감 영상의 인식을 위한 결정함수를 구하는데 적용되었다.

2. 명암도 상호 발생 행렬과 웨이블릿 변환

2.1 명암도 상호 발생 행렬(GLCM : Gray-Level Co-Occurrence Matrix)

명암도 상호발생 행렬(이하 GLCM)은 영상의 2차적 통계 특성을 포함한 상호발생 행렬을 구하고 이 행렬로부터 특징을 추출하는 방법이다. 상호발생 행렬은 두 비교 화소 사이의 거리와 방향을 변수로 하여 영상내에서 발생되는 화소값쌍의 회수를 명암도값 크기의 행과 열에 누적시킨 행렬이다. GLCM의 분포 특징은 질감이 굵은(coarse texture) 경우 행렬의 주 대각선 상에 아주 큰 값이 분포되고 가늘고 세밀한(fine texture) 경우 행렬 전체에 넓게 분포된다.

전체 영상의 크기가 $N \times N$ 일 때, $p(i, j)$ 를 (i, j) 형태의 graylevel값을 가지는 화소쌍의 전체 영상의 확률이라면, 행렬의 행과 열에 대한 평균과 표준편자는

$$\mu_x = \sum_i \sum_j i \cdot p(i, j), \quad \mu_y = \sum_i \sum_j j \cdot p(i, j) \quad (1)$$

$$\sigma_x^2 = \sum_i \sum_j (i - \mu_x)^2 \cdot p(i, j) \quad (2)$$

$$\sigma_y^2 = \sum_i \sum_j (j - \mu_y)^2 \cdot p(i, j) \quad (3)$$

이고, GLCM은 다음과 같은 특징들을 가진다.^[2]

1)Energy :

$$f_1 = \sum_i \sum_j p(i, j)^2 \quad (4)$$

2)Contrast :

$$f_2 = \sum_{n=0}^{N-1} n^2 \left\{ \sum_{i=1}^{N-1} \sum_{j=1}^{N-1} p(i, j) \mid |i-j|=n \right\} \quad (5)$$

3)Correlation :

$$f_3 = \frac{\sum_i \sum_j (ij)p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (6)$$

4)Homogeneity :

$$f_4 = \sum_i \sum_j \frac{1}{1 + (i-j)^2} p(i, j) \quad (7)$$

5)Entropy :

$$f_5 = - \sum_i \sum_j p(i, j) \log(p(i, j)) \quad (8)$$

6)Autocorrelation :

$$f_6 = \sum_i \sum_j (ij)p(i, j) \quad (9)$$

7)Dissimilarity :

$$f_7 = \sum_i \sum_j |i-j| \cdot p(i, j) \quad (10)$$

8)Cluster Shade :

$$f_8 = \sum_i \sum_j (i+j - \mu_x - \mu_y)^3 p(i, j) \quad (11)$$

9)Cluster Prominence :

$$f_9 = \sum_i \sum_j (i+j - \mu_x - \mu_y)^4 p(i, j) \quad (12)$$

10)Maximum Probability :

$$f_{10} = \max_{i, j} p(i, j) \quad (13)$$

GLCM에서는 $0^\circ, 45^\circ, 90^\circ, 135^\circ$ 의 방향에 있는 거리는 1과 2정도의 픽셀들을 고려하여 특징들을 추출해낸다.

2.2 웨이블릿 변환(Wavelet Transform)

웨이블릿 변환이란 모 웨이블릿(mother wavelet) $\Psi(t)$ 로부터 스케일링=scaling)과 전이(translation)에 의해 발생되는 함수들을 말한다.

웨이블릿 기저 함수는 다음과 같이 표현되며,

$$\Psi_{a, b}(t) = \frac{1}{\sqrt{|a|}} \Psi\left(\frac{t-b}{a}\right) \quad a \neq 0, a, b \in R \quad (14)$$

웨이블릿 변환은 다음식으로 표현된다.^[3,4]

$$X_w(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} \Psi^*(\frac{t-b}{a}) x(t) dt \quad (15)$$

웨이블릿 변환은 시간과 주파수에 대한 국부성(locality)을 갖고 신호를 표현할 수 있어서 비정재성(non-stationary)을 갖는 영상 신호를 해석함에 유리하다.

영상을 웨이블릿 변환하면 서로 다른 계층의 다해상도 부채널 신호를 얻을 수 있다. 2차원 신호인 영상을 웨이블릿 변환하기 위해서 1차원 신호와 유사한 방식으로, 처음에는 행방향으로 다음 열방향으로 QMF(Quadrature Mirror Filter)를 통과시켜 웨이블릿 변환을 수행하게 된다.

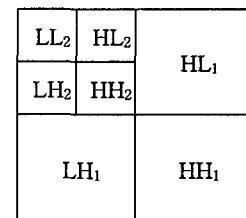


그림 1. 영상의 2-level 웨이블릿 변환

위의 그림처럼 변환된 웨이블릿 밴드의 계수들은 각 부밴드의 특성을 가지게 된다. 가장 높은 레벨의 계수는 다른 레벨의 계수들과는 다른 통계적 특징을 가지고 있고 원 영상의 통계적 성질을 유지한다는 특징이 있다.

3. 실험 과정

3.1 특징 추출(Feature Extraction)

3.3.1 GLCM feature

각각의 질감 영상에서 $0^\circ, 45^\circ, 90^\circ$ 의 방향으로 $d = 1$ 의 이웃픽셀에 대하여 10가지 특징 중 반복적 실험을 통해 Brodatz 질감 영상에 적용하기에 알맞고 베이시안 분류기에 사용 가능한 특징들을 찾아내었다. 최종적으로 5가지(Energy, Contrast, Homogeneity, Autocorrelation, Dissimilarity)를 특징값으로 사용하였다(특징개수 15개). 웨이블릿과의 조합에 있어서는 $0^\circ, d = 1$ 의 특징들만 사용하였다(특징개수 5개).

3.3.2 Wavelet feature

16-tap Johnstone filter를 사용하여 각 질감 영상을 2-level 웨이블릿 변환하였다. 그리고, 각각의 변환된 밴드에서의 에너지를 계산하였다(특징개수 7개).

이 때, 부밴드의 크기를 $M \times N$ 이라고 하고, 변환된 영상이 $x(m, n)$ 이라면 각 부밴드의 에너지는 다음과 같이 정의된다.

$$e = \frac{1}{MN} \sum_{m=1}^M \sum_{n=1}^N |x(m, n)| \quad (16)$$

3.2 가중치 특징 벡터(Weighted Feature Vector)

일반적으로 사용되는 특징들은 각각의 특징들마다 고유값을 가지게 된다. 그러나 어떤 경우에는 한 특징값의 아주 작은 변화가 다른 특징값에 큰 영향을 미치게 될 수도 있다. 이런 경우는 특징벡터 고유의 특성을 미처 고려하지 못했기 때문이다.

본 논문에서는 질감 영상 특징들의 평균(\mathbf{m}_i)과 편차(\mathbf{sv}_i)를 이용하여, 각각의 중요도에 따라 가중치를 다르게 주는 방법을 사용해 기준이 될 특징들의 고유 특성을 살리고자 하였다. 샘플마다 변화가 심한 특징은 큰 값의 편차를 가지게 된다. 이것은 인식과정에서 불필요한 영향을 줄 수 있으므로 중요도가 낮은 가중치를 부여한다. 반면, 샘플마다 유사한 값을 가지는 특징은 작은 편차값을 가지게 되어 클래스의 중요한 특징이 될 수 있으므로 높은 가중치를 부여한다.

N 개의 샘플을 가지는 어떤 i 번째 클래스의 n 번째 샘플에 대한 특징 벡터 $\mathbf{f}_{i,n} = [f_{i,n}(1), \dots, f_{i,n}(K)]^T$ ($n = 1, \dots, N, K$: 특징개수)라고 나타내며, 이 i 번째 클래스 전체의 평균 벡터와 편차 벡터는 다음과 같이 정의된다.

$$\mathbf{m}_i = \frac{1}{N} \sum_{n=1}^N \mathbf{f}_{i,n} \quad (17)$$

$$\mathbf{sv}_i = \frac{1}{N} \sum_{n=1}^N |\mathbf{f}_{i,n} - \mathbf{m}_i| \quad (18)$$

$\mathbf{m}_i = [m_i(1), \dots, m_i(K)]^T, \mathbf{sv}_i = [sv_i(1), \dots, sv_i(K)]^T$ 이다.

각각의 클래스에 대해 평균 벡터와 편차 벡터를 구한 후, 가중치 특징 벡터를 구한다. i 번째 클래스의 가중치 특징 벡터는 다음과 같이 표현될 수 있다.

$$\mathbf{w}_i(k) = \frac{\mathbf{m}_i(k)}{\mathbf{sv}_i(k)} \quad (k=1, \dots, K) \quad (19)$$

$\mathbf{w}_i = [w_i(1), \dots, w_i(K)]^T$ 이다.

이렇게 각각 특징의 평균값을 편차로 나누어 주는 방법을 이용해 특징의 중요도에 알맞은 가중치를 부여해 준다. 이렇게 생성된 가중치 특징 벡터는 클래스를 대표하는 대표 벡터가 된다.

3.3 베이시안 분류기(Bayesian Classifier)

영역 R^n 안에서의 벡터 \mathbf{x} 가 가우시안 분포(Gaussian distribution)를 따른다고 가정하면, \mathbf{x} 의 확률밀도 함수(probability density function)는 다음과 같이 표현된다.

$$p(\mathbf{x}) = \frac{1}{(2\pi)^{d/2} |\Sigma|^{\frac{1}{2}}} e^{-\frac{1}{2} (\mathbf{x}-\boldsymbol{\mu})^T \Sigma^{-1} (\mathbf{x}-\boldsymbol{\mu})} \quad (20)$$

이 때, $\mathbf{x} = [x_1, \dots, x_n], \boldsymbol{\mu} = [\mu(x_1), \dots, \mu(x_n)]$

그리고 $\Sigma = \{\Sigma_{ij} | (x_i - \mu_i)(x_j - \mu_j)^T\}$ 이다.

\mathbf{x} 가 i 번째 클래스 w_i 에 속하는 확률인 베이시안 결정 함수(Bayesian decision boundary function)는 다음과 같다.^[5,6]

$$g_i(\mathbf{x}) = \ln P_i(\mathbf{x}) = -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu}_i)^T \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu}_i) - \frac{d}{2} \ln 2\pi - \frac{1}{2} \ln |\Sigma| + \ln P(w_i) \quad (21)$$

최종 결정 함수는 다음과 같이 최소화할 수 있다.

$$g_i(\mathbf{x}) = -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu}_i)^T \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu}_i) - \frac{1}{2} \ln |\Sigma| \quad (22)$$

3.4 질감 인식(Texture Classification)

질감 인식 과정은 크게 훈련단계(training step)와 인식단계(classification step)로 나뉜다.

1) Training step

- 주어진 질감 영상을 웨이블릿 변환과 GLCM을 이용하여 특징들을 추출한다.
- 전체 T 개 클래스의 질감, 각각의 N 개의 샘플 영상에 대해 수행한다.
- 클래스의 평균 벡터(식.17)와 편차 벡터(식.18)를 구한 후에, 클래스의 대표 벡터(가중치 특징 벡터)를 찾아낸다.
- 베이시안 분류기 사용을 위해 가중치 특성

벡터의 공분산 행렬(covariance matrix)을 구한다.

2) Classification step

- 임의의 질감 영상에 대해 웨이블릿 변환과 GLCM 을 이용해 특징 벡터($\mathbf{x} = [x(1), \dots, x(K)]$)를 추출한다.
- 훈련과정에서 계산된 각 클래스의 편차 벡터(\mathbf{sv}_i)로 임의의 특징 벡터를 가중치 한다.

$$wx(k) = \frac{x(k)}{sv_i(k)}$$

가중치된 벡터 $\mathbf{wx} = [wx(1), \dots, wx(K)]^T$ 로 표현된다.

- 임의의 질감영상의 가중치 특징 벡터를 베이시안 분류기에 사용하여, 모든 클래스에 대해 식(22)을 사용하여 클래스별 결정함수(g_i)값을 계산한다.
- g_i 의 값 중, 가장 큰 값을 가지는 질감 영상 i 로 임의의 영상을 인식한다.

4. 실험 결과

본 실험에서 사용된 질감 영상은 Brodatz's texture album에서 발췌한 34가지 영상(500×500)이다.^[7]

- D1, D11, D18, D19, D20, D21, D23, D24, D26, D37, D47, D50, D56, D57, D60, D63, D64, D65, D76, D78, D81, D83, D84, D86, D87, D94, D95, D96, D101, D103, D105, D106, D109, D110 각 클래스별로 180개의 256 gray level을 가지는 64×64 샘플 영상(훈련영상 : 90개, 시험영상 : 90개)을 추출하였다. 전체 영상의 왼쪽 반은 훈련영상에 오른쪽 반은 시험영상에 사용되었다. 그리고, 각각의 샘플 영상들은 반만큼씩 겹쳐졌다.

다음 표는 실험의 인식률 결과를 나타낸 것이다.

표 1. 질감 영상 인식 결과

특징종류	특징개수	인식률(%)
GLCM(no weighted)	15	20.3
GLCM(weighted)	15	95.5
wavelet(no weighted)	7	94.2
wavelet(weighted)	7	95.4
GLCM+wavelet(weighted)	12	97.2

표 1의 결과에서 가중치 특징 벡터를 사용한 경우의 인식률은 그렇지 않은 경우에 비해 좋은 인식률의 결과를 보인다. GLCM의 경우, 영상의 크기 때문에 가중치 특징 벡터를 사용하지 않았을 때는 낮은 인식률을 보이

지만, 가중치 특징 벡터를 사용함으로써 월등히 좋은 인식률을 보였다. GLCM과 웨이블릿 특징 벡터를 조합한 실험에서 GLCM은 한 방향 특징만을 사용하였는데, 이 경우에는 GLCM만 사용한 경우보다 특징개수가 작아지므로 수행시간은 줄어들고 인식률은 더욱 좋아짐을 알 수 있다.

5. 결 론

본 논문에서는 영상의 질감을 인식하기 위한 특징 추출 방법으로 GLCM과 웨이블릿 변환 특징들에 가중치를 부가하는 방법을 제안하였다. 실제로 Brodatz 앤범에 있는 34개의 영상에 적용한 실험 결과, 가중치 특징 벡터를 사용함으로써 작은 크기의 영상에서도 GLCM은 좋은 인식률과 짧은 수행시간을 보였다. 게다가 웨이블릿 변환 가중치 특징 벡터와 조합한 한 방향 GLCM 특징 벡터는 더욱 좋은 인식률을 보였다.

참 고 문 헌

- [1] Sim J.C. "New Texture Recognition Method Using Local Weighting Averaged Texture Units", *The Journal of the KITE 1994*, vol. 31-B, no. 4. pp. 129-137, Apr. 1994.
- [2] Soh, L.-K. "Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices", *IEEE Trans. Geoscience and Remote Sensing*, vol. 37, no. 2 pp. 780-795, Mar. 1999.
- [3] Tianhorng C "Texture analysis and classification with tree-structured wavelet transform", *IEEE Trans. Image Processing*, vol. 2, no. 4, pp. 429-441, Oct. 1993.
- [4] Porter R. "Robust rotation-invariant texture classification : wavelet, Gabor filter and GMRF based schemes", *IEE Proc-Vis. Image Signal Processing*, vol. 144, no. 3, pp. 180-188, June 1997.
- [5] Zhong S. "Using Bayesian classifier in relevant feedback of image retrieval", *IEEE Tools with Artificial Intelligence, ICTAI Proceedings. 12th IEEE International Conference on*, pp. 258 -261, 2000.
- [6] Duda., R. O., Hart, P. E., and Stork, D. G. "Pattern classification", New York : John Wiley & Sons, Inc., 2001.
- [7] P. Brodatz, "Textures : A photographic album for artists & designers", New York: Dover, New York, 1966.