

論文96-33B-1-13

형태학적 정규화 패턴 스펙트럼을 이용한 질감영상 분류

(Classification of Scaled Textured Images Using Normalized Pattern Spectrum Based on Mathematical Morphology)

宋根遠*, 金紀錫*, 都敬勳*, 河永浩*

(Kun-Woen Song, Gi-Seok Kim, Kyeong-Hoon Do, and Yeong-Ho Ha)

요 약

본 논문에서는 일반적인 환경인 카메라의 줌 기능(zoom-in, zoom-out)에 의해 임의로 크기 변화된 질감 영상들을, 크기변화에 무관한 형태학적 정규화(normalized) 패턴 스펙트럼에 기반하여 분류하였다. 정규화 패턴 스펙트럼은 질감영상으로부터 형태학적 패턴 스펙트럼을 구하고 이로부터 크기변화 성분을 구한 다음 크기 변화비에 따른 선형보간을 하여 같은 부류의 질감영상내에서 크기변화를 통합함을 뜻한다. 본 논문에서는 패턴 스펙트럼을 구할 때 기존의 방법과 달리 영상의 문턱값을 중심으로 두 부분으로 계산하였다. 즉 문턱값 이상을 가지는 화소들에 대해서는 opening방법으로 패턴 스펙트럼을 구하였고 문턱값 미만을 가지는 화소들에 대해서는 closing방법으로 패턴 스펙트럼을 구하여 효과적인 정보추출을 하였다. 또 본 논문에서는 각각 명암도 방법과 이진 방법에 대한 분류 정확도를 비교·검토하였다. 제안된 방법은 효과적인 정보추출, 높은 분류 정확도, 계산량 감소, 및 병렬처리 구현등의 여러 가지 장점이 있다. 특히 제안된 방법은 질감영상 학습단계에서 최근의 방법들과는 달리 다양하게 크기변화된 질감영상들을 사용하지 않고, 즉 기준크기(1:1) 질감영상만을 사용하였음에도 불구하고 높은 분류 정확도를 얻을 수 있었다.

Abstract

In this paper, a scheme of classification of scaled textured images using normalized pattern spectrum incorporating arbitrary scale changes based on mathematical morphology is proposed in more general environments considering camera's zoom-in and zoom-out function. The normalized pattern spectrum means that firstly pattern spectrum is calculated and secondly interpolation is performed to incorporate scale changes according to scale change ratio in the same textured image class. Pattern spectrum is efficiently obtained by using both opening and closing, that is, we calculate pattern spectrum by opening method for pixels which have value more than threshold and calculate pattern spectrum by closing method for pixels which have value less than threshold. Also we compare classification accuracy between gray scale method and binary method. The proposed approach has the advantage of efficient information extraction, high accuracy, less computation, and parallel implementation. An important advantage of the proposed method is that it is possible to obtain high classification accuracy with only (1:1) scale images for training phase.

I. 서 론

* 正會員, 慶北大學校 電子工學科

(Dept. of Elec. Eng., Kyungpook Nat'l Univ.)

接受日字: 1995年4月7日, 수정완료일: 1995年12月22日

질감영상(texture image)의 해석은 컴퓨터 시각, 형태인식에 많이 이용되고 있으며 산업 자동화, 의료 영상처리, 반도체 및 금속의 표면검사, 항공사진으로부터

터의 지형추출, 산림분포의 구분 등의 여러 분야에 다양하게 적용되었다. 질감영상을 분류하는데 있어서 많은 방법들이 제안되었다. 기존의 방법은 명암도 상호발생 행렬(gray-level co-occurrence matrix), 자기상관관계(auto-correlation), 디지털 변환(digital transform), 질감 스펙트럼(texture spectrum), 질감 에너지(texture energy), 명암도 차이(gray level difference), 선길이 통계(run length statistics) 등을 이용한 다양한 특징(feature) 추출 방법이 연구되어져 왔다.^[1-5] 명암도 상호발생 행렬법은 영상의 2차적 통계특성을 포함한 상호발생 행렬을 구하고 이로부터 4방향으로 여러 거리에 대한 상호발생 행렬을 구하여 특징을 추출하는 방법으로 기존의 여러 방법중 가장 높은 인식률을 나타낸다. 그러나 여러 거리에 대한 상호발생 행렬을 구해야 하므로 수행시간이 많이 걸리는 단점이 있다. 질감 에너지법은 질감영상의 구조적 상태의 에너지 분포를 추출할 수 있는 5×5창을 영상과 상충적분하여 국부 창 내에서의 각 에너지를 구하고 이를 특징으로 삼는다. 이 방법은 구조적 상태의 에너지 분포를 측정할 수 있는 창의 수가 한정되므로 다양한 정보를 추출할 수 없다. 질감 스펙트럼법은 각 화소마다 3×3내에서 중심화소와 8개의 주변화소를 비교한 질감단위를 구하고 영상전체에서 발생하는 각 질감단위의 수를 누적한 스펙트럼을 특징으로 이용하는 방법이다. 이 방법은 효율면에서 기존의 질감특징 추출방법보다 인식률이 낮으며 질감단위가 $3^8(6561)$ 개로 너무 많아 짐이나 영상의 왜곡에 매우 민감하다. 또한 위의 방법들은 모두 카메라의 줌 기능에 의한 크기변화에 의존적이므로 학습단계와 시험단계에서 질감영상의 크기가 달라지면 인식률이 매우 낮다.

최근에 질감영상의 크기변화와 회전변화를 통합하는 Gaussian MRF(markov random field) 모델방법^[6]과 "Tuned" masks 방법^[7]이 제안되었다. Gaussian MRF 모델방법은 질감영상을 모델화하여 이로부터 크기성분과 회전성분을 추정하는 방법으로 기존의 방법중에 크기변화와 회전변화에 무관한 가장 정교한 방법이다. 그러나 이 방법은 질감영상의 크기성분과 회전성분을 추정할 때 시간이 많이 소요되는 단점이 있다. "Tuned" masks 방법은 질감 에너지법에서 사용한 Law의 5×5창을 각각 임의로 크기변화와 회전변화된 질감영상과 상충적분하여 질감 에너지를 구한다. 이 때 같은 부류(inner class)의 질감영상끼리는 거의 같

은 값의 질감 에너지를 갖고 서로 다른 부류(inter class)의 질감영상끼리는 서로 다른 값의 질감 에너지를 갖도록 5×5창내의 각 요소의 값들을 최적화(optimization) 방법에 의해 바꾸는 방법이다. 결국 최적화 방법에 의해 구해진 5×5창으로 같은 부류의 질감영상내에서는 크기변화와 회전변화가 있다 하더라도 거의 같은 질감 에너지 값을 얻는다. 이 방법은 학습시 다양하게 크기변화와 회전변화된 질감영상을 많이 사용하므로 계산량이 많은 단점이 있다.

수학적 형태학(mathematical morphology)은 다양한 영상처리분야에 유용한 도구로 발전되어왔다. 형태학적 연산은 영상물체의 모양에 직접적으로 관계하므로 형태와 관련된 영상처리분야에 유용하다. 수학적 형태학의 적용으로서 언어 질 수 있는 패턴 스펙트럼(pattern spectrum)은 영상물체의 형태와 크기에 대한 다양한 양상(aspect)을 감지할 수 있으므로 이를 이용한 질감영상 분류 방법들이 제안되었다.^[8-9] 특히 명암도 패턴 스펙트럼은 영상물체와 구조요소(structuring element)의 크기와 모양에 대한 다양한 명암도 정보를 추출할 수 있으므로 이진 패턴 스펙트럼보다 더욱 유용하다. 그러나 패턴 스펙트럼도 크기변화에 의존적이므로 이러한 문제점을 해결하고자 본 논문에서는 크기변화에 무관한 정규화 패턴 스펙트럼(normalized pattern spectrum)을 이용하여 질감영상 분류를 하였다.

본 논문에서는 정규화 패턴 스펙트럼을 구현할 때 형태학적 저역통과 필터링을 한 후 영상물체의 평균값을 구한 다음 이를 문턱값으로 하여 패턴 스펙트럼을 두 부분으로 계산하는 방법을 제안하였다. 즉 문턱값 이상을 가지는 화소들에 대해서는 opening방법으로 패턴 스펙트럼을 구하였고 반대로 문턱값 미만을 가지는 화소들에 대해서는 closing방법으로 패턴 스펙트럼을 구하여 효과적인 정보추출을 하였다. 또한 질감영상을 분류하는 전단계로 질감영상 학습시 기존의 방법과는 달리 크기변화가 되지 않은, 즉 (1:1) 기준크기의 질감영상만을 사용하여 높은 분류 정확도를 얻었으며 또한 계산시간을 단축할 수 있었다.

II. 형태학적 패턴 스펙트럼

수학적 형태학은 디지털 영상해석에 효과적인 방법을 제공한다.^[10-12] 수학적 형태학의 두 기본적인 연

산은 dilation ($A \oplus B$)과 erosion ($A \ominus B$)이다. Dilation과 erosion에 의해 closing과 opening은 다음과 같이 정의된다.

$$A^b = A \cdot B = (A \oplus B) \ominus B \quad (1)$$

$$A_B = A \cdot B = (A \ominus B) \oplus B \quad (2)$$

그리고 모든 $n \geq 1$ 에 대해서

$$\begin{aligned} \dots \subseteq X \cdot (n+1)B \subseteq X \cdot nB \dots \subseteq X \subseteq \\ \dots \subseteq X \cdot nB \dots \end{aligned} \quad (3)$$

를 만족한다. 따라서 $A(\cdot)$ 가 유한 화소 면적(finite set cardinality)을 나타낼 때 면적 $A(X \cdot nB)$ 는 n 이 증가함에 따라 유지되거나 감소한다. 다중척도 closing과 opening의 이러한 성질을 이용하여 이진 구성요소 B 에 의한 이진 영상 X 의 패턴 스펙트럼은 다음과 같이 정의되며,

$$PS_X(+n, B) = A [X \cdot nB \setminus X \cdot (n+1)B], 0 \leq n \leq N$$

$$PS_X(-n, B) = A [X \cdot (n+1)B \setminus X \cdot nB], 0 \leq n \leq K \quad (4)$$

여기서 ' \setminus '는, $S \setminus Q = \{x \in S : x \notin Q\}$, 즉 차집합을 나타내며 패턴 스펙트럼은 항상 음이 아닌 값이다. 그러므로 패턴 스펙트럼은 최소한 하나의 충격파(impulse)를 포함하게 된다. 이와 유사하게, 명암도 구성요소 g 에 의한 명암도 영상 f 의 패턴 스펙트럼은

$$PS_X(+n, g) = V [f \cdot ng \setminus f \cdot (n+1)g], 0 \leq n \leq N$$

$$PS_X(-n, g) = V [f \cdot (n+1)g \setminus f \cdot ng], 0 \leq n \leq K \quad (5)$$

이며, N 과 K 는 수렴치(convergence value)이다. 그리고 V 는 이진 패턴 스펙트럼에서의 면적 A 대신 체적을 나타낸다. 패턴 스펙트럼은 모양-크기 복잡도(shape-size complexity)와 다중척도 형태 표현(multiscale shape representation), 영상 모델링 등을 위해 Maragos^[9]에 의해 체계화되었으며, Dougherty^[13]에 의해 질감영상 특징 추출에 사용되었다.

III. 특징 추출 및 분류기

본 논문에서는 질감영상을 분류하는데 있어서 크기 변화를 고려하였다. 그림 1은 본 논문에서 제안한 질감영상 분류 알고리즘을 나타낸다. 본 논문에서 특징들

은 제안한 문턱값을 구한 다음 opening방법과 closing방법에 의해 효과적으로 얻을 수 있었다. 그림 2는 전처리 과정에서 사용된 2×2 정사각형 구조요소를 나타낸다. 이 구조요소의 원점은 좌측상단에 있다. 본 논문에서의 전처리 과정은 중요하다. 왜냐하면 카메라로부터 획득된 질감영상은 많은 잡음성분을 가지며 또 왜곡되어있다. 형태학적 패턴 스펙트럼이 모양과 크기에 의존하므로 전처리 과정이 없으면 오분류를 유발한다. 그림 3은 패턴 스펙트럼 특징들을 추출하기 위하여 사용된 구조요소를 나타낸다. 이들 구조요소의 원점은 \odot 으로 표시되어 있다. 각각은 수평라인, 수직라인, 45° 라인, 135° 라인, 정사각형 및 십자가를 나타낸다. 어떤 영상물체가 임의의 구조요소의 크기와 같은 모양과 같은 크기를 가진다면 패턴 스펙트럼에서는 하나의 충격파를 나타낸다. 만약 질감영상이 규칙적인 모양을 하지 않았다 하더라도 영상에 따라 다른 패턴 스펙트럼을 구할 수 있다.

각각의 구조요소에 의한 정규화 패턴 스펙트럼으로부터 패턴 스펙트럼의 평균, 2차 모멘트, 3차 모멘트, 및 요소차이들을 구하여 이를 분류 특징 벡터로 사용하였다. 각각은 아래와 같다.

$$\bar{M}_1 = \sum_{i=0}^M i \cdot P(i) \quad (6)$$

$$\bar{M}_2 = \sum_{i=0}^M i^2 \cdot P(i), \quad (7)$$

$$\bar{M}_3 = \sum_{i=0}^M i^3 \cdot P(i), \quad (8)$$

$$\overline{Diff} = \sum_{i=0}^M (P(i+1) - P(i))^2, \quad (9)$$

이때 i 는 정규화 패턴 스펙트럼상에서 구조요소크기를 나타내고 $P(i)$ 는 정규화 패턴 스펙트럼상에서 i 번째 구조요소크기에 패턴 스펙트럼값의 확률을 나타낸다. 식(6)은 패턴 스펙트럼의 평균으로 구조요소에 대한 영상물체의 상대적인 크기정보를 나타내며, 식(7)은 패턴 스펙트럼 2차 모멘트로서 영상물체와 구조요소간의 모양의 차이에 대한 정보를 나타낸다. 식(8)은 패턴 스펙트럼 3차 모멘트로서 패턴 스펙트럼의 skewness이다. 그리고 식(9)은 패턴 스펙트럼 요소차이로서 패턴 스펙트럼상에서 각 i 번째 구조요소크기와 $i+1$ 번째 구조요소크기에 대한 영상물체의 모양과 구조요소의 모양의 차에 대한 정보를 나타낸다. 이는 패턴 스펙트럼상에서 이웃하는 각 i 번째 구조요소크기와

$i+1$ 번째 구조요소크기에 대한 패턴 스펙트럼값의 차가 작으면 요소차이 값이 작아지고 반대로 i 번째 구조요소크기와 $i+1$ 번째 구조요소크기에 대한 패턴 스펙트럼값의 차가 크면 요소차이 값이 커진다.

구하고 이를 학습시켰다. 이로 인해 학습해야 할 질감영상의 수가 현저히 줄어들었으며 결국 계산시간이 많이 줄어들었다.

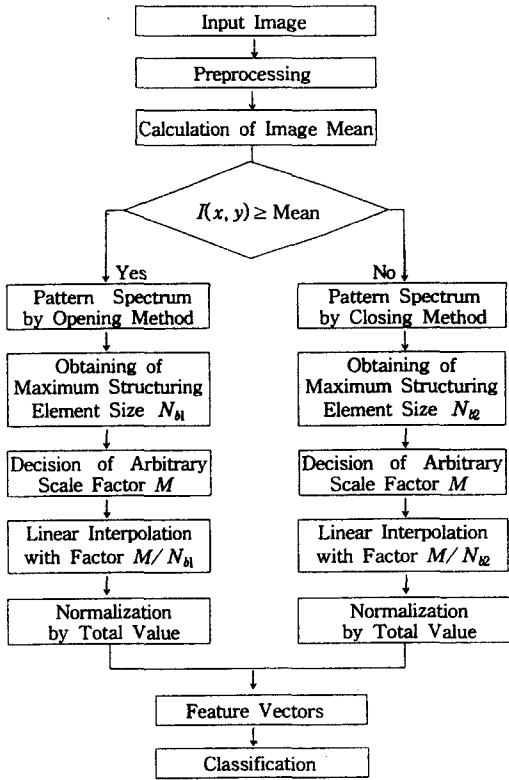


그림 1. 제안한 질감영상 분류 알고리즘
Fig. 1. The proposed algorithm for classification of texture images.



그림 2. 전처리에 사용된 구조요소
Fig. 2. Structuring element used in preprocessing.

그리고 본 논문의 최종 단계에서 사용한 분류기는 Fisher의 선형 분류기(linear discriminant classifier)이다.^[14] 이 분류기는 d 차원 데이터를 직선에 투사(projection)시킴으로써 d 차원 특징 벡터들을 1차원 벡터로 감소한다.

본 논문에서는 학습시 최근의 다른 방법들과는 달리 크기변화가 되지 않은 질감영상으로부터 특징 벡터를




그림 3. 패턴 스펙트럼 특징 추출시 사용된 구조요소들
(a) 수평 라인 (b) 수직 라인 (c) 45° 대각선 (d) 135° 대각선 (e) 정사각형 (f) 십자가

Fig. 3. Structuring elements for pattern spectrum features.
(a) Horizontal line (b) Vertical line (c) Right diagonal (d) Left diagonal (e) Square (f) Rhombus

IV. 정규화 패턴 스펙트럼

1. 기존의 정규화 알고리즘

정규화 패턴 스펙트럼은 같은 종류의 영상물체라 하더라도 카메라의 줌 기능에 의해 임의로 크기변화되면 패턴 스펙트럼이 달라 다른 영상물체로 오인식되는 경우가 있는데 같은 영상물체 내에서는 크기변화를 통합함을 뜻한다. 입력 질감영상에 형태학적 저역통과 필터링을 한 평균값을 구한 후 이를 문턱값으로 하여 문턱값 이상의 화소들과 문턱값 미만의 화소들에 대해서 각각 opening방법과 closing방법으로 패턴 스펙트럼을 구한다. 각 방법에 대하여 패턴 스펙트럼 함수가 $n = 0, \dots, N_s$ 까지 구하여진다. 여기서 n 은 패턴 스펙트럼상에서 구조요소의 크기를 나타낸다. 이로 부터 각각의 최대구조요소크기(maximum-structuring element size) N_s 를 쉽게 구할 수 있다. 최대구조요소 크기 N_s 는 영상물체의 크기에 대한 구조요소의 최대크기를 말한다. 최대구조요소크기를 구한 다음 보간(interpolation)을 위한 크기인자(scale factor) M 를 임의로 결정한다. 본 논문에서는 학습시와 시험 시에 256×256 영상으로부터 임의로 추출한 128×128 부영상(sub-image)을 사용하였다. 사용한 구조요소의 크기가 3이면 최대구조요소크기가 64이하이므로 경험적으로 100을 보간을 위한 크기인자 M 값으로써 사용하였다.




그림 4. 기존의 패턴 스펙트럼과 정규화 패턴 스펙트럼

(a) 1차원 신호 (b) (a)의 Zoom_in된 신호 (c) (a)와(b)에 대한 기존의 패턴 스펙트럼 (d) (a)와 (b)에 대한 정규화 패턴 스펙트럼

Fig. 4. Conventional pattern spectrum and normalized pattern spectrum.


(a) 1D signal (b) Zoom_in signal of (a) (c) Conventional pattern spectrum of (a) and (b) (d) Normalized pattern spectrum of (a) and (b)

더 큰 값을 사용하면 성능에는 관계없이 보간시 더 많은 계산시간이 요구된다. 그리고 보간인자 M/N_b 로 위에서 구한 패턴 스펙트럼 함수에 보간을 하였다. 이는 고정된 M 값에서 N_b 값이 커지면 보간인자 M/N_b 가 작아지므로 작게 보간해 주며 반대로 N_b 값이 작아지면 보간인자 M/N_b 가 커지므로 크게 보간해주어서 크기변화를 통합한다. 이를 수식적으로 나타내면 다음과 같다. [15]


$$A'(m) = A(X \cdot \left[\frac{mN_b}{M} \right] B), \text{ for } m = 0, \dots, M \quad (10)$$

정규화 패턴 스펙트럼 $PS_f(\pm n, B)$ 은 식(5)에서의 n 대신 $\frac{mN_b}{M}$ 으로 대치된다. 영상물체의 크기가 클수록 패턴 스펙트럼상에서 최대구조요소크기 N_b 는 커진다. 식(10)은 카메라의 zoom-in기능에 의해 영상물체의 크기가 커지면 최대구조요소크기 N_b 가 커지므로 패턴 스펙트럼을 계산할 때 크기가 큰 구조요소가 사용되며


반대로 카메라의 zoom-out기능에 의해 영상물체가 작아지면 작은 구조요소가 사용되는 것과 같은 의미를 나타낸다. 본 논문에서는 식(10)을 실질적으로 구현하기 위하여 M/N_b 값에 따른 보간을 하여 정규화하였다. 그림 4에서는 크기변화에 의존적인 기존의 패턴 스펙트럼과 크기변화에 무관한 정규화 패턴 스펙트럼의 예이다. (a)는 정규화 패턴 스펙트럼과 기존의 패턴 스펙트럼으로 비교하기 위하여 사용된 폭이 20이며, 최대값이 10인 이산 1차원 신호이다. (b)는 (a)의 크기변화된 신호이다. 크기변화비는 1:2이다. (c)는 (a)와 (b) 신호에 대해서 1x3 수평구조요소를 사용하여 패턴 스펙트럼을 구한 것이다. 이때 패턴 스펙트럼 계산시 수렴 값은 0으로 두었다. 같은 크기의 신호라도 크기변화가 일어나면 패턴 스펙트럼이 달라져 크기변화에 무관한 특징을 추출할 수 없다. (a)신호를 사용하여 패턴 스펙트럼을 구했을 때 최대구조요소의 크기 N_b 는




(a)



(b)



(c)



(d)

그림 5. opening과 closing에 의해 제안된 정규화 패턴 스펙트럼

(a) 평균값 이상 갖는 값에 대해 opening에 의한 패턴 스펙트럼 (b) 평균값 이하를 갖는 신호에 대해 closing에 의한 패턴 스펙트럼 (c) (a)에 대한 정규화 패턴 스펙트럼 (d) (b)에 대한 정규화 패턴 스펙트럼

Fig. 5. The proposed normalized pattern spectrum by opening and closing.

(a) Pattern spectrum by opening for value having above mean value (b) Pattern spectrum by closing for value having below mean value (c) Normalized pattern spectrum of (a) (d) Normalized pattern spectrum of (b)

4이며, (b)신호에 대해서는 9이다. (d)는 (c)의 패턴 스펙트럼을 이용하여 크기변화를 정규화한 것이다. 이 때 사용한 크기인자 M 은 36을 사용하였다. 그리고 정규화 알고리즘에 따라 정규화하였다. 그림에서와 같이 같은 모양의 신호가 크기변화되더라도 같은 패턴 스펙트럼을 구할 수 있다. (d)에서 두 그래프의 미세한 차는 이산영역에서 본 알고리즘을 적용하였기 때문이다.

2. 제안한 알고리즘

본 절에서는 평균값을 중심으로 각각 opening과 closing에 의해 정규화 패턴 스펙트럼을 제안하여 기존의 정규화 패턴 스펙트럼과 비교·검토하였다. 기존의 정규화 패턴 스펙트럼은 opening의 수렴성을 이용하여 opening방법으로 하였다. 패턴 스펙트럼 계산시 널리 사용하는 수렴값은 전체화소값의 90%이다. 즉

패턴 스펙트럼을 구할 때 패턴 스펙트럼상에서 각 구조요소의 크기에 대해서 구한 패턴 스펙트럼값의 합이 전체화소값의 90%값 이하일 경우 연산을 수행한다. 수렴값을 90%로 하면 수렴값을 50%로 하는 경우 보다 정보를 90%까지 추출하므로 특징 추출 면에서 효과적이나 시간이 많이 걸리는 단점이 있다. 반대로 수렴값을 50%로 하면 계산시간은 단축되나 정보를 반정도 추출하므로 특징추출면에서는 수렴값을 90%로 두고 패턴 스펙트럼을 구한 것 보다 못하다. 본 논문에서는 기존의 정규화 패턴 스펙트럼은 효과적인 정보추출은 가능하나 시간이 많이 걸리는 단점을 개선하여 효과적인 정보추출 및 계산량 감소를 할 수 있는 알고리즘을 제안한다. 영상의 평균값을 중심으로 평균값 이상을 가지는 화소들에 대해서는 opening방법으로 패턴 스펙트럼을 구하고, 평균값 미만을 가지는 화소들에 대해서

는 closing방법으로 패턴 스펙트럼을 구하였다. 각 방법이 서로 독립적이므로 병렬구현이 가능하며, 평균값을 중심으로 각각 opening과 closing으로 특징을 추출하므로 특징추출면에서 효과적이다. 패턴 스펙트럼 계산량은 opening연산으로 수행할 때는 dilation연산의 수행횟수이고, closing연산으로 수행할 때는 erosion연산의 수행횟수이다. 예로서 opening연산으로 수행할 때 erosion은 이전 erosion연산에 한번더 erosion연산을 함으로서 가능하나 dilation은 패턴 스펙트럼에서 구조요소의 크기만큼 반복해야 한다. 수렴값을 전체화소값의 90%로 두고 opening방법으로 패턴 스펙트럼을 구할 때 그림 4의 (b)신호에 1x3 수평구조요소를 사용한 경우 최대구조요소의 크기가 9이므로 총 dilation의 연산횟수는 $55(1+2+3+4+5+6+7+8+9+10)$ 번이다. (a)는 최대구조요소의 크기가 4이므로 총 dilation연산횟수는 $15(1+2+3+4+5)$ 번이다. 그림 5는 본 논문에서 제안한 평균값을 중심으로 opening과 closing으로 패턴 스펙트럼을 구했을 때 효과적인 특징추출이 가능하며 기존의 방법보다 계산량을 줄일 수 있음을 보여준다. (a)는 그림 4의 (a)와 (b)신호에 대해서 본 논문에서 제안한 평균값 이상을 가지는 값에 대해 opening방법으로 패턴 스펙트럼을 구한 것이다. 이 때 그림 4의 (a)에 대해서는 최대구조요소의 크기가 2이므로 총 dilation의 연산횟수는 $6(1+2+3)$ 번이며, 그림 4의 (b)에 대해서는 최대구조요소의 크기가 5이므로 총 dilation의 연산횟수는 $15(1+2+3+4+5)$ 이다. 그림 5의 (b)는 그림 4의 (a)와 (b)에 대해 closing방법으로 패턴 스펙트럼을 구한 것이며 총 erosion의 연산횟수는 각각 6과 15이다. 그래서 제안한 알고리즘으로 패턴 스펙트럼을 구했을 때 그림 4의 (a)경우는 총 12(6+6)회의 연산횟수가 필요한데 반해 기존의 정규화 패턴 스펙트럼으로 구현시 총 15회의 연산횟수가 필요하다. 그리고 그림 4의 (b)의 경우에는 제안한 방법이 30(15+15)회, 기존의 방법이 55회의 연산이 필요하다. 영상의 구조요소의 크기가 커지면 연산횟수는 선형적으로 증가하는 것이 아니라 기하급수적으로 급격히 증가한다. 이는 패턴 스펙트럼 계산시 시간이 많이 걸리는 주된 요인이다. 그림 5의 (c)와(d)는 각각 그림 5의 (a)와(b)를 정규화한 것이다. (c)와(d)에서의 크기변화된 신호와 크기변화되지 않은 신호의 정규화된 값의 미소한 차는 이산영역에서 계산되었기 때문이다. 위에서 본 바와 같

이 제안한 방법은 계산량을 줄이면서, 효과적인 정보추출이 가능하다.

V. 실험 및 고찰

본 실험에서는 Brodatz's texture album^[16]으로부터 얻어진 8종류의 자연 질감영상과, 한 종류의 질감영상당 카메라의 줌 기능으로 인해 임의로 크기변화된 zoom-in영상과 zoom-out영상을 사용하였다. 각 자연 질감영상은 oriental straw cloth(D52), handwoven oriental rattan(D64), handwoven oriental rattan(D65), wood grain(D68), coffee beans(D75), raffia looped to a high pile(D84), cane(D102), 및 loose burlap(D103)이다. 또 위의 한 종류의 질감영상당 임의로 크기변화된 1개의 zoom-in 질감영상($Dn-i$) 과 1개의 zoom-out 질감영상($Dn-o$)을 추가로 얻어 실험하였다. 그림 4는 본 논문에서 사용된 전체영상을 보여준다. 그리고 표 1은 각 질감영상이 카메라의 줌 기능에 의하여 임의로 크기변화된 변화 비를 나타낸다.

본 실험에서 사용된 모든 학습표본들과 시험표본들의 크기는 각 256×256 질감영상으로부터 추출된 128×128 부영상(sub-image)이다. 크기변화되지 않은 256×256 질감영상에서 일부분이 겹치도록 하여 81개의 128×128 부영상을 추출하였다. 그리고 각각의 zoom-in된 질감영상과 zoom-out된 질감영상으로부터 각 25개의 128×128 부영상을 추출하였다. 그리고 한 종류의 질감영상당 전체학습표본은 크기변화되지 않은 81개의 128×128 부영상중 무작위로 추출한 56개만을 사용하여 정규화 패턴 스펙트럼을 구하고 이로부터 특징 벡터를 추출하였다. 기존의 방법과는 달리 학습시에는 크기변화된 zoom-in영상과 zoom-out영상은 사용하지 않았다. 한 종류의 질감영상당 시험표본은 각 크기변화되지 않은 81개의 부영상중에서 학습표본에서 사용된 56개의 질감영상을 제외한 나머지 25개의 부영상, 그리고 각각 zoom-in 과 zoom-out 영상으로부터 추출된 25개의 부영상을 사용하였다. 즉 한 종류의 질감영상당 총 시험표본은 75개의 부영상이다. 본 논문에서 특징 추출시 사용된 구조요소는 모두 이진 구조요소이며 길이는 3이다. 또 정규화 패턴 스펙트럼을 구현할 때 선형 보간 과정에서 사용한 크기인자 값은 100이다. 본 실험에서는 하나의 구조요소당

평균, 2차 모멘트, 3차 모멘트, 및 요소차이를 구하여 이를 특징 벡터로 하였다. 하나의 구조요소를 opening 과 closing방법에 의해 각각 특징 벡터를 추출하므로 그림 3의 모든 구조요소가 사용되면 특징 벡터는 48이다. 그림 5는 raffia looped to a high pile(D84) 영상, zoom-in 영상(D84-i) 및 zoom-out 영상(D84-o)에 대한 기존의 패턴 스펙트럼과 정규화 패턴 스펙트럼의 예를 보여준다. 이때 수직 구조요소를 사용하였으며 명암도 closing 방법으로 구현하였다. 이때 256 × 256 질감영상에서 구현했기 때문에 보간을 위한 크기인자 M 값으로서 200을 사용하였다. 이때 (a)는 (b)를 정규화 알고리즘에 따라 구현한 후 그래프 상에서 그 변화를 자세히 관찰하기 위하여 일정한 값을 곱하였다. 그림 5에서 본 바와 같이 한 종류의 질감영상내에서 크기변화된 질감영상들에 대한 패턴 스펙트럼과 크기변화되지 않은 질감영상의 패턴 스펙트럼이 기존의 패턴 스펙트럼 보다 정규화 패턴 스펙트럼에서 더욱 유사하다. 이로 부터 여러 가지 구조요소에 대해서 거의 같은 특징 벡터들을 얻을 수 있었다.

본 논문에서는 제안한 크기변화를 통합한 방법과 기존의 크기변화를 고려하지 않은 방법에 의한 분류 정확도를 비교·검토하였다. 또한 제안한 방법으로 이진 패턴 스펙트럼과 명암도 패턴 스펙트럼 방법의 분류 정확도를 비교·검토하였다. 표 2는 크기변화를 고려하지 않은 기존의 명암도 패턴 스펙트럼 방법에 의한 분류 정확도를 나타내고 있다. 크기변화되지 않은 질감영상에 대해서는 분류 정확도가 100%이다. 그러나 크기변화를 고려하지 않았기 때문에 크기변화된 거의 모든 질감영상들의 분류 정확도가 매우 낮은 것을 알 수 있다. 이는 기존의 형태학적 패턴 스펙트럼이 크기변화에 의존적이어서 학습단계의 질감영상과 시험단계의 질감영상이 한 종류라도 카메라에 의해 크기변화되면 결국 오분류를 유발함을 말한다. 표 3은 제안한 크기변화를 고려한 명암도 패턴 스펙트럼 방법에 의한 분류 정확도를 나타낸다. 전체적으로 실험한 모든 영상에 대해 고르게 높은 분류 정확도를 나타내며, 전체 평균 분류 정확도가 98.3%로 매우 높다. 표 4는 크기변화를 고려한 이진 패턴 스펙트럼 방법에 의한 분류 정확도를 나타내고 있다. 전체 평균 정확도는 95.3%으로 명암도 방법에서와 같이 매우 높으나 D65의 zoom-out 질감영상과 D75의 zoom-in 질감영상에 대한 정확도는 낮다. 이의 주된 요인은 256x256 영상으로부터 128

x128 부영상을 생성시 잘려진 형태에 따라 패턴 스펙트럼이 학습영상의 패턴 스펙트럼과 달라 오분류를 유발한다. 이는 패턴 스펙트럼이 형태에 민감함을 나타낸다. 그리고 실험한 모든 영상에 대한 분류 정확도가 명암도 방법보다 낮다. 표3 과 표4로 부터 명암도 패턴 스펙트럼에 의한 방법이 이진 패턴 스펙트럼에 의한 방법보다 훨씬 효과적인 특징 추출을 할 수 있다는 것을 알 수 있다. 왜냐하면 명암도 패턴 스펙트럼은 이진 패턴 스펙트럼에서 얻을 수 없는 구조요소의 크기에 대한 명암도 정보까지도 추출하기 때문이다. 그러나 명암도 패턴 스펙트럼에 의한 방법이 더 많은 계산시간을 요하는 단점이 있다.

표 1. 실험에 사용된 질감영상의 크기변화비
Table 1. The scale change ratio of textured image used in the experiment.

Image \ Scale	No scale	Zoom-in	Zoom-out
D52	(1 : 1)	(1.4 : 1)	(1 : 1.3)
D64	(1 : 1)	(1.2 : 1)	(1 : 1.2)
D65	(1 : 1)	(1.3 : 1)	(1 : 1.2)
D68	(1 : 1)	(2.0 : 1)	(1 : 1.5)
D75	(1 : 1)	(1.5 : 1)	(1 : 1.3)
D84	(1 : 1)	(1.6 : 1)	(1 : 2.0)
D102	(1 : 1)	(1.5 : 1)	(1 : 1.4)
D103	(1 : 1)	(1.5 : 1)	(1 : 1.6)

본 논문에서는 여러 가지 구조요소에 대한 특징 추출 효율성에 대하여 비교·검토하였다. 표 5는 크기변화를 고려한 명암도 패턴 스펙트럼 방법에 사용된 각 구조요소에 대한 분류 정확도를 나타내고 있다. ○는 실험에서 사용된 구조요소를 나타낸다. 예로써 Case 6은 질감영상으로부터 특징들을 추출할 때 구조요소로써 수평라인, 수직라인, 정사각형, 십자가 구조요소가 사용된 것이다. Case 6과 Case 7은 좋은 분류 정확도를 나타내고 있다. 실험으로부터 수평라인, 수직라인, 정사각형, 십자가형의 구조요소가 45° 라인, 135° 라인 구조요소보다 특징 추출시 더 효율적임을 알 수 있었다. 이는 본 논문에서 사용된 영상에 의존적임을 나타낸다. 그러므로 위의 6가지 구조요소 모두를 사용하는 것이 보편적이다.




그림 6. 실험에 사용된 Brodatz's 질감영상과 각각 임의의 크기변화된 질감영상
 Fig. 6. Brodatz's textures and its arbitrary scaled textures used in the experiment.




그림 7. 명암도 closing 방법으로 수직 구조요소를 사용한 기존의 패턴 스펙트럼과 정규화 패턴 스펙트럼
 (a) 패턴 스펙트럼 (b) 정규화 패턴 스펙트럼
 Fig. 7. Conventional pattern spectrum and normalized pattern spectrum for gray scale closing method using vertical structuring element.
 (a) pattern spectrum (b) normalized pattern spectrum

표 2. 크기변화를 고려치 않은 기존의 명암도 방법에 의한 부영상 분류 정확도 [%]
Table 2. Subimage classification accuracy [%] for conventional gray scale method.

Image Scale	D52	D64	D65	D68	D75	D84	D102	D103	Avg.	Total Avg.
No scale image (Dn)	100	100	100	100	100	100	100	100	100	76.67
Zoom-in image (Dn-i)	84	76	88	48	60	64	80	52	69	
Zoom-out image (Dn-o)	80	92	64	84	48	40	12	68	61	

표 3. 제안한 크기변화를 고려한 명암도 방법에 대한 부영상 분류 정확도 [%]
Table 3. Subimage classification accuracy [%] of the proposed algorithm for gray scale method.

Image Scale	D52	D64	D65	D68	D75	D84	D102	D103	Avg.	Total Avg.
No scale image (Dn)	100	100	100	100	100	100	100	100	100	98.3
Zoom-in image (Dn-i)	100	100	100	100	100	100	100	84	98	
Zoom-out image (Dn-o)	100	100	100	100	100	88	100	88	97	

표 4. 제안한 크기변화를 고려한 이진 방법에 의한 부영상 분류 정확도 [%]
Table 4. Subimage classification accuracy [%] of the proposed algorithm for binary method.

Image Scale	D52	D64	D65	D68	D75	D84	D102	D103	Avg.	Total Avg.
No scale image (Dn)	100	100	100	100	100	100	100	100	100	95.3
Zoom-in image (Dn-i)	96	100	96	100	64	96	84	100	92	
Zoom-out image (Dn-o)	100	96	72	92	100	100	100	92	94	

VI. 결 론

본 논문에서는 크기변화를 통합하는 정규화 패턴 스펙트럼을 제안하여 질감영상 분류를 하였다. 크기변화를 고려하지 않은 기존의 명암도 패턴 스펙트럼 방법으로 분류시 zoom-in된 질감영상들과 zoom-out된 질감영상들의 평균 분류 정확도는 각각 69%와 61%로

매우 낮으며, 제안한 크기변화를 고려한 정규화 패턴 스펙트럼 방법에 의한 zoom-in 질감영상들과 zoom-out 질감영상들에 대한 평균 분류 정확도는 98%와 97%로 매우 높은 분류 정확도를 얻을 수 있었다. 또한 본 논문에서는 질감영상을 학습시 다른 방법과 달리 다양하게 크기변화된 질감영상을 사용하지 않고, 즉 학습시 기준크기의 영상만을 사용하여 매우 높은 분류 정확도를 얻을 수 있었다. 또한 전처리 과정을 통해서 영상의 상세한 정보 부분은 보존하면서 잡음을 효과적으로 제거할 수 있었다. 그리고 문턱값을 구한 후 각각 opening방법과 closing방법으로 패턴 스펙트럼을 구함으로써 효과적인 정보추출을 할 수 있었다.

표 5. 제안한 크기변화를 고려한 명암도 방법에 의한 각 특징 집합에 대한 분류 정확도 [%]
Table 5. Feature sets and classification accuracy [%] of the proposed algorithm for gray scale method.

Case #	Structuring element			Each average accuracy
	HL & VL	RD & LD	SQU & RHO	
Case 1	○			90.17
Case 2		○		84.50
Case 3			○	90.33
Case 4	○	○		94.17
Case 5		○	○	92.00
Case 6	○		○	97.17
Case 7	○	○	○	98.30

where HL : Horizontal Line, VL : Vertical Line.
RD : Right Diagonal
LD : Left Diagonal, SQU : Square.
RHO : Rhombus


본 논문에서는 학습시 최근의 다른 방법과는 달리 학습시 다양하게 크기변화된 질감영상을 사용하지 않고서도 매우 높은 정확도를 얻을 수 있었다. 하지만 완전한 질감영상 분류를 위해서는 카메라에 의한 영상의 회전까지도 고려하여야 하므로 앞으로 크기변화와 더불어 회전변화에도 무관한 알고리즘이 연구되어야 한다.

참 고 문 헌

[1] R. M. Haralick and L. G. Shapiro, *Computer and robot vision*, Addison-

- Wesley, Massachusetts, 1992.
- [2] R. M. Haralick, K. Shanmugam, and Its'hak Dinstein, "Texture features for images classification," *IEEE Trans. on Syst. Man Cybernet.*, vol. SMC-3, no. 6, pp. 610-621, 1978.
- [3] M. Pietikanien, A. Rosenfeld, and L. S. Davis, "Experiments with texture classification using averages of local pattern matches," *IEEE Trans. on Syst. Man Cybernet.*, vol. SMC-13, no. 3, pp. 421-426, 1983.
- [4] L. V. Gool, P. Dewale, and A. Oosterlinck, "Survey-texture analysis anno 1983," *Computer Vision Graphics and Image Processing*, vol. 29, pp. 336-357, 1985.
- [5] L. Wang and D. He, "Texture Classification Using Texture Spectrum," *Pattern Recogn.*, vol. 23, no. 8, pp. 905-910, 1991.
- [6] F. Cohen, Z. Fan, and M. Patel "Classification of rotated and scaled textured images using gaussian markov random field models," *IEEE Trans. Pattern Analysis Machine Intelligence*, vol. 13, pp. 192-202, Feb., 1991.
- [7] J. You and H. A. Cohen "Classification and segmentation of rotated and scaled textured images using texture "tuned" masks," *Pattern Recognition*, vol. 26, pp. 245-258, 1993.
- [8] G. S. Kim, K. H. Do, K. H. Kwon, J. C. Shim, and Y. H. Ha, "Texture classification using morphological pattern spectrum based on morphological subband decomposition," *JTC-CSCC '93*, vol. 1, pp. 212-216, Nara, Japan, Jul., 1993.
- [9] P. Maragos, "Pattern spectrum and multiscale shape representation," *IEEE Trans. Pattern Analysis Machine Intelligence*, vol. 11, pp. 701-716, 1989.
- [10] R. M. Haralick, S. R. Sternberg, and X. Zhuang, "Image analysis using mathematical morphology," *IEEE Trans. Pattern Analysis Machine Intelligence*, vol. PAMI-9, pp. 532-550, Jul., 1987.
- [11] J. Serra, *Image analysis and mathematical morphology*, vol. 1, Academic Press London: 1982.
- [12] J. Serra, *Image analysis and mathematical morphology*, vol. 2, Academic Press, London: 1988.
- [13] Dougherty, E. R., Newell, J. T., and J. B. Pelz, "Morphological texture-based maximum-likelihood pixel classification based on local granulometric moments," *Pattern Recogn.*, vol. 25, pp. 1181-1198, 1992.
- [14] J. S. Weszka, C. R. Dyer, and A. Rosenfeld, "A comparative study of texture measures for terrain classification," *IEEE Trans. System, Man, and Cybernetics*, vol. SMC-6, pp. 269-285, Apr., 1976.
- [15] P. F. Yand, P. Maragos, "Morphological systems for character image processing and recognition," *IEEE International Conference on Acoustics, Speech, and Signal Processing*, vol 5, pp. 97-100, 1993.
- [16] P. Brodatz, *Textures: A photographic album for artists and designers*, Dover Publications, 1966.

저 자 소 개



宋 根 遠(正會員)
1968年 7月 1日生. 1993年 경
북대학교 전자공학과(공학사),
1995年 경북대학교 전자공학과
대학원(공학석사). 1995年 ~
현재 동대학원 박사과정 재학중.
주관심분야는 컴퓨터 비전, 영

상 부호화등임.

金 紀 錫(正會員) 第 30 卷 B 編 第 4 號 參照

현재 경북대학교 전자공학과 박사과
정 재학중

都 敬 勳(正會員) 第 32 卷 B 編 第 12 號 參照

河 永 浩(正會員) 第 32 卷 B 編 第 12 號 參照

현재 경북대학교 전자공학과 교수