

論文94-31B-3-10

## 행렬 속성을 이용하는 질감 영상 분별기

### (A Classifier for Textured Images Based on Matrix Feature)

金 準 哲 \* , 李 俊 煥 \*\*

(Joon Cheol Kim and Joon Whoan Lee)

#### 要 約

SGLDM(Spatial Gray Level Dependence Matrix), NGLDM(Neighboring Gray Level Dependence Matrix), NSGLDM(Neighboring Spatial Gray Level Dependence Matrix), GLRLM(Gray Level Run Length Matrix) 등의 영상의 통계적 특성을 행렬의 형태로 포착하여 이용하는 질감분석 방법들에서는 각 행렬을 구하는데 요구되는 기억용량이 크고, 많은 계산량이 요구되며, 행렬이 많은 정보를 담고 있는데 반해, 그로 부터 구해진 몇몇 스칼라 측도들은 서로 상관 관계가 많고, 행렬 자체가 포함하고 있는 정보를 제한적으로 이용할 뿐이다. 본 논문에서는 행렬이 담고 있는 정보의 유실을 최대한 방지하며, 분별기 구성에 부담을 주지 않는 새로운 질감 영상의 분별기를 제안하고 평가하여 보았다. 제안된 방법에서는 이들 행렬의 의미를 부여할 수 있는 방향으로 투사(projection)하고 구해진 벡터들을 속성으로 이용한다. 제안된 분별기는 기지의 영상으로부터 얻어진 모형 벡터와 미지 영상의 속성 벡터의 유사성을 비교하여 최대의 유사성을 제공하는 영상으로 분할하는 방법을 이용하고 있다. 제안된 방법은 농산물 영상의 구별에 이용되어 85-95%의 분별력을 보였다.

#### Abstract

For the analysis of textured image, it requires large storage space and computation time to calculate the matrix features such as SGLDM(Spatial Gray Level Dependence Matrix), NGLDM (Neighboring Gray Level Dependence Matrix), NSGLDM(Neighboring Spatial Gray Level Dependence Matrix) and GLRLM(Gray Level Run Length Matrix). In spite of a large amount of information that each matrix contains, a set of several correlated scalar features calculated from the matrix is not sufficient to approximate it. In this paper, we propose a new classifier for textured images based on these matrices in which the projected vectors of each matrix on the meaningful directions are used as features. In the proposed method, an unknown image is classified to the class of a known image that gives the maximum similarity between the projected model vector from the known image and the vector from the unknown image. In the experiment to classify images of agricultural products, the proposed method shows good performance as much as 85-95% of correct classification ratio.

\* 正會員, 西南大學校 電子工學科  
(Dept. of Elec. Eng., Seonam Univ.)  
\*\* 正會員, 全北大學校 電子工學科  
(Dept. of Elec. Eng., Chonbuk Nat'l Univ.)

\* 이 논문은 1993년도 한국학술진흥재단의 공모  
과제 연구비에 의하여 연구되었습니다.  
接受日字 : 1993年 3月 24日

## I. 서 론

질감(texture)은 영상(image)내의 물체나 지역 등을 식별하는데 중요한 속성으로 의료영상<sup>1)</sup>, 항공사진등의 분석이나 작품의 품질검사<sup>2)</sup>, 현미경 사진을 이용한 기계 표면처리 검사<sup>3)</sup> 등에 널리 활용되고 있다. 현재까지 대부분의 질감영상의 분석기법은 영상의 통계적 성질을 이용하거나, 질감패턴의 구조적 특징을 이용하고 있다. 영상의 통계적 성질을 바탕한 질감분석 방법에는 영상의 자기상관 함수(autocorrelation function)를 이용하는 방법, 전력 스펙트럼(power spectrum)을 이용하는 방법<sup>4)</sup>, Julesz의 추측을 바탕으로 한 2계 통계(second-order statistics)를 이용하는 방법<sup>5)</sup>, 영상의 국부적인 그레이 레벨 변화를 이용하는 방법, 그레이 레벨의 run-length를 이용하는 방법, 차원의 개념을 일반화시킨 프랙탈 차원(fractal dimension)을 이용하는 방법<sup>6), 7)</sup> 또는 Markov Random Field를 이용하는 방법등이 사용되고 있다.<sup>8)</sup> 또한, 구조적 질감의 경우에는 질감의 기본요소(primitive)들과 이들이 배열된 구조적 형태를 일련의 규칙(Rule)으로 표시하여 이용하는 방법 등이 있다.<sup>9), 10)</sup> 본 논문에서 고려하는 질감분석 방법은 영상의 통계적 성질을 표현하는 행렬을 이용하는 방법으로, 2계 통계값을 구하는 대표적인 방법인 SGLDM(Spatial Gray Level Dependence Matrix), 영상의 국부적인 그레이 레벨 변화를 표현하는 NGLDM(Neighboring Gray Level Dependence Matrix) 및 NSGLDM(Neighboring Spatial Gray Level Dependence Matrix)과 run-length을 표현하는 GLRLM(Gray Level Run Length Matrix) 등이다.<sup>11), 12)</sup>

이러한 영상의 통계적 성질을 표현하는 행렬을 이용하는 방법들은 행렬을 구하는데 요구되는 기억용량이 크고, 많은 계산량이 요구되며, 행렬이 많은 정보를 담고 있는데 반해, 그로 부터 구해진 몇몇 스칼라 측도들은 서로 상관 관계가 많고, 행렬 자체가 포함하고 있는 정보를 충분히 표현하는데 미흡하다. 계산량의 문제점을 해결하기 위하여 고속으로 행렬을 구하는 방법이 제안되고 있으며<sup>13)</sup>, 정보 유실의 문제점은 Berry등이 행렬로부터 몇몇 스칼라 속성들을 계산하는 대신에 NGLDM이나 NSGLDM등의 비교적 크기가 작은 행렬의 요소들을 속성으로 한 질감 분별기를 제안하였다.<sup>14)</sup> 그러나, 이 방법은 행렬이 가지고 있는 많은 양의 정보를 충분히 이용할 수 있는 장점이 있으나, 속성 공간의 차원이 그레이 레벨 수에 따라 크게 증가하기 때문에 많은 그레이 레벨을 갖는

영상에 적용하는 것은 계산량이 증가하여 분별기 구성이 복잡해 진다.

이러한 문제점을 해결하기 위하여 본 논문에서는 행렬이 담고 있는 정보의 유실을 최대한 방지하며, 분별기 구성에 부담을 주지 않는 새로운 질감 영상의 분별기를 제안하고 평가하여 보았다. 제안된 방법에서는 SGLDM, NGLDM, NSGLDM, GLRLM등의 행렬을 의미를 부여할 수 있는 방향으로 투사(projection)하고, 이렇게 구해진 벡터들을 속성으로 이용한다. 또한 제안된 속성을 이용하는 분별기는 각 질감 영상들의 표본으로부터 이들 속성 벡터들을 계산하고 미지의 영상으로부터 구해진 속성 벡터와의 유사성(similarity)을 측정하여 최대의 유사성을 제공하는 영상으로 분별하는 방법을 이용한다.

제안된 방법은 산수유, 원자, 원육 및 대추등의 농산물 영상을 분별하는데 사용하여 약 85~95% 정도의 분별력을 확인하였고 기억공간이 상대적으로 적게 필요한 NGLDM과 NSGLDM이 SGLDM보다 좋은 결과를 나타내었으며, GLRLM이 가장 우수하였다. 제안한 방식의 분별기 구성은 Hamming 네트<sup>15)</sup>와 유사하게 별령처리가 가능한 방법이며, 행렬의 요소들이 접유하는 공간을 기지의 영상으로부터 투사된 벡터들을 이용하여 영역을 분할(soft partition)하고, 미지의 영상으로부터 얻어진 벡터들의 분할된 각 영역에 대한 적합도를 측정하여 분별하는 방법으로 최근에 커지 집합 이론을 이용하는 패턴인식 분야에 연구되고 있는 분야이다.<sup>16), 17)</sup>

본 논문의 Ⅱ절에서는 행렬을 이용하는 질감 분석 방법들을과 각 행렬의 투사방법을 분별기 구성 방법과 함께 기술하였으며, Ⅲ절에서는 실험 결과를 요약하고 검토하였으며, Ⅳ절에서는 결론을 맺었다.

## II. 행렬을 이용하는 질감 분석 방법 및 분별기 구성

일반적으로 행렬을 이용하는 질감 분석 과정에서는 질감을 두드러지게 하고, 행렬의 계산량과 기억용량을 줄이기 위해 그레이 준위를 재조정하는 전처리과정(preprocessing)을 거친다. 행렬을 이용하는 질감 분석 방법에서는 이러한 전처리된 영상의 통계적 성질을 표현하는 행렬을 구하고, 이를 이용하여 다양한 스칼라 측도들을 계산한다. 이러한 행렬을 이용하는 방법에는 2계 통계치를 구하는 SGLDM과, 영상의 국부적인 그레이 레벨 변화를 표현하는 NGLDM 및 NSGLDM, 그리고 run-length을 이용하는 GLRLM 등이 사용되고 있다. 본 절에서는 이들 행렬을 이용

하는 질감 분석 방법들의 정의와 성질을 요약하고, 이들 행렬을 투사하였을 경우 투사된 속성 벡터들의 의미를 서술하며, 이러한 속성 벡터를 효율적으로 이용하는 분별기를 제안한다.

### 1. 질감 영상의 통계적 성질을 표현하는 행렬

#### (1) SGLDM

질감 영상  $I(\dots)$ 의 2계 통계를 표현하는 행렬  $SGLDM(m,n)$ 은 주어진 거리  $d$ 와 방향  $\theta$ 를 파라메터로하여 다음과 같이 정의 될수 있다.<sup>[2][9][11]</sup>

$$SGLDM(m,n) = \text{Card} \left\{ \begin{array}{l} ((i,j),(k,l)) \in I \times I, \\ \rho((i,j),(k,l)) = d, \\ \text{angle}((i,j),(k,l)) = \theta, I(i,j) = m, I(k,l) = n \end{array} \right\} \quad (1)$$

여기서,  $\text{Card}()$ 는 집합의 원소의 갯수(cardinality)를 표현하며,  $\rho(\dots)$ 는 화소간의 거리,  $\text{angle}(\dots)$ 는 화소간의 각도를 표시한다. 일반적으로 거리의 정의로는

$$\rho(i,j),(k,l) = \max(|i-k|, |j-l|) \quad (2)$$

를 사용하고, 화소간의 각도는

$$\text{angle}(i,j),(k,l) = \tan^{-1}((i,j)/(k,l)) \quad (3)$$

로 주어지며, 거리  $d = 1$  인 경우, 방향  $\theta$ 는  $0^\circ, 45^\circ, 90^\circ, 135^\circ$  등이 된다. SGLDM은 각도에 관계되어 있으며, 영상의 회전에 무관(rotationally independent)한 행렬을 얻기 위해서는 각각의 각도에 해당하는 SGLDM들을 산술적으로 평균하여 하나의 행렬을 구할 수 있으며, 각도  $\theta$  와  $\theta + 180^\circ$ 를 구분하지 않기 때문에 대칭적이다. 행렬을 표현하기 위해 필요한 기억공간은 만약 그레이 레벨의 수가  $R$ 이라면,  $R^2$  개의 기억 공간이 요구되며, 그레이 레벨의 수의 제곱에 비례하는 형태로 많은 기억 공간이 필요하게 된다. 그럼 1에는 간단한 영상에 대한,  $d = 1, \theta = 0^\circ$  일 경우의 SGLDM을 표현하였다.

0	0	1	1
0	0	1	1
0	2	2	2
2	2	3	3

(a) 원 영상

4	2	1	0
2	4	0	0
1	0	6	1
0	0	1	2

(b) SGLDM ( $d = 1, \theta = 0^\circ$  일 경우)

그림 1. SGLDM의 예

Fig. 1. An Example of SGLDM.

Haralick등은 이러한 SGLDM을 행렬 요소들의 합으로 정규화하고, 10여개의 스칼라 속성들을 언급하였는데, 이들 스칼라 속성들은 서로 상관관계(correlation)가 많으며, SGLDM의 행렬을 제한적으로 표현하고 있다. 예를 들어, 균질성(Homogeneity)<sup>[2][9][11]</sup>

$$H = \sum_m \sum_n (1 + (m - n)^2)^{-1} \times SGLDM(m,n) \quad (4)$$

과 관성(Inertia)

$$I = \sum_m \sum_n (m - n)^2 \times SGLDM(m,n) \quad (5)$$

의 관계를 보면, 어떤 영상의 균질성이 크다면 SGLDM의 주대각(diagonal) 근방에 큰 값이 분포하는 경우로, 관성은 작아지게 된다. 따라서, 이들 두 속성은 동시에 사용하여 질감 분석을 행하는 것은 필수적인 속성만을 요구 하는 경우에는 피하는 것이 바람직하다.

#### (2) NGLDM 및 NSGLDM

질감 영상  $I(\dots)$ 의 NGLDM은 거리  $d$ 와 그레이 준위차를 파라메터로, 다음과 같이 두 가지 형태로 계산된다.<sup>[2][9][11]</sup>

$$NGLDM_1(m,n) = \text{Card} \left\{ \begin{array}{l} ((i,j) \in I) \mid I(i,j) = m, \text{Card} \left\{ k,l \in I - \{(i,j)\} \right. \\ \left. \rho((i,j),(k,l)) \leq d, |I(i,j) - I(k,l)| \leq \alpha \right\} = n \end{array} \right\} \quad (6)$$

$$NGLDM_2(m,n) = \text{Card} \left\{ \begin{array}{l} ((i,j) \in I) \mid I(i,j) = m, \text{Card} \left\{ k,l \in I - \{(i,j)\} \right. \\ \left. \rho((i,j),(k,l)) \leq d, |I(i,j) - I(k,l)| \leq \alpha \right\} = n \end{array} \right\} \quad (7)$$

식 (6)와 식(7)에서 알수 있드시, NGLDM이 SGLDM과 다른점은 방향성을 가지지 않기 때문에 회전에 무관하다는 것이다. 또한 NGLDM은 거리  $d$  이내의 이웃한(neighboring) 화소에 대해 국부적으로 계산되기 때문에 병렬 연산이 SGLDM에 비해 용이할 수 있으며, 필요한 기억공간 역시 NGLDM이  $R \times (R+1)$  행렬이기 때문에  $R$ 이  $R$  보다 작으면 SGLDM 보다 작게 된다. 여기서,  $R$ 은 식 (2)의 거리 정의를 이용한다면

$$R = 4d^2 + 4d + 1 \quad (8)$$

이며, 만약  $d = 1$  또는  $d = 2$ 를 사용한다면 그레이 준위의 수  $R$  보다 일반적으로 작아 진다. 또한 NSGLDM은 NGLDM과 유사한 형태로, 거리  $d$ 와 그레이 준위차  $\alpha$ 를 파라메터로 하여, 다음과 같이 정의 된다.<sup>[5]</sup>

$$\begin{aligned} NSGLDM_1(m,n) &= Card\left[\left\{(i,j) \in I \mid I(i,j) = m, Card\left[\left\{k,l \in I - \{(i,j)\} \mid |I(i,j) - I(k,l)| \leq \alpha\right\}\right] = n\right\}\right] \\ &\rho((i,j)(k,l)) = d, \mid I(i,j) - I(k,l) \mid \leq \alpha\} = n\right] \quad (9) \end{aligned}$$

$$\begin{aligned} NSGLDM_2(m,n) &= Card\left[\left\{(i,j) \in I \mid I(i,j) = m, Card\left[\left\{k,l \in I - \{(i,j)\} \mid |I(i,j) - I(k,l)| \leq \alpha\right\}\right] = n\right\}\right] \\ &\rho((i,j)(k,l)) = d, \mid I(i,j) - I(k,l) \mid \leq \alpha\} = n\right] \quad (10) \end{aligned}$$

NSGLDM은 정확히 거리  $d$ 인 이웃들만 고려 하기 때문에,  $R_1 \times (R_2+1)$  행렬이고  $d$  가 크면  $R_1 \gg R_2$  이기 때문에 NGLDM보다 더욱 기억 용량을 절약할 수 있다. 여기서,  $R_2$  는 식 (2)의 거리 정의를 이용한다면  $R_2 = 8d$  이다. 그럼 2는  $d = 1$  이고,  $\alpha = 0$  인 경우의 NGLDM을 예로 보았다. (이 경우 NGLDM<sub>1</sub>, NGLDM<sub>2</sub>, NSGLDM<sub>1</sub>, NSGLDM<sub>2</sub>는 모두 동일함)

1	1	2	3	1
0	1	1	2	2
0	0	2	2	1
3	3	2	2	1
0	0	2	0	1

(a) 원 영상

0	0	1	0	0	0	0	0	0
0	0	1	1	0	0	0	0	0
0	0	0	0	4	1	0	0	0
0	1	0	0	0	0	0	0	0

(b) NGLDM과 NSGLDM

그림 2. NGLDM과 NSGLDM의 예  
( $d = 1$ ,  $\alpha = 0$ 인 경우)

Fig. 2. An Example of NGLDM and NSGLDM.

SUN등은 NGLDM을 기초로하는 스칼라 측도 SNE(Small Number Emphasis)<sup>2, 9, 11, 17</sup>

$$SNE = \sum_m \sum_n NGLDM(m,n) / n^2 \quad (11)$$

와 LNE(Large Number Emphasis)

$$LNE = \sum_m \sum_n n^2 \times NGLDM(m,n) \quad (12)$$

등을 제안하였는데, 이들 역시 상관관계가 크다. 즉 SNE가 큰 영상, 즉 그레이 레벨의 불규칙함이 심한 영상은 일반적으로 LNE가 작게 된다. NGLDM과 NSGLDM은 SGLDM에 비해 행렬의 요소수가 크게 감소되기 때문에 행렬의 요소 전체를 속성으로 간주 할 수 있다. Berry등은 행렬의 요소들이 multinomial 확률 분포를 갖는다는 가정하에 행렬의 요소 전체를 속성으로 이용하는 maximum likelihood 분

별기를 구성하였다. 그러나, 이들의 접근 방법의 경우 그레이 레벨의 수가 증가되면 행렬의 요소수가 많게 되어 분별기 구성에 부담을 줄 수 있다.

### (3) GLRLM

질감 영상의 방향  $\theta$  를 파라메터로 GLRLM은<sup>2, 9, 11, 18</sup>

$$GLRLM(m,n) = Card\left[\left\{(i,j) \in I \mid I(i,j) = m, \tau(m,\theta) = n\right\}\right] \quad (13)$$

로 표현되며, 여기서  $\tau(m,\theta)$  는  $\theta$  방향의 그레이 레벨  $m$ 의 run-length에 해당된다. 따라서 GLRLM은 방향성을 가지고 있으며, 방향에 무관한 GLRLM을 구성하기 위해서는 각 방향의 GLRLM들을 산출 평균하여 이용할 수 있다. GLRLM은  $R_1 \times R_2$  행렬이며, 여기서  $R_2$ 는 최대의 run-length를 표현하고, 각도  $\theta$  를  $0^\circ, 45^\circ, 90^\circ, 135^\circ$  로 할 경우에는 정사각형 형태 영상의 한 변의 크기에 해당한다. GLRLM으로부터 얻을 수 있는 스칼라 척도들은 SRE(Short Run Emphasis)

$$SRE = \sum_m \sum_n GLRLM(m,n) / n^2 \quad (14)$$

와 LRE(Long Run Emphasis)

$$LRE = \sum_m \sum_n n^2 \times GLRLM(m,n) \quad (15)$$

등이 Galloway에 의해 제안된 바 있으나, 이를 역시 상관관계가 큰 것을 알 수 있다. 즉 run-length가 큰 균질한 영상에서는 LRE가 크고 SRE는 작게 되며, run-length가 작은 영상에서는 반대가 된다. 그림 3 에는 간단한 영상의 GLRLM을 예를 나타내었다.

0	1	2	3	4	0	0	0
0	2	3	3	1	0	1	0
2	1	1	1	3	0	0	0
3	0	3	0	3	1	0	0

(a) 원 영상

(b) GLRLM ( $\theta = 45^\circ$ )

그림 3. GLRLM의 예

Fig. 3. An Example of GLRLM.

## 2. 행렬의 투사 방법 및 의미

### (1) SGLDM의 경우

그레이 레벨 영상으로부터 얻어진 행렬 SGLDM

(m, n)은 대칭 행렬이고, Haralick등은 행 방향, 주 대각 방향, 부대각 방향 투사를 제안하였다.(주: Haralick등은 실제 이러한 투사된 벡터를 속성으로 이용하지는 않고, 이들 벡터로 부터 스칼라 속성들을 얻어 내는데 사용하였음) SGLDM을 행방향으로 투사하여

$$SGLDM\_M(m) = \sum_n SGLDM(m, n); m = 1, \dots, R \quad (16)$$

을 구하면 원래 SGLDM을 구하는 영상의 히스토그램과 일치하여, 영상의 밝기 정보의 분포를 구할 수 있다. 따라서, 1계 통계치(First-Order Statistics)인 평균(Mean)<sup>[2] [9] [11]</sup>은 투사된 SGLDM\_M(m)으로 부터

$$Mean = \sum_m m \times SGLDM\_M(m) \quad (17)$$

과 같이 계산되며, 분산(Variance)은

$$Var = \sum_m (Mean - m)^2 \times SGLDM\_M(m) \quad (18)$$

과 같이 계산되기 때문에 SGLDM\_M으로부터 구해진 특별한 스칼라 속성으로 생각 할 수 있다. 본 논문의 분별기에서 이용하는 속성은 SGLDM\_M(m)을 대표하는 스칼라 값들이 아니라, SGLDM\_M(m) 자체로서 R차원의 벡터이다. 만약 질감 영상의 히스토그램이 Gaussian 분포를 갖는다면, SGLDM\_M(m)의 평균과 분산의 두 스칼라 값으로서 SGLDM\_M(m)을 표현하는데 충분하나, 그렇지 않은 경우에는 두 스칼라 값의 표현은 균사화된 표현에 불과하다.

또한 행렬 SGLDM(m, n)을 부대각 방향으로 투사한

$$SGLDM\_P = \sum \sum SGLDM(m, n) \text{ for all } m - n = i, \\ \text{and } m \geq n; i = 1, \dots, R \quad (19)$$

은 이웃한 화소들의 그레이 레벨의 차가 i인 화소들의 수의 분포로 R차원의 벡터이다. 만약 화상의 인접한 화소들의 그레이 레벨 차가 서로 크다면 큰 i값에서 SGLDM\_P의 값은 커지게 되며, 균질한 영상의 경우는 작은 i값에서 큰 SGLDM\_P 값을 갖는다. Haralick등이 제안한 차 분산(Difference Variance)<sup>[11]</sup>

$$D.V = variance \text{ of } SGLDM\_P \quad (20)$$

와 차 엔트로피(Difference Entropy)

$$D.E = - \sum_m SGLDM\_P(i) \times SGLDM\_P(i) \quad (21)$$

는 SGLDM\_P로 부터 직접구해지며, 식 (4)의 균질성과 식 (5)의 관성을 SGLDM\_P의 특성을 근사적으로 표현하는 특별한 경우로 생각할 수 있다. 또한 SGLDM 행렬을 주대각 방향으로 투사한

$$SGLDM\_N(i) = \sum \sum SGLDM(m, n) \text{ for all } m + n = i, i = 2, \dots, 2R \quad (22)$$

을 생각할 수 있고, Haralick은 이 분포의 평균(Sum Average)과 분산(Sum Variance), 엔트로피(Sum Entropy)등의 스칼라 속성을 제안하였으나, 본 논문에서는 SGLDM\_N 벡터의 차원이 SGLDM\_M이나 SGLDM\_P보다 크고, SGLDM\_M과 유사한 성질을 갖기 때문에 분별기 구성시 속성에서 제외하였다.

## (2) NGLDM 과 NSGLDM

SGLDM과 마찬가지로 회전에 무관한 NGLDM 행렬도 의미를 부여할 수 있는 방향으로 투사하여 영상의 특성을 발견할 수 있다. NGLDM을 행방향으로 투사 하여

$$NGLDM\_M(m) = \sum_n NGLDM(m, n); m = 1, \dots, R \quad (23)$$

을 구하면 SGLDM\_M과 마찬가지로 영상의 명암분포가 균사적으로 표현된다. 여기서 투사되어 구한 NGLDM\_M은 R차원의 벡터이고, m이 작은 값에서 NGLDM\_M이 크다면, 어두운 영상을 의미하고, m이 큰값에서 큰 NGLDM\_M값을 갖는다면 밝은 영상이다. 또한 NGLDM 행렬을

$$NGLDM\_N(m) = \sum_n NGLDM(m, n); n = 1, \dots, R_i \quad (24)$$

와 같이 투사하면, 투사된 행렬 NGLDM\_N은 R<sub>i</sub> 차원의 벡터이며, 질감의 심한 정도를 표현한다. 즉 작은 n 값에서 NGLDM\_N이 크다면, 이웃 화소들 사이의 변화가 심한 영상이며, 큰 n 값에서 NGLDM\_N이 크다면, 비교적 균질한 영상이다. SUN등이 제안한 식 (11)의 SNE와 식 (12)의 LNE는 NGLDM으로부터 얻어 낼수 있는 스칼라 측도이다.

NSGLDM 행렬 역시 NGLDM과 같은 방향으로 투사하여 R 차원의 벡터 NSGLDM\_M과 R<sub>i</sub> 차원의 벡터 NSGLDM\_N을 얻을 수 있으며. 이들 벡터들은 각각 NGLDM\_M과 NGLDM\_N등과 유사한 의미를 부여할 수 있다.

## (3) GLRLM

각 방향으로 부터 얻어진 GLRLM들을 산술 평균하여 얻어진 GLRLM도 같은 방법으로 투사하여 R 차원의 벡터 GLRLM\_M과 R3차원의 벡터 GLRLM\_N( $n$ )를 구할 수 있으며 NGLDM에서와 유사한 의미를 부여할 수 있다. 즉 GLRLM을 행 방향으로 투사한

$$GLRLM\_M(m) = \sum_n GLRLM(m, n) : m = 1, \dots, R \quad (25)$$

은 질감 영상의 명암 정보를 표현하며,  $m$ 이 작은 값에서 GLRLM\_M의 값이 크면 어두운 영상이며,  $m$ 이 큰 값에서 GLRLM\_M 값이 크면 밝은 영상이다. 또한 GLRLM을 열 방향으로 투사한

$$GLRLM\_N(n) = \sum_m GLRLM(m, n) : n = 1, \dots, R \quad (26)$$

은 질감 영상의 run-length 분포를 표현하며, 균질한 영상의 경우는  $n$ 값이 큰 부분에 큰 값을 갖는다. 식 (14)의 SRE와 식 (15)의 LRE는 벡터 GLRLM\_N을 표현하는 스칼라 속성으로 간주할 수 있다.

## 3. 분별기 구성

1절에서 언급한 벡터들을 분별기의 속성으로 사용할 경우 속성 공간의 차원이 커지게 되어 계산량이 증가하는 단점이 있으며, 이들 벡터의 각 요소들은 독립적으로 간주하기 어려운 일종의 분포들이다. 본 논문에서는 이들 분포들이 행렬의 요소들이 분포되어 있는 형태를 근사적으로 표현한다고 간주하고, 이들 벡터의 (비)유사성을 측정하여 이용하는 분별기를 제안한다.

제안하는 분별기의 구성도는 그림 4와 같고, 그 절차를 아래의 알고리즘에 요약하였다. 그림 4에서 모형 벡터는 기지의 질감 영상들의 표본을 추출하여 행렬을 계산하고 투사하여 off-line으로 얻어지며, 미지의 질감 영상들로 부터 행렬 계산과 투사를 통하여 얻은 벡터들은 모형 벡터들과 (비)유사성을 측정하게 된다. 여기서 사용하는 각 행렬들은 항상 두방향으로 투사되어 두개의 벡터를 만들어 내고, (비)유사성 측도를 각각의 벡터들에 적용하여야 하기에, 알고리즘의 단계 3에서 와 같이 두개의 (비)유사성 측도값이 계산된다. 따라서 미지의 영상을 기지의 영상들의 총체화된 (비)유사성을 계산하여야 유사성이 큰 곳(비유사성이 작은 곳)으로 미지의 영상을 할당할 수 있고, 단계 4의 총체화 과정은 수많은 총체화 연산자(aggregation operator)를 이용하여 실현할 수 있다. 본 논문에서는 max 또는 min등의 극단적인 총

체화 방법을 피하기 위해 보상적인 성질을 갖고 계산이 비교적 간단한 산술 평균 연산자를 총체화 연산에 이용하였다.

제안한 분별기에서 이용하는 벡터 SGLDM\_M, NGLDM\_M, NSGLDM\_M, GLRLM\_M등은 질감 영상의 밝기 정보를 담고 있기 때문에 전처리과정에서 질감을 두드러지게 하는 히스토그램 평활화(equalization)를 하면, 그 의미를 상실할 수 있다. 따라서 제안된 분별기에서 전처리 과정은 단순하게 선형적으로 양자화하여 256개의 그레이 레벨의 수를 줄이는 것을 말한다.

## 알고리즘

- 단계 1: 기지의 질감 영상들의 표본들로 부터 2.1 절의 행렬을 계산하고, 2.2절의 투사를 통하여 얻은 모형 벡터들  $A_{k1}, A_{k2}, k = 1, \dots, N$ 을 구한다. 여기서  $N$ 는 고려하는 질감 영상의 종류의 개수이고,  $A_{11}, A_{k2}$ 는  $k$  번째 기지의 영상으로 부터 얻은 행렬을 두 방향으로 투사하여 얻은 벡터들이다.
- 단계 2: 미지의 질감 영상의 창틀 내의 질감에 대하여 2.1절의 행렬을 계산하고, 두 방향으로 투사하여 벡터  $B_1$ 과  $B_2$ 를 얻는다.
- 단계 3: 모든  $k = 1, \dots, N$ 에 대하여  $A_{k1}$  와  $B_1$ 의 (비)유사성  $S_{k1}$ ,  $A_{k2}$ 와  $B_2$ 의 (비)유사성  $S_{k2}$ 를 계산한다.
- 단계 4: 모든  $k = 1, \dots, N$ 에 대하여 (비)유사성  $S_{k1}$  와  $S_{k2}$ 를 총체화 연산을 이용하여, 총체화된 (비)유사성  $S_k$ 를 구한다.
- 단계 5: 비유사성 측도를 사용하였을 경우에는  $\min\{S_k\}$ 을 제공하는 기지의 영상으로 미지의 영상을 분별하고, 유사성 측도를 사용 하였을 경우에는  $\max\{S_k\}$ 를 제공하는 기지의 영상으로 분별한다.




그림 4. 분별기 구성도

Fig. 4. Schematic Diagram of Proposed Classifier.

모형과 입력영상으로부터 얻어진 투사된 행렬들을 비교할 때 어떠한 (비)유사성 측도를 사용하는가는 중요한 문제이다. 본 논문에서는 최대값을 1로 정규화한 두 벡터 A와 B를 퍼지 소속함수로 가정하고, 다음과 같은 (비)유사성 측도들을 고려하였다. 본 논문에서 투사된 벡터들을 퍼지 집합으로 가정하고 이들의 (비)유사성을 비교한 이유(평균 자승 오차 제외)는 최종적으로 분류되는 기지의 영상과 미지의 영상 사이의 (비)유사성 측도는 분류시 신뢰도를 부여 할 수 있는 장점이 있기 때문이다. 예를 들어 어떤 미지의 영상이 기지의 영상에 최종적인 유사성이 0.9로 분류된다면, 0.5로 분류되는 것 보다는 신뢰성이 높은 것으로 간주될 수 있다.

(1) 평균 자승 오차(Mean Square Error)의 비유사성 측도

$$MSE = \sum_i (A[i] - B[i])^2 \quad (27)$$

(2) Max-Min의 유사성 측도

$$K = \max_i \{ \min(A(i), B(i)) \} \quad (28)$$

(3) 퍼지 Hausdorff distance의 비유사성 측도<sup>[19]</sup>

$$q(A, B) = \int q(A(\alpha), B(\alpha)) d\alpha \quad (29)$$

여기서,  $A(\alpha)$  와  $B(\alpha)$  는 퍼지 집합  $A(i)$ 와  $B(i)$ 의  $\neg$ -level 집합으로 소속함수의 값이  $\alpha$  보다 큰 구간을 표현하며, 괴적분함수  $q(\dots)$ 는 두 구간의 Hausdorff distance로 만약  $A(\alpha) = [a_1, b_1]$ ,  $B(\alpha) = [a_2, b_2]$  라면

$$q(A(\alpha), B(\alpha)) = \max \{ |a_1 - b_1|, |a_2 - b_2| \} \quad (30)$$

이다.

(4) Dubois 와 Prade의 유사성 측도<sup>[20]</sup>

$$S(A, B) = |A \cap B| / |A \cup B| \quad (31)$$

여기서

$$A \cap B = \min[A(i), B(i)] \quad (32)$$

$$A \cup B = \max[A(i), B(i)] \quad (33)$$

이며,

$$|A| = \sum_i A(i) \quad (34)$$

로 퍼지 집합의 cardinality이다.

본 논문의 분별기는 그림 4에서 알 수 있드시. Hamming 네트와 유사한 형태로 구성되며, 병렬처리가 가능하다. 즉 단계 3에서 기지의 영상으로부터 얻어진 벡터 속성과 미지 영상으로 얻어진 벡터간의 (비)유사성을 병렬적으로 측정할 수 있고, 이들을 비교하는 부분은 (min)max 네트를 이용하여 분별기를 구성할 수 있다. (Hamming 네트에서는 벡터의 내적을 유사성 측도로 사용하고, 유사성의 크기 비교는 max 네트를 이용하고 있음)<sup>[13]</sup>

또한 제안된 분별기는 그림 5와 같이 질감을 표현하는 행렬의 요소들이 점유하는 공간을 기지의 영상으로부터 투사된 벡터들을 이용하여 영역을 분할하고, 미지의 영상으로부터 얻어진 벡터들의 분할된 각 영역에 대한 적합도의 유사성을 측정하여 분별하는 방법으로 간주될 수 있다. 그림 5에서  $A_i$ 는 투사된 벡터들을 의미하고  $P_i$ 는 분할된 영역들이다.




그림 5. 행렬의 분할

Fig. 5. Soft Partition of a Matrix.

### III. 실험 및 검토

행렬들로 부터의 제안된 질감 속성 추출 방법과 분별기의 성능을 검토하기 위하여 실험에서는 256 x 256 x 6 bit의 산수유, 원지, 원육, 대추등의 농산물 영상을 분별하는데 적용하였다. 그림 6은 실험에 사용한 영상을 나타내었다. 실험 영상들로 부터 속성 벡터들은 각 영상에 대하여 창틀크기를 64 x 64 블럭으로 하여 창틀을 16스텝씩 행과 열로 이동하여 169 개의 행렬을 구하고, 각 행렬을 2.2절에서 언급한 두 방향으로 투사하여 행렬당 두개의 벡터를 만들었다.

기지 영상의 모형 벡터를 위해서  $2 \times 169$  개의 벡터 중에서  $2 \times 20$ 개를 취하고, 이 벡터들을 평균하여 기지 영상당 2개의 모형 벡터를 만들어내고, 나머지  $2 \times 149$ 개의 벡터를 검증 데이터로 분할하는데 사용하였다.




그림 6. 실험에 사용한 영상들

Fig. 6. Textured Images for Experiment.

본 실험에서는 (비)유사성 측도중에서 식 (27)의 평균 자승 오차와 Dubois 와 Prade가 제안한 식 (31)의 퍼지집합 이론적 유사성 측도만 사용하여 실험한 결과만을 나열하였다. 그 이유는 Max-Min 측도는 너무 극단적인 비교가 이루어져서 에러가 매우 크고, 퍼지 Hausdorff distance 측도는 가장 우수한 성능을 보였으나, 벡터들이 convex하지 않아서 -level 집합이 하나의 구간이 아니고 일반적으로 많은 구간이 발생되어, 유사성을 측정하는데 너무 많은 계산량이 요구 되기 때문에 제외하였다. 평균 자승 오차의 비유사성 측도 값과 Dubois와 Prade의 유사성 측도 값을 총체화하기 위해서는 평균연산자를 사용하였고 최소의 오차 또는 최대의 유사성을 제공하는 영상으로 미지의 영상을 할당하였다.

표 1은 SGLDM을 이용하였을 경우로 가장 우수한 성능을 나타낸  $d = 2$  일 경우의 혼동 행렬 (confusion matrix)를 표시하였다. 표 1의 수치는 기지의  $2 \times 20$ 개의 모형 벡터를 만들기위한 표본을 서로 다르게 바꾸어 가며 5회 반복 실험한 결과를 평균한 것이다. 표 1에서 알 수 있드시, 모든 에러는 눈으로 보기에도 분류가 수월하지 않은 산수유와 원

육 사이에서 발생하고(단 칼라 영상에서는 산수유는 붉은색계통이고 원육은 짙은 고동색이므로 구별이 쉬움) 원지와 대추 영상은 완벽하게 분류해냈다. 또한 평균자승 오차를 이용한 경우에 비해 Dubois와 Prade의 유사성 측도를 이용하는 경우가 성능이 더욱 좋음을 알 수 있다. 표 2에는  $d = 2$  일 경우 SGLDM으로 부터 얻을 수 있는 에너지(Energy)<sup>[2]</sup>

$$Energy = \sum_m \sum_n SGLDM^2(m, n) \quad (35)$$

엔트로피(Entropy)

$$Entropy = -\sum_m \sum_n SGLDM(m, n) \times \log(SGLDM(m, n)) \quad (36)$$

와 식 (5)의 관성등 3가지 속성을 이용하여 단층 퍼셉트론(single-layer perceptron)<sup>[21]</sup>을 이용하여 분류한 경우로 표 1의 제안된 방법을 이용하는 경우보다 훨씬 성능이 떨어지는 것을 알 수 있었고, 학습 데이터에 따라 산수유와 원육은 선형분리(linearly saparable) 불가능한 경우도 나타났다.

표 3에는  $d = 2$ ,  $\alpha = 0$  인 경우의 NGLDM의 결과를 요약한 경우로 모형 벡터를 바꾸어 가며 5 회 반복 수행한 결과의 평균치이다. 표 2에서 알 수 있드시 NGLDM의 결과는 SGLDM의 결과 보다 우수하였고, 표 1의 결과와 같이 Dubois와 Prade의 유사성을 사용할 경우가 평균 자승 오차의 경우보다 우수하고, 산수유와 원육의 분별에서 에러를 발생하였다.

표 4에는  $d = 2$ ,  $\alpha = 0$ 일 경우의 NSGLDM의 결과로 NGLDM과 유사함을 알 수 있다. 표 5에는 GLRLM의 결과로 Dubois와 Prade의 유사성을 이용하였을 경우 다른 모든 행렬을 이용하는 경우보다 가장 우수한 결과를 얻을 수 있었다. 표 6에는 각각의 알고리즘과 (비)유사성 측도들을 이용하였을 경우의 에러율(%)을 총괄적으로 나타내었다. SGLDM, NGLDM 및 NSGLDM은  $d = 1, 2, 3, 4$  에 대하여 실험하였고,  $\alpha = 0$  으로 고정하였으며, 각 실험을 5 회 반복하여 평균을 구한 값들이다. 표 6에서 알 수 있드시 평균 자승 오차를 이용하는 경우가 Dubois와 Prade의 유사성을 이용하는 경우에 비해 열등하였으며, 실험된 영상에서는 SGLDM, NGLDM 및 NSGLDM의 경우  $d = 1$  인 경우에 분별력이 좋았음을 알 수 있으며, 거리와 상관없는 GLRLM이 가장 우수하였다. 또한 저장공간이 적게 필요한 NGLDM 및 NSGLDM이 SGLDM 보다 좋은 결과를 나타내었다.

표 1. SGLDM을 이용하였을 경우의 혼동 행렬( $d = 2$ )

Table 1. Confusion Matrix of the SGLDM Experiment.

평균 자승 오차						Dubois and Prade의 유사성					
	산수유	원지	원육	대추	에러율(%)		산수유	원지	원육	대추	에러율(%)
산수유	118	0	31	0	20.8		128	0	21	0	14.1
원지	0	149	0	0	0.0		0	149	0	0	0.0
원육	40	0	109	0	26.8		31	0	118	0	20.8
대추	0	0	0	149	0.0		0	0	0	149	0
계	158	149	140	149	11.9		159	149	139	149	8.7

표 2. SGLDM의 스칼라 속성을 이용하는 단층 퍼셉트론의 결과

Table 2. Result of the Single-Layer Perceptron (Three Scalar Features of SGLDM).

(a)  $d = 2$  일 경우

	산수유	원지	원육	대추
산수유		10.7	41.5	1.3
원지	10.7		0.5	3.2
원육	41.8	0.5		*
대추	1.3	3.2	*	

(b)  $d = 3$  일 경우

	산수유	원지	원육	대추
산수유		26.4	40.1	2.3
원지	26.4		0.4	11.3
원육	40.1	0.4		*
대추	2.3	11.3	*	

\*: unseparable

표 3. NGLDM을 이용하였을 경우의 혼동 행렬( $d = 2, \alpha = 0$ )

Table 3. Confusion Matrix of the NGLDM Experiment.

평균 자승 오차					
	산수유	원지	원육	대추	에러율(%)
산수유	121	0	28	0	18.8
원지	0	149	0	0	0.0
원육	23	0	126	0	15.4
대추	0	0	0	149	0.0
계	144	149	154	149	8.6

Dubois and Prade의 유사성					
	산수유	원지	원육	대추	에러율(%)
산수유	128	0	21	0	14.1
원지	0	149	0	0	0.0
원육	10	0	139	0	6.7
대추	0	0	0	149	0.0
계	138	149	160	149	5.2

표 4. NSGLDM을 이용하였을 경우의 혼동 행렬( $d = 2, \alpha = 0$ )

Table 4. Confusion Matrix of the NSGLDM Experiment.

평균 자승 오차					
	산수유	원지	원육	대추	에러율(%)
산수유	105	0	44	0	29.5
원지	0	149	0	0	0.0
원육	11	0	138	0	7.4
대추	0	0	0	149	0.0
계	116	149	182	149	9.2

Dubois and Prade의 유사성					
	산수유	원지	원육	대추	에러율(%)
산수유	128	0	21	0	14.1
원지	0	149	0	0	0.0
원육	9	0	140	0	6.0
대추	0	0	0	149	0.0
계	137	149	161	149	5.0

표 5. GLRLM을 이용하였을 경우의 혼동 행렬

Table 5. Confusion Matrix of the NSGLDM Experiment.

평균 자승 오차					
	산수유	원지	원육	대추	에러율(%)
산수유	108	1	40	0	27.5
원지	0	149	0	0	0.0
원육	18	0	131	0	12.1
대추	0	0	0	149	0.0
계	126	150	171	149	9.9

Dubois and Prade의 유사성					
BB-V	산수유	원지	원육	대추	에러율(%)
산수유	147	0	2	0	1.3
원지	0	149	0	0	0.0
원육	20	0	129	0	13.4
대추	0	0	0	149	0.0
계	167	149	131	149	3.7

표 6. 총괄된 실험결과  
Table 6. Summarized Experiment Result.

	SGLDM		NGLDM		NSGLDM		GLRLM	
	mse	set	mse	set	mse	set	mse	set
d=1	12.8	12.5	10.8	5.5	10.8	5.5	9.9	3.7
d=2	11.9	8.7	8.6	5.2	9.2	5.0	-	-
d=3	13.2	10.9	9.7	8.4	12.2	9.5	-	-
d=4	13.0	12.3	39.0	13.5	11.3	12.1	-	-

#### IV. 결 론

질감 분석에 있어서 영상의 통계적 성질을 표현하는 SGLDM, NGLDM, NSGLDM 및 GLRLM등의 행렬을 이용하는 방법들은 행렬을 구하는데 요구되는 기억용량이 크고 많은 계산량이 요구되며, 행렬이 많은 정보를 담고 있는데 반해, 그로 부터 구해진 몇몇 스칼라 측도들은 서로 상관 관계가 많고, 행렬 자체가 포함하고 있는 정보를 충분히 표현하는데 미흡하다. 이러한 정보 유실의 문제점을 해결하기 위하여 본 논문에서는 행렬이 담고 있는 정보의 유실을 최대한 방지하며, 분별기 구성에 부담을 주지 않는 새로운 질감 영상의 분별기를 제안하고 평가하여 보았다. 제안된 방법에서는 SGLDM, NGLDM, NSGLDM, GLRLM등의 행렬을 의미를 부여할 수 있는 방향으로 투사하고, 이렇게 구해진 벡터들을 속성으로 이용한다. 또한 제안된 속성을 이용하는 분별기는 각 질감 영상들의 표본으로부터 이를 속성 벡터들을 계산하고 미지의 영상으로부터 구해진 속성 벡터와의 (비)유사성을 측정하여 (최소)최대의 (비)유사성을 제공하는 영상으로 분별하는 방법을 이용한다.

본 연구에서는 정보의 유실이 많은 통계행렬의 스칼라측도들을 속성으로 사용하지 않고 분별기 구성에 부담을 주지 않는 속성벡터를 산수유, 원지, 원육 및 대추등의 농산물 영상을 분별하는데 사용하여 약 85-95% 정도의 분별력을 확인하였고 기억공간이 상대적으로 적게 필요한 NGLDM과 NSGLDM이 SGLDM보다 좋은 결과를 나타내었으며, GLRLM이 가장 우수하였다. 모든 에러의 주원인은 칼라영상에서는 구별이 있지만 그레이 영상에서는 눈으로 보기에도 분류가 수월하지 않는 산수유와 원육사이에서 발생함을 알 수 있었다. 제안한 방식의 분별기 구성은 Hamming 네트와 유사하게 병렬처리가 가능한 방법이며, 행렬의 요소들이 점유하는 공간을 기지의 영상으로부터 투사된 벡터들을 이용하여 영역을 분할하고, 미지의 영상으로부터 얻어진 벡터들의 분할된

각 영역에 대한 적합도를 측정하여 분별하는 방법이다.

향후에는 분별기 뿐 아니라 이러한 행렬을 투사하여 얻은 벡터를 속성으로 이용하는 클러스터링 방법과 아울러 투사된 벡터와 질감의 언어적 해석과 밀접한 관계를 가지고 있음에 착안하여 질감 영상의 언어적 모형화 방법도 연구될 예정이다.

#### 参考文獻

- [1] K. C. Choi, J. W. Hong, H. J. Kim, S. I. Kim, D. S. Lee, "Texture Classification for the Ultrasonographic Liver Image Using Run Difference Matrix and Neural Network," *KITE Journal of Electronics Engineering*, Vol. 3, no. 2, Nov. pp.99-103, 1992.
- [2] Lee Hok Siew, Robert M. Hodgson, and Error J. Wood, "Texture Measures for Carpet Wear Assessment", *IEEE Trans. on PAMI*, vol. 10, no. 1, pp. 92-105, 1988.
- [3] 박 귀태, 김 민기, 김 진현, 정 순현, "이진 영상의 계조차 동시발생 행렬을 이용한 타이어 접지 패턴의 분류," 1992 한국자동화학회 논문집, pp. 100-105, 1992. 10.
- [4] R. M. Haralick, "Statistical and Structural Approaches to Texture," *IEEE Trans. on PAMI*, vol. 67, pp. 786-804, 1979.
- [5] Jon R. Berry, Jr., and John Goutias, "A Comparative Study of Matrix Measures for Maximum Likelihood Texture Classification", *IEEE Trans. on SMC* under consideration.
- [6] James M. Keller, Susan Chen, and Richard M. Crownover, "Texture

- Description and Segmentation through Fractal Geometry", *CVGIP*, vol. 45, pp 150-166, 1989.
- [7] Alex P. Pentland, "Fractal-Based Description of Natural Scenes", *IEEE Trans. on PAMI*, vol. 6, no. 6, pp. 661-674, 1984.
- [8] S. N. Jayaramamurthy, T. L. Huntsberger, and Jason Hu, "Fractal Signature Analysis of Images Containing Mixtures of Natural Textures", Proceedings of the 19th Southeastern Symposium on System Theory, pp 363-366, Clemson, South Carolina, Mar. 1987.
- [9] Richard W. Conners, and Charles A. Harlow, "A Theoretical Comparison of Texture Algorithms", *IEEE Trans. on PAMI*, vol. 2, no. 3, pp. 204-222, 1980.
- [10] Dana H. Ballard, and Christopher M. Brown, *Computer Vision*, Prentice-Hall, 1982.
- [11] Robert M. Haralick, K. Shanmugam, and Its'hak Dinstein, "Textural Features for Image Classification", *IEEE Trans. on SMC*, vol. 3, no 6, pp. 610-621, 1973.
- [12] 이정환, 김성대, "Texture 영상 분할을 위한 고속 적용 특징 추출 방법," 제4회 신호처리 학술 발표대회 논문집, 제4권 제1호, pp.161-164, 1992.
- [13] R. P. Lippmann, B. Gold and M. L. Malpass, "A Comparison of Hamming and Hopfield Neural Nets for Pattern Classification," *M.I.T. Technical Report* 21, May, 1987.
- [14] Joonwhoan Lee, *Fuzzy-Connective-Based Information Fusion Networks and Their Application to Computer Vision*, Ph. D Dissertation, Univ. of Missouri in Columbia, Aug. 8.
- [15] W. Pedrycz, "Neurocomputations in Relational Systems," *IEEE Trans. on PAMI*, vol. 13, no. 3, pp. 289-297, 1991.
- [16] D. P. Mandal, C. A. Murthy, and S. K. Pal, "Formulation of Multivalued Recognition System.", *IEEE Trans. on SMC*, vol. 22, no. 4, pp. 607-620, 1992.
- [17] C. Sun and W. G. Wee, "Neighboring gray level dependence matrix," *CVGIP*, vol. 23, pp. 341-345, 1982.
- [18] M. M. Galloway, "Texture analysis using gray level run lengths," *CVGIP*, vol. 4, pp 172-179, 1975.
- [19] R. Zwick, D. V. Budescu, "Measures of Similarity between Fuzzy Concepts: A Comparative Analysis", *International Journal of Approximate Reasoning*, 1986.
- [20] Dubois, D., and H. Prade, *Fuzzy Sets and Systems. Theory and Applications*, Academic Press, New York, 1980.
- [21] J. T. Tou and R. C. Gonzalez, *Pattern Recognition Principles*, Reading, MA : Addison-Wesley, 1974.

## 著者紹介



金 準 哲(正會員)

1960年 9月 1日生. 1986年 2月  
전북대학교 전자공학과(공학사).  
1988年 2月 전북대학교 대학원 전  
자공학과(석사). 1988年 1月 ~  
1991年 2月 금성산전 연구소 근  
무. 1993年 3月 전북대학교 대학  
원 전자공학과 박사과정 수료. 1993年 3月 서남대학  
교 전자공학과 전임강사. 주관심 분야는 패턴인식,  
컴퓨터 비전, 영상처리 등임.

李 俊 煥(正會員)

1957年 7月 26日生. 1980年 2月 한양대학교 전자공  
학과(공학사). 1982年 2月 한국과학원 전기 및 전자  
공학과 졸업(석사). 1990年 8月 미국 미주리대학교  
전기 및 컴퓨터 공학과 졸업(박사). 1985年 3月 전북  
대학교 전자공학과 전임강사. 1990年 3月 전북대학  
교 전자공학과 조교수. 주관심 분야는 인공지능, 영  
상처리 및 인식, 퍼지이론 및 신경회로망 등임.