

퍼지 클러스터링 알고리즘을 이용한 타이어 접지면 패턴의 분류 Tire Tread Pattern Classification Using Fuzzy Clustering Algorithm

강 윤 관*, 정 순 원*, 배 상 옥*, 김 진 현*, 박 귀 태**
Yoon-Kwan Kang*, Soon-Won Jung*, Sang-Wook Bae*, Gwi-Tae Park**

요 약

본 논문에서는 GFI(Generalized Fuzzy Isodata) 와 FI(Fuzzy Isodata) 알고리즘에 관한 이론을 고찰하고 이를 타이어 접지면 패턴 분류에 적용해 보았다. GFI 알고리즘은 FI 알고리즘의 일반화된 형태로서 분할된 군집에 대해서도 퍼지 분할 행렬(fuzzy partition matrix)을 고려해 다시 군집화(clustering)를 가능하게 하는 알고리즘이다. GFI 알고리즘을 사용하여 이진 트리를 구성함에 있어서 각 노드에서의 분할 여부, 즉 군집화의 타당성(clustering validity) 점검 및 최종적인 이진 트리의 완성은 FDH(Fuzzy Divisive Hierarchical) 군집화 알고리즘을 통해 이루어진다. 타이어 접지면에 대한 표준 특징량을 선정하거나 패턴 분류를 수행함에 있어서 이들 알고리즘은 모두 우수한 성능을 가짐을 알 수 있었다.

패턴의 특징량으로는 전처리된 타이어 접지면 영상에 나타나는 윤곽선(edge)의 각도 성분을 선정하였으며 이렇게 선정된 특징량은 패턴의 특징을 잘 표현해주는 유용한 정보를 가진 것으로 생각된다.

Abstract

In this paper GFI(Generalized Fuzzy Isodata) and FI(Fuzzy Isodata) algorithms are studied and applied to the tire tread pattern classification problem. GFI algorithm which repeatedly grouping the partitioned cluster depending on the fuzzy partition matrix is general form of GI algorithm. In the constructing the binary tree using GFI algorithm, cluster validity, namely, whether partitioned cluster is feasible or not is checked and construction of the binary tree is obtained by FDH clustering algorithm. These algorithms show the good performance in selecting the prototypes of each patterns and classifying patterns.

Directions of edge in the preprocessed image of tire tread pattern are selected as features of pattern. These features are thought to have useful information which well represents the characteristics of patterns.

I. 서 론

최근 퍼지 집합 이론을 이용한 패턴 분류 기법은 영상 처리뿐만 아니라 문자 인식, 언어 인식, 의료 진단등 많은

* 高麗大學校 電氣工學科

** 高麗大學校 電氣工學科, 教授, 工博, 서울대 ERC-ACI 연구위원

분야에 적용되어 그 유용성이 실험적으로 입증되고 있다. 이러한 유용성은 퍼지 집합 이론이, 데이터 취득(data acquisition), 특징량 추출(feature extraction), 패턴 분류(pattern classification)등으로 구성되는 일반적인 패턴 분류 체계에 존재하는 여러 불확실성들을 효과적으로 처리할 수 있다는 사실에 근거한다[1]. 또한 이 기법은 패턴 분류기 설계시 비수치적인 특성의 정보에 근거하여 각종 패턴들을 인식하는 인간의 추론법을 도입할 수 있으며, 그 분류 결과로서 다치의 소속 정도를 발생하므로, 기존의 베이시안(Bayesian) 접근법과 같은 통계적 패턴 분류에 비해 더욱 유연한 특성을 갖는 패턴 분류 체계를 구성할 수 있다.

본 논문에서는 퍼지 집합 이론을 이용한 패턴 분류 기법들 중에서 일반적으로 잘 알려진 FI(Fuzzy Isodata) 클러스터링 알고리즘[2,3] 과 이의 일반적 형태인 GFI(Generalized Fuzzy Isodata) 클러스터링 알고리즘에 대하여 고찰하고 이를 타이어 접지면 패턴 인식에 적용하여 특성을 비교 고찰하고자 한다. FI 클러스터링 알고리즘은 주어진 데이터 집합의 구조를 밝힘으로써 그 데이터 집합들을 유사한 성질을 갖는 클러스터들로 분할할 뿐만 아니라, 그 대표값들을 발생시킨다. 또한 GFI 클러스터링 알고리즘은 이미 분할된 군집에 대해서도 퍼지 분할 행렬을 고려해 다시 군집화시킴으로서 이진 트리의 구성을 가능하게 한다. 이진 트리를 구성함에 있어서 각 계층(hierarchy)에서의 퍼지 분할은 GFI 클러스터링 알고리즘을 통해 구해지나 각 노드에서의 분할 여부, 즉 군집화된 클러스터의 타당성(clustering validity) 점검과 이를 계층적으로 수행하여 얻어지는 최종적인 이진 트리는 FDH(Fuzzy Divisive Hierarchical) 군집화 알고리즘에 의해 이루어진다.

한편 이러한 분류 기법을 타이어 접지면 패턴 분류에 실제로 적용하여 위에서 언급한 퍼지 패턴 분류 체계의 장점을 갖게끔 하려고 한다.

타이어는 그 공정상 한 컨베이어를 통해 여러 종류의 제품이 무작위로 사출되며 사출되는 타이어의 종류에 따라 다른 작업이 필요하게 된다. 예를 들면, 타이어의 표면을 처리하는 트리밍 공정은 타이어의 접지면에 따라 서로 다른 작업이 요구된다. 그러므로 이 공정에 들어가기에 앞서 타이어를 분류할 필요가 있다. 현재, 트리밍 작업 자체는 자동화되어 있으나 투입되는 타이어의 분류는 수작업에 의해 이루어지고 있다. 이런 수작업들을 화상 처리 기술을 이용하여 기계로 대체하여 자동화를 이룰 수 있다.

이러한 방법으로 구성되는 타이어 접지면 패턴 분류 체계는 클래스 소속값(class membership)의 할당을 고려하여 원형 패턴을 좀 더 체계적으로 구할 수 있으며, 패턴 분류 결과가 다치의 소속값으로 발생되므로 "Unknown" 과 같은 부류로의 분류도 가능하다.

II. 퍼지 클러스터링 알고리즘

본 장에서는 패턴 분류에 있어서 퍼지 클러스터링의 필요성과 구현 방법에 관해 다루도록 하겠다.

2.1 퍼지 클러스터링의 필요성

패턴인식 과정은 크게 데이터 취득(data acquisition), 특징량 추출(feature extraction), 패턴 인식(pattern classification)의 3단계로 나누어 생각할 수 있다.

패턴 인식의 과정에서는 몇가지 불확실성이 내포되는데, 그 중에서 부류 할당(class labelling)에 관련하여 발생하는 불확실성을 살펴보면 다음과 같다.

고전적인 패턴 인식에서는 부류 소속 정도(class membership)를 부울린 숫자로 생각한다. 그러므로, "주어진 패턴이 어떤 클래스 ω_i 에 속한다."라는 표현의 진위를 "사실" 혹은 "거짓"으로서 판단한다. 그러나, 이렇게 패턴을 매우 엄격히 분류하는 것이 불가능할 경우가 있어 흑백 논리식 부류 할당 방식은 제한성을 갖는다.

이러한 부류 할당 상에서 일어나는 문제는 어느 부류를 정하는데 있어서 소속 함수(class membership function)를 도입함으로써 해결될 수 있다. 이러한 퍼지 라벨링(fuzzy labelling)은 흑백 논리에 입각한 단순 라벨링(hard labelling)에 비해 분류 결과를 유연성 있게 해석할 수 있기 때문에 더 높은 유통성을 갖는다.

2.2 계층적 클러스터링 알고리즘[4]

$X = \{x_1, x_2, \dots, x_p\}$ 가 패턴들의 집합이라 하고, 패턴 x_i 는 d 개의 특징량으로 이루어져 있다고 하자. 즉, $\forall x_i \in$

R^d 이다. 패턴 집합을 여러 부류로 분해할 경우 최종적인 분류 목적을 얻을 수 있을 때까지 분할을 계속할 수 있다. 즉, 퍼지 클래스 C 가 이종(heterogeneous)이면 C 의 부분 구조를 구한다. 이 부분 구조는 C 의 퍼지 분할에 의해 표현된다. 이렇게 부분 구조를 찾음으로써 다층 퍼지 분류(multi-level fuzzy classification)를 얻을 수 있다.

먼저 몇가지 용어의 정의와 퍼지 분할 사이의 세분 관계(refinement relation)를 소개한다. 퍼지 집합 (X, A) 의 전체 집합(universe of discourse)은 X 이고 멤버십 함수는 $A : X \rightarrow I, I = [0, 1]$ 이다. 퍼지 집합들에 대한 집합 연산자들은 삼각 노름(t-norm)에 의해 정의된다. 삼각 노름(t-norm)은 결합 법칙과 교환 법칙이 성립하고, 단조 증가이며 I 에 속하는 모든 a 에 대해 $T(a, 1) = a$ 이다. T 에 대한 t -conorm은 $S(x, y) = 1 - T(1-x, 1-y)$ 로 같이 정의된다. A 와 B 가 퍼지 집합일 때 그들 간의 합집합과 교집합은 다음과 같이 정의된다.

$$(A \cup B)(x) = T(A(x), B(x)) \quad (\text{For } \forall x \in X)$$

$$(A \cap B)(x) = S(A(x), B(x)) \quad (\text{For } \forall x \in X) \tag{1}$$

본 논문에서는 $T(x, y) = \max(x + y - 1, 0)$ 와 $S(x, y) = \min(x + y, 1)$ 인 집합 연산자를 사용한다. 퍼지 집합들의 패밀리인 $A_1, A_2, A_3, \dots, A_n (n \geq 2)$ 가 다음을 만족하면 서로소이다.

$$(\cup_{i=1}^k A_i) \cap A_{k+1} = \emptyset \text{ for } k = 1, \dots, n-1 \tag{2}$$

이때, $\phi(x) = 0, \forall x \in X$ 이다.

만약 $C = \cup_{i=1}^n A_i, \forall x \in X$ 이면 서로 소인 퍼지 집합들의 패밀리 $A_1, A_2, A_3, \dots, A_n$ 는 퍼지 집합 C 의 퍼지 분할을 나타낸다. 이 정의는 $\sum_{i=1}^n A_i(x) = C(x), \forall x \in X$ 와 같은 의미이다. 퍼지 분할의 세분(refinement)은 다음과 같이 정의될 수 있다. C 의 모든 퍼지 분할들의 패밀리를 $\mathbf{A} = \{A_1, A_2, \dots, A_m\}, \mathbf{B} = \{B_1, B_2, \dots, B_n\}$ 를 $F(C)$ 에 속하는 퍼지 분할이라고 할 때, 만약 \mathbf{A} 의 모든 멤버가 \mathbf{B} 의 멤버들의 합집합으로 표현된다면 퍼지 분할 \mathbf{B} 를 퍼지 분할 \mathbf{A} 의 세분이라고 하고, 기호로는 $\mathbf{A} \langle \mathbf{B}$ 으로 표기한다.

2.2.1 일반화된 퍼지 이소데이터 알고리즘(GFI)

FI 알고리즘은 GFI 알고리즘의 특수한 경우라 할 수 있다. FI 알고리즘이 패턴 집합을 주어진 임의의 갯수로 군집화 시키는 것과는 달리 GFI 알고리즘은 이미 군집화되어 있는 부분 패턴 집합에 대해서 퍼지 분할 행렬을 참조하여 각 군집을 나누는 것을 가능하게 한다. 본절에서는 GFI 알고리즘을 기술하고 FI 알고리즘과의 관계에 대하여 살펴보겠다.

X 의 클러스터 구조를 나타내는 퍼지 분할이 $\mathbf{A} = \{A_1, A_2, \dots, A_n\}$ 라고 가정한다. \mathbf{A} 의 모든 원소는 X 에 있는 점들의 클래스(혹은, 클러스터)에 대응하고, 모든 클래스 A_i 는 표현 공간 \mathcal{L} 에서의 원형(prototype) L_i 에 의해 표현될 수 있다. 즉, 모든 클러스터는 클러스터의 중심(center)에 의해 표현되어진다. 이 경우에 표현 공간은 R^d 이다.

$D(x_j, L_i)$ 를 원형 L_i 와 샘플 x_j 의 상이성 정도를 측정하는 상이성 지표(dissimilarity index)로 정의하자. 여기서, D 는 자승 거리 즉, $D(x, y) = d^2(x, y) = \|x - y\|^2$ 이고, d 는 R^d 에서의 측정자(metric)이며, $\|\cdot\|$ 는 스칼라 내적 행렬 노름이다. 유클리디안 공간에서의 스칼라 내적은 $(x, y) = x^T M y$ 이다. 이때, M 은 symmetric positive definite 행렬이고, T 는 전치(transpose)를 나타낸다.

R^d 에서 A_i 의 멤버십을 고려한 국부 거리(local distance) d_i 를 다음과 같이 정의한다.

$$d_i(x, y) = \begin{cases} \min[(A_i(x), A_i(y))]d(x, y) & \text{if } x, y \in X \\ A_i(x)d(x, y) & \text{if } x \in X, y \notin X \\ d(x, y) & \text{if } x, y \notin X \end{cases} \tag{3}$$

그리고, 국부 상이성(local dissimilarity) D_i 를 다음과 같이 정의한다.

$$D_i(x, y) = d_i^2(x, y) \quad (4)$$

만약 X 에서 A_i 에 대한 L_i 의 소속 정도가 가장 크다면 $d_i(L_i, x_j) = A_i(x_j) \cdot d(L_i, x_j)$ 이 된다.

이는 $L_i \in X$ 인 경우에 있어서 위의 국부 거리의 정의와 일치한다. 그러므로, 식(3), (4)에 따라 x_j 와 원형 L_i 사이의 상이성은 다음과 같다.

$$D_i(x_j, L_i) = d_i^2(x_j, L_i) = (A_i(x_j))^2 d^2(x_j, L_i) \quad (5)$$

클래스 A_i 와 L_i 사이의 부적합(inadequacy) $I(A_i, L_i)$ D_i 를 사용해서 다음과 같이 계산할 수 있다.

$$I(A_i, L_i) = \sum_{j=1}^p D_i(x_j, L_i) = \sum_{j=1}^p (A_i(x_j))^2 d^2(x_j, L_i) \quad (6)$$

이때, 분할 \mathbf{A} 와 그의 표현 $\mathbf{L} = \{L_1, L_2, \dots, L_n\}$ 사이의 부적합도 $J = J(\mathbf{A}, \mathbf{L})$ 는 다음과 같이 주어진다.

$$J(\mathbf{A}, \mathbf{L}) = \sum_{j=1}^p I(A_i, L_i) = \sum_{j=1}^p (A_i(x_j))^2 d^2(x_j, L_i) \quad (7)$$

여기서, 평가 함수 J 를 최소화 시키는 퍼지 분할 \mathbf{A} 와 그의 표현 \mathbf{L} 을 구하는 것이 문제가 된다. 클래스 $C \in \mathbf{A}$, $\mathbf{A} \in F(X)$ 의 클러스터 부분 구조는 C 의 퍼지 분할에 의해 기술된다. \mathbf{A} 를 이종인 클래스들로 분할하는 것에 의하여 새로운 퍼지 분할 $\mathbf{A}^1 \in F(X)$ 를 얻을 수 있다. 퍼지 분할 \mathbf{A}^1 은 \mathbf{A} 의 세분이며 더 세분된 분할 \mathbf{B} 는 X 의 클러스터 구조에 대해서 \mathbf{A} 보다 더 많은 정보를 담고 있다. 퍼지 클래스 C 의 최적 퍼지 분할 $\mathbf{B} = \{B_1, B_2, \dots, B_n\}$ 는 다음과 같은 최소화 문제의 국부해(local solution)로서 구해진다.

$$\text{minimize } J(\mathbf{B}, \mathbf{L}), \mathbf{B} \in F_n(x) \quad (8)$$

여기서 $F_n(x)$ 은 n 개의 요소를 가지는 C 의 퍼지 분할들의 패밀리이고, $J(\mathbf{B}, \mathbf{L})$ 는 다음과 같다.

$$\begin{aligned} J(\mathbf{B}, \mathbf{L}) &= \sum_{i=1}^n \sum_{j=1}^p (B_i(x_j))^2 \|x_j - L_i\|^2 \\ &= \sum_{i=1}^n \sum_{j=1}^p (B_i(x_j))^2 (x_j - L_i)^T M (x_j - L_i) \end{aligned} \quad (9)$$

$\mathbf{B} \in F_n(x)$ 가 함수 $J(\cdot, \mathbf{L})$ 의 최소값이 될 필요 충분 조건은 다음과 같다.

$$B_i(x_j) = \frac{C(x_j)}{\sum_{k=1}^n \frac{d^2(x_j, L_i)}{d^2(x_j, L_k)}}, \quad i = 1, \dots, n; j = 1, \dots, p \quad (10)$$

또한 $\mathbf{L} \in (\mathbb{R}^d)^n$ 가 함수 $J(\mathbf{B}, \cdot)$ 의 국부 최소가 될 필요 충분 조건은 다음과 같다.

$$L_i = \frac{\sum_{j=1}^p (B_i(x_j))^2 x_j}{\sum_{j=1}^p (B_i(x_j))^2}, \quad i = 1, \dots, n \quad (11)$$

위의 두 식을 사용해서 피카르드 반복법(Picard iteration)을 행하여 식(8)의 해를 구한다. 이 반복법을 GFI 알고리즘이라 한다. 특히, $C = X$ 인 경우에 GFI는 일반적으로 잘 알려진 FI 알고리즘이다[5, 6].

2.2.2 편극과 구조

GFI 알고리즘을 이용하여 퍼지 클래스 C 를 분할해서 얻은 퍼지 클래스들을 C_1, C_2 라 한다. 만약 C 에 구조가 없다면 즉, C 가 컴팩트(compact)한 클러스터라면 C_1 과 C_2 의 멤버십이 정도가 같게 된다. 그 반면에 C_1 과 C_2 가 잘 분리된 상태라면 멤버십들 $C_1(x)$ 과 $C_2(x)$ 는 0과 $C(x)$ 로 편극화(polarization)하는 경향이 있다. 편극은 데이터의 구조의 존재 유무와 관계 있다. 즉, 구조는 편극을 의미한다. 퍼지 분할의 편극 정도는 분할에 대한 질(quality)의 척도가 된다.

콤팩트하고 잘 분리된 참(real)인 클러스터들의 멤버십 정도는 편극이 0과 1의 근방에서 유지하는 데이터들을 연속적으로 이진 분할을 행함으로써 구할 수 있다. 소속 정도들이 1/2 근방에 있으면 구조가 존재하지 않음을 뜻한다. 이러한 이유로 인해 다음과 같은 적당한 편극 정도를 측정하는 함수를 이용할 수 있다.

$$R_1(P) = \frac{\sum_x (C_{1, 1/2}(x) + C_{2, 1/2}(x))}{\sum_x C(x)} \quad (12)$$

여기서, $C_{i, 1/2}(x) = \begin{cases} C_i(x) & \text{if } C_i > 1/2 \\ 0 & \text{otherwise} \end{cases}$ 이다.

위의 함수를 사용하면 퍼지 분할 $P = \{C_1, C_2\}$ 가 참 클러스터일 필요 충분조건은 다음과 같다. 즉, 모든 클래스 C_i 에 대해 $C_i(x) > 1/2$ 인 패턴 벡터 x 가 존재하고 $R_1(P) \geq t$ 이어야 한다. 여기서 $t \in (0, 1)$ 는 적당한 임계치(threshold)이며 참 클러스터인 정도를 나타낸다.

2.2.3 FDH 클러스터링 알고리즘

본 절에서는 퍼지 계층(fuzzy hierarchy)을 구성하기 위한 분할 기법(divisive technique)에 관해 다루겠다. 여기에서 계층 지표는 분할(decomposition)의 레벨을 나타낸다.

퍼지 분할 계층 과정은 다음과 같이 설명될 수 있다. 먼저 X 의 퍼지 분할 $\{A_1, A_2\}$ 를 구한다. 만일 A_1, A_2 가 참 클러스터가 아니면 X 에는 구조가 존재하지 않는다고 한다.

동종(homogeneous)의 클러스터 X 의 원형(prototype)은 각 클러스터에 속하는 패턴들의 무게 중심으로 구해지게 된다. 만일 A_1, A_2 가 참 클러스터이면 $P^{(1)} = \{A_1, A_2\}$ 라 하고 계속해서 GFI 알고리즘을 이용하여 $P^{(1)}$ 의 모든 원소 A_i 에 대하여 이진 퍼지 분할을 구하게 된다. 이러한 과정은 분할을 했을 때 더 이상 참 클러스터가 구해지지 않을 때까지 계속된다.

다음에 FDH 알고리즘에 대해 간략히 기술하였다.

1. $l=0, N=0, P^{(l)} = \{X, \emptyset\}$ 라 초기화 한다. (l 은 계층 지표(stratification index))
2. $P^{(l)}$ 에 속하는 모든 원소 C 가 마크되어 있으면 $P^{(l+1)}$ 에 할당하고, 그렇지 않으면 4를 실행한다.
3. 만약 $P^{(l+1)} = P^{(l)}$ 이면 알고리즘을 중지하고, 그렇지 않으면 2를 실행한다.
4. GFI 알고리즘을 이용하여 C 의 이진 퍼지 분할 $\{C_1, C_2\}$ 를 계산한다. 만약 C_1, C_2 가 참 클러스터들이면 C_1, C_2 를 $P^{(l+1)}$ 에 할당한다. 그렇지 않으면 C 를 +1를 마크하고, $N = N + 1$ 로 증가시킨다. 여기서 N 은 최적의 클러스터 수를 나타낸다.

결론적으로 이진 트리의 터미널 노드 갯수 N 은 X 에 존재하는 최적 클러스터의 갯수를 나타내게 된다.

2.2.4 국부 거리자와 정규화

퍼지 클래스 C 의 퍼지 분할을 계산할 경우에 X 의 거리자가 부적당할 때가 있다. 이때, C 의 소속 정도를 고려한 C 의 국부 거리자를 생각하면 효과적이다. 우선 j 번째 특징량들의 값에 대응하는 변수를 x_j 라 하면 i 번째 패턴에 대한 x_j 의 값은 $x_j(i) = x_{ij}, i = 1, 2, \dots, p$ 이다.

클래스 C 에서 x_j 의 평균은 다음과 같이 정의한다.

$$m_{c,j} = m_c(x_j) = \frac{\sum_{i=1}^p C(x_i)x_j(i)}{\text{card } C} \quad (13)$$

클래스 C 에서 x_j 의 분산은 다음과 같이 주어진다.

$$\begin{aligned} \sigma_{C,j}^2 &= \sigma^2(x_j) = m_c[(x_j - m_c(x_j))^2] \\ &= m_c(x_j^2) - (m_c(x_j))^2 \end{aligned} \quad (14)$$

이렇게 하여 새로운 변수 $x'_j = (x_j - m_c(x_j))/\sigma_{C,j}$ 이 되는데, 이는 클래스 C 에서의 정규화 하는 변환을 뜻한다. 이와 같이 함으로써, 변위와 스케일 변동이 있어도 C 의 구조가 변하지 않는다.

2.3 패턴 분류(pattern classificatoin)

패턴 분류는 전 절의 FI, GFI 클러스터링 알고리즘을 주어진 데이터 집합의 클러스터링에 적용하여서 구한 각 클러스터들의 중심값(원형 패턴)을 이용하여 행해진다. 즉, 새로운 입력 패턴을 분류하고자 할 때, 각 클래스에 소속되는 정도 $\vec{u} = [u_1, u_2, u_3, \dots, u_c]$ 를 구한 후, 그 소속 정도가 가장 큰 클래스에 속하는 것으로 분류하게 되는데, 그 소속 정도 $S_i(x)$ 와 부류 할당은 다음 식과 같이 계산된다.[7]

$$S_i(x) = \frac{1}{\sum_{k=1}^n \frac{d^2(x, L_i)}{d^2(x, L_k)}}, \quad i = 1, \dots, c \quad (15)$$

$$\max_{1 \leq i \leq c} S_i(x) = S_{i_0}(x) \rightarrow x \in w_{i_0} \quad (16)$$

Ⅲ. 타이어 접지면 패턴 분류

본 장에서는 본 논문에서 제안된 타이어 접지면 패턴 분류 체계의 각 구성 요소에 대하여 기술한다. 본 논문의 타이어 접지면 패턴 분류 체계에서 데이터 취득 및 특징량 추출 알고리즘으로서 텍스처 분석 방법이 사용되었으며, 패턴 분류 알고리즘은 전 장에서 기술한 퍼지 클러스터링 알고리즘이 사용되었다.

3.1 타이어 접지 패턴

화상 처리의 관점에서 볼 때, 타이어 접지 패턴은 텍스처의 한 부류로 볼 수 있으며 동일한 부패턴이 정렬되어 있으므로 결정적 텍스처라 볼 수 있다. 그림 3. (a)~(f)는 타이어 접지면 패턴의 예를 보인 것이다. 특징량을 추출하기 위하여 제조치 동시 발생 행렬(gray level cooccurrence matrix)이라 불리는 2차 통계량을 사용하였다. 이 행렬을 구하는 과정은 단순하며, 화상이 이치화되어 있을 경우에 특징량은 쉽게 계산될 수 있다. 다음 절에 특징량을 구하는 과정에 대해 기술하도록 하겠다.

3.2 화상의 전처리

타이어 접지면 패턴의 특징량을 추출하기 전에 화상에 대한 전처리가 수행된다. 본 논문에서의 전처리의 목적은 화상 데이터의 양을 줄이고 특징량을 추출하기에 적당하도록 화상을 이치화 시키는데 있다. 먼저 3×3 저역 통과 필터를 거친 화상을 서브 샘플링(subsampling)한다. 그리고 나서 화상의 이치화와 에지 검출을 동시에 행하는 수정된 라플라시안 윤곽선 검출 알고리즘(modified Laplacian edge detection algorithm)을 적용한다. 알고리즘은 다음과 같다. [8]

$$g(i, j) = \begin{cases} 1, \text{ if } (g(i-1, j) + g(i+1, j) - 2g(i, j) > T_1) \text{ or} \\ \quad g(i, j-1) + g(i, j+1) - 2g(i, j) > T_2) \text{ or} \\ \quad g(i-1, j-1) + g(i+1, j+1) - 2g(i, j) > T_3) \text{ or} \\ \quad g(i+1, j-1) + g(i-1, j+1) - 2g(i, j) > T_4); \\ 0, \text{ otherwise} \end{cases} \quad (17)$$

여기서, $g(i, j)$ 는 처리 대상 화소이며, T_1, T_2, T_3, T_4 는 각각 가로, 세로, 대각선 방향에 민감한 임계치 (threshold value)를 나타낸다.

3.3 계조치 동시 발생 행렬(COM : gray level cooccurrence matrix)

타이어 접지면 패턴에 존재하는 윤곽선의 방향에 대한 정보는 이치화 영상에 대한 COM에 의하여 표현된다. [9] 이 행렬의 (2, 2)요소(element)는 윤곽선 방향에 관한 유용한 정보이며 대응하는 각도에 대한 윤곽선의 많고 적음을 나타낸다. 타이어의 종류에 따라 각 각도에 대한 윤곽선의 양이 틀리므로 다양한 각도에 대한 행렬의 (2, 2)요소 값은 패턴을 대표하는 특징량 값으로 선정될 수 있다.

그림 1. (a)에 대하여 $0^\circ, 45^\circ, 90^\circ, 135^\circ$ 의 방향에 대응하는 COM을 구하면 그림 1. (b)-(e)가 되며 각 행렬에 대한 (2, 2) 요소는 각각 계조치가 1인 화소의 방향 성분을 나타내게 된다. 따라서 이치화 화상 그림 1. (a)에 대한 패턴 벡터를 구하면 (0, 6, 0, 6)이 된다. 이러한 성질을 이용하여 각도를 다양하게 줌으로서 그에 해당하는 각도의 성분을 추출할 수 있다. 본 연구에서는 각도의 성분을 12종류로 주었으며, 이로부터 COM을 구하고 이들 행렬에서 구한 12개의 양을 패턴 벡터로 삼아 분류를 행할 수 있다. 타이어 접지 패턴의 경우, 전처리를 행한 후에 위와 같은 과정을 거치면 패턴 분류에 사용할 수 있는 패턴 벡터를 구할 수 있다.




그림 1. 이치화 영상에 대한 계조치 동시 발생 행렬
 (a)이치화 영상 (b)-(e)이치화 영상에 대한 계조치 동시 발생 행렬
 Fig. 1. Gray-level cooccurrence matrix for the binary image
 (a)Binary image (b)-(e)Gray-level cooccurrence matrix

3.4 타이어 접지면 패턴 분류 알고리즘의 구성

타이어 접지면 패턴 분류를 위한 분류 체계는 전 절의 방법으로 구한 각각의 타이어 접지면 패턴들에 대해서 i) 퍼지 클러스터링 알고리즘인 FI, FDH 클러스터링 알고리즘을 적용하여 각 클래스의 원형 패턴을 찾는 과정, ii) 식(15), (16)의 분류 알고리즘을 이용한 패턴 분류 과정으로 구성된다. ii)의과정은 각 타이어 패턴 클래스의 원

형 패턴이 구해지면 식(15)의 수치적인 계산에 의해 각 클러스터에 대한 소속 정도를 계산하여 식(16)에 의해 그 값이 최대가 되는 클래스로 분류함으로써 수행된다. 그리고, i)의 과정에서 사용된 퍼지 클러스터링 알고리즘의 적용상 기법에 대해 좀 더 자세히 기술하면 다음과 같다.

우선, FI 클러스터링 알고리즘을 사용하는 경우에 대해 살펴 보겠다. 일반적인 FI은 비교사(unsupervised) 클러스터링 기법중의 한 종류이며, 인식 공간상에서 패턴 벡터들의 위치와 분산을 고려하지 않고 동일한 크기의 클러스터로 분할되는 특성을 가진다. 따라서, 타이어 접지면 패턴들을 입력 패턴으로 투입하여 클러스터링을 행할 경우 올바르게 구해진 클러스터 중심값의 갯수가 분류하고자 하는 타이어의 갯수와 일치하지 않는 경우가 발생할 수 있다. 또한 잡음에 의해 오손된 패턴을 클러스터링에 포함시킬 경우 잘못된 중심값을 얻을 수가 있다. 이러한 적용상의 문제점을 방지하기 위해 본 연구에서는 각 타이어 접지면의 영상과 그 패턴에 대한 특징량들을 검사하여 잡음에 의해 두드러지게 오손된 패턴을 미리 제거한 후, 클러스터링 시에는 오퍼레이터의 직관에 의해 기지의 패턴들의 원형을 구하기 위해 단계적으로 FI를 적용하였다. 즉, 선택된 모든 타이어 패턴을 투입하여 1차적인 클러스터링을 행하고, 그 결과를 주어진 데이터들과 비교하여 그 중심값이 올바르게 구해진 타이어 패턴들을 선별한 다음 나머지 패턴들을 투입하여 다음 단계의 클러스터링을 행하는 방법을 사용하였다.

FDH 클러스터링 알고리즘을 적용한 경우를 살펴 보면 다음과 같다. FDH 알고리즘은 비교사 클러스터링 기법으로 참 클러스터들에 대해 이진 퍼지 분할을 행함으로써 클러스터링이 수행된다. 타이어 접지면 패턴을 클러스터링할 때, FDH 알고리즘을 이용하여 최종적으로 6개의 클러스터로 분할 하였다. 이때, FDH 클러스터링 알고리즘상에서 d_{ik}^2 를 $\|\vec{x}_k - \vec{v}_i\|^2$ 인 벡터 노음과 $\|x_k - v_i\|^2 c = (x_k - v_i - m_c)^T M^c (x_k - v_i - m_c)$ 인 벡터 노음을 사용하여 계층적 이진 퍼지 분할을 행하였으며 전자를 FDH1, 후자를 FDH2라고 하였다.


여기서 M 은 각 클러스터의 직경(distance)과 분산(variance)을 고려한 행렬이다.

IV. 실험 결과

본 장에서는 타이어 접지면 패턴을 제안된 타이어 접지면 패턴 분류 체계에 적용하여 모의 실험을 행함으로써 본 분류 체계의 유용성을 입증한다.

4.1 타이어 접지면 패턴 및 화상의 전처리.

본 논문의 타이어 접지면 패턴 분류에 사용된 타이어의 종류는 모두 6가지이다. 타이어 접지면 화상 취득은 각






그림 2. 타이어 접지면 패턴의 예
 (a)-(f)타이어 접지면 패턴 p_1, p_2, \dots, p_6
 Fig. 2. The sample tire tread patterns
 (a)-(f) Tire tread patterns p_1, p_2, \dots, p_6

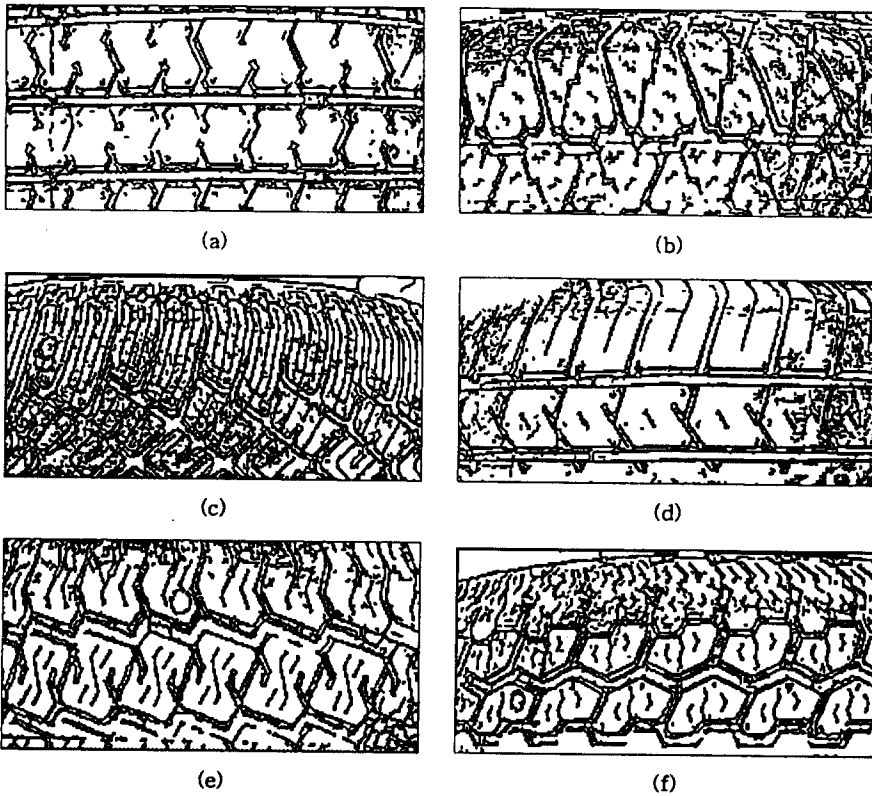


그림 3. 전처리된 타이어 접지면 패턴
 (a)-(f)전처리된 타이어 접지면 패턴 p_1, p_2, \dots, p_6
 Fig. 3. The tire tread patterns after preprocessing
 (a)-(f)Tire tread patterns p_1, p_2, \dots, p_6 after preprocessing

각의 타이어를 촬영대 위에 올려 놓고 회전시키고, 뒤집으면서 화상을 취득하였다. 이렇게 취득한 6개의 타이어 접지면 화상을 그림 2. (a)~(f)에 보였다. 이 6가지 타이어 접지면 화상에 대한 전처리 과정을 거친 화상을 그림 3. (a)~(f)에 나타내었다. 이때, 화상의 이치화 과정에서 사용된 T_1, T_2, T_3, T_4 는 모두 15로 선정하였다.

4.2 특징량 추출

전처리된 이치화 화상에 대하여 $0^\circ, 14^\circ, 27^\circ, 45^\circ, 63^\circ, 76^\circ, 90^\circ, 104^\circ, 117^\circ, 135^\circ, 153^\circ, 166^\circ$ 의 12가지 각도 성분 에 대한 COM을 구하고, 이것으로부터 특징량을 추출하였다. 그림 4는 각각의 특징량에 대응하는 윤곽선의 각도를 나타낸다. 표 1, 표 2는 각각 클러스터링과 패턴 분류에 사용된 입력 패턴의 예를 나타낸다. f_i 는 패턴 클래스 P_i 에 속하는 패턴이다. 각 타이어 접지면에 대해 40개씩 총 240개의 패턴 벡터를 구하였다.




그림 4. 특징량에 대응하는 윤곽선의 각도

Fig. 4. Direction of edge corresponding to the features

표 1. 클러스터링에 사용된 입력패턴의 예

Table 1. Sample patterns for clustering

패턴 특징량	P_1	P_2	P_3	P_4	P_5	P_6
f_1	1722	438	218	1541	593	211
f_2	932	1166	1189	1075	1001	1076
f_3	1846	2375	2515	2095	1903	2056
f_4	1975	2511	3164	2178	1990	2537
f_5	2510	2645	2854	2503	2113	2687
f_6	1174	1504	1721	1287	1145	1638
f_7	149	380	299	174	214	421
f_8	1077	1614	1266	1157	1036	1583
f_9	2406	2568	2292	2562	1787	2378
f_{10}	1972	2523	2703	2323	1945	2413
f_{11}	1728	2398	2546	2095	1805	2463
f_{12}	2168	2533	2416	2748	1961	2643

표 2. 패턴 분류에 사용된 입력 패턴의 예

Table 2. Sample patterns for classification

패턴 특징량	P_1	P_2	P_3	P_4	P_5	P_6
f_1	1651	504	166	1597	593	306
f_2	975	1249	1310	1227	984	1174
f_3	1818	2505	2773	2315	1898	2249
f_4	1942	2536	3485	2385	1976	2637
f_5	2274	2599	3157	2580	2094	2881
f_6	1113	1471	1974	1509	1151	1585
f_7	236	367	400	264	220	358
f_8	1015	1600	1512	1277	1032	1524
f_9	2199	2528	2580	2643	1762	2484
f_{10}	1870	2511	3111	2551	1945	2502
f_{11}	1784	2487	2683	2229	1816	2572
f_{12}	2310	2571	2634	2725	1948	2948

4.3 타이어 접지면 패턴의 클러스터링

앞 절에서 구한 240개의 패턴중에서 임의로 120개(각 패턴당 20개)의 타이어 접지면 패턴을 선정해 클러스터링 하는데 이용하였다.

다음에는 각각의 퍼지 클러스터링 알고리즘들을 이용한 타이어 접지면 패턴의 원형 추출을 구하는 과정을 설명 하겠다.

(i) FI 클러스터링 알고리즘

클러스터링에 사용된 타이어 접지면 패턴을 FI 클러스터링 알고리즘으로 6개의 클래스로 클러스터링을 수행한 후, 이를 비교 분석하여, P₂, P₃, P₆패턴에 대한 원형을 구하고 P₁, P₄, P₅패턴에 대해 각각 다시 클러스터링을 수행하여 패턴의 원형을 구했다. 이렇게 함으로써, 6개의 타이어 접지면 패턴 클래스의 원형을 모두 추출하였다. 표 3은 FI 클러스터링 알고리즘을 이용하여 구한 원형을 나타낸다.

표 3. FI를 이용하여 구한 각 클래스의 원형

Table 3. Obtained prototypes for each class using FI

클래스 특징량	P ₁	P ₂	P ₃	P ₄	P ₅	P ₆
f ₁	1681	499	200	1557	242	718
f ₂	941	1160	1238	1085	1131	1020
f ₃	1897	2377	2584	2066	2185	1849
f ₄	2001	2487	3269	2100	2589	1918
f ₅	2378	2564	2979	2536	2649	1954
f ₆	1169	1416	1871	1305	1524	1000
f ₇	199	360	362	202	371	174
f ₈	1100	1553	1360	1165	1500	929
f ₉	2265	2505	2401	2609	2409	1681
f ₁₀	1966	2435	2838	2312	2419	1847
f ₁₁	1812	2393	2529	2050	2458	1788
f ₁₂	2215	2459	2515	2689	2754	1947

(ii) FDH 클러스터링 알고리즘

FDH를 이용한 계층적 이진 퍼지 분할과정을 통해 클러스터링을 수행함으로써 각 타이어 접지면 패턴 클래스의 원형을 구하였다. 그림 5, 그림 6은 FDH 클러스터링 알고리즘을 이용하여 이진 퍼지 분할을 행함으로써 얻어진 트리 구조를 나타내며, 표 4, 표 5은 이 때 얻어진 원형 패턴을 나타낸다.

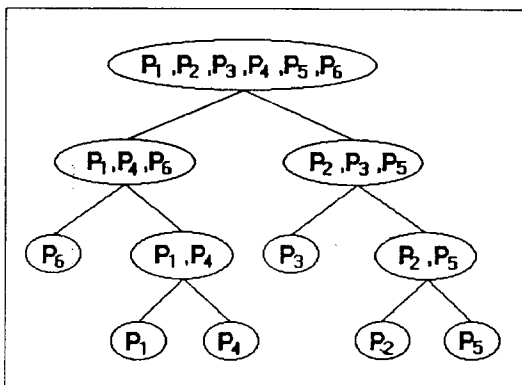


그림 5. FDH1을 이용한 이진 퍼지 분할 트리
Fig. 5. Binary fuzzy partition using FDH1




그림 6. FDH2을 이용한 이진 퍼지 분할 트리
Fig. 6. Binary fuzzy partition using FDH2

표 4. FDH1을 이용하여 구한 각 클래스의 원형

Table 4. Obtained prototypes for each class using FDH1

클래스 특징량	P ₁	P ₂	P ₃	P ₄	P ₅	P ₆
f ₁	1666	455	211	1566	277	768
f ₂	951	1167	1232	1067	1121	1019
f ₃	1901	2369	2557	2050	2194	1854
f ₄	1988	2522	3198	2075	2563	1921
f ₅	2411	2598	2947	2503	2624	1969
f ₆	1185	1453	1842	1282	1509	1007
f ₇	192	367	364	210	375	174
f ₈	1098	1559	1377	1158	1501	940
f ₉	2320	2507	2410	2556	2410	1709
f ₁₀	1984	2465	2796	2264	2413	1859
f ₁₁	1821	2413	2527	2024	2423	1790
f ₁₂	2272	2526	2539	2614	2662	1963

표 5. FDH2를 이용하여 구한 각 클래스의 원형

Table 5. Obtained prototypes for each class using FDH2

클래스 특징량	P ₁	P ₂	P ₃	P ₄	P ₅	P ₆
f ₁	1.340	-1.140	-1.792	1.064	-1.666	-0.702
f ₂	-0.857	-0.747	-0.705	-0.771	-0.737	-0.806
f ₃	-0.783	-0.687	-0.639	-0.739	-0.701	-0.789
f ₄	-0.875	-0.817	-0.724	-0.857	-0.785	-0.884
f ₅	-0.882	-0.872	-0.833	-0.867	-0.856	-0.923
f ₆	-0.993	-0.978	-0.942	-0.981	-0.964	-1.007
f ₇	-1.067	-1.056	-1.054	-1.067	-1.055	-1.069
f ₈	-0.994	-0.968	-0.974	-0.989	-0.968	-1.005
f ₉	-0.929	-0.922	-0.921	-0.910	-0.922	-0.962
f ₁₀	-0.955	-0.936	-0.918	-0.938	-0.931	-0.961
f ₁₁	-0.968	-0.946	-0.937	-0.957	-0.940	-0.968
f ₁₂	-0.957	-0.950	-0.944	-0.939	-0.937	-0.967

4.4 타이어 접지면의 분류 결과

본 절에서는 제안된 분류 체계의 유용성과 잡음에 대하여 건실함을 검증하기 위하여 타이어 접지면 패턴에 대한 분류 모의 실험 결과를 보였다.

앞 장에서 설명한 3가지 클러스터링 방법을 이용해서 구한 원형 패턴을 사용하여 식(15)에 의해 각 클래스에 소속되는 정도를 구하였다. 표 6, 표 7, 표 8은 표 3, 표 4, 표 5의 원형을 이용하여 패턴을 분류한 결과이다. 이 결과를 살펴 보면 FDH1의 방법은 96.7%(116/120), FI, FDH2는 97.5%(117/120)의 인식율을 보였다.

표 6. FI를 이용하여 구한 원형으로 분류한 결과의 예
Table 6. The examples of classification using prototype from FI

클래스 패턴	P ₁	P ₂	P ₃	P ₄	P ₅	P ₆
p ₁	<u>0.993</u>	0.000	0.000	0.005	0.000	0.002
p ₂	0.000	<u>0.944</u>	0.003	0.001	0.052	0.000
p ₃	0.000	0.002	<u>0.994</u>	0.000	0.003	0.000
p ₄	0.038	0.042	0.008	<u>0.886</u>	0.020	0.005
p ₅	0.001	0.093	0.030	0.004	<u>0.871</u>	0.001
p ₆	0.005	0.001	0.000	0.001	0.001	<u>0.992</u>

표 7. FDH1을 이용하여 구한 원형으로 분류한 결과의 예
Table 7. The examples of classification using prototype from FDH1

클래스 패턴	P ₁	P ₂	P ₃	P ₄	P ₅	P ₆
p ₁	<u>0.982</u>	0.000	0.000	0.013	0.000	0.003
p ₂	0.000	<u>0.964</u>	0.002	0.000	0.034	0.000
p ₃	0.000	0.005	<u>0.988</u>	0.000	0.005	0.000
p ₄	0.072	0.059	0.014	<u>0.811</u>	0.035	0.008
p ₅	0.002	0.261	0.070	0.005	<u>0.661</u>	0.002
p ₆	0.005	0.001	0.000	0.002	0.001	<u>0.990</u>

표 8. FDH2을 이용하여 구한 원형으로 분류한 결과의 예
Table 8. The examples of classification using prototype from FDH2

클래스 패턴	P ₁	P ₂	P ₃	P ₄	P ₅	P ₆
p ₁	<u>0.991</u>	0.000	0.000	0.009	0.000	0.000
p ₂	0.000	<u>0.998</u>	0.000	0.000	0.001	0.001
p ₃	0.000	0.000	<u>0.971</u>	0.000	0.028	0.000
p ₄	0.065	0.000	0.000	<u>0.935</u>	0.000	0.000
p ₅	0.000	0.002	0.054	0.000	<u>0.944</u>	0.000
p ₆	0.000	0.006	0.000	0.000	0.001	<u>0.992</u>

V. 결 론

본 논문에서는 FI, FDH 클러스터링 알고리즘들을 이용한 타이어 접지면 패턴 분류 체계를 제안하고, 이들 두 분류 체계를 비교 분석하였다. 특징 공간은 각 타이어 접지면 영상의 COM으로부터 특징량을 추출하여 구성하였다. 패턴 분류 알고리즘으로서, 타이어 패턴들에 대해 FI 클러스터링 알고리즘으로 단계적 클러스터링을 수행하였으며, FDH를 이용하여서는 이진 퍼지 분할을 행하여 원형 패턴을 구하였다. 이렇게 구한 원형 패턴과 입력 패턴 간의 퍼지 거리의 합이 최소가 되는 소속 함수 값을 할당하여 그 소속 정도가 최대가 되는 부류로 분류하는 방법을 사용하였다. 제안된 타이어 접지면 패턴 분류 체계는 원형 패턴의 발생을 체계화하였다는 점과 패턴 분류 결과가 다치의 소속 정도로 표현되므로 유연한 분류 체계를 세울 수 있다는 장점을 가진다. 또한 최종적인 패턴 분류 알고리즘은 그 구조가 매우 간단하여 영상에 대한 실시간 전처리 보드를 이용할 경우 분류에 걸리는 전체 시간은 1초 이내가 되며, 이는 실제 타이어 생산 라인에서 요구되는 처리 시간이 6초라는 점을 고려할 때 실시간 적용이 가능한 것이 된다. 그리고, 본 분류 체계의 분류 결과를 보면 96.7%(FDH1), 97.5%(FI,FDH2)의 인식율을 보였다.

그리고, FI, FDH들을 이용한 각각의 타이어 접지면 패턴 분류 체계를 살펴 보면 다음과 같은 결론을 얻을 수 있다.

i) 원형 패턴 취득의 체계화

FI를 이용한 원형 패턴 추출에 있어서는 FI이 비교사 클러스터링 알고리즘임에도 불구하고 오퍼레이터의 직관적인 판단에 의해 여러번 클러스터링을 수행하여 원형을 추출하였으며, 원형 추출시 모든 클래스 상호간의 영향을 고려치 않았다.

그 반면, FDH는 원형패턴을 체계적으로 추출할 수 있었으며, 원형 추출시 모든 클래스 상호간의 영향을 고려하여 추출함으로써 패턴 분류에 더 효과적이었다.

ii) 잡음 제거

클러스터링에 사용되는 패턴중에 잡음에 오손된 데이터가 있을 때, FI은 미리 제거후 클러스터링을 수행 하였으나, FDH는 알고리즘 실행시 자동적으로 잡음으로 오손된 데이터의 영향을 줄여주는 효과를 나타내었다.

參 考 文 獻

1. W. Pedrycz, "Fuzzy Sets in Pattern Recognition ;Methodology and Methods", Pattern Recognition, Vol. 23, No. 1/2, pp. 121-146, 1990.
2. R. L. Cannon, J. V. Dave, and J. C. Bezdek, "Efficient Implementation of Fuzzy C-Means Clustering Algorithms", IEEE Trans. Pattern Anal. &Machine Int., Vol. PAMI-8 No. 2, pp. 248-255, 1986.
3. J. C. Bezdek, Pattern Recognition with Fuzzy Objective Function Algorithms, New York, Plenum Press, 1981.
4. D. Dimitrescu, "Hierarchical Pattern Classification", Fuzzy sets and Systems, No. 28, pp. 145-162, 1988.
5. J. Dunn, "A Fuzzy Relative of ISODATA Process and Its Use in Detecting Compact, Well-separated Clusters", J. Cybern., pp. 319-350, 1974.
6. J. Bezdek, "Clusters Validity with Fuzzy Sets", J. Cybern., No. 3, pp. 58-72, 1974.
7. W. Pedrycz, "Algorithms of Fuzzy Clustering with Partial Supervision", Pattern Recognition Letters, No. 3, pp. 13-20, 1985.
8. 정순원, "이치화 영상에 대한 계조치 동시 발생 행렬을 이용한 타이어 접지 패턴의 분류", 고려대 석사 학위 논문, 1992.
9. R. M. Haralick, K. Shanmugam, and I. Dinstein, "Textural Features for Image Classification", IEEE Trans. Sys., Man, &Cybern. SMC-3, No. 6, pp. 610-621, 1973.