

절리군 분석을 위한 퍼지 클러스터링 기법

정용복^{1)*}, 전석원²⁾

Fuzzy Clustering Method for the Identification of Joint Sets

Yong Bok Jung and Seok Won Jeon

Abstract The structural behaviour of rock mass structure, such as tunnel or slope is critically dependent on the various characteristics of discontinuities. Therefore, it is important to survey and analyze discontinuities correctly for the design and construction of rock mass structure. One inevitable procedure of discontinuity survey and analysis is joint set identification from a lot of raw directional joint data. The identification procedure is generally done by a graphical method. This type of analysis has some shortcomings such as subjective identification results, inability to use extra information on discontinuity, and so on. In this study, a computer program for joint set identification based on the fuzzy clustering algorithm was implemented and tested using two kinds of joint data. It was confirmed that fuzzy clustering method is effective and valid for joint set identification and estimation of mean direction and degree of clustering of huge joint data through the applications.

KeyWords: fuzzy K-mean, orientation matrix, distance measure, joint set identification

초 록 터널이나 사면과 같은 암반 구조물의 거동은 불연속면에 의해 지배적인 영향을 받는다. 따라서 암반내 존재하는 불연속면 자료의 조사 및 분석은 암반구조물 설계 및 시공에 있어서 상당히 큰 중요성을 가진다. 이러한 불연속면의 조사 및 분석 작업 중에서 반드시 거쳐야 할 작업 중 하나가 절리군을 분별하는 것이다. 기존의 절리군 분석 작업은 대부분 시각적인 방법으로 행해지고 있다. 이 경우 분석자의 주관에 따라 차이를 보일 수 있으며 절리의 방향 정보 외의 다른 추가적인 정보들은 사용하기 힘든 단점이 있다. 본 연구에서는 절리군 분석을 돋기 위하여 퍼지 클러스터링 기법을 이용한 프로그램을 개발하였으며 이를 두 가지 형태의 절리 자료에 대한 절리군 분석에 적용하였다. 적용 결과 퍼지 클러스터링 기법이 다수의 절리 자료에 대한 절리군 분석, 평균방향 및 밀집도 추정에 효과적이며 타당한 방법임을 확인하였다.

핵심어: 퍼지 클러스터링, 방향행렬, 거리척도, 절리군 분석

1. 서 론

터널이나 사면과 같은 암반 구조물의 거동은 불연속면에 의해 지배적인 영향을 받는다. 따라서 암반내 존재하는 불연속면 자료의 조사 및 분석은 암반구조물 설계 및 시공에 있어서 상당히 큰 중요성을 가진다.

이러한 불연속면의 조사 및 분석 작업 중에서 반드시 거쳐야 할 작업 중 하나가 절리군을 분별하는 것이다. 기존의 절리군 분석 작업은 대부분 시각적인 방법으로 행해지고 있다. 이 경우 분석자의 주관에 따라 차이를

보일 수 있으며 절리의 방향 정보 외의 다른 추가적인 정보들은 사용하기 힘든 단점이 있다.

본 연구에서는 절리군 분석을 돋기 위한 퍼지 클러스터링 기법을 소개한다. 클러스터링 기법은 이미지 처리 분야 외에도 많은 분야에서 이미 적용되고 있는 방법이며 다만 절리와 같은 방향성 자료의 경우 약간의 변형이 요구된다. 또한 사전단계에서 절리군의 수 및 분포에 대한 가정을 하지 않아도 되는 장점이 있으므로 다른 확률론적 방법보다는 유리한 점이 있다 (Hammah & Curran, 1998). 본 연구에서는 추가적으로 절리자료를 특정 군에 할당하는 방식에 있어서 소속도값의 본래 의미를 고려한 새로운 개념을 적용하였으며 이를 투영망에 표현할 수 있는 기법을 다루었다.

¹⁾정희원, 서울대학교 공학연구소 연구원

²⁾정희원, 서울대학교 지구환경시스템공학부 교수

*교신저자(Corresponding Author): cozy@rockeng.snu.ac.kr

접수일: 2003년 6월 3일

심사 완료일: 2003년 7월 14일

2. 퍼지 클러스터링

2.1 방향 행렬

퍼지 클러스터링 기법을 방향성 자료에 대해서 적용할 경우 각각의 불연속면의 법선벡터를 가지고 수행하게 된다. 이 경우 법선벡터 자료에 대해서 기존의 클러스터링 알고리즘을 적용할 경우 각 벡터의 방향에 대해서 하나하나 점검하며 계산을 수행해야 하는 단점이 있다. 즉, 불연속면의 법선 벡터 $(0,0,1)$ 와 $(0,0,-1)$ 벡터는 사실상 같은 방향을 가리키는 것으로 볼 수 있으나 일반적인 평균을 구하게 되면 $(0,0,0)$ 이라는 방향을 지시하게 된다. 이와 같은 방향성 자료의 경우 각 벡터의 부호를 고려하여 계산해야 하는 단점이 있다.

그러나 방향행렬을 사용할 경우 이러한 단점은 제거된다. 각 법선벡터의 부호에 관계없이 사용할 수 있으며 또한 법선벡터의 분산에 대한 추정치도 제공하게 된다. 따라서 본 연구에서는 방향 행렬을 사용하여 절리군의 평균방향, 밀집도 및 분산을 추정하였다.

N 개의 방향벡터에 대한 방향코사인, (x_i, y_i, z_i) 가 주어진 경우 일반적인 방향행렬(Orientation Matrix), S 는 다음과 같이 정의된다(Markland, 1973).

$$S = \begin{bmatrix} \sum_{j=1}^N x_j x_j & \sum_{j=1}^N x_j y_j & \sum_{j=1}^N x_j z_j \\ \sum_{j=1}^N x_j y_j & \sum_{j=1}^N y_j y_j & \sum_{j=1}^N y_j z_j \\ \sum_{j=1}^N x_j z_j & \sum_{j=1}^N y_j z_j & \sum_{j=1}^N z_j z_j \end{bmatrix} \quad (1)$$

위 방향행렬에 대한 고유치(eigen values) τ_1, τ_2, τ_3 및 고유벡터(eigen vectors) ξ_1, ξ_2, ξ_3 를 구하면 최대 고유치 (τ_3)와 관련된 고유벡터 ξ_3 가 N 개의 벡터에 대한 평균방향이 된다.

위의 방향행렬을 클러스터링 기법에 그대로 적용할 경우 전체 자료의 평균을 구하는 것이기 때문에 적절하지 않다. 따라서 i 번째 클러스터에 대한 방향행렬은 소속도값(membership value)을 이용하여 다음과 같이 가중치를 적용한다(Hammah & Curran, 1998).

$$S_i = \frac{1}{\sum_{j=1}^N (u_{ij})^m} \begin{bmatrix} \sum_{j=1}^N (u_{ij})^m x_j x_j & \sum_{j=1}^N (u_{ij})^m x_j y_j & \sum_{j=1}^N (u_{ij})^m x_j z_j \\ \sum_{j=1}^N (u_{ij})^m x_j y_j & \sum_{j=1}^N (u_{ij})^m y_j y_j & \sum_{j=1}^N (u_{ij})^m y_j z_j \\ \sum_{j=1}^N (u_{ij})^m x_j z_j & \sum_{j=1}^N (u_{ij})^m y_j z_j & \sum_{j=1}^N (u_{ij})^m z_j z_j \end{bmatrix} \quad (2)$$

여기서 u_{ij} 는 j 번째 자료가 i 번째 클러스터에 속하는 정도를 표시하는 소속도값이며 m 은 퍼지정도(degree of fuzziness)를 표시하는 상수이다. 위와 같이 변형된 방향행렬에 대한 고유치, τ_1, τ_2, τ_3 와 고유벡터, ξ_1, ξ_2, ξ_3 를 구하면 최대 고유치 τ_3 와 관련된 고유벡터 ξ_3 가 i 번째 클러스터의 평균방향(\hat{V}_i)이 된다.

$$\hat{V}_i = \xi_3 \quad (3)$$

나머지 두개의 고유치는 해당 고유벡터 방향의 분산에 대한 최대우도추정자(Maximum Likelihood Estimator)이다(Marcotte & Henry, 2002). 따라서 방향행렬의 고유치와 고유벡터를 통해서 방향벡터의 분포 형태에 대한 추정을 할 수 있다.

2.2 Fuzzy K-Means Algorithm

퍼지 클러스터링 알고리즘(이하 FKM)은 목적함수 최소화 문제를 풀기위해 반복적 방법을 사용한다. 측정하고자 하는 자료가 P 차원의 벡터이고 이러한 자료에 대한 N 개의 측정치, $X_j = (X_{j1}, \dots, X_{jp}), j=1, \dots, N$ 가 있다고 하자. FKM은 이러한 자료에 대해서 각 자료 간의 거리 척도에 근거해서 K 개의 클러스터로 분할을 하게 되며 자료가 밀집된 위치를 찾게 된다. 원형(prototype) 또는 중심(centroid), \hat{V}_i 는 각 클러스터의 대표 벡터를 의미하며 해당 클러스터에 속한 모든 벡터의 기하평균이 된다. 수집한 자료를 K 개의 클러스터로 분할하는 것은 다음과 같은 퍼지 목적함수를 최소화하여 구할 수 있다.

$$J_m(U, V) = \sum_{j=1}^N \sum_{i=1}^K (u_{ij})^m d^2(X_j, V_i) \quad (4)$$

u_{ij} 는 j 번째 자료가 i 번째 클러스터에 속하는 정도를 나타내는 소속도값이며 d 는 j 번째 자료와 i 번째 클러스터 중심사이의 거리를 나타낸다. m 은 퍼지정도(degree of fuzziness)를 나타내는 상수이며 1보다 큰 수이다. 클러스터링 적용시 m 의 값으로 2를 사용하는 것이 일반적이다(Hammah & Curran, 1998). 거리척도는 두 자료의 차이 또는 이질성을 측정하는 것이다. 거리는 두 자료가 일치한다면 0이 되며 서로 다를수록 증가한다. 클러스터 중심 및 중심으로부터 각 자료 사이의 거리에 대한 개념을 Fig. 1에 표시하였다.

R^P 공간(P 차원 유클리드 공간)에서 새로운 클러스터 중심은 다음 식을 통해 구할 수 있다.

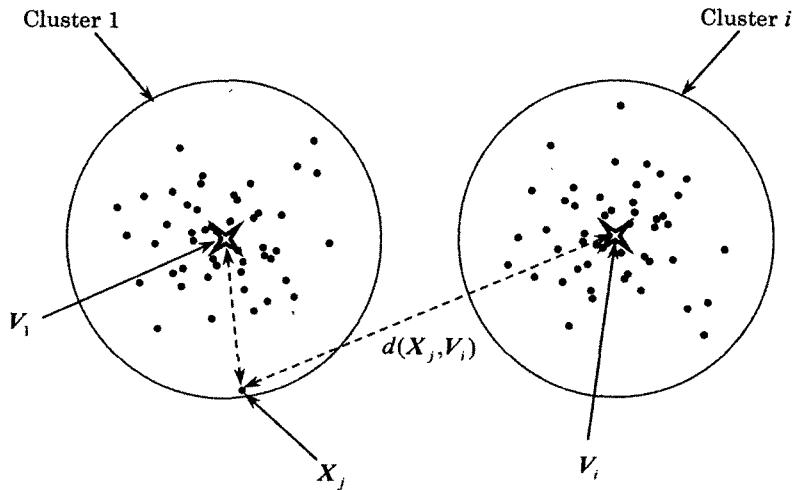


Fig. 1. 2D illustration of the geometric meaning of cluster centroids and distance of an observation from these centroids (After Hammah & Curran, 1999).

$$\widehat{V}_i = \frac{\sum_{j=1}^N (u_{ij})^m X_j}{\sum_{j=1}^N (u_{ij})^m} \quad (5)$$

방향성 자료의 경우 2.1에서 살펴본 바와 같이 (5)식을 그대로 적용할 수 없다. 따라서 본 연구에서는 2.1에서 소개한 (2) 및 (3)식을 사용하여 중심방향을 구한다.

클러스터링 기법은 하드 및 소프트 클러스터링으로 크게 분류할 수 있으며 퍼지 클러스터링 기법은 후자에 속한다. 즉, 어느 자료가 특정 클러스터에 속하는 정도가 (0,1)과 같이 속하거나(소속도값=1) 속하지 않거나(소속도값=0) 하는 두 가지 상태로 존재하는 것이 아니라 0에서 1 사이의 임의값을 갖게 되는 것이다. 식 (2), (4) 및 (5)에 나타난 소속도값 u_{ij} 는 X_j 가 i 번째 클러스터에 속하는 정도를 나타내는 것이며 이는 클러스터 중심과 자료사이의 거리의 함수이다.

$$u_{ij} = \frac{[1/d^2(X_j, V_i)]^{1/(m-1)}}{\sum_{k=1}^K [1/d^2(X_j, V_k)]^{1/(m-1)}} \quad (6)$$

FKM의 경우 소속도값이 계산되면 다시 이 값을 사용해서 중심방향을 구할 수 있다. 새로운 중심방향을 가지고 다시 각 자료와의 거리를 계산하면 다시 소속도값이 갱신된다. 이러한 과정을 다음과 같은 조건이 만족할 때 까지 반복수행하게 된다. 본 연구에서는 $\epsilon = 0.001$ 로 하였으며 이는 각 계산단계에 따른 소속도값 차이가 소수

점 이하 셋째자리까지 일치하는 경우 수렴한 것으로 판단한 것이다.

$$\max_{ij} [|u_{ij} - \widehat{u}_{ij}|] < \epsilon \quad (7)$$

최종적인 소속도값에 근거하여 자료를 각각의 클러스터에 할당한다. 일반적으로 자료 X_j 는 $u_{ij}(i=1, \dots, K)$ 값 중에서 최대값을 가지는 i 번째 클러스터에 할당된다. 만일 두개 이상의 클러스터에 속하는 소속도가 동일할 경우 일반적으로 자료수가 적은 클러스터에 할당을 한다 (Gustafson & Kessel, 1978).

본 연구에서는 기존의 FKM에서 할당하는 방법에서 최대 소속도값이 0.5보다 큰 경우에만 클러스터에 할당하고 0.5 이하일 경우는 랜덤 자료, 즉 어느 군에도 속하지 않는 자료로 처리하였다. 이는 소속도값이 0.5 이하일 경우 특정 클러스터에 속하지 않을 가능성이 더 큼을 의미하며, u_{ij} 값이 0.5라는 것은 j 번째 자료의 i 번째 클러스터 소속여부에 대한 정보가 가장 불확실한 상태임을 의미하는 것임으로 본 연구에서는 이러한 자료를 그대로 군에 할당하는 것을 배제하였다. 따라서 본 연구에서는 0.5 이상의 소속도값을 문턱값(threshold value)으로서 사용자가 지정할 수 있도록 하였다.

이상과 같은 FKM의 계산 순서를 Fig. 2의 순서도에 개략적으로 표시하였다.

2.3 거리척도

거리척도는 자료가 존재하는 공간에 의해 결정된다.

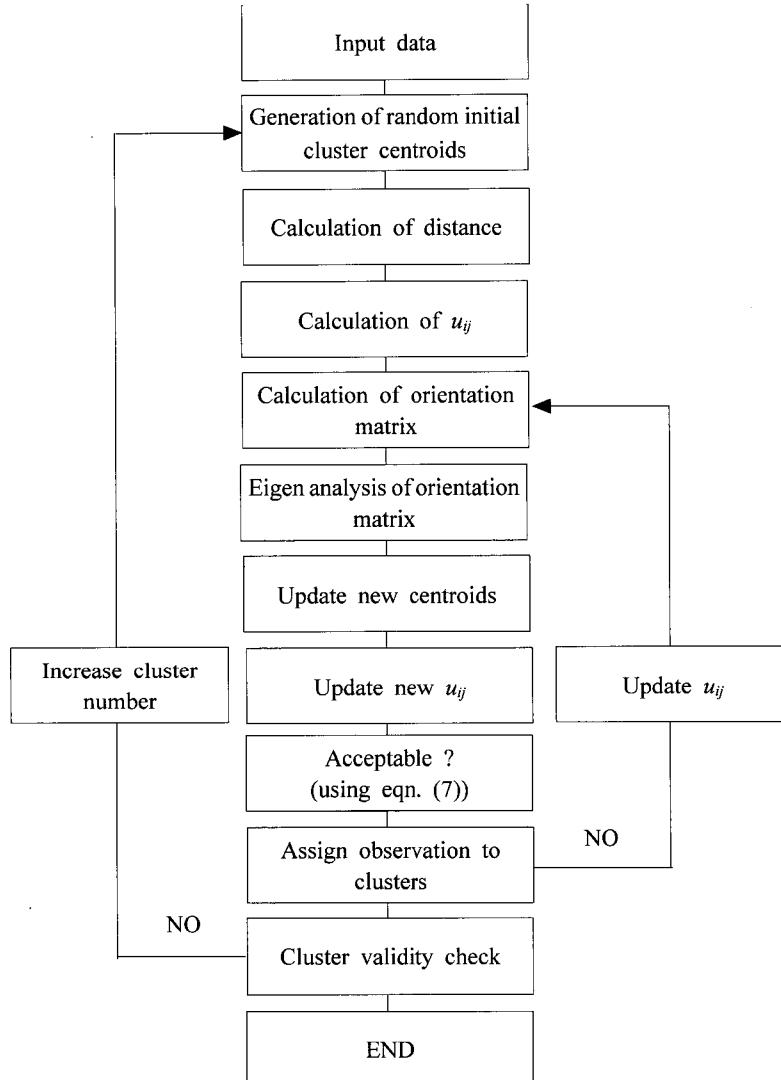


Fig. 2. Flow chart of the FKM algorithm for the clustering of discontinuity orientation data.

R^P 공간에서의 유클리드 놈(norm)은 일반적인 클러스터링 기법의 거리척도로 사용될 수 있다.

$$d^2(X_j, V_i) = \sum_{p=1}^P (X_{jp} - V_{ip})^2 \quad (8)$$

방향성 자료의 거리를 측정하기 위해서는 먼저 방향 자료를 단위수직벡터로 변환한다. 이 경우 각 자료는 유클리드 평면이 아닌 단위구면상에 위치하게 된다. 이러한 공간에서는 두 수직벡터가 이루는 각에 대한 사인 값이 거리척도로 사용될 수 있다. 따라서 구면상에 위치한 벡터에 대해서 다음과 같은 거리척도를 사용할 수

있다.

$$d^2(X_j, V_i) = 1 - (X_j \cdot V_i)^2 \quad (9)$$

FKM에서 거리척도는 분석하고자 하는 자료의 위상 (topology)을 결정한다. (9)식과 같은 거리척도를 사용할 경우 중심방향에 대해서 회전 대칭성을 가지게 된다. 즉, Fisher 분포와 유사성을 가진다. 그러나 절리 방향 자료의 경우 항상 회전대칭성을 가진다고 가정할 수 없으므로 회전비대칭성을 고려할 수 있는 거리척도를 사용해야 더 일반성을 가질 수 있다. Grossman(1985), 류

동우 등(2002)은 이러한 점을 고려하기 위해 접평면 상에서의 이변량정규분포 모델을 사용하여 회전비대칭성을 고려하였다.

본 연구에서는 (9)식의 거리척도와 회전 비대칭성 모델인 Kent 분포로부터 유도된 다음과 같은 거리척도를 사용하였다(Hamman & Curran, 1999).

$$f(X) = c(x, \beta) \exp\{x(X \cdot \xi_3) + \beta[(X \cdot \xi_2)^2 - (X \cdot \xi_1)^2]\} \quad (10)$$

$$d^2(X_j, \xi_{i3}) = 1 - \frac{(x_i(X_j \cdot \xi_{i3}) + \beta_i[(X_j \cdot \xi_{i2})^2 - (X_j \cdot \xi_{i1})^2])^2}{x_i^2} \quad (11)$$

ξ_{ij} 는 변형된 방향행렬(2.1)에서 구한 고유벡터이다. x 와 β 는 Kent 분포의 형태를 기술하는 매개변수이다. x 는 형상변수(또는 집중변수)로서 $\beta=0$ 인 경우 Fisher 분포의 K상수와 동일한 값이며, 중심벡터에 대한 자료의 집중정도를 조절한다. 즉, x 값이 클수록 분산이 적고 중심방향으로 자료가 밀집되어 있음을 나타내는 것이다. β 는 최대 및 최소 축방향으로의 밀집도 비를 표시하는 변수이다. β 값이 클수록 분포는 회전대칭성에서 벗어나게 된다. β 가 0인 경우 Kent 분포는 Fisher분포와 동일하다. 거리척도의 경우에도 β_i 가 0일 경우 (11)식은 (9)식과 동일한 식이 된다.

(11)식과 같은 거리척도를 사용할 경우 i번째 클러스터에 대한 x_i 와 β_i 를 구해야 한다. 이를 구하는 방법은 Kent(1982)가 제시했으며 다음과 같은 순서로 계산한다(Hammah & Curran, 1999).

$$1) R_{ix} = \sum_{j=1}^N (u_{ij})^m x_j, \quad R_{iy} = \sum_{j=1}^N (u_{ij})^m y_j, \\ R_{iz} = \sum_{j=1}^N (u_{ij})^m z_j \quad (12)$$

$$2) \overline{R}_i = \sqrt{R_{ix}^2 + R_{iy}^2 + R_{iz}^2} / \sum_{j=1}^N (u_{ij})^m \quad (13)$$

$$3) Q'_i = \tau_2 - \tau_1 \quad (14)$$

$$4) \widehat{x}_i = (2 - 2 \overline{R}_i - Q'_i)^{-1} + (2 - 2 \overline{R}_i + Q'_i)^{-1} \quad (15)$$

$$5) \widehat{\beta}_i = \frac{1}{2} (2 - 2 \overline{R}_i - Q'_i)^{-1} - (2 - 2 \overline{R}_i + Q'_i)^{-1} \quad (16)$$

2.4 퍼지 α -cut

퍼지집합 A의 α -cut(또는 α -level set)은 다음과

같이 정의된다.

$$A_\alpha = \{x | \mu_A(x) \geq \alpha\} \quad (17)$$

α -cut은 소속도값이 α 보다 크거나 같은 집합을 의미하며 α 가 1일 경우 core라고 하며 α 가 0.5일 때의 x값을 crossover point라고 한다. (17)식에서 \geq 대신에 $>$ 를 적용할 경우 strong α -cut이라고 하며 본 연구에서는 strong α -cut 개념을 적용하였다.

본 연구에서는 소속도값을 이용하여 각 절리 자료를 군에 할당할 때 문턱값을 정할 수 있게 하였으며 일반적으로 0.5를 사용하였다. 그리고 사용자가 정한 α -cut 을 투영망에 표현하기 위해 다음과 같은 방법을 적용하였다.

먼저 각 절리 자료를 군별로 고유벡터를 이용해 접평면에 투영시킨다. 이렇게 투영된 절리 자료와 소속도값을 이용하여 다음과 같은 2차원 가우시안 형태의 소속도 함수의 상수(w_x, w_y)를 최소자승법으로 구하였다.

$$\mu_A(x, y) = \exp\left(-\frac{1}{2} \frac{x^2}{w_x^2}\right) \cdot \exp\left(-\frac{1}{2} \frac{y^2}{w_y^2}\right) \quad (18)$$

일단 w_x 와 w_y 가 구해지면 다음과 같은 접평면상에서 특정 α 값을 가지는 타원을 구할 수 있게 된다.

$$\frac{x^2}{w_x^2} + \frac{y^2}{w_y^2} = -2 \log \alpha \quad (19)$$

타원상의 (x, y) 좌표를 필요한 개수(투영망상에 원 또는 타원으로 표시할 수 있는 정도의 수, 80개)만큼 구하고 나머지 z좌표는 단위구면상에 존재하는 좌표이므로 $\sqrt{1-x^2-y^2}$ 식을 사용하여 구한다. 이렇게 구한 (x, y, z) 좌표는 접평면상에서 정의된 좌표이므로 이를 다시 고유벡터를 사용하여 원래의 단위구면상의 좌표로 변환하면 투영망에 α -cut을 표시할 수 있게 된다.

3. 클러스터링 타당성 기준

실제로 자료가 K개의 클러스터를 가지고 있는지에 관계없이 FKM은 K개의 군으로 분할을 한다. 따라서 실제 클러스터 수를 결정하는 것에 대한 기준이 요구되며 여러 가지 기준식들이 제시되어 있다.

일반적으로 클러스터링 타당성 기준은 결정된 클러스터가 가능한 한 덜 퍼지해야 하며 부피(hyper-volume)가 작아야 되고 밀도는 높아야 된다는 개념에서 출발한

Table 1. Various cluster validity criteria.

Type	Criteria Equation	ETC
Fuzzy hyper-volume (F_{HV})	$F_{HV} = \sum_{i=1}^K [\det(F_i)]^{1/2}$	Min
Average partition density(D_{PA})	$D_{PA} = 1/K \sum_{i=1}^K S_i / [\det(F_i)]^{1/2}$	Max
Partition density(P_D)	$P_D = S / F_{HV}$	Max
Xie-Beni index(XB)	$\nu(U, V; X) = \frac{\sum_{i=1}^K \sum_{j=1}^N (u_{ij})^m X_j - V_i ^2}{N(\min_{i \neq k} \{ V_i - V_k ^2 \})}$	Min

* F_i : fuzzy covariance matrix, S_i : sum of central members, $S = \sum_{i=1}^K S_i$

것이다(Gath & Geva, 1989). Table 1에 표시된 기준식들 중에서 Xie-Beni 기준식을 제외한 나머지는 이러한 개념으로 정의된 것이다. Xie-Beni 기준식의 경우는 가중된 총 분산정도(compactness)와 분할된 각 클러스터 간의 최소거리(separation)의 비로서, 각각 분할된 클러스터 중심사이의 거리가 클수록, 분산이 적을수록 분할이 잘 되었음을 의미하는 것이다. 따라서 Xie-Beni 기준식의 경우 최소값일 때가 최적의 클러스터 개수를 지시하는 것이다.

한편, 불연속면과 같은 방향성 자료의 경우 Table 1의 식을 그대로 사용할 수 없기 때문에 각 식의 거리 норм(norm)을 계산할 경우 (9)식 또는 (11)식을 적용해야 한다.

클러스터 수를 변경해가면서 각 기준식을 계산하여 최대 또는 최소가 되는 경우의 클러스터 수가 최적의 값이 되는 것이지만 기준식마다 기준 근거가 다를 경우 서로 다르게 최적 클러스터 수를 제시할 수 있기 때문에 어느 하나의 식으로만 결정하는 것은 무리가 있다. 본 연구에서는 Table 1에 나오는 4가지 기준식들을 모두 적용하였고 이를 근거로 최적 클러스터 수를 결정하였다.

4. 적용 및 분석

4.1 CASE I

구현된 FKM의 성능을 검증하기 위해 Fisher 분포를 따르는 세 개의 절리군을 발생시키고 이 자료를 사용하여 절리군 분석을 실시하여 FKM이 적절히 군을 분류하는지 테스트하였다. 발생된 모의 절리군의 통계적 특성은 Table 2와 같다.

Table 2와 같은 모의 절리자료에 대해서 절리군 수를 2~5개, 거리척도 2가지 조건(식 (9), (11))에 대하여 FKM을 적용하였으며 Table 3은 이러한 결과를 정리한

것이다. 적용 결과, 4개의 기준식 모두 거리 척도의 형태와 관계없이 3개의 절리군으로 분할하였을 때 최적의 값이 됨을 보여주고 있다(Table 3). 절리군 수를 3으로 결정했을 때 각 절리군의 평균방향 및 Fisher 상수는 Table 4와 같다. 평균방향의 경우 추정값이 참값과 1° 이내에서 일치함을 알 수 있으며 이는 측정오차범위를 고려할 때 본 연구에서 적용한 FKM 알고리즘이 절리군 분석 및 평균방향 추정에 있어서 공학적으로 타당한 도구임을 입증하는 것이다.

밀집도 및 분산의 경우 Fisher상수 K와 고유치를 통해서 추정가능하다. 최대고유치 τ_{13} 가 모두 0.9 이상으로 나왔으며 이는 평균방향으로 밀집되어 분포함을 보여주는 것이다. 최대고유치가 1인 경우는 모든 절리 방향이 동일할 때이다. Fisher 상수가 원 자료값과 차이를 보이는 것은 모의 생성 자료의 최대분산각에 기인한 것이다. 모의절리자료 생성시 최대분산각이 적을수록 일종의 절삭이 발생하기 때문에 이러한 차이가 발생하며 30° 이상 커질 경우 원래의 값과 유사하게 나타난다.

절리군을 3개로 하여 분할하였을 경우 분류 결과 및 $a-cut(+ symbol)$ 을 Fig. 3에 표시하였다. 거리척도에 따른 차이는 거의 없으며 다만 $a-cut$ 의 모양이 절리군 3의 경우 거리척도에 따라 원과 타원형으로 약간 다르게 나타남을 알 수 있다.

4.2 CASE II

CASE II의 경우 Hammah & Curran(1998)이 적용한 DIPS 프로그램내의 자료를 사용하여 절리군 분석을 실시하였다. CASE II에 사용된 절리 자료는 Fig. 4와 같으며 등고선도를 고려할 때 4개의 절리군이 존재할 수 있음을 알 수 있다.

이 경우에도 CASE I과 동일한 방법으로 절리군 분석을 실시했으며 다만 절리군 수를 3개에서 6개까지 증가시키면서 FKM을 적용하였다.

Table 2. Synthetic joint data for fuzzy clustering.

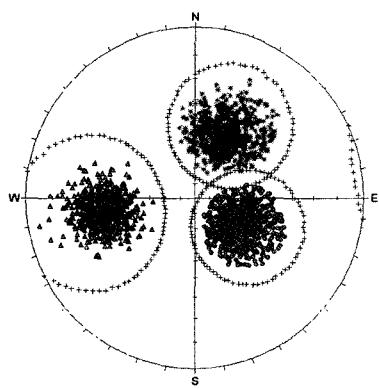
Set	Mean direction (dip direction/dip)	Fisher's K	Max. dispersion angle from mean	
1	205/47	25	28°	
2	300/35	20	25°	
3	82/57	45	30°	

Table 3. Performance measures for the CASE I(simulated joint data).

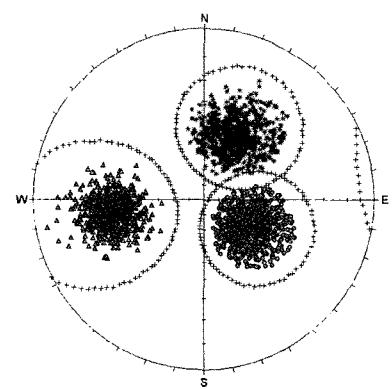
Distance measure	Number of clusters (NK)	F_{HV}	D_{PA}	P_D	XB	Iteration steps
Eqn.(9)	2	0.1769	4339.5760	4387.3305	0.2742	6
	3	0.0882	7866.5276	8152.9059	0.0671	19
	4	0.1009	6891.8850	7150.0755	0.4267	61
	5	0.1304	5758.4640	5720.0280	0.6359	15
Eqn.(11)	2	0.1286	5241.5698	6004.0021	0.1087	8
	3	0.0882	7871.5214	8155.3538	0.0667	10
	4	0.0989	6953.2945	7205.7553	0.3166	41
	5	0.1159	6001.5393	6274.5444	0.2602	27

Table 4. Estimated mean direction and Fisher constant of each joint set for the CASE I(NK=3).

Distance measure	Joint set	Mean direction (dip direction/dip)	Fisher's K	Eigen values	
				Eqn.(9)	Eqn.(11)
Eqn.(9)	1	207/46	29.6	0.0323 < 0.0341 < 0.9334	
	2	299/35	31.7	0.0304 < 0.0315 < 0.9379	
	3	83/57	42.4	0.0200 < 0.0266 < 0.9533	
Eqn.(11)	1	207/46	29.6	0.0321 < 0.0343 < 0.9335	
	2	299/35	31.7	0.0303 < 0.0316 < 0.9380	
	3	83/57	42.3	0.0197 < 0.0270 < 0.9532	



(a) hyper-spherical distance measure



(b) hyper-elliptical distance measure

Fig. 3. Results of fuzzy clustering for CASE I(NK=3).

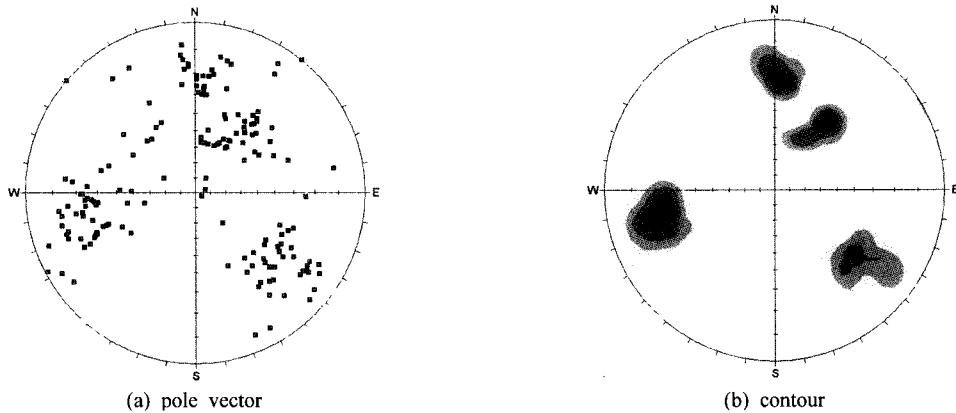


Fig. 4. Joint orientation data for CASE II.

CASE II의 경우 타당성 기준에 있어서 Xie-Beni 기준을 제외하고는 모두 절리군이 4개일 때가 최적인 것으로 나타났다(Table 5). 이와 같이 경우에 따라서 최적 절리군 수를 타당성 기준에 따라 다르게 평가할 수 있기 때문에 3절에서 언급한 바와 같이 여러 가지 기준식

을 적용하여 판단해야만 한다.

절리군이 4개일 경우 추정된 각 군의 평균방향과 Fisher 상수를 Table 6에 표시하였다. 거리척도에 따른 평균방향의 차이는 1° 이내로 나타나서 큰 차이를 보이지 않았지만 $\alpha - cut$ 의 경우 Fig. 5에 표시한 것과 같아

Table 5. Performance measures for the CASE II.

Distance measure	Number of clusters (NK)	F_{HV}	D_{PA}	P_D	X_B	Iteration steps
Eqn.(9)	3	0.1719	429.9635	445.6097	0.0952	70
	4	0.1463	564.7309	568.5249	0.1461	13
	5	0.1623	515.6395	524.6513	0.4166	35
	6	0.1598	513.5455	522.8120	0.3679	13
Eqn.(11)	3	0.1675	437.3086	452.5957	0.0928	9
	4	0.1433	580.9255	584.0271	0.1385	15
	5	0.2032	352.8957	484.5015	0.1001	15
	6	0.1579	543.5466	552.549	0.3703	13

Table 6. Estimated mean direction and Fisher constant of each joint set for the CASE II(NK=4).

Distance measure	Joint set	Mean direction (strike/dip-right)	Fisher's K	Eigen values
Eqn.(9)	1	127/46	25.9	$0.0255 < 0.0500 < 0.9244$
	2	220/66	25.6	$0.0339 < 0.0427 < 0.9232$
	3	348/67	28.1	$0.0269 < 0.0430 < 0.9300$
	4	91/67	26.6	$0.0330 < 0.0406 < 0.9262$
Eqn.(11)	1	126/46	25.7	$0.0235 < 0.0528 < 0.9236$
	2	220/66	26.2	$0.0330 < 0.0418 < 0.9250$
	3	347/68	28.0	$0.0264 < 0.0437 < 0.9298$
	4	91/67	27.7	$0.0300 < 0.0407 < 0.9291$

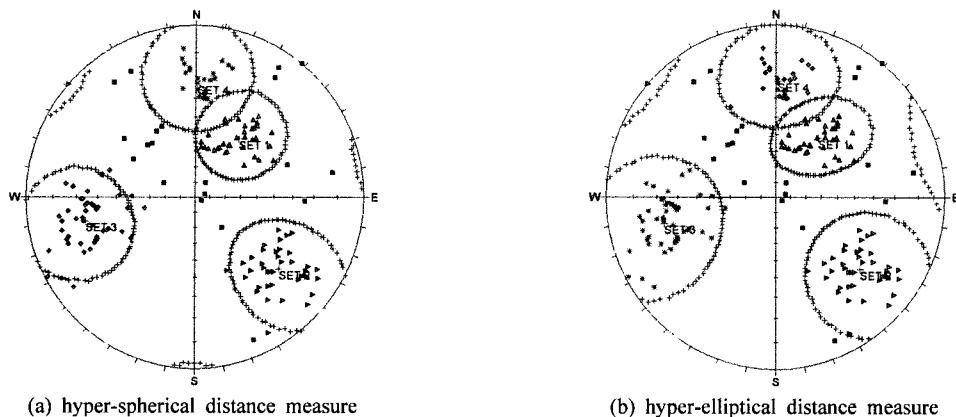


Fig. 5. Fuzzy clustering results for CASE II (NK=4).

회전대칭성 거리척도(9)의 경우 원형으로 나타나지만 회전비대칭성 거리척도(11)의 경우 타원형으로 나타나며 이를 통해서 회전비대칭성 거리척도가 더 일반적인 척도임을 알 수 있다.

이상의 결과로부터 퍼지 클러스터링 알고리즘은 절리군 분석을 보조할 수 있는 효율적이며 탄당한 방법임을 확인하였다.

5. 결 론

본 연구에서는 퍼지 클러스터링 알고리즘을 적용한 절리군 분석 프로그램을 개발하였으며 이를 절리군 분석에 적용한 결과 다음과 같은 결론을 얻을 수 있었다.

- 1) Fisher분포를 따르는 모의 자료에 대한 퍼지 클러스터링 알고리즘 적용 결과 참값과 1° 이내의 범위에서 각 군의 평균방향을 추정했으며 군 분류 결과도 참값과 일치하였다.
- 2) 회전대칭성 및 비대칭성 거리척도에 따른 퍼지 클러스터링 결과 두 방법간의 차이는 CASE I, II의 경우 1° 이내로 나타났다. 그러나 실제 절리방향의 분포 특성이 방향성을 가질 경우 두 거리척도간의 차이는 증가할 것으로 판단된다.
- 3) 퍼지 클러스터링 알고리즘은 절리군 분류에 있어서 사전 단계에서 방향성 자료의 분포에 대한 가정을 할 필요가 없으며 다수의 절리 자료를 분류 및 정리하는 데 있어서 효율적인 방법이다. 또한 방향 자료 외에 추가적인 정보도 적용할 수 있는 장점이 있으므로 절리군 분석을 보조하는 효과적인 도구임을 본 연구를 통하여 확인하였다.

감사의 말

본 연구는 2001년도 건설교통부 과제(자유 A-07)에 의해 연구비를 지원 받았다. 연구비를 지원해준 건설교통부에 감사 드린다.

참고문헌

1. Hammah, R. E. and Curran, J. H., 1998, Fuzzy cluster algorithm for the automatic identification of joint sets, Int. J. Rock Mech. Min. Sci., 35(7), 889-905.
2. Markland, J., 1973, The analysis of principal components of orientation data, Int. J. Rock Mech. Min. Sci., 11(3), 157-163.
3. Hammah, R. E. and Curran, J. H., 1999, On distance measures for the fuzzy K-means algorithm for joint data, Rock Mech. Rock Engng., 32(1), 1-27.
4. Gustafson, D. E. and Kessel, W. C., 1979, Fuzzy clustering with a fuzzy covariance matrix, Proc. IEEE Conf. on Decision and Control, San Diego, 761-766.
5. Grossman, N. F., 1985, The bivariate normal distribution on the tangent plane at the mean attitude: A keynote lecture, Proc. Int. Sympo. on Fundamentals of Rock Joints, Björkliden, 15-20.
6. 류동우, 김영민, 이희근, 2002, 암반 절리 방향성 자료의 통계적 분석 기법에 관한 연구, 터널과 지하공간, 12(1), 19-30.
7. Kent, J. T., 1982, The Fisher-Bingham distribution on the sphere, J. R. Statist. Soc. B, 44(1), 71-80.
8. Gath, I. and Geva, A. B., 1989, Unsupervised optimal fuzzy clustering, IEEE Trans. Pattern Anal. Machine Intell., 11(7), 773-781.

정 용 복

1994년 서울대학교 공과대학 자원공학과
공학사
1996년 서울대학교 대학원 자원공학과
공학석사
2000년 서울대학교 대학원
지구환경시스템 공학부 공학박사
Tel: 02-880-7232
E-mail: cozy@rockeng.snu.ac.kr
현재 서울대학교 공학연구소 연구원

전 석 원

1987년 서울대학교 공과대학
자원공학과 공학사
1989년 서울대학교 대학원 자원공학과
공학석사
1996년 미국 아리조나 주립대학
공학박사
Tel: 02-880-8807
E-mail: sjeon@rockeng.snu.ac.kr
현재 서울대학교 지구환경시스템공학부
교수