

# 분산 기반의 Gradient Based Fuzzy c-means 에 의한 MPEG VBR 비디오 데이터의 모델링과 분류

정회원 박 동 철\*, 김 봉 주\*\*

## Modeling and Classification of MPEG VBR Video Data using Gradient-based Fuzzy c\_means with Divergence Measure

Dong-Chul Park\*, Bong-Joo Kim\*\* *Regular Members*

### 요 약

GPDF(Gaussian Probability Density Function)을 효율적으로 근집화할 수 있는 GBFCM(DM)(Gradient Based Fuzzy c\_means with Divergence Measure) 알고리즘이 본 논문에서 제안되었다. 제안된 GBFCM(DM)은 데이터 사이의 거리 척도로 발산거리(Divergence measure)를 적용한 새로운 형태의 FCM으로, 기존의 GBFCM에 기반을 두는 알고리즘이다. 본 논문에서는 MPEG VBR 비디오 데이터를 GPDF형태의 다차원 데이터로 변형시켜 모델링 하고, 모델링 한 MPEG VBR 비디오 데이터를 영화 또는 스포츠 형태로 분류하는데 응용되었다. 본 논문의 실험 에서 기존의 FCM, GBFCM과 새롭게 제안된 GBFCM(DM)을 사용하여 모델링 및 분류결과를 상호 비교하였다. 비교결과 GBFCM(DM)이 오분류율의 기준에서 기존의 다른 알고리즘들에 비해 약 5~15%의 향상된 성능을 보였다.

Key Words : FCM, GPDF, Divergence, MPEG

### ABSTRACT

GBFCM(DM), Gradient-based Fuzzy c-means with Divergence Measure, for efficient clustering of GPDF(Gaussian Probability Density Function) in MPEG VBR video data modeling is proposed in this paper. The proposed GBFCM(DM) is based on GBFCM( Gradient-based Fuzzy c-means) with the Divergence for its distance measure. In this paper, sets of real-time MPEG VBR Video traffic data are considered. Each of 12 frames MPEG VBR Video data are first transformed to 12-dimensional data for modeling and the transformed 12-dimensional data are pass through the proposed GBFCM(DM) for classification. The GBFCM(DM) is compared with conventional FCM and GBFCM algorithms. The results show that the GBFCM(DM) gives 5~15% improvement in False Alarm Rate over conventional algorithms such as FCM and GBFCM.

### 1. 서 론

멀티미디어 기술은 정보,통신,교육 등의 여러 분야에서 폭넓고 빠르게 변화되어왔는데, 비디오 서비스는 가장 중요한 서비스의 하나이다[1]. 최근 들어 멀티

미디어 서비스에서 비디오 전송에 관한 연구가 활발하게 진행되고 있고, 비디오 서비스 분야는 광대역 네트워크의 영향으로 미래에는 더욱 중요한 자리를 차지하게 될 것이다[2]. 여러 응용분야에서 비디오 데이터는 데이터의 콘텐츠를 바탕으로 분석되는데, 데이터의 용량이 커질수록 운용성이 점점 떨어지기 때문에 콘텐츠

\*, \*\* 명지대학교 정보공학과 지능컴퓨팅 연구실

접수일자 논문번호: 030533-1202, 접수일자: 2003년 12월 2일

본 연구는 한국과학재단 지역대학우수과학자 지원연구(R05-2003-000-10992-0)의 지원으로 수행되었음.

츠만을 적용하여 데이터를 분석하기가 쉽지 않으며, 여러 가지 압축 기법에 의해 저장된 디지털 비디오를 콘텐츠만을 이용하여 분류하는 것은 더욱 어렵게 된다 [3]. 따라서, MPEG VBR 비디오 데이터에 대해, 압축된 상태에서 직접 그 내용을 분류해 낼 수 있다면, 시스템의 분석 및 이용의 효율성이 대단히 높아질 수 있다. 본 논문에서는 MPEG VBR 비디오 데이터를 복원단계 없이, 직접 분류해 낼 수 있는 알고리즘을 제안한다.

Patel 와 Sethi[4]는 의사결정 분류기를 이용하여 압축된 비디오를 직접 분석하는 방법을 제안했고, Liang 과 Mendel[5]는 FCM을 이용한 퍼지 분류기를 사용하는 분류 방법을 제안하였는데, 이들 방법에서의 성능은 알고리즘의 개선을 통해 향상될 수 있었다. 즉, 이 두 가지의 방법은 기본적으로 MPEG VBR 비디오 데이터를 시계열 특성의 데이터로 가정하였다. 그러나, Rose의 분석에 의하면 MPEG VBR 비디오 데이터는 확률적 특성을 지니는 데이터로 취급함이 더욱 적절하다[7]. 따라서, 본 논문에서는 MPEG VBR 비디오 데이터를 다차원의 확률적 형태인 GPDF로 가정하여, 이를 군집화하는 알고리즘의 개발과 응용을 통해 데이터를 분류하는 방법을 제안한다.

본 논문에서 MPEG VBR 비디오 데이터의 트레픽에 대한 소개가 2장에 주어졌으며, 3장에서는 실험에 사용한 알고리즘에 대한 간략한 설명, 4장에서는 Divergence 척도의 소개, 5장에서는 제안되는 알고리즘인 GBFCM(DM) (Gradient-based FCM with Divergence Measure)을 제안하고, 6장에서 실험 및 결과, 그리고 7장에서 본 논문의 결론이 주어진다.

## II. MPEG Video 의 특징

MPEG에서 제안하고 있는 동영상 압축 기법은 I-frame, P-frame, B-frame을 포함하며, 이 세 가지를 구분하여 부호화 시킨다. 실험에 사용될 MPEG VBR 비디오 데이터는 Wurzburg 대학의 Rose가 공개한 10개의 비디오 데이터 이다[7]. 이 데이터는 MPEG-1 기법으로 압축이 되어 있고, GoP size는 12로 IBBPBBPBBPBB의 형태를 가지고 있다. 비디오 stream은 40,000 video frame 이고, 25 frames/s 로 약 30분 분량의 실시간 동영상이다. 실험에 사용될 비디오의 주제는 표1에 나타나 있다.

표1. 실험에 사용될 MPEG VBR Video

영화	스포츠
"Jurassic Park"(Dino)	ATP tennis final (Atp)
"The silence of the lambs"(Lambs)	Formula 1 race:GP Hockenheim 1994 (Race)
"Star Wars"(Star)	Super Bowl final 1995: San Diego-San Francisco (Sbowl)
"Terminator 2"(Term)	Two 1993 soccer World Cup matches (Soc1)
"a 1994 movie preview"(Movie2)	Two 1993 soccer World Cup matches (Soc2)

Rose의 비디오 데이터는 Manzoni 등[8]에 의해서 Gamma 또는 Lognormal 을 이용하여 frame 과 GoP size에 대한 통계적 특징을 근사화 시켜 해석되었고, Krunch 등[9]은 Lognormal 에 의한 근사화가 I/P/B frames에 가장 좋은 분류성을 제공할 수 있음을 보였다. 따라서 본 논문에서는 MPEG VBR 비디오 데이터를 Lognormal을 취하여 실험에 사용 하였다.

## III. 기존의 알고리즘

### 1) Fuzzy c-means(FCM)

Bezdek 에 의해 제안되어 널리 쓰이고 있는 FCM에서 목적함수  $J_m$ 은 다음의 식 (1)으로 정의된다 [10].

$$J_m(U, v) = \sum_{k=1}^n \sum_{i=1}^c (\mu_{ki})^m (d_i(\vec{x}_k))^2 \quad (1)$$

여기서  $d_i(\vec{x}_k)$ 은 입력 패턴  $\vec{x}_k$ 과 군집의 중심인  $\vec{v}_i$  사이의 거리로서 Euclidean 거리를 사용하고, 센터 값은 각 그룹 내의 데이터들의 평균값을 의미하며,

$\mu_{ki}$ 는 군집 i와 입력 패턴  $\vec{x}_k$  사이의 멤버십 등급, m은 가중지수, c는 군집의 수이며, n은 입력 데이터의 수이다. Bezdek은 이 목적함수를 최소화시키기 위한 조건을 다음과 같이 정의하였다[12].

$$\mu_{ki} = \frac{1}{\sum_{j=1}^c \left( \frac{d_i(\vec{x}_k)}{d_j(\vec{x}_k)} \right)^{\frac{2}{m-1}}} \quad (2)$$

$$\vec{v}_i = \frac{\sum_{k=1}^n (\mu_{ki})^m \vec{x}_k}{\sum_{k=1}^n (\mu_{ki})^m} \quad (3)$$

2) Gradient Based Fuzzy c-means(GBFCM)

위의 식 (2) 와 (3)에서 보듯이, Bezdek의 FCM 은 중심의 값을 갱신하기 위해 모든 데이터를 사용하지만, GBFCM에서는 오직 하나의 데이터를 가지고 중심의 값을 갱신한다[6]. 즉, 하나의 데이터  $\vec{x}_i$  와 군집의 중심  $\vec{v}_j (j = 1, 2, \dots, K)$  를 갖는 K개의 군집이 주어지고,  $m = 2$  일 때, 목적함수는 다음과 같이 정의되며, 멤버십 등급의 합은 항상 1로 제한된다. 즉,

$$J_i = \mu_{1i}^2 (\vec{v}_1 - \vec{x}_i)^2 + \mu_{2i}^2 (\vec{v}_2 - \vec{x}_i)^2 + \dots + \mu_{ci}^2 (\vec{v}_c - \vec{x}_i)^2 \quad (4)$$

$$\mu_{1i} + \mu_{2i} + \dots + \mu_{ci} = 1 \quad (5)$$

위의 조건에 최적의 군집 중심값을 찾기 위한 조건으로 기울기 감소 방법을 다음과 같이 적용할 때,

$$\vec{v}_{k+1} = \vec{v}_k - \eta \frac{\partial J_i}{\partial \vec{v}_k} = \vec{v}_k - \eta \mu_{ki}^2 (\vec{v}_k - \vec{x}_i) \quad (6)$$

최적의 중심값을 위한 필요조건은 다음과 같다. 즉,

$$\frac{\partial J_i}{\partial \mu_i} = 0 \quad (7)$$

이며, GBFCM에서는 이를 적용하여 멤버십 등급을 다음으로 정한다.

$$\mu_i(\vec{x}_k) = \frac{1}{\sum_{j=1}^c \left( \frac{d_i(\vec{x}_k)}{d_j(\vec{x}_k)} \right)^2} \quad (8)$$

FCM 과 GBFCM 은 둘 다 같은 목적함수를 사용한다는 것이 공통점이지만, FCM은 중심의 값을 갱신하기 위해, 모든 데이터가 사용되는 반면, GBFCM은 주어진 각각의 데이터에 대해 식 (6) 과 (8) 을 교대

로 적용하여, 최적의 중심값과 멤버십 등급을 구하게 되므로, 학습시간과 정확성에서 더욱 효율적인 결과를 얻을 수 있다 [6].

IV. Divergence Measure

본 논문에서 군집화하려는 데이터의 형태는 MPEG VBR 비디오 데이터로서, 시계열 형태의 1차원 데이터를 다차원의 형태로 변화 시켜 각 데이터의 평균과 분산의 정보로 재구성된 다차원 공간상의 GPDF이다. 군집화 과정에서 데이터 사이의 유효한 거리 측정은 군집화 결과의 성능을 결정하는 중요한 부분이다[11]. 즉, 군집화 하려는 데이터가 확정적 데이터가 아니라, GPDF 데이터로 가정하므로, 일반적인 Euclidean 거리를 사용하여 데이터 사이의 유효한 거리를 측정하는 것에 기반을 둔 분류 알고리즘은 그 성능에서 제한적일 수밖에 없다[4,5]. 따라서 본 논문에서는 분포 사이의 거리 측정 방법으로 많이 사용되어 유용성을 인정받고 있는 Divergence 척도( Kullback-Leibler Divergence)에 기반을 둔 알고리즘이 제안되는데, Divergence 척도의 정의는 다음의 식 (9)로 주어진다[11] - [13].

$$D(x, y) = \sum_{k=1}^D \frac{x_n^{\vec{\sigma}}(k) + (x_n^{\vec{\mu}}(k) - y_n^{\vec{\sigma}}(k))^2}{y_n^{\vec{\sigma}}(k)} + \frac{y_n^{\vec{\sigma}}(k) + (x_n^{\vec{\mu}}(k) - y_n^{\vec{\sigma}}(k))^2}{x_n^{\vec{\sigma}}(k)} \quad (9)$$

여기서,  $x_n^{\vec{\mu}}(k)$  와  $x_n^{\vec{\sigma}}(k)$  는 각각 n 번째 입력 GPDF의 k번째 차원의 평균과 분산의 값,  $y_n^{\vec{\mu}}(k)$  와  $y_n^{\vec{\sigma}}(k)$  는 각각 j 번째 중심 GPDF의 k번째 차원의 평균과 분산의 값, D는 데이터의 각각의 차원을 나타낸다. 기존의 Euclidean 거리를 사용하여 GPDF 사이의 거리를 측정할 경우 각 GPDF의 평균값들 사이의 거리만을 측정하게 되는데 비해 Divergence 척도는 분포의 정보인 평균과 분산을 모두 사용하여 군집간의 거리를 측정한다.

V. 분산기반의 GBFCM

본 논문에서 제안된 분산기반의 GBFCM인

GBFCM(DM)은  $\vec{v}_i$  와 멤버십 등급  $\mu$  의 갱신 등은 GBFCM 의 방법을 따른다. GBFCM(DM)은 다차원 공간상의 확률분포로 표현되는 데이터를 군집화 하여 모델링 하는 것이 목적이므로, Euclidean 거리 대신 Divergence 척도를 사용하여 다차원 공간상의 분포간의 거리를 측정하게 된다. 다차원 공간상의 GPDF를 군집화 하기 위해서, 중심값  $\vec{v}$ 에 대한 평균과 분산을 함께 갱신하게 되는데, 다음의 수식으로 주어진다.

$$\vec{v}_{n+1}^{\mu} = \vec{v}_n^{\mu} - \eta\mu_i^2(\vec{v}_n^{\mu} - \vec{x}_i^{\mu}) \quad (\text{평균}) \quad (10)$$

$$\vec{v}^{\sigma^2} = \frac{\sum_{k=1}^{N_i} (\vec{x}_k^{\sigma^2} + (\vec{x}_k^{\mu} - \vec{v}_i^{\mu})^2)}{N_i} \quad (\text{분산}) \quad (11)$$

여기서  $\vec{v}_k^{\mu}$  는 중심의 평균,  $\vec{x}_i^{\mu}$  는 입력의 평균,  $\vec{x}_k^{\mu}$  와  $\vec{x}_k^{\sigma^2}$  는 각각 i번째 군집에 속한 k번째 입력 GPDF의 평균값과 분산값,  $N_i$  는 i번째 군집에 속한 입력 GPDF의 수를 각각 나타낸다. 식 (10)의 평균에 관한 식은 GBFCM에서 사용한 것이며[6], 식 (11)의 (분산)에 관한 식은 일반적인 여러 개의 GPDF 데이터의 전체 분산을 구하는 식이다. 표 2는 GBFCM(DM)의 수행코드이다.

표 2. GBFCM(DM)의 수행코드

Algorithm GBFCM(DM)

Procedure main()

Read c,  $\epsilon$ , m

[c is initialize cluster,  $\epsilon$  is small value, m is weighting exponent ( $m \in \{1, \dots, \infty\}$ )]

error := 0

While (error >  $\epsilon$ )

While (input file is not empty)

Read one datum  $\vec{x}_k$

[Update GBFCM(DM) center Mean]

$$\vec{v}_{n+1}^{\mu} = \vec{v}_n^{\mu} - \eta\mu_k^2(\vec{v}_n^{\mu} - \vec{x}_k^{\mu})$$

[Update GBFCM(DM) membership grade]

$$\mu_{ki} = \frac{1}{\sum_{j=1}^c \left( \frac{d_i(\vec{x}_n)}{d_j(\vec{x}_n)} \right)^2}$$

$$e = v_{n+1}^{\mu} - v_n^{\mu}$$

end while

$$\vec{v}^{\sigma^2} = \frac{\sum_{k=1}^{N_i} (\vec{x}_k^{\sigma^2} + (\vec{x}_k^{\mu} - \vec{v}_i^{\mu})^2)}{N_i}$$

error := e

end while

Output  $\mu_i, \vec{v}_{n+1}^{\mu}$  and  $\vec{v}^{\sigma^2}$

end main()

VI. 실험 및 결과

본 실험에서는 주어진 영화와 스포츠 그룹 데이터에 대해 일부를 사용하여 여러 알고리즘의 학습에 사용하고, 나머지를 여러 알고리즘의 성능검증에 사용하였는데, 비교되는 알고리즘은 GBFCM (DM), FCM, GBFCM이다. 실험은 다음의 두 가지 경우에 대해 수행되었다.

실험 1) Dino(영화) 와 Atp(스포츠)를 사용하여 알고리즘을 학습 시키고, 나머지 데이터 8개에 대해 영화와 스포츠로 분류 한다.

실험 2) 각 MPEG 비디오 데이터에서 10%를 무작위로 추출하여 알고리즘의 학습을 수행하고 나머지 90%의 MPEG VBR 비디오 데이터를 가지고 영화와 스포츠로 분류 한다. (이 경우 학습 및 검증의 데이터 선택은 무작위로 추출되는 20번의 다른 경우에 대해 실험이 수행되었다.)

실험을 위한 데이터의 전처리 과정으로 데이터를 log화 시켰고, 각 데이터를 학습 데이터와 검증을 위한 데이터로 미리 구분을 해두었다. 성능의 척도로는 다음의 오분류율이 사용되었다:

오분류율 =

$$(\text{오분류 데이터 수} / \text{전체 데이터 수}) \times 100 \%$$

하나의 MPEG VBR 비디오 데이터는 3,333개의 GPDF 데이터로 구성되어 있고, 총 10개의 비디오가 있으므로 전체 33,330개의 GPDF 데이터가 실험에 사용되었다. 각 실험에서 사용된 FCM 과 GBFCM 은 학습하는데 있어서 평균만을 이용하였고, GBFCM(DM) 은 평균과 분산을 사용하여 학습하였다. 즉, FCM 과 GBFCM에서는 각 GoP의 12개의 frame 평균값이 분류기의 입력으로 사용되었으며, GBFCM(DM) 에서는 평균과 분산이 사용되어 각 GoP 당 24개의 입력값이 분류기의 입력으로 사용되었다.

실험의 학습 후 분류단계에서 잘못 분류해낸 것을 오분류율로 표현하였고, 그 결과는 아래의 표3에 나타내고 있다. 표3에서 보듯이 FCM 과 GBFCM은 각 알고리즘의 특성상, 비슷한 결과를 얻었지만, 이들 군집은 평균만을 사용하는 알고리즘에 비해, 평균과 분산을 거리척도로 사용하는 GBFCM(DM)은 5~15%의 성능 향상을 보여주었다. 한편, 군집의 수를 달리하면서 실험을 수행한 결과를 볼 때에도, 제안된 GBFCM(DM)은 군집의 수에 영향을 받지 않고 매우 안정적인 결과를 얻을 수 있음을 보여준다. 즉, 분포함수로 주어질 수 있는 데이터의 군집화에서는 확정적 데이터에서와 달리, 데이터의 퍼짐척도인 분산이 매우 중요한 역할을 하기 때문에 Divergence 척도를 사용하는 GBFCM(DM)이 매우 유용하게 사용될 수 있음을 알 수 있다.

표 3. 실험 결과 : 군집의 수에 따른 각 알고리즘의 평균 오분류율(%)

군 집 수	실험 1			실험 2		
	FCM	GBFCM	GBFCM (DM)	FCM	GBFCM	GBFCM (DM)
3	31.1	28.6	13.2	17.4	15.8	10.4
4	28.6	26.7	12.9	21.2	16.5	10.1
5	26.8	26.8	12.7	20.5	15.2	9.9
6	30.1	24.8	14.2	13.8	22.1	9.9
7	27.8	25.7	12.8	13.4	17.6	9.9

## VII. 결 론

GPDF를 효율적으로 군집화할 수 있는 GBFCM(DM) 알고리즘이 본 논문에서 제안되었는데, 제안된 GBFCM(DM)은 데이터 사이의 거리 척도로 발산거리를 적용한 새로운 형태의 군집화 알고리즘이다. 제안된 GBFCM(DM)을 이용해 MPEG VBR 비디오 데이터를 분류 하는데 사용하였는데, 기존의 알고리즘인 FCM, GBFCM보다 속도와 오분류율에서 실험의 종류에 따라 약 5% - 15%의 향상된 성능을 나타내고 있다. 따라서 제안된 GBFCM(DM)은 MPEG VBR 비디오 데이터의 분류 이외에, GPDF의 형태를 가지는 다른 데이터의 군집화에도 유용한 결과를 얻을 수 있는 알고리즘으로 추정된다.

## 참 고 문 헌

- [1] G. Pacifici, et. al, "Guest editorial real-time video services in multimedia networks," *IEEE J. Select. Areas Comm.*, Vol. 15, pp.961-964, Aug.1997
- [2] D. Tsang, et. al. "Fuzzy-based rate control for real-time MPEG video," *IEEE Tr. Fuzzy Syst.*, Vol.6, pp504-516, 1998
- [3] N. Dimitrova and F. Golshani, "Motion recovery for video content classification," *ACM Trans. Inform. Syst.*, Vol. 13, No. 4, pp. 408-439, Oct. 1995
- [4] N. Patel and I. Sethi, "Video shot detection and characterization for video databases," *Pattern Recog.*, Vol. 30, No 4, pp. 583-592, 1977
- [5] Q. Liang and J. Mendel, "MPEG VBR Video Traffic Modeling and Classification Using Fuzzy Technique", *IEEE Tr. Fuzzy Syst*, Vol. 9, No.1, pp. 183-193. 2001
- [6] Carl Looney, *Pattern Recognition Using Neural Networks*, New York, Oxford University Press, pp. 252-254, 1997
- [7] O. Rose, "Statistical properties of MPEG video traffic and their impact on traffic modeling in ATM systems," *Univ. Wurzburg,Inst. Comp. Sci., Rep.* 101, 1995

[8] P. Manzoni, et. al., "Workload models of VBR video traffic and their use in resource allocation policies," *IEEE Trans. Networking*, Vol. 7, pp. 387-397, 1999.

[9] M. Krunz, et. al. "Statistical characteristics and multiplexing of MPEG streams," *Proc. INFOCOM'95*, Vol.2, pp. 445-462, Boston, MA, 1995.

[10] J. Bezdek, *Pattern recognition with fuzzy objective function algorithms*, New York : Plenum, 1981


[11] E. Gokcay and J. C Principe, "Information Theoretic Clustering", *IEEE Tr. on PAMI*, Vol.24, pp 158-171, 2002.

[12] D. Park and O. Kwon, " Centroid Neural Network with the Divergence Measure for GPDF Data Clustering," *IEEE Tr. Neural Networks*, (in review)

[13] D. Park et. al. " Clustering of Gaussian Probability Density Functions Using Centroid Neural Networks," *IEE Electronic Letters*, Vol. 49, No. 4, pp. 381-382, 2003

박 동 철 (Dong-Chul Park)

정회원



1980년 2월 : 서강대학교  
전자공학과(공학사)  
1982년 2월: 한국과학기술원  
전기 및 전자공학과(공학석사)  
1990년 6월: Univ. of  
Wahsington (Seattle),  
Electrical Engineering  
(Ph.D.)

1990년 8월 - 1994년 2월: 조교수, Florida Int'l  
Univ. Dept. of Eelct. and Comp. Eng.  
1994년 3월 - 현재: 명지대학교 정보공학과 교수  
1997년 - 2000년: IEEE Tr. on Neural Networks,  
Associate Editor  
1999년 - 현재: IEEE Senior Member  
<주관심분야> 신경망 알고리즘 개발, 음성인식,  
신경망의 금융공학에의 응용

김 봉 주 (Bong-Joo Kim)

정회원



2002년 2월: 명지대학교  
제어계측공학과(학사)  
2004년 2월: 명지대학교  
정보제어공학과(석사)  
2005년 2월~ 현재 :  
(주) 모다정보통신

<주관심분야> 신경망, 패턴인식, Mobile System