

論文2002-39SP-4-11

개선된 미세분할 방법과 가변적인 가중치를 사용한 벡터 부호책 설계 방법

(The design method for a vector codebook using a variable weight and employing an improved splitting method)

趙濟煌 *
(Che Hwang Cho)

요약

벡터 부호책 설계에 사용되는 기존 K-means 알고리즘은 모든 학습반복에서 고정된 가중치를 적용하는데 반해 제안된 방법은 학습반복마다 가변되는 가중치를 적용한다. 초기 학습반복에서는 새로운 부호벡터를 얻기 위해 수령영역을 벗어나는 2 이상의 가중치를 사용하고, 이 값이 클수록 가변 가중치를 적용하는 학습반복을 줄임으로써 우수한 부호책을 설계할 수 있다. 초기 부호책 설계에 사용되는 미세분할 방법을 개선하기 위하여 소속 학습벡터와 대표벡터간의 오차를 줄이는 방법을 사용한다. 즉 자승오차가 최대인 대표벡터를 제외시키고 최소인 대표벡터를 미세분할함으로써 초기 부호벡터로 대체될 보다 적절한 대표벡터를 얻을 수 있다.

Abstract

While the conventional K-means algorithms use a fixed weight to design a vector codebook for all learning iterations, the proposed method employs a variable weight for learning iterations. The weight value of two or more beyond a convergent region is applied to obtain new codevectors at the initial learning iteration. The number of learning iteration applying a variable weight must be decreased for higher weight value at the initial learning iteration to design a better codebook. To enhance the splitting method that is used to generate an initial codebook, we propose a new method, which reduces the error between a representative vector and the member of training vectors. The method is that the representative vector with maximum squared error is rejected, but the vector with minimum error is splitting, and then we can obtain the better initial codevectors.

Key Words : 부호책(codebook), 미세분할 방법, K-means 알고리즘

I. 서론

영상과 음성 데이터의 실시간 처리를 위한 손실압축 등에서 사용되는 벡터양자화(VQ ; vector quantization)는 송수신측에 미리 설계된 동일한 부호책(codebook)을

* 正會員, 東新大學校 電氣電子工學科
(Dept. of Electrical and Electronic Eng., Dongshin Univ.)

接受日字:2001年11月30日, 수정완료일:2002年4月8日

갖는다. 송신측에서는 부호책을 구성하는 부호벡터(codevector) 중에서 입력벡터와 가장 유사한 부호벡터의 주소를 출력하고, 수신측에서는 이 주소에 대응되는 부호벡터를 조합함으로써 원 데이터를 복원한다. 부호책은 VQ의 성능을 결정하는 중요한 부분으로써 부호책을 설계하는데 가장 널리 사용되는 방법은 LBG (Linde, Buzo, and Gray) 알고리즘으로도 알려져 있는 K-means 알고리즘이다.^[1] K-means 알고리즘은 국부적으로 최적인 부호책으로 수렴하고, 초기 부호책에 의해 성능이 크게 좌우되는 문제를 갖고 있기 때문에 이

러한 점을 개선하여 부호책 성능을 높이려는 시도가 다양하게 이루어져 왔다.^[1~3] 초기 부호책을 구하는 방법으로는 splitting, pruning, pairwise nearest neighbor (PNN), random, 그리고 maximum distance 등이 제안되었는데, 이 방법 중 미세분할(splitting) 방법은 설계 시간이 길다는 문제를 제외하면 가장 우수한 초기 부호책을 설계하는 것으로 알려져 있다.

K-means 알고리즘에 의한 부호책 설계 과정에서는 두 가지 조건을 만족하는데, 하나는 학습벡터와 부호벡터 간의 거리가 최소일 때 그 학습벡터는 고려된 부호벡터가 대표 벡터인 클래스(class)에 속한다는 최단거리 이웃조건(the nearest neighbor condition)과, 새로운 부호벡터는 클래스를 구성하는 학습벡터의 중심벡터라는 중심조건(centroid condition)이다. 부호책 성능을 높이기 위해 새로운 부호벡터를 결정하는 중심조건을 수정한 다양한 방법이 제시되었다.^[4~7] 이 방법 중 현재 부호벡터와 현재 중심벡터의 연장선상에 두 벡터 거리의 1.8배 되는 위치의 벡터를 새로운 부호벡터로 정하는 가중치의 적용으로 기존의 K-means 알고리즘이보다 빠른 수렴성을 얻을 수 있다.^[5] 그러나 이 방법도 모든 학습반복에서 동일한 가중치를 적용하는 것으로 초기 학습반복에서의 가중치 적용은 새로운 부호벡터 결정에 크게 영향을 미치지만, 학습반복이 후반부로 갈수록 그 영향이 적어지기 때문에 모든 학습반복에서 동일한 가중치를 적용하는 것은 적절하지 않다.

본 논문에서는 보다 우수한 초기 부호책을 구하기 위한 새로운 초기 부호책 설계 방법과 학습반복에 대해 가변 가중치를 적용한 개선된 K-means 방법을 제안하여 기존의 방법과 비교 고찰하고자 한다. 본 논문의 I장 서론에서는 기존 부호책 설계 방법에 대한 소개와 수정된 알고리즘이 제안된 이유를 설명하고, II장 이론에서는 제안된 초기 부호책 설계방법과 수정된 K-means 알고리즘에 대한 이론적인 설명을 하며, III장 실험 및 고찰과 IV장 결론 부분으로 구성된다.

II. 이 론

1. 제안된 미세분할 방법

그림 1은 초기 부호책 설계를 위해 제안된 방법의 블록도이다. 제안된 방법은 현재 클래스의 중심벡터와 소속된 모든 학습벡터 간의 자승오차(squared error)가

최대인 클래스의 중심벡터를 제외시키고, 대신 자승오차가 최소인 클래스의 중심벡터를 미소 분리하여 2개의 대표벡터가 있도록 하는 방법이다. 즉 대표벡터와 소속 학습벡터 간의 자승오차가 최대인 클래스는 대표벡터의 설정이 적절치 않다는 의미로써 자승오차가 최소인 클래스의 다른 대표벡터로 대체함으로써 전체 학습벡터에 대해 보다 적절한 대표벡터를 구할 수 있다.




그림 1. 제안된 초기 부호책 설계 방법의 블록도

Fig. 1. Block diagram of the proposed initial codebook design method.


그림 2는 기존의 미세분할 방법과 제안된 방법에 의한 초기 부호책을 구하는 과정에서 학습반복에 대한 로그 스케일의 MSE(mean square error)를 나타낸다. 그림으로부터 알 수 있듯이 기존의 방법보다 제안된 방법이 각 학습반복에서 보다 낮은 MSE를 나타내므로 보다 우수한 초기 부호책을 기대할 수 있다. 그림 2(a)와 그림 2(b)는 각각 본 논문에서 사용할 Lena 와 Peppers 영상에 대한 실험 결과이고, MSE는 다음과 같이 정의된다.

$$MSE = \frac{1}{NM} \sum_{j=1}^N \sum_{i=1}^M d_{\min}(\mathbf{x}_i, \mathbf{y}_j), \text{ for } i=1,2,\dots,M \text{ and } j=1,2,\dots,N \quad (1)$$


여기서 $M (= m \times m)$ 은 학습벡터의 수이고, N 은 부호책의 크기이다. 부호벡터 \mathbf{y}_j 가 대표벡터인 클래스 S_j 에 소속되는 학습벡터 \mathbf{x}_i 의 개수를 T_j 라하면

$M = \sum_{k=1}^N T_k$ 가 만족된다. $d_{\min}(\mathbf{x}_i, \mathbf{y}_j)$ 는 모든 i 에 대해

\mathbf{x}_i 와 \mathbf{y}_j 간의 자승오차 $\|\mathbf{x}_i - \mathbf{y}_j\|^2$ 가 최소인 값을 의미하며, 이때 \mathbf{x}_i 는 S_j 에 속한다.



(a)



(b)

그림 2. 학습반복에 대한 MSE(log) (a) Lena 영상 (b) Peppers 영상

Fig. 2. MSE(log) versus learning iteration (a) Lena image (b) Peppers image.

2. 제안된 K-means 알고리즘

K-means 알고리즘에서 최단거리 이웃조건은 \mathbf{x}_i 가 S_j 에 소속되는 여부를 나타내는 소속함수(membership function) $mf(\mathbf{x}_i, \mathbf{y}_j)$ 로 표현되며, 다음과 같이 정의할 수 있다.

$$mf(\mathbf{x}_i, \mathbf{y}_j) = \begin{cases} 1, & \text{with } d_{\min}(\mathbf{x}_i, \mathbf{y}_j) \text{ for } \mathbf{x}_i \text{ and } \mathbf{y}_j \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

클래스 S_j 의 중심벡터 \mathbf{m}_j 는 다음과 같은 중심조건에

의해 얻을 수 있다.

$$\mathbf{m}_j = \frac{\sum_{i=1}^M mf(\mathbf{x}_i, \mathbf{y}_j) \cdot \mathbf{x}_i}{\sum_{i=1}^M mf(\mathbf{x}_i, \mathbf{y}_j)} \quad (3)$$

기존의 K-means 알고리즘은 n 번 째 학습반복에서 새로운 부호벡터 \mathbf{y}_j^{n+1} 를 식 (3)으로 얻어지는 S_j 의 중심벡터 \mathbf{m}_j^{n+1} 로 결정한다. 참고문헌 [5]에서 제안된 수정된 K-means 알고리즘은 두 벡터 \mathbf{y}_j^n 와 \mathbf{m}_j^{n+1} 의 끝점을 연결하는 연장선상에 크기 $|\mathbf{m}_j^{n+1} - \mathbf{y}_j^n|$ 의 1.8 배 되는 위치의 벡터를 새로운 코드벡터로 결정하는 방법으로써 기존 방법보다 더 빠른 수렴속도를 갖고, 따라서 우수한 부호책을 설계할 수 있다. n 번 째 학습 반복에서 j 번 째 새로운 부호벡터 \mathbf{y}_j^{n+1} 와 중심벡터 \mathbf{m}_j^{n+1} , 현재 부호벡터 \mathbf{y}_j^n 그리고 학습반복의 함수로 표현되는 가중치 $\delta(n)$ 간의 관계식은 다음과 같이 나타낼 수 있고, 이 식에 대한 설명은 그림 3에 주어진다.

$$\mathbf{y}_j^{n+1} = \mathbf{y}_j^n + \delta(n)(\mathbf{m}_j^{n+1} - \mathbf{y}_j^n) \quad (4)$$




그림 3. 새로운 부호벡터, 현재 부호벡터, 중심벡터, 그리고 가중치 간의 관계

Fig. 3. The relationship between a new codevector, a present codevector, a central vector, and a weight.

기존의 K-means 알고리즘과 참고문헌 [5]에서 제안된 수정된 K-means 알고리즘은 식 (4)에 의하면 가중치 $\delta(n)$ 가 각각 1.0, 1.8로써 모든 학습반복에서 값이 고정된다. $0 < \delta(n) < 1.0$ 인 경우는 $\delta(n)=1.0$ 일 때에 비해 부호벡터의 느린 수렴결과를 가져오고, $1.0 < \delta(n) < 2.0$ 인 경우는 빠른 수렴결과를 가져온다. 특히 $\delta(n)=2.0$ 인 경우는 수렴과 발산의 경계에 새로운 부호벡터가 위치함을 의미한다.^[8] 본 논문에서는 그림 4

에 주어진 것과 같이 가중치 $\delta(n)$ 를 학습반복에 대해 가변적으로 변화시킨다. 이러한 제안의 근거는 가중치 $\delta(n)$ 의 효과가 학습반복에 따라 다르기 때문인데, 초기 학습반복에서는 $|m_i^{n+1} - y_i^n|$ 가 후반부 학습반복보다 크고 따라서 가중치 $\delta(n)$ 의 효과가 크며, 학습반복이 후반부로 갈수록 $|m_i^{n+1} - y_i^n|$ 가 작아지므로 $n > c$ 에서 $\delta(n)$ 는 그림에서와 같이 b로 고정시키더라도 그 크기의 차이에 의한 영향은 거의 없다. 앞서의 연구에 의하면 초기 학습반복에서 가중치 $\delta(n)$ 를 수렴영역을 벗어난 2.0~4.0 이상의 값을 줄 때 보다 우수한 부호책을 설계할 수 있는 것으로 알려졌다.^[9] 이러한 결과는 초기 학습반복에서 새로운 부호벡터를 수렴영역에서 벗어나도록 하여 국부적으로 보다 최적인 점으로 수렴할 가능성을 높이는 것으로 볼 수 있다. 그림 4에 주어진 $\delta(n)$ 는 다음과 같은 식으로 표현할 수 있다.

$$\delta(n) = \begin{cases} \frac{b-a}{c} \cdot n + a, & \text{for } 0 < n \leq c \\ b & , \text{for } c < n \leq d \end{cases} \quad (5)$$






그림 4. 제안된 가변 가중치 모델

Fig. 4. Model of a proposed variable weight.

여기서 본 논문에서 사용한 각 매개변수 값은 $a=2.0 \sim 4.0$, $b=1.0$ 혹은 1.8 , $d=20$ 이다.



(a)



(b)

그림 5. 학습반복에 대한 PSNR(dB) (a) Lena 영상
(b) Peppers 영상

- 기존 미세분할 방법, 모든 학습반복에 대해 $\delta=1.0$ 로 고정
- 기존 미세분할 방법, 모든 학습반복에 대해 $\delta=1.8$ 로 고정
- ▼ 제안된 미세분할 방법, 모든 학습반복에 대해 $\delta=1.0$ 로 고정
- ▽ 제안된 미세분할 방법, 모든 학습반복에 대해 $\delta=1.8$ 로 고정

Fig. 5. PSNR(dB) versus learning iteration (a) Lena image (b) Peppers image

- The conventional splitting method, fixed $\delta=1.0$ for all learning iterations
- The conventional splitting method, fixed $\delta=1.8$ for all learning iterations
- ▼ The proposed splitting method, fixed $\delta=1.0$ for all learning iterations
- ▽ The proposed splitting method, fixed $\delta=1.8$ for all learning iterations

III. 실험 및 고찰


본 논문에서 사용할 시험영상은 512×512 화소(pixel)와 256 그레이레벨(gray level)의 Lena 와 Peppers 흑백 영상이다. 학습벡터는 4×4 화소로 구성되며, 부호책의 크기는 256이다. K-means 알고리즘을 적용할 때 학습반복의 수는 모든 실험에서 20회로 제한한다. 설계된 부호책을 사용하여 재구성된 영상의 화질 정도는 아래에 주어지는 PSNR(peak signal to noise ratio)을 사용하여 평가된다.

$$PSNR = 20 \log_{10} \frac{255}{\sqrt{\frac{1}{m^2} \sum_{i=1}^m \sum_{j=1}^m (f_{ij} - g_{ij})^2}} \quad (6)$$


여기서 m 은 512이며, f_{ij} 와 g_{ij} 는 각각 원영상과 복원된 영상의 i 번째 열과 j 번째 행의 화소값이다.

그림 5는 기존 미세분할 방법과 제안된 방법에 의해 얻어진 초기 부호책을 사용하여 모든 학습반복에서 고정된 $\delta(n)=1.0$ 와 $\delta(n)=1.8$ 를 적용하는 경우, 설계된 부호책의 성능을 비교하였다. 그림 2에서 예상했듯이 제안된 미세분할 방법에 의해 얻어진 초기 부호책을 사용함으로써 $\delta(n)=1.0$ 와 $\delta(n)=1.8$ 모두에 대해 더 우수한 부호책을 설계할 수 있음을 알 수 있다.


그림 6에서 (a)~(d)는 Lena 영상에 대해, (e)~(h)는 Peppers 영상에 대해 20번 째 학습반복에서 얻어지는 부호책에 대한 PSNR를 각각 나타낸다. 각 그림에서 (a), (b), (e), (f)는 기존 미세분할 방법에 의해 얻어진 초기 부호책을 사용하여 모든 학습반복에서 각각 $\delta(n)=1.0$ 과 $\delta(n)=1.8$ 로 고정된 기존의 K-means 알고리즘과 $\delta(n)$ 가 식 (5)에 의해 학습반복에 따라 가변되는 제안된 K-means 알고리즘을 적용하여 구한 부호책의 성능을 나타낸다. (c), (d), (g), (h)는 제안된 미세분할 방법에 의해 얻어진 초기 부호책을 사용하고, 앞에서와 같이 기존의 K-means 알고리즘과 제안된 K-means 알고리즘을 적용하여 구한 부호책의 성능을 나타낸다. 결과적으로 제안된 미세분할 방법에 의해 생성된 초기 부호책을 사용하여 제안된 K-means 알고리즘으로 설계된 부호책의 성능이 가장 우수한 것을 알 수 있다. 그림 7은 그림 6으로부터 최대 PSNR이 얻어지는 a 와 c 를 구한 결과이다. 그림으로부터 알 수 있듯이 a 가 증가할수록 최대 PSNR을 얻기 위해서는 c 는 감소되어야 한다. 이것은 초기 학습반복에서 a 가 크게 주어지면 c 를 감소시켜 새로운 부호벡터가 수렴영역을 벗어나는 경우의 학습반복을 줄여야 함을 의미한다. 제안된 미세분할 방법에서는 자승오차가 최대인 대표벡터를 제외시키고 최소인 대표벡터를 미세분할함으로써 초기 부호벡터로 대체될 보다 적절한 대표벡터를 얻을 수 있고, 결과적으로 기존 미세분할 방법에서의 경우보다 소속 학습벡터와 대표벡터간의 오차가 줄어든다. 그림 7에서 알 수 있듯이 제안된 미세분할 방법에 의한 초기 부호책을 사용하는 경우, 기존 미세분할 방법에 의한 초기 부호책을 사용하는 경우보다 주어진 c 에 대해



(a)



(b)



(c)




그림 6. 부호책의 성능 비교 (a)~(d) Lena 영상 (e)~(h) Peppers 영상
(a), (e) 기존 미세분할 방법, $n > c$ 에서 $\delta(n) = 1.0$
(b), (f) 기존 미세분할 방법, $n > c$ 에서 $\delta(n) = 1.8$
(c), (g) 제안된 미세분할 방법, $n > c$ 에서 $\delta(n) = 1.0$
(d), (h) 제안된 미세분할 방법, $n > c$ 에서 $\delta(n) = 1.8$

Fig. 6. The performance comparison of codebooks
(a)~(d) Lena image (e)~(h) Peppers image
(a), (e) The conventional splitting method,
 $(n)=1.0$ for $n > c$
(b), (f) The conventional splitting method,
 $\delta(n)=1.8$ for $n > c$
(c), (g) The proposed splitting method, $\delta(n)$
 $=1.0$ for $n > c$
(d), (h) The proposed splitting method, $\delta(n)$
 $=1.8$ for $n > c$




그림 7. 그림 6으로부터 최대 PSNR의 a 와 c (a) Lena 영상 (b) Peppers 영상

- 기존 미세분할 방법,
 $n > c$ 에서 $\delta(n)=1.0$
- 기존 미세분할 방법,
 $n > c$ 에서 $\delta(n)=1.8$
- ▼— 제안된 미세분할 방법,
 $n > c$ 에서 $\delta(n)=1.0$
- ▽— 제안된 미세분할 방법,
 $n > c$ 에서 $\delta(n)=1.8$

Fig. 7. a and c in maximum PSNR from Fig.6 (a)
Lena image (b) Peppers image

- The conventional splitting method, $\delta(n)=1.0$ for $n > c$
- The conventional splitting method, $\delta(n)=1.8$ for $n > c$
- ▼— The proposed splitting method, $\delta(n)=1.0$ for $n > c$
- ▽— The proposed splitting method, $\delta(n)=1.8$ for $n > c$

최대 PSNR을 얻기 위한 a 의 범위가 더 확대되는데, 이것은 제안된 미세분할 방법에서 보다 우수한 대표벡터를 구할 수 있기 때문에 초기 학습반복에서 a 의 선택 범위가 넓어짐을 의미한다.

IV. 결 론

K-means 알고리즘은 초기 부호책의 영향을 크게 받는 단점에도 불구하고 알고리즘의 단순성 때문에 가장 보편적으로 사용되는 부호책 설계 방법이다. 기존의 다양한 초기 부호책 설계 방법 중에서 미세분할 방법은 계산이 많다는 점을 제외하면 과정이 단순하면서도 가장 우수한 초기 부호책을 설계하는 것으로 알려져 있다. 본 논문에서는 초기 부호책 생성 알고리즘으로 현재 클래스의 중심벡터와 소속된 모든 학습벡터 간의 자승오차를 고려하여 대표벡터를 대체하는 수정된 미세분할 방법을 제안하고, 부호책 생성을 위해 모든 학습반복에서 가중치가 고정되는 기존의 K-means 알고리즘을 개선하여 학습반복에 대해 가변되는 가중치를 갖는 수정된 K-means 알고리즘을 제안한다. 실험 결과로부터 본 논문에서 제안한 방법이 기존 방법보다 우수한 부호책을 설계할 수 있음을 알 수 있다.

참 고 문 헌

- [1] Y.Linde, A.Buzo, and R.M.Gray, "An algorithm for vector quantizer design," *IEEE Trans. Commun.*, Vol. COM-28, pp. 84~95, January 1980.
- [2] W.H.Equit, "A new vector quantization clustering algorithm," *IEEE Trans.Acoust. Speech and Signal Proc.*, Vol. 7, pp. 1568~1575, October 1989.
- [3] I.Katsavounidis, C.C. Jay Kuo, and Z.Zhang, "A new initialization technique for generalized Lloyd iteration," *IEEE Signal Processing Letters*, Vol. 1, pp. 144~146, October 1994.
- [4] H.A.Monawer, "Image vector quantization using a modified LBG algorithm with approximated centroids," *Electronics Letters*, Vol. 31, pp. 174~175, February 1995.
- [5] D.Lee, S.Baek, and K.Sung, "Modified K-means algorithm for vector quantizer design," *IEEE Signal Processing Letters*, Vol. 4, pp. 2~4, January 1997.

- [6] S.Baek, B.Jeon, D.Lee and K.Sung, "Fast clustering algorithm for vector quantization," *Electronics Letters*, Vol. 34, pp. 151~152, January 1998.
- [7] P.Veprek and A.B.Bradley, "An improved algorithm for vector quantizer design," *IEEE Signal Processing Letters*, Vol. 7, pp. 250~252,
- [8] M.R.Anderberg, *Cluster analysis for applications*, Academic, New York, 1973.
- [9] 박소희, 조제황, "초기 학습반복시 수렴영역을 벗어난 가중치에 의한 K-means 알고리즘," 한국음향학회 추계학술발표대회 논문집, 제20권, 제2(s)호, 143~146쪽, 2001년 11월

저자 소개



趙濟煌(正會員)

1984년 2월 : 광운대학교 전자공학과(학사). 1986년 2월 : 광운대학교 대학원 전자공학과(석사). 1990년 2월 : 광운대학교 대학원 전자공학과(박사). 1989년 3월 ~ 현재 : 동신대학교 전기·전자공학부 부교수.

<주관심분야: 적응신호처리, 영상처리, 패턴인식, MEMS>