

표본 적응 프리덕트 양자기에 기초한 DPCM을 이용한 고 전송률 영상 압축

정회원 김 동 식*, 이 상 욱**

High Bit Rate Image Coder Using DPCM based on Sample-Adaptive Product Quantizer

Dong Sik Kim*, Sang Uk Lee** *Regular Members*

요 약

본 논문에서는 표본 적응 프리덕트 양자기(sample-adaptive product quantizer: SAPQ)라 불리는 새로운 기법의 양자기를 불변 길이 출력을 가지며 높은 전송률을 가지는 DPCM(differential pulse coded modulation)에 기초한 영상 데이터 감축에 적용하였다. DPCM의 성능을 개선하기 위해서는 기존의 스칼라 양자기 대신에 벡터 양자기(vector quantizer: VQ)를 사용해야 하는데, 전송률이 증가함에 따라 일반적인 VQ나 심지어 나무 구조를 가지는 변형된 VQ도 부호화 복잡도나 요구되는 기억 장치의 양으로 인하여 그 구현이 거의 불가능하다. SAPQ는 매우 짧은 적응 주기를 가지는 feed-forward 적응 스칼라 양자기로 일종의 제한적 구조를 가지는 VQ의 일종이다. 따라서, 비록 전송률이 높다고 해도, SAPQ를 사용하면 일반 VQ에서의 부호화 복잡도와 요구되는 기억 장치의 양을 줄이면서 VQ의 성능을 얻을 수 있다. 나아가서 SAPQ가 스칼라 양자기의 구조를 가지고 있으므로 DPCM 부호기에서 기존의 스칼라 값을 예측하는 예측기를 그대로 사용하면서 SAPQ는 양자화 역할을 수행할 수 있다. 합성 신호와 실제 영상 데이터에 대하여 실험한 결과 DPCM의 양자화 부분만을 바꾸어서 전송률이 4 b/point 이상에서 2~3 dB 정도의 성능 향상을 얻을 수 있었다.

ABSTRACT

In this paper, we employed a new quantization scheme called sample-adaptive product quantizer (SAPQ) to quantize image data based on the differential pulse code modulation (DPCM) coder, which has fixed length outputs and high bit rates. In order to improve the performance of traditional DPCM coders, the scalar quantizer should be replaced by the vector quantizer (VQ). As the bit rate increases, it will be nearly impossible to implement a conventional VQ or modified VQ, such as the tree-structured VQ, even if the modified VQ can significantly reduce the encoding complexity. SAPQ has a form of the feed-forward adaptive scalar quantizer having a short adaptation period. However, since SAPQ is a structurally constrained VQ, SAPQ can achieve VQ-level performance with a low encoding complexity. Since SAPQ has a scalar quantizer structure, by using the traditional scalar value predictors, we can easily apply SAPQ to DPCM coders. For synthetic data and real images, by employing SAPQ as the quantizer part of DPCM coders, we obtained a 2~3 dB improvement over the DPCM coders, which are based on the Lloyd-Max scalar quantizers, for data rates above 4 b/point.

* 한림대학교 전자공학부 (dskim@ee.hallym.ac.kr), ** 서울대학교 전기공학부 (sanguk@sting.snu.ac.kr)
논문번호 : 99003-0104, 접수일자 : 1999년 1월 4일

I. 서론

DPCM(differential pulse code modulation)은 예측 신호의 오차 신호를 양자화 하는 방법으로 음성 부호화나 DCT(discrete cosine transform) 변환된 영상 데이터 중에서 DC 성분의 양자화에 널리 쓰이고 있다^[3]. DPCM의 성능과 복잡도는 예측기라 불리는 예측 알고리즘에 따라 달라진다. 예를 들어 정지 화상 부호화를 위한 JPEG(Joint Photographic Experts Group) 표준을 고려해 보자. JPEG에서 DC 값은 하나의 DCT 블록을 구성하는 화소들의 평균 값으로, 인접한 다른 DCT 블록의 DC와 매우 높은 상관성을 가지고 있다. 그래서 JPEG에서는 이들의 차이를 부호화 하는 방법을 사용하고 있다^[5]. x_0, x_1, x_2, \dots 를 DPCM 부호기의 입력들이라고 하고 \hat{x}_i 을 i 번째 입력 x_i 의 예측이라 하면, JPEG에서의 예측기는 다음과 같이 묘사된다.

$$\hat{x}_i = x_{i-1}, \quad i=1,2,\dots \quad (1)$$

따라서 예측 오차 $x_i - \hat{x}_i = x_i - x_{i-1}$ 을 entropy 부호기로 부호화 한다. 참고로 JPEG에서는 entropy 부호기를 사용하고 있는데 만일 가변 길이 출력을 가지는 entropy 부호기 대신에 불변 길이 부호로 양자기의 출력을 나타낸다고 하면 DPCM에서 사용되는 양자기는 Lloyd-Max 양자기와 같은 비 균일 양자기가 되어야 한다. ITU-R CMTT 721-1 표준은 이와 같이 불변 길이 출력에 높은 전송률을 가지는 DPCM에 기초한 영상 부호화 기법의 예이다. 이 표준은 140 Mbps의 전송률을 가지는 디지털 TV 신호 전송용으로 고 화질을 가지고 있다. 그런데 이러한 DPCM 부호기는 entropy 부호기를 사용하지 않든 스칼라 양자기(scalar quantizer: SQ)보다 성능을 높이기 위해서는 벡터 양자기(vector quantizer: VQ)를 사용해야 한다.

입력되는 신호들을 m 개마다 묶어서 m 차원 벡터로 만들어 벡터 양자화 해 보자. 그러면 VQ의 특성에 의해 벡터 내의 원소들 간에는 DPCM과 같은 상관성을 없애 주는 기법이 필요하지 않다. 일반적으로 낮은 전송률에서는 이러한 VQ의 구현은 가능하다. 반면에 전송률이 올라가고 성능을 올리기 위해 벡터의 차수 m 을 증가시키면 VQ의 구현은 거의 불가능해진다. 예를 들어 전송률이 4 b/point 이고 벡터의 차수가 $m=8$ 일 때, 만일 나무 구조

VQ(tree-structured VQ)를 사용한다고 하면 부호화 복잡도는 $O(m)$ 의 수준으로 낮출 수 있지만 필요한 기억 장치는 $O(m2^m)$ 이 되어서 약 6.9×10^{10} 개의 원소를 위한 기억 장치가 요구된다^[4]. 만일 VQ의 구현을 가능하게 하기 위해 낮은 차수의 벡터를 사용한다고 하면, 이득을 얻기 위하여 벡터 값을 예측하는 예측기를 사용하는 DPCM 부호기를 고안해야만 한다.

본 논문에서는 특별히 높은 전송률에서, SQ의 구조를 가지며 VQ의 성능을 얻을 수 있는 일명 표본 적응 프리덕트 양자기(sample-adaptive product quantizer: SAPQ)^{[7],[8]}를 DPCM 부호기에 적용하였다. SAPQ는 m 차원의 공간에서 구조적 제한을 가지는 m 차원 VQ의 일종이므로 비록 입력 소스가 i.i.d.(independent, and identically distributed)라고 할지라도 입력에 따라 큰 이득을 얻을 수 있다. 또한 4 b/point 정도의 고 전송률에서도 VQ의 성능을 얻을 수가 있다. 본 논문에서는 제안한 DPCM 부호기를 DSAPQ(DPCM SAPQ)라 부르기로 하자. DSAPQ의 성능은 입력 분포에 따라서 2~3 dB의 이득을 얻을 수 있다.

본 논문의 구성은 다음과 같다. 먼저 제 II장에서는 SAPQ에 대해 간단히 소개하였다. 제 III장에서는 제안한 DSAPQ를 기존의 DPCM과 함께 수식으로 정리하였다. 제 IV 장에서는 실험 결과 제시 및 토론을 하였으며, 마지막 장에서 본 논문의 결론을 내렸다.

II. 표본 적응 프리덕트 양자화

본 장에서는 일반적인 양자기의 기본 정의를 수식을 이용해서 정리하였으며 새로 제안하는 SAPQ 기법을 간단히 소개하였다.

양자화 하려는, m 개의 Euclidean 공간 R 에서 정의되는 불규칙 변수를 X_1, \dots, X_m 이라 하자. 이때 X_1, \dots, X_m 은 동일하게 분포되어 있다고 가정하자. 여기서 $E\{X_i\}^2 < \infty$ 라 가정하자. R 에서 n 개의 원소를 가지는 모든 집합의 클래스를 Λ_n 이라 하고 Λ_n 의 원소를 “ n 개의 대표치를 가지는 부호책”이라 하자. 다시 말하면 이 부호책은 n 개의 부호 단어를 가지고 있다. 불규칙 변수 X_i 를 양자화 한다고 하는 것은 X_i 의 관찰 열들을 부호책의 원소의 열로 사상하는 것으로 이러한 사상을 양자기라 한다. 부호책 $C (\in \Lambda_n)$ 를 사용해서 불규칙 변수 X_i 를 양자

화 할 때의 평균 왜곡은 다음과 같다.

$$E\{\min_{y \in C} (X_i - y)^2\} \quad (2)$$

이 양자화에서 만일 불변 길이 부호화를 양자기의 출력 부호화에 사용한다고 하면 필요한 전송률은 $R = \log_2 n$ b/point가 된다. 이 양자기의 입력과 부호책의 원소는 모두 R에 속해있으므로 이러한 양자기를 SQ라 한다.

만일 m 개의 불규칙 변수 X_1, \dots, X_m 을 하나의 부호책 $C (\in A_n)$ 로 양자화 한다고 하면 총 평균 왜곡은 다음과 같다.

$$E\left\{\frac{1}{m} \sum_{i=1}^m \min_{y \in C} (X_i - y)^2\right\} \quad (3)$$

이러한 양자화 방법은 R^m 공간에서 프리덕트 집합(product set, 곱집합) $C = C^m$ 으로의 사상이므로 이 양자기를 프리덕트 양자기(product quantizer: PQ)라 하자^[4, p.430]. PQ에서 C 는 m 차원의 부호책으로 $C \in R^m$ 이며 그 크기는 $|C| = n^m$ 이므로 전송률은 다음과 같다.

$$R = \frac{1}{m} \log_2 |C| = \log_2 n \quad (4)$$

만일 불규칙 변수 X_1, \dots, X_m 이 서로 상관성이 없거나 독립이라고 하면 식 (3)과 같이 양자화 하는 것이 일반적이다. 그러나 불규칙 변수 X_1, \dots, X_m 이 i.i.d. 신호라 할지라도 식 (3)의 PQ는 여러 가능한 부호화 방식 중의 하나이며, block source coding theorem^[2]에 의하면 더 좋은 성능을 얻을 수 있는 양자화 기법이 존재한다. 이의 대표적인 예가 VQ로 C 를 m 차원의 VQ 부호책이라 하고 $|C| = \nu$ 라 하면 VQ의 평균 왜곡은 다음과 같다.

$$E\left\{\min_{y \in C} \frac{1}{m} \sum_{i=1}^m (X_i - y)^2\right\} \quad (5)$$

이 식에서 $y := (y_1, \dots, y_m) (\in R^m)$ 이며 전송률은 $R = (1/m) \log_2 \nu$ 이다.

이제 본 논문에서 제한하는 SAPQ를 소개하면 다음과 같다. SAPQ는 R^m 공간에서 구조적으로 제한이 있는 부호책을 가지는 VQ로 식 (3)의 PQ보다 좋은 성능, 즉 VQ의 성능을 얻을 수 있다. 그러나 SAPQ의 구조는 SQ에 기초한 feed-forward 적응 양자기의 형태^[1]를 가지고 있다. 음수가 아닌 정수 η

를 SAPQ의 부가 bit라 하자. 또한 양의 정수 n' 에 대해 부호책 $C_j \in A_{n'}$ 를 고려하자. 여기서 j 의 범위는 $j \in \{1, \dots, M\}$ 이며 $N = 2^\eta$ 이다. x_1, \dots, x_m 을 불규칙 변수 X_1, \dots, X_m 의 한 관찰이라고 할 때, SAPQ는 먼저 부호책 C_1, \dots, C_N 을 사용하여 다음과 같은 N 개의 거리를 구한다.

$$\frac{1}{m} \sum_{i=1}^m \min_{y \in C_j} (x_i - y)^2, \quad j = 1, \dots, N \quad (6)$$

다음, 이 중에서 거리가 가장 작은 j 를 선택한다. 따라서 SAPQ의 평균 왜곡은 다음과 같다.

$$E\left\{\min_{j \in \{1, \dots, N\}} \frac{1}{m} \sum_{i=1}^m \min_{y \in C_j} (X_i - y)^2\right\} \quad (7)$$

식 (6)과 (7)을 통해서 SAPQ는 R^m 에서 프리덕트 집합의 합집합인 $C = \bigcup_{j=1}^N C_j^m$ 로의 사상을 알 수 있다. SAPQ의 출력 bit 열은 각 표본에 대해 사용된 부호책의 index j , 즉 η bit 과 m 개의 양자화 index로 구성되어 있다. 이는 feed-forward 적응 양자화 기법과 동일한 구조를 가지고 있는 것으로 따라서 SAPQ의 전송률은 다음과 같다.

$$R = \log_2 n' + \frac{\eta}{m} \quad (8)$$

이 식에서 η/m 은 부가 전송률로 복호기로 하여금 어떠한 부호책이 사용되었는지 알게 해 준다. 본 논문에서는 양자화의 성능 비교의 목적으로 식 (4)와 (8)의 $\log_2 n$ 과 $\log_2 n'$ 가 정수가 아닌 다른 값을 가질 수 있다고 가정하였다.

이제 식 (7)의 SAPQ를 통해서 얻을 수 있는 이득에 대해 간단히 논해보자. 식 (7)의 SAPQ에서는 주어진 j 에 대해 하나의 부호책 C_j 를 사용하는데 이를 보다 일반화 시켜서 m 개의 다른 부호책을 사용하는 방법을 고려해보자. 양의 정수 n'_i 에 대해 $C_{i,j} \in A_{n'_i}$ 인 부호책 $C_{i,j}$ 를 X_i 의 양자화에 각각 사용하자. 이때의 평균 왜곡은 다음과 같다.

$$E\left\{\min_{j \in \{1, \dots, N\}} \frac{1}{m} \sum_{i=1}^m \min_{y \in C_{i,j}} (X_i - y)^2\right\} \quad (9)$$

이러한 일반화 된 SAPQ는 m 차원의 가능한 SAPQ의 부호책이 항상 PQ의 모든 가능한 부호책을 포함하고 있으므로 PQ보다 좋은 성능을 얻을 수 있다. (SAPQ의 보다 상세한 성능에 대한 분석은

[7]을 참조 바람.) 반면에 식 (7)의 SAPQ는 PQ보다 항상 좋은 성능을 얻을 수는 없다. 그러나 다음 장에서 제안할 부호책 설계 알고리즘으로 설계된 부호책의 성능을 보면 m 이 커짐에 따라 ($m \geq 3$) SAPQ의 성능은 PQ보다 좋아짐을 관찰할 수 있다^[8]. 보다 자세한 실험 결과를 제 IV장에서 제시하였다.

III. SAPQ에 기초한 DPCM

본 장에서는 제 II장에서 제안한 SAPQ를 DPCM의 양자기로 사용하는 새로운 DSAPQ 방식을 제안하였다.

DSAPQ를 수식으로 나타내기 위하여 $Lm+1$ 개의 불규칙 변수 X_0, X_1, \dots, X_{Lm} 을 고려하자. 여기서 L 은 양의 정수이다. 불규칙 변수 X_0, X_1, \dots, X_{Lm} 의 한 관찰을 x_0, x_1, \dots, x_{Lm} 이라 표기하자. \hat{x}_i 을 현재 i 일 때의 x_i 의 예측이라고 하고 δ_i 을 오차 신호라 할 때, 이 오차 신호는 다음과 같이 정의된다.

$$\delta_i := X_i - \hat{X}_i \quad (10)$$

이 오차 신호는 X_i 과 같은 표본 공간 Ω 에 정의되는 불규칙 변수이다. 만일 부호책 $C (\in \mathcal{A}_n)$ 를 사용해서 오차 신호 δ_i 을 양자화 한다고 하면 일반적인 DPCM 부호기의 평균 왜곡은 다음과 같다.

$$E\left\{\frac{1}{Lm} \sum_{i=1}^{Lm} \min_{y \in C} (\delta_i - y)^2\right\} \quad (11)$$

$y_i (\in C)$ 을 $\delta_i^* = x_i - \hat{x}_i$ 의 양자화 된 값이라 하자. 즉 $\min_{y \in C} (\delta_i^* - y)^2 = (\delta_i^* - y_i)^2$ 이 성립된다. 여기서 ω 는 표본 점으로 $\omega \in \Omega$ 이다. 그러면 복호된 값 z_i 은 다음과 같다.

$$z_i := y_i + \hat{x}_i \quad (12)$$

따라서 식 (11)의 평균 왜곡은 다음과 같이 다시 쓸 수 있다.

$$E\left\{\frac{1}{Lm} \sum_{i=1}^{Lm} \min_{y \in C} (X_i - Z_i)^2\right\} \quad (13)$$

이 식에서 Z_i 은 복호된 신호의 불규칙 변수이다.

DPCM의 한 예로, 분산 σ_X^2 를 가지는, 동일한 분포를 가지는 불규칙 변수의 열을 생각해 보자. 또한 DPCM의 예측기로, 1차 선형 예측인 $a_1 x_{i-1}$ 를 x_i

의 예측으로 사용하자. 여기서 a_1 은 예측 계수이다. 그러면 다음과 같은 평균 오차를 최소화시키는 예측 계수 a_1 은 $a_1 = \rho$ 이다.

$$E\left\{\frac{1}{Lm} \sum_{i=1}^{Lm} (X_i - a_1 X_{i-1})^2\right\} \quad (14)$$

이 식에서 ρ 는 불규칙 변수의 상관 계수이다. 또 한 이때의 오차 신호 $X_i - a_1 X_{i-1}$ 의 분산은 다음과 같다.

$$\text{Var}(X_i - a_1 X_{i-1}) = (1 - \rho^2) \sigma_X^2 \quad (15)$$

그런데 DPCM 장치에서 부호기와 복호기는 서로 복호된 같은 신호를 따라가며 부호화 과정을 수행해야 하므로 예측기는 입력되는 신호를 그대로 예측 계산을 위해 사용하지 못하고 복호된 신호 z_{i-1}, z_{i-2}, \dots 를 사용해야한다. 즉 앞의 예에서는 다음과 같은 예측기를 사용해야 한다.

$$\hat{x}_i = a_1 z_{i-1} \quad (16)$$

만일 양자화 왜곡이 매우 작은 경우는 식 (16)을 $a_1 x_{i-1}$ 로 근사시킬 수 있다. (예를 들어 전송률이 2 bpp 이상인 경우 이러한 근사화를 할 수 있다^[3].) 그러므로 오차 신호 $\delta_i (\approx X_i - a_1 X_{i-1})$ 은 식 (15)의 분산을 가진다. 식 (15)에서 $(1 - \rho^2)$ 항은 만일 $|\rho| < 1$ 이면 항상 1보다 작다. 그러므로 이웃한 불규칙 변수간에 상관성이 존재하면 DPCM을 사용하여 이득을 얻을 수 있다. Markov-1 신호에 대해 예를 들면, 양자화 왜곡은 입력 신호의 분산에 비례하므로 DPCM을 통해서 $-10 \log(1 - \rho^2)$ dB 만큼 왜곡을 줄일 수 있다. 상관 계수가 $\rho = 0.9$ 인 Gaussian Markov-1 신호에 대한 실험 결과는 $n = 16$ 에서 7.15 dB 이었는데 이는 이론 값 7.21 dB와 거의 비슷하다. 참고로 오차 신호 $x_i - a_1 x_{i-1}$ 은 분산이 $(1 - \rho^2) \sigma_X^2$ 인 Gaussian i.i.d. 신호로, 식 (11)에서 사용되는 부호책은 오차 신호 $x_i - a_1 x_{i-1}$ 에 최적인 Lloyd-Max 부호책이다.

이제 제안할 DSAPQ를 DPCM의 수식을 바탕으로 하여 나타내보자. 이전 장의 SAPQ에서 사용한 index i 와 새로운 index h 를 도입하여 오차 신호 $\delta_i(h)$ 를 다음과 같이 정의하자.

$$\delta_i(h) := \begin{cases} \delta_{m(h-1)+i-1}, \\ i = 1, \dots, m, \quad h = 1, \dots, L \end{cases} \quad (17)$$

그러면 식 (15)의 DPCM 평균 왜곡은 다음과 같이 다시 쓸 수 있다.

$$E\left\{\frac{1}{L} \sum_{n=1}^L \frac{1}{m} \sum_{i=1}^m \min_{y \in C} (\delta_i(h) - y)^2\right\} \quad (18)$$

이 식은 식 (3)의 PQ와 같은 형태이다. 부호책 크기 n' 에 $N=2^n$ 개의 부호책 C_1, \dots, C_N ($\in A_{n'}$)을 DSAPQ의 양자화 부분인 SAPQ에 사용하면 이 때 DSAPQ의 평균 왜곡은 다음과 같다.

$$E\left\{\frac{1}{L} \sum_{n=1}^L \min_{j \in \{1, \dots, M\}} \frac{1}{m} \sum_{i=1}^m \min_{y \in C_j} (\delta_i(h) - y)^2\right\} \quad (19)$$

이 식에서 DSAPQ의 전송률은 다음과 같다.

$$R = \log_2 n' + \frac{\eta}{m} \quad (20)$$

제안된 DSAPQ의 블록 선도를 그림 1과 2에 도시하였다. 그림 1은 SAPQ 부분이며 DPCM 부분인 DQ,는 그림 2에 도시하였다. 그림 1의 SAPQ에서 가능한 부호책 선택의 수는 $N=2^n$ 가지이다. DQ_j는 일반적인 DPCM 부호기의 구조를 가지고 있는데 부호책 C_j로 부호화를 수행하며 m개의 왜곡을 더할 수 있는 덧셈기가 추가되어 있다. 그림 1의 SAPQ 부분은 DQ_j 중에서 가장 왜곡이 작은 j를 선택해서 출력하게 된다.




그림 1. DSAPQ의 블록선도 (SAPQ 부분).




그림 2. DSAPQ의 블록선도 (DQj: j번째 DPCM part).

IV. 모의 실험 결과 및 토론

본 장에서는 제안한 DSAPQ를 영상 데이터에 적용하기 전에 DSAPQ의 SAPQ 부호책을 합성 데이터를 사용하여 설계하고 그 성능을 보았다. 다음에 이렇게 설계된 SAPQ의 부호책을 영상 데이터를 위한 DSAPQ에 사용하였다.

먼저 합성 데이터를 TS(training sequence)로 사용하여 참고 문헌 [8]의 제 IV장에서 제안된 군집화 알고리즘으로 SAPQ의 부호책을 설계해 보자. 주어진 부호책 크기 n' 와 부가 bit η 에 대해서 표본의 크기 m 을 바꾸어 가면서 여러 SAPQ 부호책을 설계할 수 있다. 그러나 실험에 의하면 [8]에서 제안한 군집화 알고리즘과 분열 기법으로 설계된 SAPQ 부호책은 m 에 관계없이 거의 일정하다는 것을 알았다. 다시 말하면 어떠한 m 에 대해 설계된 부호책을 다른 표본의 크기 m' ($\neq m$)를 가지는 SAPQ의 부호책으로 사용할 수 있다. 이를 뒷받침하는 실험 결과를 표 1에 정리하였다. 표 1의 실험에서는 크기가 260,000 정도인 TS를 사용해서 두 가지 SAPQ 부호책을 각각 $m=4$ 일 때와 $m=16$ 일 때 설계하였다. 이들을 다시 표본 주기 $m=4$ 와 16을 가지는 SAPQ들에 사용하여 TS와 validating sequence를 양자화 하였다. 표에서 보는 바와 같이 설계된 두 개의 부호책은 같은 성능을 나타냄을 알 수 있다. 그러나 부호책 설계 시 계산 양을 줄이기 위해서는 주어진 TS에 대해 m 을 크게 하는 것이 유리하다. 참고로 본 실험의 군집화 알고리즘에서는 주어진 소스에 충실한 부호책 설계를 위하여 TS의 크기를 설계하려는 SAPQ 부호 단어 개수의 5,000배 이상으로 하였으며^[6], 초기 부호책을 위한 분할 방법에서는 분할 상수를 $\gamma=0.001$ 로 사용하였다.

표 1. 여러 표본의 크기 m에 대해 설계된 SAPQ의 왜곡 (dB).

전송률 (b/point)		설계된 SAPQ 부호책		
		$m = 4$	$m = 16$	
4.25 ($m = 4$)	TS	-22.61	-22.58	≈ -22.6
	VS	-22.62	-22.62	
4.0625 ($m = 16$)	TS	-21.41	-21.43	≈ -21.4
	VS	-21.42	-21.44	

DSAPQ의 SAPQ 부호책은 오차 신호 $\delta_i(h) = X_i - \hat{X}_i$ 에 최적이어야 한다. 그러나 이 신호

는 양자화 왜곡을 포함하고 있으므로 그 성격을 정확히 규명하는 것은 쉽지가 않다. 따라서, 예를 들어 오차 신호가 $\delta_i(k) = X_i - \rho Z_{i-1}$ 이라 하면 일반적으로 다음과 같은 근사 식을 도입한다.

$$\delta_i(k) \approx X_i - \rho X_{i-1} \quad (21)$$

만일 입력이 Gaussian Markov-1 신호이면 오차 신호 $\delta_i(k)$ 는 근사적으로 분산이 $(1-\rho^2)\sigma_x^2$ 인 Gaussian i.i.d. 신호가 된다. 그러므로 Gaussian Markov-1 신호를 위해 DSAPQ를 설계하는 것은 분산이 $(1-\rho^2)\sigma_x^2$ 인 Gaussian i.i.d 신호에 SAPQ를 설계하는 것이다. 이러한 원리를 기초로 하여 먼저 어떠한 신호에 적합하게 SAPQ 부호책을 설계하고 이를 적절하게 분산에 따라 scaling하여 DSAPQ의 부호책으로 사용하였다




그림 3. SAPQ와 PQ의 왜곡(dB) (분산 1의 Gaussian i.i.d., $n' = 16$).




그림 4. DSAPQ와 DPCM의 왜곡(dB) (분산 1의 Gaussian Markov-1, $\rho = 0.9$, 식 (21)의 1차 예측기)

그림 3에는 분산이 1인 Gaussian i.i.d. 소스에 대해 설계된 SAPQ의 성능을 나타내고 있다. 이 그림의 PQ에서 사용된 양자기는 Lloyd-Max 양자기이다^[7]. $m=16$ 그리고 $\eta=4$ 일 때의 SAPQ의 성능은 PQ에 비하여 약 1.8 dB의 이득을 보이고 있다. 이

렇게 설계된 부호책을 식 (15)의 분산을 사용, 그 비율대로 부호책을 바꾸어 Gaussian Markov-1 신호의 양자화를 위한 DSAPQ에 사용하였다. 이때의 결과를 그림 4에 도시하였다. PQ와 SAPQ 간에 얻을 수 있는 이득을 DPCM과 DSAPQ 간에도 거의 비슷하게 얻을 수 있음을 알 수 있었다(특히 $m=16$ 과 $m=24$ 의 경우에서). 같은 방법으로 Laplacian Markov-1 신호에 대해서도 같은 실험을 하여 그 결과를 그림 5와 6에 도시하였다. 이 경우 $m=16$ 과 $\eta=4$ 에서 약 2.9 dB의 이득을 얻었음을 알 수 있다.




그림 5. SAPQ와 PQ의 왜곡(dB) (분산 1의 Laplacian i.i.d., $n' = 16$).




그림 6. DSAPQ와 DPCM의 왜곡(dB) (분산 1의 Laplacian Markov-1, $\rho = 0.9$, $n' = 16$).

이제 실제 영상 데이터를 사용하여 양자화를 해보자. 먼저 제안한 DSAPQ를 사용해서 얻을 수 있는 양자화 왜곡 측면에서의 이득과 복호된 영상의 화질을 비교하기 위해 2차원의 영상 데이터를 그림 7과 같이 지그재그로 주사하여 1차원 신호로 만들었다. 그리고 다음과 같은 1차 예측기를 사용하였다.

$$\hat{x}_i = z_{i-1} \quad (22)$$

참고로 불규칙 변수 $X_i - X_{i-1}$ 의 분산은

$Var\{X_l - X_{l-1}\} = 2(1-\rho)\sigma_x^2$ 이므로 오차 신호는 다음과 같은 분산을 근사적으로 얻을 수 있다.

$$Var\{X_l - Z_{l-1}\} \approx 2(1-\rho)\sigma_x^2 \quad (23)$$

표 2에는 두 종류의 영상 데이터의 오차 신호에 대한 분산들을 구하여 정리하였다. (이제부터 소개되는 표들에서 분산 σ_s^2 은 양자화 왜곡을 고려하지 않은 것들이다.) 표 2에서 보논바와 같이 원 신호의 분산 σ_x^2 보다도 오차 신호의 분산이 작음을 알 수 있다.




그림 7. 2차원 영상 신호의 지그재그 주사를 통한 1차원 신호화.

표 2. 영상 데이터의 분산과 상관 계수.

Image	ρ	평균	σ_x^2	$X_l - \rho X_{l-1}$		$X_l - X_{l-1}$	
				$(1-\rho)\sigma_x^2$	σ_s^2	$2(1-\rho)\sigma_x^2$	σ_s^2
LENA	0.9719	124.1	2290	126.8	126.8	128.6	128.6
BRIDGE	0.9403	113.8	2996	346.9	347.0	357.6	357.6

이제 여러 표본의 크기에 따른 DPCM과 DSAPQ의 PSNR(peak signal to noise ratio) 결과를 구하여 표 3에서 비교하였다. PSNR에서 입력 신호의 분산은 255^2 이다. 표 3에서 영상 신호의 오차 신호를 양자화 하기 위하여 그림 3과 5에서 설계된 SAPQ 부호책을 각각 사용하였다. 여기서 SAPQ 부호책은 표준 편차 σ_s 로 영상에 따라 scaling하였다. 이 표를 통해서 오차 신호는 Laplacian pdf에 보다 가까운 것을 알 수 있으며 DPCM에 비하여 2~3 dB 정도의 이득이 있음을 알 수 있다. 그런데 표 3의 결과를 보면 BRIDGE의 DPCM 이나 DSAPQ의 결과가 LENA 보다 좋음을 알 수 있다. 이는 표 2의 오차 신호의 분산을 볼 때 LENA가

더 좋은 결과를 나타내야 한다는 사실과 어긋난다. 그러나 이러한 실험 결과는 pdf 형태의 불일치에 의한 것으로^[3], scale factor를 바꾸어 줌으로 어느 정도 성능을 개선시킬 수 있다. 표 4에는 scale factor를 바꾸어서 얻어낸 결과를 정리하였다.

표 3. DPCM과 DSAPQ의 PSNR(dB) (식 (21)의 1차 예측기, scale factor: 표준 편차 σ_0).

Image	Quantizer	DPCM (n = 19)	DSAPQ(n' = 16)			
			$\eta=1$ m=4	$\eta=2$ m=8	$\eta=3$ m=12	$\eta=4$ m=16
LENA	Laplacian	40.5	40.6	42.0	42.8	44.0
	Gaussian	33.4	34.1	34.8	35.3	36.4
BRIDGE	Laplacian	41.8	42.4	43.3	43.4	44.0
	Gaussian	37.1	37.8	38.4	38.7	39.7

표 4. DPCM과 DSAPQ의 PSNR(dB) (식 (21)의 1차 예측기, Laplacian 부호책).

Image	Scale Factor	σ_s	DPCM (n = 19)	DSAPQ (n' = 16)			
				$\eta=1$ m=4	$\eta=2$ m=8	$\eta=3$ m=12	$\eta=4$ m=16
LENA	18	11.34	44.72	44.72	45.72	46.31	46.86
BRIDGE	21	18.91	41.89	42.59	43.44	43.66	44.20

그림 8~11에는 DPCM 부호화의 slope overload 왜곡^[4]을 관찰하기 위해 표 3의 몇 가지 결과의 일부를 나타내었다. 이 그림에서 DSAPQ의 부호책은 Laplacian pdf에 대해 설계된 것이다. 그림 2를 보면 “모자” 부근에서 지그재그 형태의 왜곡을 발견할 수 있다. 그러나 그림 3과 4의 DSAPQ의 결과를 보면 이러한 왜곡이 감소되는 것을 알 수 있다.

다음 실험은 표 3과 4의 실험에서 1차 예측기 대신에 2차원의 2차 예측기를 사용하여 수행한 것으로 표 5와 6에 각각 그 결과를 정리하였다. 2차 예측기는 그림 12에 도시한 것과 같이 현재의 화소 X의 예측은 좌측의 화소 A와 위쪽의 화소 B의 평균인 $X = (A+B)/2$ 이다. 표 5와 6의 결과를 보면 1차 예측기를 사용한 경우보다 약 2~3 dB 정도 더 좋은 성능을 DPCM과 DSAPQ에서 동일하게 얻을 수 있음을 알 수 있다. 그림 13과 14에는 여러 부호책의 크기 n'에 대해 실험한 결과로 DSAPQ가 DPCM보다 여러 부호책의 크기 n'에 대해 비슷한 이득을 얻음을 관찰할 수 있다.




그림 8. 원 영상 LENA (150x150, 8 b/pixel).



그림 9. $n = 19$ 일 때의 DPCM 결과 ($R \approx 4.25$ b/pixel, 40.50 dB).



그림 10. $n' = 16, \eta = 2, m = 8$ 일 때의 DSAPQ 결과 ($R=4.25$ b/pixel, 41.95 dB).



그림 11. $n' = 16, \eta = 4, m = 16$ 일 때의 DSAPQ 결과 ($R = 4.25$ b/pixel, 43.95 dB).




그림 12. 2차원 영상 데이터를 위한 2차 예측기: $X=(A+B)/2$.

표 5. DPCM과 DSAPQ의 왜곡(dB)(그림 12의 2차 예측기, Laplacian 부호책, scale factor: σ_8).

Image	σ_8	DPCM ($n = 19$)	DSAPQ ($n' = 16$)			
			$\eta=1$ $m=4$	$\eta=2$ $m=8$	$\eta=3$ $m=12$	$\eta=4$ $m=16$
LENA	7.918	41.23	40.45	42.34	43.53	45.23
BRIDGE	15.71	43.72	44.60	45.11	45.44	45.70

표 6. DPCM과 DSAPQ의 왜곡(dB) (그림 12의 2차 예측기, Laplacian 부호책).

Image	Scale Factor	σ_8	DPCM ($n = 19$)	DSAPQ ($n' = 16$)			
				$\eta=1$ $m=4$	$\eta=2$ $m=8$	$\eta=3$ $m=12$	$\eta=4$ $m=16$
LENA	14	7.918	47.02	47.14	48.35	49.05	49.54
BRIDGE	16	15.71	43.71	44.60	45.11	45.44	45.73




그림 13. 여러 n' 에 대한 DPCM과 DSAPQ의 PSNR(dB) (LENA, 2차 예측기, scale factor: 14).




그림 14. 여러 n' 에 대한 DPCM과 DSAPQ의 PSNR(dB) (BRIDGE, 2차 예측기, scale factor: 16).

V. 결론


본 논문에서는 일종의 구조적 제한 벡터 양자기 (vector quantizer: VQ)인 표본 적응 프러덕트 양자기(sample-adaptive product quantizer: SAPQ)를 사용한 DPCM 부호기를 제안하였으며 합성 및 실제 영상 데이터에 적용하여 2~3 dB의 성능 향상을 얻었다. SAPQ는 스칼라 양자기(scalar quantizer: SQ)를 사용한 적응 양자기의 형태를 가지고 있어서 부호화 복잡도와 필요한 부호책의 크기는 SQ와 같이 매우 작으면서 VQ의 성능을 얻을 수 있다. 아울러 이러한 SQ의 구조 덕분에 기존의 스칼라 값을 예측하는 예측기들을 제안한 DPCM 부호기에서는 그대로 사용할 수가 있었다.

참고 문헌

- [1] L. R. Rabiner and R. W. Schafer, *Digital Processing of Speech Signals*. New Jersey: Prentice-Hall, 1978.
- [2] A. J. Viterbi and J. K. Omura, *Principles of Digital Communication and Coding*. McGraw Hill, 1979.
- [3] N. S. Jayant and P. Noll, *Digital Coding of Waveforms*. New Jersey: Prentice-Hall, 1984.
- [4] A. Gersho and R. M. Gray, *Vector Quantization and Signal Compression*. Boston: Kluwer Academic Publishers, 1992.
- [5] G. K. Wallace, "The JPEG still picture compression standard," *IEEE Trans. Consumer Electronics*, vol. 38, pp. 18-34, Feb. 1992.
- [6] D.S. Kim and N.B. Shroff, "Quantization based on a novel sample-adaptive product quantizer (SAPQ)," *IEEE Trans. Inform. Theory*, vol. IT-45, no. 7, pp.2306-2320, Nov. 1999.
- [7] 김동식, 박섭형 "표본 적응 프러덕트 양자화와 설계 알고리즘," *한국통신학회 논문지*, 게재 예정, 제 24권, 제 12호, 12. 1999

김 동 식(Dong Sik Kim)

정회원



1986년 2월 : 서울대학교 제어
계측 공학과 학사.
1988년 2월 : 서울대학교 제어
계측 공학과 석사.
1994년 2월 : 서울대학교 제어
계측 공학과 박사.

1986년부터~현재 : (주)오토만의 이사.
1996년 10월~1998년 5월 : 미국 인디애나주 Purdue 대학의 연구원
1998년 6월~1999년 6월 : 미국 인디애나주 Purdue 대학, School of Electrical and Computer Engineering의 연구 조교수
1999년 8월~현재 : 한림대학교 전자공학부 조교수
<주관심 분야> 부호 이론, 양자화 이론, 영상 처리, multimedia network, RF 회로 설계.

이 상 욱(Sang Uk Lee)

정회원

한국통신학회 논문지, 제21권, 제5호 참조