

## 研究

## 分光画像圧縮のための自己組織化ネットワークを用いた 2 段ベクトル量子化器

井上 卓・伊東 一良・一岡 芳樹

大阪大学工学部応用物理学科 〒565 吹田市山田丘 2-1

(1994 年 5 月 17 日受付, 1994 年 6 月 27 日受理)

### Two-Stage Vector Quantization for Compression of Multispectral Image Data Using Self-Organizing Network

Takashi INOUE, Kazuyoshi ITOH and Yoshiki ICHIOKA

Department of Applied Physics, Faculty of Engineering, Osaka University,  
2-1, Yamadaoka, Suita 565

(Received May 17, 1994; Accepted June 27, 1994)

A data-compression algorithm for multispectral images is presented. This algorithm consists of a cascade of two vector-quantizers using a balanced-error self-organizing network (T. Inoue, K. Yamatani, K. Itoh and Y. Ichioka: *International Journal of Optical Computing*, **2** (1991) 385-396). The first vector quantizer encodes input vectors by using a codebook that has been obtained by learning. The second one adaptively changes its codebook and encodes the outputs of the first quantizer. While the dimensions of input vectors to these quantizer are small, the effective dimension of the vectors processed by the cascade is large. The time for data-compression by this cascade is 0.05 times as short as that by one vector quantizer based on the self-organizing network.

#### 1. はじめに

多数のスペクトルバンドの画像から構成される分光画像 (multispectral image) は, リモートセンシングと天文学においてはかなり以前から利用されている<sup>1-3)</sup>. 最近では, 走査型トンネル分光法<sup>4)</sup> や magnetic resonance imaging (MRI)<sup>5)</sup> などのように, 光以外の波動や粒子をプローブとして得られる分光画像も利用されており, 分光画像を利用する分野はますます広がりを見せている. このような分光画像を計測するシステムは, 近年のめざましい技術の発展, 特に検出器とコンピュータの高性能化によって, より高分解能になりつつある. しかし, このような高分解能システムによって計測された分光画像は膨大な量のデータであるため, 伝送や保存における大きな負担となっており, 効率の良いデータ圧縮技術が求められている.

ベクトル量子化は, 効率の良いデータ圧縮法として知られている<sup>6)</sup>. ベクトル量子化は, 入力ベクトルを有限個の符号ベクトルと比較し, 最も量子化歪が小さくなる符号ベクトルを選択する. 各符号ベクトルには番号を割り当てておき, この番号のみを出力することによりデータ圧縮を行う. 量子化歪として, 通常は 2 乗ユークリッド距離  $d(\mathbf{x}, \mathbf{y}) = \|\mathbf{x} - \mathbf{y}\|^2$  を用いる. 符号ベクトルの集合を符号表と呼ぶ. ベクトル量子化は, 入力ベクトルの次元数を大きくとることにより, 圧縮の効率が高くなることが知られている. しかし一方で, 次元数の増大に伴って符号表の設計が困難となる. そのため, 低次元で設計した複数の符号表から, 直積を用いて実効的に高い次元の符号表を構成する手法<sup>7)</sup> などが提案されている. しかし, 筆者らの知る限りでは, ベクトル量子化を直列多段階に行うことにより, 実効的に次元数を大きくしようとする試みはなされていない (ベクトル量子化器を直列

多段階に接続する手法がすでにいくつか提案されている<sup>8,9)</sup>が、これらは前段のベクトル量子化による誤差を後段で符号化することにより圧縮誤差を低減することを目的としており、扱うベクトルの次元数を大きくしようとするものではない。

符号表の設計には、さまざまな方法が提案されている。その中でも自己組織化ニューラルネットワークを用いる方法は効率の良い符号表を設計することが可能であり注目されている<sup>10)</sup>。われわれは、分光画像のデータ圧縮を目的として、均等化誤差自己組織化ネットワーク (balanced-error self-organizing network; BESON) を提案した<sup>11)</sup>。われわれは、この BESON を用いて実際の分光画像のデータ圧縮を行い、その有効性を確認した。しかし、1個のベクトル量子化器を用いて圧縮を行ったため、BESON に入力するベクトルの次元数が大きくなり、符号表の設計に膨大な時間を必要とした。

本論文では、ベクトル量子化器 (vector quantizer: VQ) を直列2段に接続したデータ圧縮アルゴリズムを提案する。第1段目の VQ は、小さな次元数に分割されたベクトルを入力とし、固定の符号表を用いて圧縮を行う。第2段では、1段目の VQ の出力を複数個まとめたベクトルを入力とし、BESON によって符号表を適応的に設計し圧縮を行う。それぞれの VQ に入力するベクトルの次元数が小さいため、符号表の設計が容易になり、また高速な処理が可能である。第2章では、BESON を簡単に説明する。第3章で、提案するアルゴリズムを説明する。第4章では、実際の分光画像データを圧縮した実験結果を示す。最後に第5章でまとめを述べる。

## 2. BESON

BESON<sup>11)</sup> の構成を Fig. 1 に示す。BESON は、入力層と出力層の2層からなる1種の Kohonen タイプ<sup>12)</sup> のネットワークである。出力層では、各ユニットはリング上に配置され、片方の隣りのユニットとのみ接続されている。まず、出力ユニットの発火の様子を説明する。入力ユニットには、入力ベクトル  $\mathbf{x}$  が入力され、すべての出力ユニットに伝えられる。各出力ユニットは、VQ の符号ベクトル  $\mathbf{y}$  を保持する。ベクトル  $\mathbf{x}$  が入力ユニットに入力されると、各出力ユニットは量子化歪  $d(\mathbf{x}, \mathbf{y})$  を計算し、これが最も小さくなる出力ユニットのみが発火する。発火した出力ユニットの番号が、ベクトル量子化の出力に対応する。

BESON の自己組織化は、入力 (トレーニング) ベク




Fig. 1 Balanced-error self-organizing network.

トルを多数集めたトレーニングセットを用いて行う。各ユニットは、符号ベクトル  $\mathbf{y}$  と、これを発火させるトレーニングベクトルの部分集合  $P$  の重心  $\mathbf{G}$  と、各ユニットで生じる高量化歪  $\varepsilon = \sum_{\mathbf{x}_i \in P} d(\mathbf{x}_i, \mathbf{y})$  の三つの情報を記憶する。トレーニングベクトルをすべてネットワークに入力したあと、各ユニットの符号ベクトル  $\mathbf{y}$  を、次の式のように変化させていく。

$$\begin{aligned} \mathbf{y}_j(t+1) = & \mathbf{y}_j(t) + \alpha(t)[\mathbf{G}_j(t) - \mathbf{y}_j(t)] \\ & + \beta(t)[\mathbf{G}_{j+1}(t) - \mathbf{y}_j(t)] \\ & + \gamma g(\delta\varepsilon_j)[\mathbf{y}_{j+1}(t) - \mathbf{y}_j(t)], \end{aligned} \quad (1)$$

ここで、 $\alpha(t)$ ,  $\beta(t)$  は単調減少関数、 $\delta\varepsilon_j = [\varepsilon_{j+1}(t) - \varepsilon_j(t)]/\varepsilon_j(t)$ ,  $g(\cdot)$  は、 $-1$  から  $1$  までの値をとるシグモイド関数である。また、 $\gamma$  は定数であり、 $j$  は  $1$  から  $N$  までの整数でユニット番号を表している。このプロセスを反復することにより自己組織化が行われる。トレーニングセットに対する量子化歪の総和の変化率があらかじめ設定しておいた値より小さくなるまで反復を行う。

(1) 式の右辺第2, 3項は、1次元の神経場を持つ Kohonen のネットワーク<sup>12)</sup>において、BESON と同様のネットワークポロジを採用したときの自己組織化の働きを近似したものである。この項により、ネットワーク上で隣り合うユニットの符号ベクトルは、入力ベクトル空間上でも隣り合うように自己組織化される。第4項は、各ユニットの  $\varepsilon$  を均等な大きさにするように働く。自己組織化の初期段階では、 $\gamma$  に対して  $\beta(t)$  の値が大きい値を保ち、次第に減少してゆくように設定する。また、 $\alpha(t)$  は、 $\gamma$  と  $\beta(t)$  に対し、常に大きな値を保つようにする。このことにより、BESON は、初期段階では Kohonen 型の自己組織化を行い、しだいに第4項による誤差の調整を主に行うようになっていく。

ノイマン型コンピュータで BESON を実現しようとすると、入力ベクトルと符号ベクトルとの間の量子化歪の計算が、自己組織化に要する処理時間の大部分を占め

る。量子化歪の計算には、減算、乗算、加算の三つの処理が含まれ、これらは1回の反復ではほぼ同数回必要とされる。いま、トレーニングベクトルの数を  $R$ 、BESONのユニット数(符号ベクトルの数)を  $N$ 、入力ベクトルの次元数を  $K$  とする。反復回数を  $T$  とすると、自己組織化に要する乗算の回数  $C$  は、

$$C = RNKT \quad (2)$$

で表される。これは、ノイマン型コンピュータを用いたときの処理時間の目安となる。この反復処理は、通常数百から数千回で収束する。また、BESONの反復回数は、符号ベクトルの次元数が増えるに従い、急速に増加する傾向がある。

### 3. 2段ベクトル量子化アルゴリズム

提案する2段ベクトル量子化アルゴリズム(two-stage vector quantizer; TSVQ)を Fig. 2 に示す。分光画像はさまざまな離散的にサンプリングされたパワースペクトル密度関数の集まりと考えることができる。パワースペクトル密度関数を小さなブロックに分割し、それぞれのブロック内の密度関数の値から、それらのブロック内での平均値を差し引いたものを要素パターンとする(前処理)。この要素パターンを、1段目のベクトル量子化器(VQ1)に入力する。さらに、ひとつのパワースペクトル密度関数に関するVQ1の出力値をまとめて1個のベクトルとして取り扱い、2段目のベクトル量子化

(VQ2)を行う。VQ1では、固定の符号表を読み出し専用メモリ(read only memory; ROM)に保持しておき、これを用いて圧縮を行う。VQ2では、BESONを用いて分光画像データに応じて符号表を作成し、圧縮を行う。このとき、BESONの自己組織化のためのトレーニングセットとして、圧縮対象の分光画像データに関するVQ1の出力のすべてを用いる。VQ1の固定の符号表は、あらかじめBESONを用いて作成しておく。圧縮データは、スカラー量子化された各ブロックの平均値、VQ2の符号表、およびVQ2の出力から構成される。

前処理は、VQ1における符号ベクトルの数を少なくするためにやっている。これは、符号ベクトルの数が大きいときは、符号表の設計に長い時間が必要になるためである。したがって、十分な個数の符号ベクトルを用いることが可能ならば、前処理の必要はない。

TSVQのそれぞれのVQの動きについて考える。いま、白色光で照明された拡散反射物体を測定した分光画像データを圧縮することを考えよう。この場合、要素パターンの長さに比べて分光画像のスペクトル方向の分解能が十分に高ければ、要素パターンは緩やかな曲線と考えることができる。このような要素パターンを用いてBESONによって設計された符号ベクトルは、緩やかな曲線パターンを表すようになる。したがって、VQ1ではパワースペクトル密度関数を複数の緩やかな曲線パターンで近似する処理を行っていることになる。一つのパワースペクトル密度関数はさまざまな曲線パターンの組み合わせで表現されることになり、この組み合わせをVQ2におけるBESONで学習しているのである。したがって、緩やかに変化するスペクトル密度関数で構成されている分光画像データに対しては、VQ2でのBESONの適応性だけで対応できるため、同一のROMを用いればよい。また、スペクトルに急激な変化が含まれる場合には、ROMを切り替えて対応することが可能である。このようにTSVQでは、何種類かのROMを用意しておき、これらを適切に選択することにより、さまざまな分光画像データを効率よく圧縮することが期待できる。

TSVQでは、それぞれの量子化器で量子化誤差が生じる。特に、VQ2における量子化誤差は、再生される要素パターンの組み合わせを変えることになる。そのため、もしVQ1の符号表中で近接した番号を割り当てられた符号ベクトルが大きく異なっていたら、TSVQ全体の量子化誤差は大きなものとなる。しかし、BESONは、類似した符号ベクトルに対しては近接した番号を割

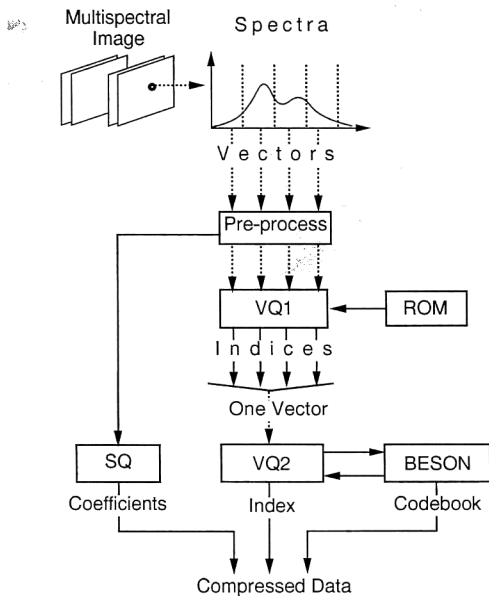


Fig. 2 Two-stage VQ algorithm using BESON.

り当てるように学習を行うために、VQ2における量子化誤差は小さいものと考えられる。

提案するアルゴリズムとVQを1段で用いる圧縮アルゴリズム(one-stage vector quantization; OSVQ)<sup>11)</sup>の処理時間を比較する。OSVQでは、パワースペクトル密度関数を分割せずに1個のベクトルとして、ベクトル量子化器に入力する(Fig. 3)。また、個々の分光画像データに応じてBESONを用いて符号表を作成し、データ圧縮を行う。圧縮処理に要する時間は、どちらのアルゴリズムにおいてもBESONの自己組織化に要する時間が大部分を占めている。そのため、圧縮処理時間はBESONの自己組織化に要する時間を見積もることにより求めることができる。分光画像の空間分解点数を $K$ とし、スペクトル方向の分解点数を $H$ とする。このとき、TSVQでは、要素パターンに含まれる画素数 $M$ がVQ1への入力ベクトルの次元数となる。また、VQ2の入力ベクトルの次元数は、 $H/M$ で表される。したがってTSVQでは、BESONに入力するベクトルの次元数は $H/M$ であり、トレーニングセットに含まれる入力ベクトルの個数は分光画像の空間分解点数 $K$ に等しい。一方、BESONに入力するベクトルの次元数は、分光画像のスペクトル方向の分解点数 $H$ に等しく、また、トレーニングベクトルの数は $K$ で与えられる。TSVQの第2段のベクトル量子化器の符号ベクトルの数を $N_t$ とし、OSVQのベクトル量子化の符号ベクトルの数を $N_o$ とする。また、OSVQとTSVQにおける自己組織化の収束までの反復回数をそれぞれ $T_o$ 、 $T_t$ とする。このとき、OSVQとTSVQにおけるBESONの自己組織化の処理時間の比は、(2)式から、

$$MN_o T_o / (N_t T_t) \quad (3)$$

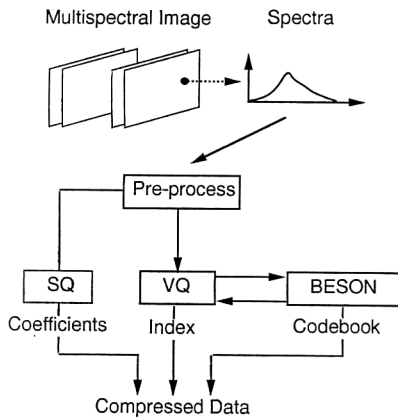


Fig. 3 Compression algorithm of one-stage VQ by sing BESON.

となる。

#### 4. 実験結果

TSVQを用いて、分光画像をデータ圧縮した結果をFig. 4に示す。数種類の花を像面フーリエ分光映像法<sup>3)</sup>によって計測したデータを用いた。VQ1用の符号表の設計および圧縮処理はHP9000 model 720 (Hewlett-Packard)を用いて行った。分光画像は、空間分解点数が $88 \times 88$ 点、スペクトル分解点数が48点のデータ



Fig. 4 (a) Cross sections of the original multispectral image that are perpendicular to the spectral axis. (b) Cross sections of the reconstructed multispectral image after the data compression by TSVQ. The number in each cross section denotes the wavelength.

**Table 1** Results of compression of multispectral images.

Algorithm	Compression rate [%]	Compression error [%]	Processing time [h]	Number of iterations
TSVQ	0.07	0.72	2.6	280
OSVQ	0.1	0.84	52.3	3000

で、一つの画素が 16 ビットで表現されている。一つのパワースペクトル密度関数を、6 個の 8 次元の構成ベクトルに分割した。VQ1 では 1024 個の符号ベクトルを、VQ2 では 1024 個の符号ベクトルを用いた。これらのパラメータは、256 個のユニットからなる BESON を用いた OSVQ と比較するために圧縮率および圧縮誤差が同程度になるように定めた。TSVQ と OSVQ の比較を **Table 1** に示す。圧縮誤差として、原画像との差の 2 乗平均平方根と分光画像の peak-to-peak 値との比を用いた。また、収束回数は自己組織化の反復回数を示している。256 個の符号ベクトルを用いた 1 段の VQ のみによる圧縮の結果と比較すると、圧縮処理が約 20 倍速くなっていることがわかる。(3)式に実験の数値を代入すると、TSVQ が 21.4 倍速くなることになり、実験結果とはほぼ一致する。

## 5. ま と め

BESON を用いた VQ を直列 2 段に接続したデータ圧縮アルゴリズムを提案した。このアルゴリズムでは、自己組織化ネットワークに入力するベクトルの次元数を小さくすることができるため、符号表の設計が容易であり、アルゴリズム全体で処理されるベクトルの次元が実効的に高いため、圧縮効率が高い。また、実際の分光画像データを用いた実験により、VQ を 1 段で用いるアルゴリズムに比べて、本アルゴリズムは約 20 倍高速に圧縮できることを示した。本アルゴリズムでは、1 段目の VQ での符号ベクトルの数を大きく取ることにより、圧縮誤差をより小さくすることが可能である。

今後の課題として、ベクトル量子化器の接続段数を最適化することが残されている。また、空間相関を利用して圧縮を行うような量子化器を付加することによって、

圧縮効率をさらに高める方法の検討が残されている。

## 文 献

- 1) 例えば, *Imaging Spectroscopy II, Proc. SPIE 834*, ed. Gregg Vane (1987).
- 2) G.H. Gao and Z. Lin: "Acoust-optic supermultispectral imaging," *Appl. Opt.*, **32** (1993) 3081-3086.
- 3) T. Inoue, K. Itoh and Y. Ichioka: "Fourier-transform spectral imaging near the image plane," *Opt. Lett.*, **16** (1991) 934-936.
- 4) R.J. Hamers, R.M. Trop and J.E. Demuth: "Surface electronic structure of Si(111)-(7×7) resolved in real space," *Phys. Rev. Lett.*, **56** (1986) 1972-1975.
- 5) J. P. Hornak and L. M. Fletcher: "Multispectral image segmentation in magnetic resonance imaging," *Digital Image Processing Methods*, ed. Edward R. Dougherty (Marcel Dekker, Inc., New York, 1994).
- 6) N.M. Nasrabadi and R.A. King: "Image coding using vector quantization: a review," *IEEE Trans. Commun.*, **COM-36** (1988) 957-971.
- 7) M.J. Sabin and R.M. Gray: "Product code vector quantizers for waveform and voice coding," *IEEE Trans. Acoust., Speech, Signal Process.*, **ASSP-32** (1984) 474-488.
- 8) B. H. Juang and A. H. Gray, Jr.: "Multi stage vector quantization for speech coding," *Proc. IEEE ICASSP* (1982) pp. 597-600.
- 9) H. Sun and M. Goldberg: "Radiographic image sequence coding using two-stage adaptive vector quantization," *IEEE Trans. Med. Imag.*, **7** (1988) 118-126.
- 10) N.M. Nasrabadi and Y. Feng: "Vector quantization of images based upon the Kohonen self-organizing feature maps," *Proc. IEEE Int. Conf. Neural Networks*, vol. I (San Diego, CA, 1988) I-101-108.
- 11) T. Inoue, K. Yamatani, K. Itoh and Y. Ichioka: "A self-organizing network for vector quantization of spectral image," *Int. J. Opt. Comput.*, **2** (1991) 385-396.
- 12) T. Kohonen: *Self-Organization and Associative Memory* (Spring Verlag, Berlin, 1989).