

変化する入力データに対する学習の定常特性と過渡特性を改善する 新しいベクトル量子化アルゴリズム

芳澤 伸一[†] 道木 慎二[†] 大熊 繁[†]

A New VQ Algorithm for Time-Varying Data to Improve Both Steady-State Performance and Transient Performance

Shinichi YOSHIKAWA[†], Shinji DOKI[†], and Shigeru OKUMA[†]

あらまし 統計的分布が時間的に変化しない、固定した入力データに対するベクトル量子化では、定常特性が問題となる。それに対して、統計的分布が時間的に変化する入力データに対するベクトル量子化は、入力データに対する過渡特性と定常特性の間で生じるジレンマを解決する必要がある。そのため、入力データの統計的分布が時間的に変化する場合を陽に扱うベクトル量子化アルゴリズムはほとんど提案されていない。そこで本論文では、上記の問題を解決する新しいベクトル量子化アルゴリズム (DOCL-II) を提案する。DOCL-II は、筆者らが提案した DOCL を拡張したもので、アニーリング操作により良質な解を獲得するものであり、入力データの統計的分布の変化に対するアニーリング操作の開始時期と終了時期を自律的に決定することで、過渡特性と定常特性のジレンマを解決する。本論文では、提案するアルゴリズムである DOCL-II の特徴を述べ、シミュレーションにより従来のアルゴリズムとの比較を行い、本アルゴリズムの有効性を示す。

キーワード ベクトル量子化, アニーリング, 時変データ, 情報圧縮

1. ま え が き

ベクトル量子化 (VQ: Vector Quantization) は、画像や音声信号の情報圧縮などの分野で広く利用されている。ベクトル量子化は、入力データを参照ベクトルで近似することでデータ圧縮を行うものであり、入力データを参照ベクトルで近似するときの量子化誤差を最小化するように参照ベクトルが決定される。

従来の多くのベクトル量子化アルゴリズムでは、時間的に不変な統計分布に従う、入力データの集合 (以後、入力データセットと呼ぶ) を前提に、学習結果が局所解に陥らないための様々な工夫がなされている。

そのようなアルゴリズムとして、FSCL (Frequency Sensitive Competitive Learning) [4], [5], SOFM (Self-Organizing Feature Map) [6], [7], CSL (Competitive and Selective Learning) [4], DOCL (Diversity Oriented Competitive Learning) [1], [2]

などが提案されている^(注1)。

動画画像や音声などをオンラインでベクトル量子化する場合、入力データセットの統計的分布が時間的に変化していく。このような変化する入力データセットを対象としたベクトル量子化では、過渡特性と定常特性の間で生じるジレンマを解決する必要がある。すなわち、定常特性の改善を行うと過渡特性が悪化し、過渡特性の改善を行うと定常特性が悪化する。ここで、過渡特性とは、参照ベクトルの入力データセットの変化への追従性をいい、定常特性とは、入力データセットが固定したとき獲得された参照ベクトルの近似の度合をいう。そのため、入力データセットが変化する場合を陽に扱うベクトル量子化アルゴリズムはほとんど提案されていない。

入力データセットが変化する場合を陽に扱っている数少ないアルゴリズムとして、Optm (Optimal Adaptive K-Means Algorithm with Dynamic Adjustment of Learning Rate) [3] が提案されている。Optm では、入力データセットの変化に対する過渡特性と定常特性

[†]名古屋大学大学院工学研究科, 名古屋市
Nagoya Univ. Grad. School of Eng., Furo-cho, Chikusa-ku,
Nagoya-shi, 464-8603 Japan

(注1): 文献[2]ではDLRアルゴリズムとなっているが、本質的にDOCLアルゴリズムと同等である。

のジレンマを解決するために、参照ベクトルが1回の学習で移動する大きさ、すなわち学習率が、入力データセットの変化と学習の進行度合に応じて変化する。入力データセットが変化したとき、学習率を大きくして参照ベクトルの入力データセットの変化への追従性を上げ、逆に、入力データセットが固定されたとき、学習率を小さくして良質な参照ベクトルの配置を獲得する。しかし、このアルゴリズムでは局所解に陥るといった問題が残されている。

そこで本論文では、入力データセットが時間的に変化する場合を扱うベクトル量子化アルゴリズムとして、筆者らが提案した DOCL アルゴリズムを拡張した新しいベクトル量子化アルゴリズム (DOCL-II) を提案する。提案するアルゴリズムは、アニーリング操作を用い、局所解問題に対処し解の質の改善を図り、入力データセットの変化に対する過渡特性と定常特性のジレンマを解決するものである。

本論文では、ベクトル量子化について述べたのち DOCL アルゴリズムの概略を述べる。次に、変化する入力データセットを扱うため、DOCL を拡張した DOCL-II アルゴリズムを提案し、DOCL-II の特徴を Optm と比較して述べる。最後にシミュレーションにより従来のアルゴリズムとの比較を行い DOCL-II の有効性を示す。

2. ベクトル量子化

図1に示すように、入力空間 R^k を参照ベクトルの集合 $W = \{w_1, w_2, \dots, w_N \in R^k\}$ により決定する部分領域 S_1, S_2, \dots, S_N に分割する。そして、部分領域 S_i ($i = 1, 2, \dots, N$) の内部に存在する入力ベクトル $x \in R^k$ を参照ベクトル $w_i \in R^k$ で近似することで、ベクトル量子化を行う。

入力ベクトル x を参照ベクトル w_i で近似したときの誤差を $d(x, w_i) = \|x - w_i\|^2 = \sum_{j=1}^k (x_j - w_{ij})^2$




図1 ベクトル量子化
Fig. 1 Vector quantization.

で表す。そのとき、部分領域 S_i ($i = 1, 2, \dots, N$) の集合 S は以下の条件を満たす。

$$S_i = \{x : d(x, w_i) \leq d(x, w_j) \text{ for all } j \neq i\} \quad (1)$$

$$\cup_{i=1}^N S_i = R^k \text{ and } S_i \cap S_j = \phi \text{ for } i \neq j \quad (2)$$

ベクトル量子化の目的は、すべての入力ベクトル x を参照ベクトル w_i ($i = 1, 2, \dots, N$) で近似したときの誤差

$$D = \frac{1}{k} \sum_{i=1}^N \int_{S_i} d(x, w_i) p(x) dx = \frac{1}{k} \sum_{i=1}^N D_i \quad (3)$$

を最小とする参照ベクトルの集合 W を、学習により獲得することである。ここで、 $p(x)$ は入力ベクトルの確率分布関数を表し、 k は入力ベクトルの次元である。また D_i は部分領域 S_i における局所誤差である。

3. DOCL アルゴリズム

DOCL-II アルゴリズムを示すために、DOCL (Diversity Oriented Competitive Learning) アルゴリズム [1], [2] の概略を述べる。DOCL は、2 ステージの学習過程をもち、第1ステージでは、入力データセットの大域的構造を考慮して、アニーリング操作により大まかな参照ベクトルの配置を決定する。第2ステージでは、第1ステージで獲得された参照ベクトルをもとに、参照ベクトルの詳細な配置を決定する。各ステージでは、参照ベクトルが収束するまで以下の2ステップを繰り返して学習を行う。

Step 1: 入力ベクトル $x = (x_1, x_2, \dots, x_k) \in R^k$ と参照ベクトル $w_i = (w_{i1}, w_{i2}, \dots, w_{ik}) \in R^k$ を用いて $V(x, w_i)$ ($i = 1, 2, \dots, N$) を計算し、更新を行う参照ベクトル w_c ($1 \leq c \leq N$) を以下の式に従い決定する。

$$V(x, w_c) \geq V(x, w_i) \text{ for all } i \quad (4)$$

ここで、

$$V(x, w_i) = \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left(-\frac{1}{2}\left(\frac{d(x, w_i)}{\sigma_i^2}\right)\right) \quad (5)$$

$$\sigma_i = \begin{cases} \frac{1}{\alpha + \beta n_i} & (\exists_i n_i \leq n_{const}) \\ \sigma_{const} & (\forall_i n_i > n_{const}) \end{cases} \quad (6)$$

($i = 1, 2, \dots, N$)

ここで、 n_i は参照ベクトル w_i の学習回数であり、 α, β は σ_i と n_i の関係を決定するパラメータである。また、 n_{const} は学習ステージを決定するパラメータであり、 σ_{const} は第2ステージでの σ_i である。

Step 2: 参照ベクトル w_c を更新する。

$$w_c(n+1) = w_c(n) + \eta_c(n)[x(n) - w_c(n)] \quad (7)$$

ここで、 $\eta_c(n)$ は学習率を表し以下の式で与えられる。

$$\eta_c(n) = \begin{cases} \frac{1}{1+0.01n_c} & (\exists_i n_i \leq n_{const} \\ & : \text{1st stage}) \\ \frac{1}{1+0.01(\sum_{i=1}^N n_i)/N} & (\forall_i n_i > n_{const} \\ & : \text{2nd stage}) \end{cases} \quad (8)$$

入力データセットの分布が十分滑らかであり、参照ベクトルの数が十分多い場合に、各参照ベクトルに対する局所誤差をすべて等しくすれば、全体の誤差が最小になるという定理がある [3], [4]。この条件のもとでは、各参照ベクトルに対する局所誤差をすべて等しくすることは、各参照ベクトルの学習回数を等しくすることと近似的に等価であると考えられる。

DOCL では、学習回数の偏りを生じさせないために、アニーリング操作により参照ベクトルの配置を決定する。ここでのアニーリング操作とは、温度 T が高いときには、誤差 D を考慮しつつ積極的に参照ベクトルの学習回数をそろえるように学習を行い、温度 T が徐々に下がるにつれ、本来最小化したい誤差関数 D の最小化を行う学習に移行していく操作のことをいう。DOCLでは、温度 T は $\sigma_i (i = 1, 2, \dots, N)$ のばらつきにより決定される。 σ_i のばらつきが大きい、学習の初期では、温度が高く、学習が進み σ_i のばらつきが小さくなるにつれて温度が下がる仕組みとなっている。図2は、参照ベクトルの学習回数と学習を行う参照ベクトルの関係を示した図である。図2の上図において、参照ベクトル w_4 は、近傍に他の参照ベクトルが存在しないため、学習回数が多くなっている。その結果、参照ベクトル w_4 から少し離れた入力データ x に対して、参照ベクトル w_4 よりも入力データから離れた学習回数の少ない参照ベクトル w_3 で学習することになり、参照ベクトル w_3 は参照ベクトル w_4 の近傍に移動する。このことから、各参照ベクトルの学習回数が徐々に多くなるに従い、学習回数の多い参照

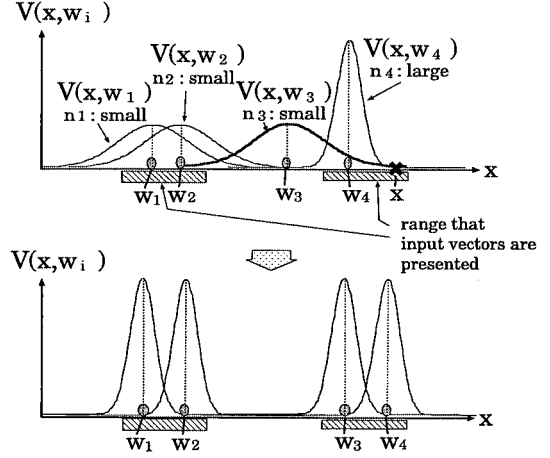


図2 アニーリング操作
Fig. 2 Annealing operation.

ベクトルの近傍に他の参照ベクトルが移動し、学習回数の偏りが徐々に小さくなる。その結果、良質な参照ベクトルの配置が獲得される。このように、DOCLでは局所解問題に対処している。DOCL-IIにおいても同様に局所解問題に対処する。Optmはアニーリング操作を行わないため、後に述べるように局所解に陥るという問題を有する。

4. 変化する入力データセットに対する新しいベクトル量子化アルゴリズム (DOCL-II)

DOCLアルゴリズムは、一つの入力データセットに対して、アニーリング操作を行うことにより、良質な解を獲得するものであった。そこで、DOCLアルゴリズムを拡張し、時間的に変化する入力データセットに対して対処可能な新しいベクトル量子化アルゴリズムであるDOCL-IIアルゴリズムを提案する。なお、ここで対象とする「時間的に変化する入力データセット」は、アルゴリズムにおける学習の繰返し回数に対して、ある程度の期間、定常状態を保ち、断続的に変化していくものとする。そして、提案アルゴリズムでは、学習は入力データセットの断続的な変化と関係なく、一定の時間間隔で繰返し行うことを想定している。

DOCL-IIの特徴は、アニーリング操作により、参照ベクトルが入力空間上を大きく飛び回りながら徐々に参照ベクトルの配置を決定していくというDOCLの性質を受け継ぎつつ、入力データセットの変化に対

してアニーリング操作の開始と終了の時期を自律的に決定することにある。DOCL-II では、入力データセットの変化に対する過渡特性と定常特性の間で生じるジレンマが解決され、良質な解を獲得することが可能となっている。

以下、最初に DOCL-II で用いる学習収束度について定義し、DOCL-II アルゴリズムを示す。

4.1 学習収束度

入力データセットの変化と学習の進行度合を評価する尺度として、学習収束度 I を定義する。この尺度を用いてアニーリング操作の開始と終了時期を自律的に決定し、入力変化に対する過渡特性と定常特性のジレンマを解決する。

学習収束度 I を定義するに先立ち、まず忘却付学習回数 $\hat{n}_i (i = 1, 2, \dots, N)$ とそのエントロピーを定義する。

入力ベクトルが提示されるごとに以下の式を繰り返し計算し、忘却付学習回数を求める。

$$\hat{n}_i = \begin{cases} \lambda \hat{n}_i + 1 & i = c \\ \lambda \hat{n}_i & \text{otherwise} \end{cases} \quad (9)$$

$(i = 1, 2, \dots, N)$

ここで、 λ は忘却係数であり、1 よりわずかに小さな値をとる。本論文では $\lambda = 0.9990, 0.9995$ とした。

次に、忘却付学習回数のエントロピーを以下の式により計算する。

$$\text{entropy} = \sum_{i=1}^N -\frac{\hat{n}_i}{\sum_{j=1}^N \hat{n}_j} \ln\left(\frac{\hat{n}_i}{\sum_{j=1}^N \hat{n}_j}\right) \quad (10)$$

そして、学習収束度 I を次式で定義する。

$$I = \frac{\text{entropy}}{\ln(N)} \quad (11)$$

学習収束度 I は 0~1 の値をとり、1 に近いほど学習が最終段階の方向に向かっていることを示す。

忘却付学習回数は、入力パターンの提示ごとに忘却操作を施した各参照ベクトルの学習回数である。単なる学習回数とは異なり、参照ベクトルの学習が行われない限り、入力パターンの提示が進むにつれ、その値は減少していく。結果的に、直近(その期間は忘却係数 λ で操作される)の入力データセットに対する各参照ベクトルの学習頻度を反映することとなる。

入力データセットに変化がない場合、学習が進行し、各参照ベクトルが適切に配置される。すると、各参照

ベクトルの忘却付学習回数は等しくなり、式(10)で定義されるエントロピーは増加する。一方、入力データセットが変化した場合、それまでに学習した参照ベクトルの配置が不適切となる。そのとき、各参照ベクトルの忘却付学習回数に差が生じ、エントロピーはすみやかに減少し、各参照ベクトルの配置の再学習が開始される。このとき、単なる学習回数を用いてエントロピーを定義した場合、このエントロピーは、過去の学習履歴の影響を受けるため、入力データセットの変化時に、その値がすみやかに減少しない場合がある点に注意されたい。

ゆえに、忘却付学習回数のエントロピーに基づき式(11)で定義される学習収束度 I を、入力データセットの変化を判断する指標とする。

4.2 DOCL-II アルゴリズム

DOCL-II アルゴリズムにおいても、アニーリング操作の有無により二つのステージに分かれる。ここでのステージは DOCL のステージに対応する。すなわち、第1ステージでは、アニーリング操作により、参照ベクトルの大まかな配置の決定が行われ、第2ステージでは、参照ベクトルの詳細な配置が決定される。ただし、参照ベクトルの学習ステージが、学習収束度 I の大小によって選択される点が、DOCL と異なる。すなわち、ある入力データセットに対して十分に学習が進んだ後に、入力データセットに変化が生じた場合、学習収束度が減少する。その値がしきい値 I_{th} 以下になった場合、再び第1ステージに戻り、参照ベクトルの大まかな再配置が行われるのである。

DOCL-II では、いずれのステージも、以下の五つのステップで構成される。

Step 1: 入力ベクトル $\mathbf{x} = (x_1, x_2, \dots, x_k) \in \mathbf{R}^k$ と参照ベクトル $\mathbf{w}_i = (w_{i1}, w_{i2}, \dots, w_{ik}) \in \mathbf{R}^k$ を用いて $V(\mathbf{x}, \mathbf{w}_i) (i = 1, 2, \dots, N)$ を計算し、更新を行う参照ベクトル $\mathbf{w}_c (1 \leq c \leq N)$ を以下の式に従い決定する。

$$V(\mathbf{x}, \mathbf{w}_c) \geq V(\mathbf{x}, \mathbf{w}_i) \quad \text{for all } i \quad (12)$$

ここで、

$$V(\mathbf{x}, \mathbf{w}_i) = \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left(-\frac{1}{2}\left(\frac{d(\mathbf{x}, \mathbf{w}_i)}{\sigma_i^2}\right)\right) \quad (13)$$

$$\sigma_i = \frac{1}{\alpha + \beta n_i} \quad (i = 1, 2, \dots, N) \quad (14)$$

とする。 n_i は参照ベクトル \mathbf{w}_i の学習回数に後に述べる修正を加えたものであり、以後、修正学習回数と呼

ぶこととする． α, β は σ_i と n_i の関係を決定するパラメータである． σ_i のばらつきによりアニーリング操作の「温度」が決定される．本論文では，パラメータの値として $\alpha = 1.0, \beta = 0.01$ を用いた．

Step 2: 参照ベクトル w_c を更新する．

$$w_c(n+1) = w_c(n) + \eta_c(n)[x(n) - w_c(n)] \quad (15)$$

ここで， $\eta_c(n)$ は学習率を表し以下の式で与えられる．

$$\eta_c(n) = \frac{1}{1 + \gamma n_c} \quad (16)$$

ここで， γ は修正学習回数と学習率の関係を決定するパラメータである．本論文では $\gamma = 0.01$ とした．

Step 3: 入力データセットの変化と学習の進行度の判断基準として，学習収束度 I を式 (10)，式 (11) を用いて計算する．

Step 4: 修正学習回数 n_i ($i = 1, 2, \dots, N$) を更新する．ここで，学習収束度 I の大小によりステージが決定される．ここでステージは DOCL のステージに対応する． $I < I_{th}$ のとき，第 1 ステージとして，アニーリング操作を行う． $I \geq I_{th}$ のとき，第 2 ステージに移り，参照ベクトルの詳細な配置が決定される．ここで， I_{th} はステージの切替時期を決定するパラメータであり，1 よりもわずかに小さな値をとる．本論文では $I_{th} = 0.995$ とした．

1st stage ($I < I_{th}$)

以下の二つの処理を行う．

(1) 修正学習回数 n_i ($i = c$) の増加

$$n_c = n_c + 1 \quad (17)$$

(2) 修正学習回数 n_i ($i = 1, 2, \dots, N$) の減少

忘却付学習回数の少ない l 個の参照ベクトルの，修正学習回数を減少させる．忘却付学習回数を用いて参照ベクトルを $\hat{n}_1 \leq \dots \leq \hat{n}_l \leq \hat{n}_{l+1} \leq \dots \leq \hat{n}_N$ の順に並べ換えたのち，以下の式に従い修正学習回数を減少させる．

$$n_i = n_i - \frac{d}{l} \quad (i \leq l \leq N) \quad (18)$$

ここで， l は修正学習回数を減少させる参照ベクトルの数であり， d は減少量の総和である．

2nd stage ($I \geq I_{th}$)

$$n_i = n_{const} \quad (i = 1, 2, \dots, N) \quad (19)$$

ここで， n_{const} は参照ベクトルが収束したときの学習率を決定する．本論文では $n_{const} = 5000$ とした．

Step 5: 忘却付き学習回数 \hat{n}_i ($i = 1, 2, \dots, N$) を式 (9) を用いて更新する．

ここで導入された修正学習回数 n_i ($i = 1, 2, \dots, N$) は，基本的には各参照ベクトルの学習回数である．ただし，忘却付学習回数の小さい (現在余り学習に参加していない) l 個の参照ベクトルについては，その学習回数が少なく見えるように修正を加えている．

学習回数に修正を加えることにより，現在余り学習に参加していない，すなわち，現在適切な配置にない参照ベクトルに対して，式 (14) を通して式 (13) の σ を大きくすることで，アニーリング操作における温度を高くして学習に参加させやすくして，適切な配置へ移動を行う．また，更新を行う参照ベクトルとして選択されたとき，式 (16) を通して式 (15) の学習率 η を大きくすることで素早く参照ベクトルの配置を修正する．

提案アルゴリズムでは，アニーリング操作の有無を決定するステージ選択の判断に忘却付学習回数を用い，アニーリング操作を行う際の温度パラメータと学習率の決定に修正学習回数を用いている．このように，学習回数に関する 2 種類の値を保持することにより，「入力データセット変化の検出」と「アニーリング操作の温度・学習率の決定」という異なる要求を個別に満たすことが可能となっている．

4.3 局所解問題への対応と過渡特性と定常特性のジレンマの解決

本節では，はじめに，局所解問題に対してアニーリング操作を用いることの有効性を，Optm アルゴリズムとのシミュレーション比較を用いて示す．次に，新たに導入した学習収束度 I によりアニーリング操作の開始と終了時期を決定することにより，過渡特性と定常特性のジレンマを解決することを示す．

4.3.1 局所解問題への対応

Optm とのシミュレーション比較を行う．シミュレーション条件として，参照ベクトルの数 N を $N = 12$ とし，修正学習回数を減少させる参照ベクトルの数 l を $l = 3$ ，修正学習回数の減少量の総和 d を $d = 2.0$ ，並びに忘却付き学習回数の更新に必要なパラメータ λ を $\lambda = 0.9990$ とした．参照ベクトルの初期値を各成分に対して $-0.7 \sim 0.7$ のランダムな値とした．また， n_i, \hat{n}_i の初期値として 0 を用い，Optm の条件は文献 [3] と同様な条件とした．本論文におけるすべての

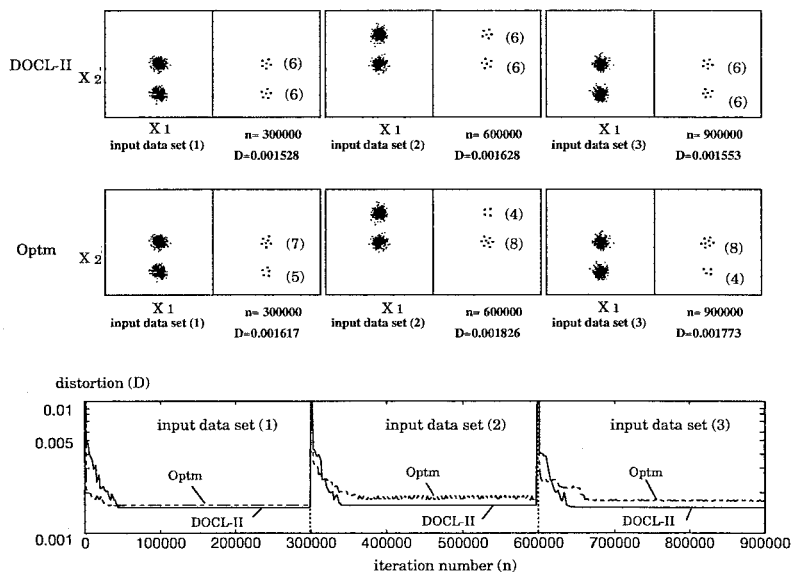


図3 参照ベクトルの最終配置と誤差
Fig. 3 Final location of representative vectors and distortion.

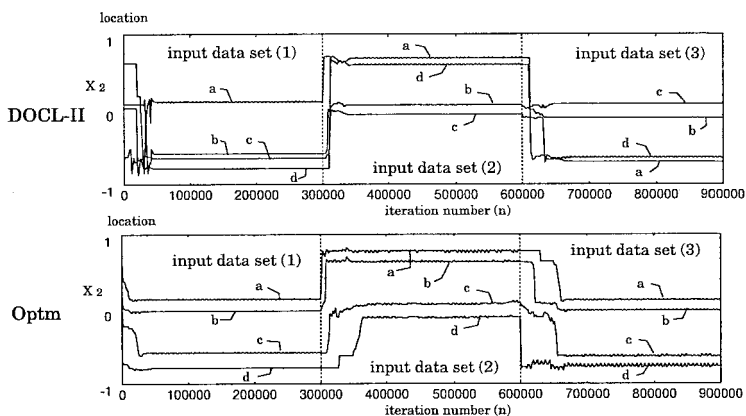


図4 参照ベクトルの x_2 成分の軌跡
Fig. 4 x_2 -component trajectories of representative vectors.

シミュレーションにおいて、参照ベクトル (w_i), 修正学習回数 (n_i), 忘却付き学習回数 (\hat{n}_i) の初期化を同様に行い, Optm の条件として同じものを用いた.

入力データセットとして, 2次元でクラス数が2個のものを3種類 (input data set (1)~(3)) 用いた. 入力データセットを図3に示す. 2個のクラスは同じ確率分布関数をもつ. 3種類の入力データセットを繰返し回数 $n = 0, 300000, 600000$ で切り換えて利用する. そのとき, 新たな入力データセットに対する参

照ベクトルの初期値として, 以前の入力データセットにより獲得された参照ベクトルの値を用いることとする. ここで繰返し回数 n とは, Step 1 から Step 5 を繰返す回数である.

シミュレーション結果を図3, 図4に示す. 図3の上図に, DOCL-II と Optm による, 各入力データセットにより獲得された参照ベクトルの最終的な配置とそのときの誤差 D が示されており, 図中の数字は各クラスにおける参照ベクトルの数を示している. また,

図 3 の下図に、学習過程における誤差 D の推移が示されている。図 4 には、12 個の参照ベクトルのうち 4 個の参照ベクトルの、学習過程における x_2 成分の軌跡が示されている。

図 3 より、Optm と比較して、DOCL-II では 3 種類すべての入力データセットに対して良好な結果が獲得されていることがわかる。図 3 上図より、DOCL-II において、参照ベクトルの数が入力データの各クラスに均等に配置され最適解を獲得しているのに対して、Optm では、多くの参照ベクトルが中央のクラスにトラップされ、局所解に陥っている。

また、図 4 より、DOCL-II では、入力データセットが変化したときに参照ベクトルが大きく移動しアンニーリング操作が行われている。そのため、局所解から脱することが可能となっている。それと比較し、Optm は、基本的には入力データとユークリッド距離が近い参照ベクトルで入力データを学習するため、参照ベクトルは入力空間上を連続的に移動する。実際に、Optm のシミュレーション結果では、参照ベクトル d は、入力データセット (1) により下部のクラスに移動しており、入力データセットが (1) から (2) に変化したとき、近傍に存在した中央のクラスへの連続的に移動しているのがわかる。このとき、参照ベクトル d は、中央のクラスを飛び越えて上部のクラスへ移動することはない。この結果、学習過程で多くの参照ベクトルの近傍となる中央のクラスに参照ベクトルがトラップされやすくなり、局所解に陥ってしまう。

以上の結果から、DOCL-II でのアンニーリング操作が有効に働いていることがわかる。

4.3.2 過渡特性と定常特性のジレンマの解決

入力データセットの変化に対するアンニーリング操作の開始と終了時期を自律的に決定することで、過渡特性と定常特性のジレンマが解決されることを示す。DOCL-II では、学習収束度 I をもとにアンニーリング操作の有無を決定している。ここで、学習収束度 I は参照ベクトルに対する忘却付き学習回数のばらつきを示している。また、式 (18) により、学習への参加度が小さい何割かの参照ベクトルに対して、学習回数を意図的に減少するという新たな処理を導入している。この処理が、入力データセットの変化を察知し、アンニーリング操作の有無を導く様子について述べる。

入力データセットに変化がなく、参照ベクトルが収束している場合は、すべての参照ベクトルに対して忘却付き学習回数は等しくなる。この結果、学習収束度

I は増加し、第 2 ステージに入り、修正学習回数は等しくなり、式 (14)、式 (16) を用いてアンニーリング操作は停止される。

一方、入力データセットに変化が生じた場合、忘却付き学習回数に偏りが生じる。このとき、学習収束度 I が減少し、第 1 ステージへ移行する。そこでは、学習への参加度が少ない特定の参照ベクトルに対する修正学習回数が大きく減少することになる。この結果、修正学習回数の偏りが生じ、式 (14)、式 (16) を通じてアンニーリング操作のパラメータが自律的に修正され、アンニーリング操作が開始される。

図 4 より、DOCL-II では、入力データセットに変化が生じたときのみアンニーリング操作が開始されることがわかる。

DOCL-II では、アンニーリング操作の開始時期を入力データセットの変化により決定することで、入力データセットの変化に対する過渡特性と定常特性のジレンマを解決している。

4.4 アンニーリング操作に用いるパラメータの学習結果への影響

本論文では、入力データセットが変化したときに、アンニーリング操作が自律的に行われるようにするため、新たな処理として式 (18) を導入した。本節では、この処理で用いるパラメータ l (修正学習回数を減少させる参照ベクトルの数) と d (修正学習回数の減少量の総和) の学習結果への影響についてシミュレーションにより考察を行う。

シミュレーション条件として、パラメータ l, d 以外の条件は、入力データセットも含めて前節のシミュレーションと同様のものを用いた。

図 5 に、修正学習回数の減少量の総和を $d = 2.0$ と一定にして、修正学習回数を減少させる参照ベクトルの数を $l = 1, 3, 6$ としたときの誤差 D に関するシミュレーション結果を示す。図 6 に、修正学習回数を減少させる参照ベクトルの数を $l = 1$ と一定にして、修正学習回数の減少量の総和を $d = 0.5, 2.0, 5.0$ としたときの誤差 D に関するシミュレーション結果を示す。比較のため、Optm の結果を重ねて示す。

図 5 より、 $l = 1, 3$ と l の値が小さい場合には良好な結果が得られるが、 $l = 6$ と l の値が大きくなった場合、局所解に陥る可能性があることがわかる。これは、 l の値が大きい場合、多くの参照ベクトルに対して修正学習回数が均等に減少するため、入力データセットが変化したときに修正学習回数に差が現れず、アンニー




図5 パラメータの学習結果への影響
Fig. 5 Dependency on parameters.




図6 パラメータの学習結果への影響
Fig. 6 Dependency on parameters.

リング操作が有効に行われていないためである。この結果より、 l の値を小さくすることが好ましいことがわかる。

また、図6より、 $d = 0.5$ と d の値が小さい場合には、局所解に陥る可能性があることがわかる。これは、修正学習回数の減少量が小さいため修正学習回数の差が大きくなり、アンニリング操作が有効に行われなためである。逆に $d = 5.0$ と極端に大きい場合には、学習結果が振動することがわかる。これは、一度に修正学習回数が大きく減少するため、学習に参加する参照ベクトルが大きく変動するためである。しかし、いずれの場合も Optm より良好な結果が得られている。

以上の結果より、パラメータ l と d の値の選択基準として、 l の値を比較的小さい値とし、 d の値を学習結果に振動が生じない程度に大きな値にすることが望ましいと考えられる。経験的には、 $l = 1 \sim 3$ 、 $\frac{d}{l} = 0.6 \sim 2.0$ のとき良好な結果が獲得されている。本論文では、以上の結果に基づいてパラメータの値を経験的に決定した。

5. DOCL-II の他のベクトル量子化アルゴリズムに対する比較検討

2次元データと16次元データを用いてシミュレ-

ーションを行い、DOCL-II と従来の代表的なアルゴリズムである Optm [3]、CL [4]、[5]、FSCL [4]、[5] との比較を行い、DOCL-II が他のアルゴリズムより有効であることを示す。

5.1 2次元データによる比較

2種類のシミュレーションを行う。それぞれのシミュレーションに対して3種類の入力データセット (input data set (1) ~ (3)) を用いた。入力データセットを図7、図8に示す。図中の3種類の入力データセットを繰り返し回数 $n = 0, 300000, 600000$ で切り換えて利用する。そのとき、新たな入力データセットに対する参照ベクトルの初期値として、以前の入力データセットにより獲得された参照ベクトルの値を用いることとする。シミュレーション条件として、 $N = 24, l = 3, d = 3.0, \lambda = 0.9990$ を用い、その他の条件は前章までのシミュレーションと同様なものとした。CL、FSCL の条件は、文献 [4]、[5] と同様なものを用い、学習率を 0.1 とした。

シミュレーション結果を図7、図8に示す。図において DOCL-II と Optm の参照ベクトルの最終配置を示し、DOCL-II、Optm、CL、並びに FSCL の誤差の変化を示す。図より、DOCL-II は他のアルゴリズムより良好な結果を得ていることがわかる。CL、FSCL

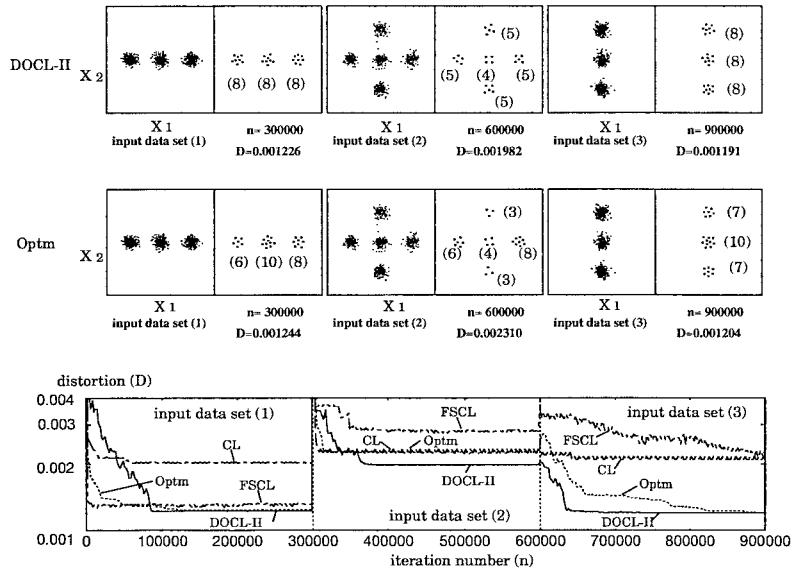


図 7 2次元データにおける参照ベクトルの最終配置と誤差
Fig. 7 Final location of representative vectors and distortion for 2-dimensional data.

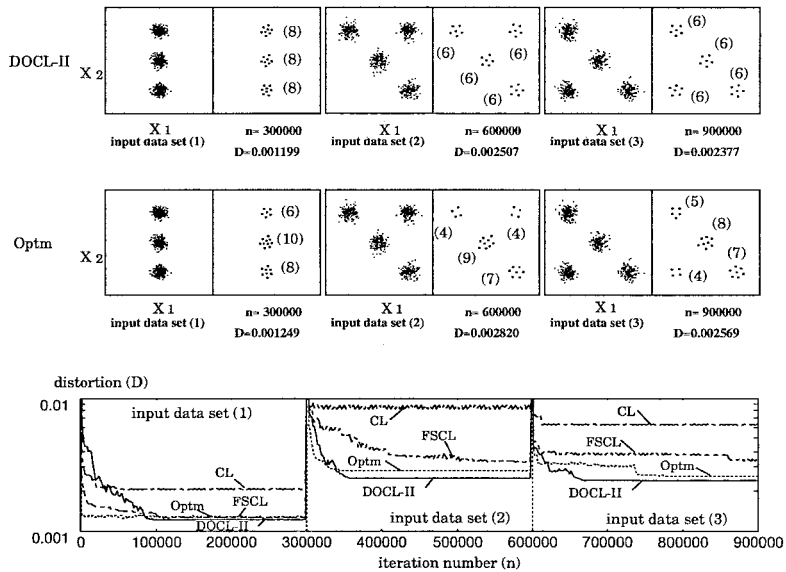


図 8 2次元データにおける参照ベクトルの最終配置と誤差
Fig. 8 Final location of representative vectors and distortion for 2-dimensional data.

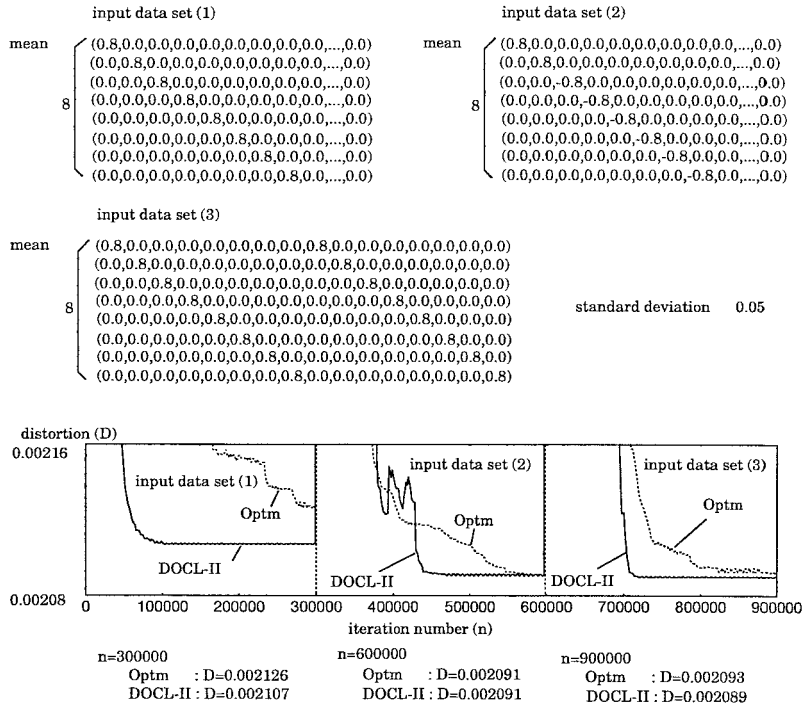


図9 16次元入力データにおける入力データセットと誤差
Fig. 9 Input data sets and distortion for 16-dimensional data.

では、学習率が一定であるため、入力データセットの変化に対する過渡特性と定常特性のジレンマが解決されていない。局所解に陥るといった問題も解決されていない。また、Optmでは、学習率を可変とすることで、入力データセットの変化に対する過渡特性の改善は図られているものの、学習結果が局所解に陥るといった問題を残していることがわかる。

5.2 16次元データによる比較

入力データセットの次元数が大きい場合においても、DOCL-IIが有効に働くことをシミュレーションにより示す。

入力データセットとして3種類の入力データセット (input data set (1)~(3)) を用いた。各入力データセットは8個の標準偏差が0.05のガウス分布からなるクラスタから構成されており、図9にクラスタの中心値 (mean) を示した。3種類の入力データセットを繰り返し回数 $n = 0, 300000, 600000$ で切り換えて利用する。そのとき、新たな入力データセットに対する参照ベクトルの初期値として、以前の入力データセットにより獲得された参照ベクトルの値

を用いることとする。シミュレーション条件として、 $N = 40, l = 3, d = 2.0, \lambda = 0.9995$ を使い、その他の条件は2次元データによるシミュレーションと同様なものとした。

シミュレーション結果を図9に示す。図9には学習過程における誤差の変化が示されている。図よりOptmは局所解に陥る可能性があるが、DOCL-IIでは、3種類すべての入力データセットに対して良質な解が獲得されていることがわかる。また、DOCL-IIはOptmより比較的速く良質な解を獲得していることがわかる。

6. むすび

画像処理や音声処理等において学習過程で変化する入力データセットを扱うため、アルゴリズム (DOCL-II) を提案した。DOCL-IIでは、局所解問題に対して、アニーリング操作を用いることで、良好な結果を得ることができ、入力データセットの変化と学習の進行度合によりアニーリング操作の開始と終了時期を自律的に決定することで変化する入力データセット

に対する過渡特性と定常特性のジレンマを解決している．次に，DOCL-II の特徴を Optm と比較して示し，DOCL-II が局所解に陥らないことを示した．更に，DOCL-II に用いるパラメータの学習結果への影響をシミュレーションにより明らかにした．最後にシミュレーションにより，CL，FSCL は，学習率が一定であるため過渡特性と定常特性のジレンマの問題が解決されず，Optm は，過渡特性と定常特性のジレンマは解決しているが，参照ベクトルが入力空間上を連続的に移動するため，局所解に陥るという問題を有することを示し，DOCL-II が他のアルゴリズムより優れていることを示した．Optm と比較し DOCL-II は，入力データセットが大きく断続的に変化する場合に特に有効であると考えられる．

文 献

- [1] S. Yoshizawa, S. Doki, and S. Okuma, "A new algorithm for vector quantization based on the diversity of learning areas of representative vectors," Proc. ICONIP, pp.229-232, 1997.
- [2] 芳澤伸一, 道木慎二, 大熊 繁, "参照ベクトルの学習範囲に多様性を持たせ局所解回避を目的とした新たなベクトル量子化アルゴリズム," 信学技報, NC97-11~24, June 1997.
- [3] C. Chinrungrueng and C.H. Séquin, "Optimal adaptive K-means algorithm with dynamic adjustment of learning rate," IEEE Trans. on Neural Networks, vol.6, no.1, pp.157-169, 1995.
- [4] N. Ueda and R. Nakano, "A new competitive learning approach based on an equidistortion principle for designing optimal vector quantizers," Neural Networks, vol.7, no.8, pp.1211-1227, 1994.
- [5] L. Xu and A. Krzyzak, "Rival penalized competitive learning for clustering analysis, RBF net, and curve detection," IEEE Trans. on Neural Networks, vol.4, no.4, pp.636-649, 1993.
- [6] D.-I. Choi and S.-H. Park, "Self-creating and organizing neural networks," IEEE Trans. on Neural Networks, vol.5, no.4, pp.561-575, 1994.
- [7] T. コホネン著, 徳高平蔵, 岸田 悟, 藤村喜久郎訳, "自己組織化マップ," シュプリンガー・フェアラーク東京(株), 1996.
- [8] 前田道治, 宮島廣美, 村島定行, "ベクトル量子化のための自己組織化アルゴリズムの構成," 電学論 C, vol.117-C, no.8, pp.1084-1091, 1997.
- [9] Y. Linde, A. Buzo, and R.M. Gray, "An algorithm for vector quantizer design," IEEE Trans. Commun., vol.Com-28, no.1, pp.84-95, 1980.

(平成10年4月14日受付, 9月21日再受付)



芳澤 伸一 (学生員)

1994 名大・工・電気卒．1996 同大学院博士課程前期課程了．現在，同大学院博士課程後期課程に在学中．ニューラルネットワークに関する研究に従事．電気学会，計測自動制御学会各会員．



道木 慎二 (正員)

1995 名大大学院工学研究科博士課程後期課程電子機械工学専攻了．同年4月同助手，現在に至る．博士(工学)．主として，制御理論のモータドライブへの応用，記憶・認識システムに関する研究に従事．IEEE，電気学会，計測自動制御学会各会員．



大熊 繁

1972 名大大学院修士課程電気工学専攻了．1974 ケース・ウエスタン・リザーブ大学大学院修士課程システム工学専攻了．1977 名大大学院博士課程電気工学専攻了．同年，名古屋大学工学部電気学科助手，講師，助教授を経て1990 同教授，現在に至る．主としてロボティクス，パワーエレクトロニクス，創発型ソフトコンピュータに関する研究に従事(工博)．1992 IEEE IECON Best Paper Award, 1994 精密工学会論文賞, 1995 電気学会論文賞をそれぞれ受賞．電気学会，システム制御情報学会，日本機械学会，日本ロボット学会，IEEE 各会員．