

画像の標準パターン作成とシミュレーテドアニーリング

2C-6

増田 芳成,
茨城大学

川本 博海,
茨城大学

松山 泰男
茨城大学

1はじめに

パターンマッチングや情報圧縮における標準パターン集合(符号帳)を作成するためのベクトル量子化は、より高い視野から見ると、競争学習を用いた自己組織化アルゴリズムとなる。この問題においては、その起源的研究の当初である1970年代後半から、局所最適性について議論がなされてきた。しかし、音声や画像に適用した結果では、性質の極めて悪い局所最適解に捕捉されるることはまれであった。しかしながら、ベクトル量子化そのものの研究としても、また、自己組織化の問題の研究としても、いろいろな変形が提案されつつあり、どの程度の(準)最適な解になっていくのかの比較が大事となってくる。そこで、悪い局所最適点(local optima)からの脱出法であるシミュレーテドアニーリングを行って、どの程度の改善が得られるのかを調べてみる。

ただし本稿では、画像によるトレーニングデータを採用し、文献[1]の特別な場合である位相なしの2重降下競争学習アルゴリズム[2]について実験を行ってみる。2重降下の場合のシミュレーテドアニーリングと局所最適性との関連については、従来検討がなされていない。

2二重降下競争学習アルゴリズム

競争学習としての通常のベクトル量子化は、大きさと形状が固定された領域に対する一様な情報の割り当てであるため、各領域の相対的情報量が不平等になり、再生情報に不当な量子化雑音が現れる。位相なしの2重降下競争学習(可変領域ベクトル量子化)は、これを情報割り当ての立場から改善することを試みたものである。次に、位相なしの2重降下競争学習について説明する。

2.1準備

$\mathbf{x}_i \in \mathbb{R}^M, (i = 0, \dots, T-1)$ は固定された T 個のベクトルであり、M は正の整数である。これらはグループ化されてスーパーベクトル $\mathbf{v}_j, (j = 0, \dots, J-1)$ を作る。ここで J は固定された自然数で、各 \mathbf{v}_j は可変次元である。

$$\mathbf{v}_j \in \mathbb{R}^{*M} = \{\mathbb{R}^M, \mathbb{R}^{2M}, \dots, \mathbb{R}^{(T-J+1)M}\}$$

$\mathbf{v}_j, (j = 0, \dots, J-1)$ を作るためのグループ化パターンの集合を \mathcal{U} とし、その要素を u_k とする。コードブック(標準パターン集合)を $\mathcal{C} = \{\mathbf{c}_0, \dots, \mathbf{c}_n, \dots, \mathbf{c}_{N-1}\}$ とし、 $\|\mathcal{C}\| = N$, $\mathbf{c}_n \in \mathbb{R}^{LM}$, $(n = 0, \dots, N-1)$ である。ここで、L は固定された自然数である。 $\mathbf{v}_j, (j = 0, \dots, J-1)$ は最隣接要素(最優位ニューロン) \mathbf{c}_n によってグループ化され、分割 $A_n, (n = 0, \dots, N-1)$ を得る。すなわち、

$$\bigcup_{i=0}^{T-1} \mathbf{x}_i = \bigcup_{j=0}^{J-1} \mathbf{v}_j = \bigcup_{n=0}^{N-1} A_n,$$

Standard pattern self-organization of image and simulated annealing
Yoshinari MASUDA, Hiromi KAWAMOTO, Yasuo MATSUYAMA
Dept. of Computer and Information Sciences, Ibaraki University

$$\mathbf{v}_i \cap \mathbf{v}_j = \emptyset (i \neq j), A_m \cap A_n = \emptyset (m \neq n)$$

となる。また、 \mathbf{v}_j, A_n はそれぞれ、 $\mathbf{v}_j(u_k), A_n(u_k)$ とも書ける。

コスト(ひずみ測度)は、 $\mathbb{R}^{*M} \times \mathbb{R}^{LM} \rightarrow \mathbb{R}^{*M}$ とする写像を導入することより与える。この写像は、 $\mathbf{v}_j(u_k)$ に応じて \mathbf{c}_n に対して時空圧伸を施すことを意味している。これにより $\mathbb{R}^{*M} \times \mathbb{R}^{LM} \rightarrow \mathbb{R}^+ \cup \{0\}$ なるコスト(ひずみ測度)を与える。

2.2アルゴリズム

以下に今回のシミュレーテドアニーリングの対象となっている位相なしの2重降下競争学習のアルゴリズムを述べる。

Step 1 ($k = 0$)

トレーニング列 $\{\mathbf{x}_i\}, (i = 0, \dots, T-1)$,
ニューロンの初期集合(初期コードブック) $\mathcal{C}[0]$,
コスト関数(総合ひずみ) $D[0] = \infty$,
グループ化パターン $u_0, \epsilon > 0$
が与えられている。

Step 2 ($k \leftarrow k + 1$)

$\{\mathbf{x}_i\}, \mathcal{C}[k-1]$ に対して $D[k]$ を最小にする u_k を求める。
最適化グループ化パターン $\{\mathbf{v}_j(u_k)\}, (j = 0, \dots, J-1)$,
各 $\mathbf{v}_j(u_k)$ に対する最優位ニューロン(最隣接要素)
 $\mathbf{c}_{n_j}[k-1], (j = 0, \dots, J-1)$ とコスト関数 $D[k]$ を計算する。

Step 3

$(D[k-1] - D[k])/D[k] < \epsilon$ ならば
 $\mathcal{C}[k-1] \rightarrow \mathcal{C}, u_k \rightarrow u$ として終了。
そうでなければ Step 4 へ行く。

Step 4

分割 $A_n(u_k), (n = 0, \dots, N-1)$ に対する一般化された重心 $\mathbf{c}_n[k]$ を求め、これより、 $\mathcal{C}[k] = \{\mathbf{c}_0[k], \dots, \mathbf{c}_{N-1}[k]\}$ が得られる。

Step 5

Step 2 へ行く。

3シミュレーテドアニーリング

2重降下競争学習のアルゴリズムを画像に適用することを考える。従来のベクトル量子化では、画像をコードワード(標準パターン)と同形(4×4程度の矩形領域)に分割し、それをトレーニングベクトルとしていた。2重降下競争学習ではトレーニングベクトルとなる領域を任意の形状の凸四角形とする。ただし、コードワードは4×4程度の矩形領域である。また、 \mathbf{x}_i はピクセルに、 \mathbf{v}_j は凸四角形の領域に対応している。よって、各 \mathbf{v}_j は凸四角形の頂

点(vertex)によって決定され, vertex パターンの集合が \mathcal{V} となる。従って, グループ化パターンの準最適化は vertex を移動させることによって実現している。

シミュレーテドアニーリングとは, 最適化問題の一手法で, 制御された不規則性を導入することにより, 悪い局所最適状態から脱出しようとするものである。

2重降下競争学習により画像の標準パターンを求めるときのシミュレーテドアニーリングには, 大別して次の2つの方法が考えられる。

1. 与えられたデータやそれに伴う状態に雑音を加え, 雜音のレベルを徐々に下げる。
2. グループ化写像 (u_k の更新) 等の写像自体を変形して確率的性質をもたせる。その写像を適用する毎に不規則性のレベルを下げる。

1には, 画像に雑音を加える方法が考えられる。雑音の与え方には, つぎのようなものが考えられる。

- a. $N(0, T^2)$ の正規乱数を加える。
- b. 各ピクセルに対する雑音の初期値を作つておく。この雑音は正規乱数で, それに T をかけて加える。 $(T : 1 \rightarrow 0)$
- c. オリジナルのピクセル値を od , 雜音の加えられたピクセル値を nd としたときに, $nd = C + (od - C)/(T + 1)$ とする。 $(T : \infty \rightarrow 0)$ ここで C は適当な定数である。

bの方法は, 同形の雑音を強さを変えて与えている。cは, 画像のコントラストを変化させている。1には他にも, コードブックに雑音を加える方法が考えられるが, ここでは触れないことにする。

2には, vertex を確率的に移動させる方法が考えられる。ある vertex v が K 個の点 $v^{(k)}$, $(k = 0, \dots, K-1)$ のうち 1 点に移動するものとする。 v が $v^{(k)}$ に移動する確率を p_k で表す。 v が $v^{(k)}$ に移動したときのエネルギーを E_k とする。エネルギー E_k には, 総合ひずみや, v の移動によって変形される凸四角形のひずみの和等が考えられる。 E_k の最小値, 最大値をそれぞれ E_{\min}, E_{\max} とする。このとき, ΔE_k を以下のような式で与える。

$$a. \Delta E_k = E_k - E_{\min}$$

$$b. \Delta E_k = \begin{cases} \frac{(E_k - E_{\min})}{(E_{\max} - E_{\min})} & \text{if } E_{\max} \neq E_{\min} \\ 0 & \text{if } E_{\max} = E_{\min} \end{cases}$$

$$c. \Delta E_k = \begin{cases} (E_k - E_{\min})/E_{\min} & \text{if } E_{\min} \neq 0 \\ \infty & \text{if } E_k > E_{\min} = 0 \\ 0 & \text{if } E_k = E_{\min} = 0 \end{cases}$$

aは単純に差をとったものであり, bは $0 \sim 1$ に正規化するものである。cは E_{\min} との比を基準している。

ΔE_k から $p_k = A^{-1} \exp(-\Delta E_k/T)$ として p_k が求まる。ここで A は確率の正規化のための定数で

$$A = \sum_{k=0}^{K-1} \exp(-\Delta E_k/T)$$

である。

4 実験と結果

32×32 の白黒画像に対して実験を行つてみた。原画像を 6×6 の領域に分割し, コードワードの大きさは 4×4 で, その数は 4 とし, グループ化を行うときのコストについて調べてみた。vertex の移動に関しては,隣接する vertex との中点に限定し, これを繰り返した。これは, 部分最適化法を用いていることを意味している。コスト関数としてはユークリッド距離の 2乗を用い, 空間圧縮および補間に双一次変換, 双一次パッチを用いている。シミュレーテドアニーリングの方法としては,

- 画像に正規乱数を加える。(1.a)
- 画像のコントラストを変える。(1.c)
- vertex を確率的に移動させる。(2.c)

の3つを行つた。温度パラメータ T のスケジュールは

$$(1.a) T : 200 \rightarrow 200 \times 0.9 \rightarrow \dots \rightarrow 200 \times (0.9)^{50} \approx 1.03 \rightarrow 0$$

$$(1.c) \alpha = (T + 1)^{-1} \text{としたときに}$$

$$\alpha : 0.00 \rightarrow 0.05 \rightarrow 2 \times 0.05 \rightarrow \dots \rightarrow 0.95 \rightarrow 1.00$$

$$(2.c) T : 2.0 \rightarrow 2.0 \times 0.9 \rightarrow \dots \rightarrow 2.0 \times (0.9)^{50} \approx 0.013 \rightarrow 0.0$$

である。

結果は, シミュレーテドアニーリングを行わない場合と比較して, (1.a), (1.c), (2.c) はコスト関数の値をそれぞれ 9%, 12%, 24% 改善した。

5 まとめ

2重降下競争学習による標準パターンの自己組織化(可変領域ベクトル量子化)について, シミュレーテドアニーリングを試み, どの程度コストが改善されるかを調べてみた。その結果, 10~20% 程度の改善があることが分かった。これは, 次のように解釈される。すなわち, 競争学習による自己組織化の変種どうしの性能を比べる場合においては, シミュレーテドアニーリングなしでは, ある方法が別の方法より 10% 程度良いという結果が出ても, 手法の優劣を断言することは危険であるということである。これは, 局所最適解どうしの比較だからである。

本稿では, 逐次更新 [1] について触れていないが, [1] はシミュレーテドアニーリングとより良くなじむことを指摘しておく。

参考文献

- [1] 松山泰男: 競争学習によるニューラルネット自己組織化アルゴリズム, 本大会 (1990).
- [2] 松山泰男: 可変領域ベクトル量子化, 信学論(A), Vol. J70-A, pp.1830~1837 (1987).
- [3] van Laarhoven, P.J.M. and Aarts, E.H.L. : Simulated Annealing : Theory and Applications, D.Reidel (1988).
- [4] Aarts, E. and Korst, J. : Simulated Annealing and Boltzmann Machines, John Wiley (1989).