

3C-4

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

松山 泰男

茨城大学 工学部 情報工学科

1. はじめに

競争学習によるニューラルネット自己組織化のアルゴリズムを与える。アルゴリズムには、大別して一括更新型と逐次更新型があり、両者はそれぞれ有用である。また、両者の混在も許される。これらのアルゴリズムは、従来のパターンマッチングや情報圧縮の他に、自己組織化の学習過程を利用して、組合せ最適化問題を扱うことができる。これは、Hopfield net や、それに雑音を加えたモデル等とは異なり、コスト関数を自ら最適化していくことを利用するものである。

2. 準備

以下のような記号を用いる。

$\{\mathbf{x}_i\}_{i=0}^{T-1}$ … トレーニングデータ,
 $\{\mathbf{v}_j\}_{j=0}^{J-1}$ … グループ化されたトレーニングデータ,
 Φ … コストを減少させるグループ化写像の集合,
 $\prod_{q=0}^{Q-1} \mathcal{C}^{(q)}[old]$ … 直積型 neuro-node の集合,
 $\Psi_q \cdots \mathcal{C}^{(q)}[old]$ に対して、一般化された重心を更新する写像（またはその有限近似写像）の集合。

他の記号については、アルゴリズム中で説明する。

3. 一括更新型アルゴリズム

写像スケジューラ

写像スケジューラは次のような規則を有しており、Step 0 ~ Step 5 における各種のパラメータ調節や選択を行う。

[グループ化写像選択規則]

Φ の中から写像を選ぶ。ただし、最適化写像の集合（あるいはその有限近似写像の集合） $\tilde{\Phi}$ の各要素は無限回生起（i.o.）が起こるよう計画されている。

[neuro-node 位相の規則]

自己組織化の過程での neuro-node 間の位相的制約。

[結合 \mathcal{L} の規則]

最優位 neuro-node が与える他の neuro-node への興奮性および抑制性結合の強さとその変更規則。

[更新近傍の変更規則]

最優位 neuro-node の update 近傍の変更規則。

[更新確率の変更規則]

最優位 neuro-node とその結合 neuro-node, そしてそれらの近傍 neuro-node を更新する確率とその変更規則。

[公正競争バイアスの変更規則]

最優位 neuro-node を決めるときの公平競争バイアスの変更規則。

[繰り返し回数] K_{max}

写像スケジューラにより管理される 6 つのステップは、次の通りである。

Step 0 (初期状態 $k = 0$)

次のような初期値が与えられている。

Generalized neural net self-organization by competitive learning,

Yasuo Matsuyama, Dept. of Computer and Information Sciences, Ibaraki University, Hitachi 316, Japan

● neuro-node の集合

$$\prod_{q=0}^{Q-1} \mathcal{C}^{(q)}[old]$$

$u[old]$

$$\mathcal{O}^{(q)}(\mathbf{c}_{n_q}^{(q)}[old], [old])$$

$n_q = 0, \dots, N_q - 1$,

$q = 0, \dots, Q - 1$.

$$p^{(q)}(\mathbf{b}^{(q)}[old], \mathcal{O}^{(q)}(\mathbf{c}_{n_q}^{(q)}[old], [old]))$$

$$\mathbf{b}^{(q)}[old] \in \mathcal{O}^{(q)}(\mathbf{c}_{n_q}^{(q)}[old], [old]).$$

$h_{n_q}[old] = 0$, その集合を \mathcal{H} で表わす。

$$\alpha_{\mathcal{L}}[old].$$

Step 1 (グループ化)

スケジューラは Φ から φ を選択し、その φ を

$$\left(\prod_{q=0}^{Q-1} \mathcal{C}^{(q)}[old], u[old] \right)$$

に適用して $u[new]$ を得る。

Step 2 (停止判定)

もし前回の停止判定以後、全ての $\tilde{\Phi}$ と $\tilde{\Psi}_q$ ($q = 0, \dots, Q - 1$)、すなわち最適写像またはその近似の全てが選択された場合には、 $k := k + 1$ とする。 $k \geq K_{max}$ になっていれば終了し、 u と $\prod_{q=0}^{Q-1} \mathcal{C}_{n_q}^{(q)}$ を得る。

Step 3 (公正競争に対する最優位neuro – node)

$$d_{\mathcal{H}}(\cdot, \prod_{q=0}^{Q-1} \mathbf{c}_{n_q}^{(q)}[old]) = f(d(\cdot, \prod_{q=0}^{Q-1} \mathbf{c}_{n_q}^{(q)}[old]), \mathcal{H})$$

を用いて、 \mathbf{v}_j に対する最優位 neuro-node を求める。そして、

$$h_{n_q}^{(q)}[new] = h_{n_q}[old] + (\mathbf{c}_{n_q}^{(q)}[old] の人口数)$$

を行う ($\forall n_q, \forall q$).

Step 4 (neuro – node更新)

Step 4.1 (人口調整)

● 各 neuro-node $\mathbf{c}_{n_q}^{(q)}[old]$ について、 $\mathcal{O}^{(q)}(\mathbf{c}_{n_q}^{(q)}[old], [old])$ 中の neuro-node を、確率 $p^{(q)}(\mathbf{c}_{n_q}^{(q)}[old], \mathcal{O}^{(q)}(\mathbf{c}_{n_q}^{(q)}[old], [old]))$ で $\mathbf{c}_{n_q}^{(q)}[old]$ のメンバーに加える。

● 各 neuro-node $\mathbf{c}_{n_q}^{(q)}[new]$ が興奮性結合を与える neuro-node $\mathbf{e}^{(q)}[old]$ と、その近傍 $\mathcal{O}^{(q)}(\mathbf{e}^{(q)}[old], [old])$ 中の $\mathbf{b}^{(q)}[old]$ に対して、 $\mathbf{c}_{n_q}^{(q)}[old]$ を $\mathbf{c}_{n_q}^{(q)}[old]$ 中の人口数だけの重複度をもって加える。その確率は、 $\alpha_{\mathcal{L}}[old] p^{(q)}(\mathbf{b}^{(q)}[old], \mathcal{O}^{(q)}(\mathbf{e}^{(q)}[old], [old]))$ とする。

● 各 neuro-node $\mathbf{c}_{n_q}^{(q)}[old]$ が、抑制性結合を与える neuro-node $\mathbf{e}^{(q)}[old]$ とその近傍 $\mathcal{O}^{(q)}(\mathbf{e}^{(q)}[old], [old])$ 中の近傍 $\mathcal{O}^{(q)}(\mathbf{e}^{(q)}[old], [old])$ 中の $\mathbf{b}^{(q)}[old]$ に対して、抑制性結合の効果を増す neuro-node のメンバーを加える。それぞれの確率は $\alpha_{\mathcal{L}}[old] p^{(q)}(\mathbf{e}^{(q)}[old], \mathcal{O}^{(q)}(\mathbf{e}^{(q)}[old], [old]))$,

$$\alpha_{\mathcal{L}}[old] p^{(q)}(\mathbf{b}^{(q)}[old], \mathcal{O}^{(q)}(\mathbf{e}^{(q)}[old], [old]))$$

である。

Step 4.2 (neuro-nodeの更新)

ψ_p を Ψ_p から選び、 $\psi_p(\prod_{q=0}^{Q-1} C^{(q)}[old], u[new])$ を計算する ($\forall p$).

Step 5 (各種の変更規則の実行)

- $O^{(q)}(\cdot, [old])$ を近傍縮小規則に従って縮小し、 $O^{(q)}(\cdot, [new])$ とする。
 - 更新確率を変更確率に従って調節する。
 - 結合重み $\alpha_L[new]$ を得る。
 - 公正競争バイアスを変更し、 $H[new]$ を得る。
 - $[old] \leftarrow [new]$ とする。
- 次いで、Step 1へ戻る。

4. 逐次更新型アルゴリズム

「逐次」とは、直列処理計算を意味するものではなくて、並列処理計算にじむものであることをあらかじめ注意しておく。

写像スケジューラ

写像スケジューラは次のような規則を有しており、Step 0～Step 5における各種のパラメータ調節や選択を行なう。

[グループ化写像選択規則]

$\tilde{\Phi}$ の中から写像 φ を選び、その φ か恒等写像 φ^0 のどちらかを選択し、それを φ とする。ただし $\tilde{\Phi}$ の各要素は無限界生起(i.o.)するように計画されている。

[neuro-node 位相の定義]、[結合 L の定義]、[更新近傍の変更規則]、[更新確率の変更規則]、[公正競争バイアスの変更規則]、[繰返し回数]について、一括更新型アルゴリズムと同じとする。

スケジューラは次の 6 つのブロックを管理する。

Step 0 (初期状態 $k = 0$)

次のような初期値が与えられている。

- neuro-node $\prod_{q=0}^{Q-1} C^{(q)}[old]$
- グループ化パターン $u[old]$
- neuro-node 近傍 $O^{(q)}(c_{n_q}^{(q)}[old], [old])$
- neuro-node 更新確率 $p^{(q)}(b^{(q)}[old],$
 $O^{(q)}(c_{n_q}^{(q)}[old], [old]))$,
 $b^{(q)}[old] \in O^{(q)}(c_{n_q}^{(q)}[old], [old]).$
- neuro-node 選択回数 $h_{n_q}^{(q)} = 0$, その集合を H と表す。
- 結合量 $\alpha_L[old]$.
- 学習率 $\epsilon^{(q)}[old]$.

Step 1 (グループ化 $k := k + 1$)

グループ化写像選択規則により選ばれた φ をデータに適用し、

$$B[new] = \varphi(B[old]) = \{v_j\}$$

を求める。すなわち、部分最適化により $u[new]$ を求める。

Step 2 (停止判定)

$k \geq K_{max}$ になつていれば終了し、 u と $\prod_{q=0}^{Q-1} C^{(q)}$ を得る。

Step 3 (最優位neuro-nodeの発見)

$$d_H(\cdot, \prod_{q=0}^{Q-1} c_{n_q}^{(q)}[old]) = f(d(\cdot, \prod_{q=0}^{Q-1} c_{n_q}^{(q)}[old]), H[old])$$

を用いて、 v_j に対する最優位 neuro-node

$$\prod_{q=0}^{Q-1} c_{v_j}^{(q)}[old], \quad \forall v_j \in B[new]$$

を求める。そして、

$$h_{n_q}^{(q)}[new] = h_{n_q}^{(q)}[old] + 1$$

を行なう。

Step 4 (neuro-nodeの更新)Step 4.1 (最優位neuro-nodeとその近傍neuro-nodeの更新)

$$\begin{cases} c_{v_j}^{(q)}[new] = c_{v_j}^{(q)}[old] + \epsilon^{(q)}[old]r^{(q)}(v_j, c_{v_j}^{(q)}[old]), \\ w.p. p^{(q)}(c_{v_j}^{(q)}[old], O^{(q)}(c_{v_j}^{(q)}[old], [old])), \\ \forall q, \forall v_j \in B[new]. \end{cases}$$

$$\begin{cases} b^{(q)}[new] = b^{(q)}[old] + \epsilon^{(q)}[old]r^{(q)}(v_j, b^{(q)}[old]), \\ w.p. p^{(q)}(b^{(q)}[old], O^{(q)}(c_{v_j}^{(q)}[old], [old])), \\ \forall b^{(q)} \in O(c_{v_j}^{(q)}[old], [old]), \\ \forall q, \forall v_j \in B[new]. \end{cases}$$

を実行する。

Step 4.2 (興奮性および抑制性結合に関連した更新)

$e^{(q)}[old]$ は $c_{v_j}^{(q)}[new]$ との興奮性/抑制性結合が決められている neuro-node とする。このとき、次のように更新する。

$$\begin{aligned} b^{(q)}[new] &= b^{(q)}[old] \pm \epsilon^{(q)}[old]r^{(q)}(v_j, b^{(q)}[old]), \\ w.p. \alpha_L p^{(q)}(b^{(q)}[old], O^{(q)}(e^{(q)}[old], [old])), \\ \forall b^{(q)}[old] \in O^{(q)}(e^{(q)}[old], [old]), \forall v_j \in B[new], \forall q. \end{aligned}$$

ただし、 $+\epsilon^{(q)}[old]$ は興奮性結合、 $-\epsilon^{(q)}[old]$ は抑制性結合を意味する。

Step 5 (各種の変更規則の実行)

学習率を更新する他は一括更新型と同じで、Step 1 に戻る。

5. 収束性

収束性については次の事がいえる。

(定理) 一括更新型アルゴリズムも逐次更新型アルゴリズムも $K_{max} \rightarrow \infty$ のとき収束する。

(注) 一括更新型については、条件を厳しくすると K_{max} が有限で収束する。

6. 修正ベクトルの例

巡回セールスマントロード問題や画像のような 2 次形式については、

$$r^{(q)}(v_j, c_{v_j}^{(q)}[old]) = \bar{w}^{(q)}(v_j) - c_{v_j}^{(q)}[old],$$

音声については、

$$r_i^{(q)}(v_j, c_{v_i}^{(q)}[old]) = 2(k_{v_i}^{(i)} - k(i))/f(k_{v_i}^{(i)}, k(i)), \forall i.$$

となる。ここに、 $f(\cdot, \cdot)$ は、線形予測理論により同出される重み量である。

7. 考察

LGB ベクトル量子化は、一括更新型による $\varphi = \varphi^0$ で $Q = 1$ かつ O, L, α_L, H のない場合である。Kohonen らによるベクトル量子化は、 $\varphi \equiv \varphi^0$ 、 $Q = 1, 2$ 乗ノルムコストであり、 L, α_L, H のない場合である。

可変領域ベクトル量子化^[1]は一括更新型で、 O, L, α_L, H のない場合である。

適用例については、本大会の別稿として与えてある。

文献

- [1] 松山、可変領域ベクトル量子化、信学論、Vol. J70-A, p.1830 (1987).
- [2] Matsuyama, Y., Multiple descent cost algorithms, IJCNN-WASH-90 (1990).

- [3] Kohonen, T., Self-Organization and Associative Memory, Springer (1984 and 1988).