

時系列アナログパターンのための領域表現を用いた高速 KFM 連想メモリ

緑川裕樹 長名優子

東京工科大学 コンピュータサイエンス学部

1 はじめに

ニューラルネットワークのモデルの多くでは学習過程と実行過程が分離しているため、学習すべき情報があらかじめすべて与えられていなければ学習を行うことができない。しかし、実際にはあらかじめ記憶すべき情報がすべては得られない場合も数多く存在し、そのような場合には逐次学習可能なモデルが必要となる。

本研究では、時系列アナログパターンのための領域表現を用いた高速 KFM (Kohonen Feature Map) 連想メモリを提案する。提案モデルは、時系列アナログパターンのための領域表現を用いた改良型 KFM 連想メモリ [1] に基づいたモデルであり、重みの更新方法を変更することで学習の高速化を実現している。また、想起時に再帰差分ベクトルのノルムがしきい値以下であるようなマップ層のニューロンを勝ちニューロンとしてランダムに 1 つ選択するように変更することで、時系列パターンの先頭が共通項であるような場合にも正しく想起が行えるようにしている。

2 時系列アナログパターンのための領域表現を用いた高速 KFM 連想メモリ

2.1 構造

提案モデルは入出力層とマップ層の 2 層から構成されており、入出力層は $\mathbf{Y}^{(k,t)}$ と $\mathbf{Y}^{(k,t+1)}$ の 2 つのパターンに対応する 2 つの部分に分けられている。このモデルでは再帰差分ベクトルを用いることで共通項を含むような時系列パターンの連想を実現している。

2.2 学習過程

$\mathbf{Y}^{(k,1)} \rightarrow \mathbf{Y}^{(k,2)} \rightarrow \dots \rightarrow \mathbf{Y}^{(k,t_k)}$ のような時系列パターンを学習する場合、 k 番目の時系列パターンの t 番目のパターンを学習するための学習ベクトル $\{\mathbf{X}^{(k,t)}\}_{k=1,\dots,p}$ として式 (1) のようなベクトル用

Fast Kohonen Feature Map Associative Memory using Area Representation for Analog Sequential Patterns
Hiroki Midorikawa and Yuko Osana (Tokyo University of Technology, osana@cs.teu.ac.jp)

いる。

$$\mathbf{X}^{(k,t)} = (\mathbf{Y}^{(k,t)}, \mathbf{Y}^{(k,t+1)})^T \quad (t = 1, \dots, t_k - 1) \quad (1)$$

学習アルゴリズムを以下に示す。

- (1) ランダムに重みの初期値を選び、再帰差分ベクトルを $\mathbf{y}_i = \mathbf{0}$ とする。
- (2) マップ層の各ニューロンに対して、再帰差分ベクトルを求める。時系列パターン k の t 番目のパターン $\mathbf{X}^{(k,t)}$ に対するマップ層ニューロン i の再帰差分ベクトル $\mathbf{y}_i(t)$ は、

$$y_{ij}(t) = \begin{cases} \sum_{n=0}^t (1-\beta)^{t-n} X_j^{(k,t)} - \sum_{n=0}^t (1-\beta)^n W_{ij}(t), & (j \leq M/2) \\ X_j^{(k,t)} - W_{ij}(t), & (\text{それ以外}) \end{cases} \quad (2)$$

で与えられる。ここで、 β ($0.5 < \beta < 1$) は重み付け係数である。

- (3) マップ層の勝ちニューロン r を以下のように決定する。

$$r = \underset{i: 1-s H^{\text{learn}}(d_{ii^*}) < \theta^r}{\operatorname{argmin}} (\|\mathbf{y}_i(t)\| (1 - s H^{\text{learn}}(d_{ii^*}))) \quad (3)$$

ここで、 s は $0 < s < 1$ の係数である。また、 d_{ii^*} はニューロン i とニューロン i に一番近い重みが固定されているニューロン i^* の距離である。また、式 (3)において、 $H^{\text{learn}}(d_{ii^*})$ は、

$$H^{\text{learn}}(d_{ii^*}) = \frac{1}{1 + \exp\left(-\frac{d_{ii^*} - 2D}{\varepsilon^t}\right)} \quad (4)$$

で与えられる。ここで、 D は領域のサイズを決める定数、 ε^t は関数の傾きを決める係数である。提案モデルでは、式 (4) を用いることで重みが固定されたニューロンから $2D$ 以上離れた位置にあるニューロンが勝ちニューロンとして選ばれ、確実に勝ちニューロンを中心とした半径 D の円で表される領域を確保できるようにしている。

- (4) 重みの値が固定されていないニューロンに結合する重みベクトルを以下の式に基づいて更新する。

$$W_{ij}(t+1) = \begin{cases} \frac{\sum_{n=0}^t (1-\beta)^{t-n} X_j^{(k,t)}}{\sum_{n=0}^t (1-\beta)^n} & \\ X_j^{(k,t)}, (\theta_1^{\text{learn}} \leq H(d_{ri}) \text{かつ } j \leq M/2) \\ W_{ij}(t) + H(d_{ri}) \left(\frac{\sum_{n=0}^t (1-\beta)^{t-n} X_j^{(k,t)}}{\sum_{n=0}^t (1-\beta)^n} \right) & \\ (\theta_2^{\text{learn}} \leq H(d_{ri}) < \theta_1^{\text{learn}} \text{かつ } H(d_{ii^*}) < \theta_1^{\text{learn}} \text{かつ } M/2 < j) \\ W_{ij}(t) + H(d_{ri}) X_j^{(k,t)}, & \\ (\theta_2^{\text{learn}} \leq H(d_{ri}) < \theta_1^{\text{learn}} \text{かつ } H(d_{ii^*}) < \theta_1^{\text{learn}} \text{かつ } j \leq M/2) \\ W_{ij}(t), & \text{(それ以外)} \end{cases} \quad (5)$$

ここで、 θ_1^{learn} , θ_2^{learn} （ただし、 $\theta_1^{\text{learn}} > \theta_2^{\text{learn}}$ ）はしきい値である。また、 $H(d_{ri})$, $H(d_{ii^*})$ は式 (6) で与えられるような準固定を実現するための関数であり、 $H(d_{ri})$ は近傍関数の役割も果たしている。

$$H(d_{ij}) = \frac{1}{1 + \exp\left(\frac{d_{ij} - D}{\varepsilon}\right)} \quad (6)$$

勝ちニューロンとその周辺の半径 D の円で表される領域に含まれるニューロンに対しては学習ベクトルに基づいて重みを決定し、領域の周辺の部分に関しては再帰差分ベクトルと学習ベクトルを用いて近傍関数も考慮して重みを決定することで重みの更新を繰り返し行う必要がなくなり、かつ近傍領域も含めた学習が可能になる。

- (5) 勝ちニューロン r に結合する重みを固定する。
 (6) $t = t_k - 1$ になるまで (2)～(5) を繰り返す。
 (7) 新しい時系列パターンが与えられるたびに (2)～(6) を繰り返す。

2.3 想起過程

提案モデルの想起過程では、入出力層の左側の部分にパターンが入力されると対応するパターンが入出力層の右側の部分に出力される。パターン $\mathbf{X}^{(t)}$ ($= (\mathbf{Y}^{(t)}, \mathbf{0})^T$) が入力されたときのマップ層のニューロン i の時刻 t における出力 $x_i^{\text{map}}(t)$ は

$$x_i^{\text{map}}(t) = \begin{cases} 1, & (i = r) \\ 0, & \text{(それ以外)} \end{cases} \quad (7)$$

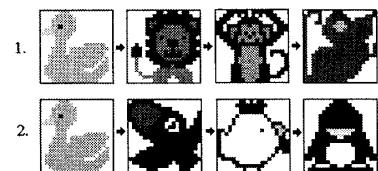


図 1: 学習パターンの例

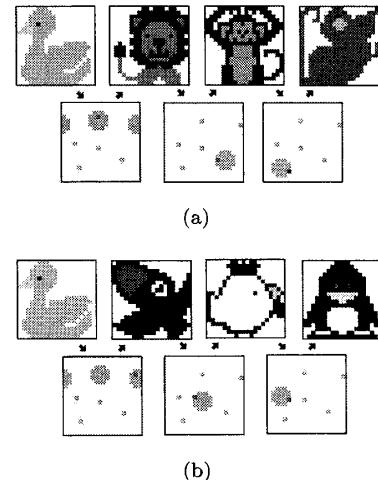


図 2: 想起結果

で与えられる。なお、 r は

$$\| \mathbf{y}_i(t) \| \leq \theta^{\text{map}} \quad (8)$$

を満たすニューロンの中からランダムに 1 つ選ばれる。ここで、 $\mathbf{y}_i(t)$ はマップ層のニューロン i の時刻 t における再帰差分ベクトルである。また、 θ^{map} はマップ層ニューロンのしきい値である。また、入出力層のニューロン j の時刻 t における出力 $x_j^{\text{io}}(t)$ は

$$x_j^{\text{io}}(t) = W_{rj} \quad (9)$$

で与えられる。

3 計算機実験

図 1 に示すような共通項を含む時系列パターンを提案モデルに学習させ、想起を行った結果を図 2 に示す。また、同じ長さの時系列パターンを学習するのに要する時間を従来のモデル [1] と比較したところ、1/15 程度に短縮できることを確認した。

参考文献

- [1] T. Shiratori and Y. Osana : "Kohonen feature map associative memory with area representation for sequential analog patterns," Proceedings of IEEE and INNS International Joint Conference on Neural Networks, Hong Kong, 2008.