

重みベクトルの分布に基づいた想起が可能な KFM 連想メモリの学習の高速化の実現

羽田貴央 長名優子

東京工科大学大学院 バイオ・情報メディア研究科コンピュータサイエンス専攻

1 はじめに

近年、生物の脳や神経系に見られるような柔軟な情報処理を行う手法として、ニューラルネットワークの研究が盛んに行われており、多くのモデルが提案されている。しかしながら、これら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。それに対し、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する。そのような場合には学習過程と実行過程を区別しない逐次学習可能なモデルが必要となる。

本研究では、重みベクトルの分布に基づいた想起が可能な KFM(Kohonen Feature Map) 連想メモリ [1] において、学習時に学習する領域の中心となるニューロンを決定する方法を工夫することで学習の高速化と記憶容量の改善を行う。

2 重みベクトルの分布に基づいた想起が可能な KFM 連想メモリの学習の高速化

提案モデルでは、学習が十分に進んだニューロンの重みを固定し、新しいパターンを学習する場合には、重みが固定されたニューロンとその周辺の領域と重ならないように領域を確保できるようなニューロンのみを対象として学習する領域の中心となるニューロンを決定することで、学習済みパターンの情報の破壊を防ぎつつ、新しいパターンの学習を行うことができる。また、学習パターンに対応した領域のサイズはパターンごとに設定することができる。提案モデルでは、学習時に学習する領域の中心となるニューロンを決定する方法を工夫することで学習の高速化と記憶容量の改善を行う。想起時には、入力パターンに対応する複数のニューロンのうち 1 つだけがランダムに選ばれて発火する。このモデルでは、入力パターンに類似した

Faster Learning for KFM Probabilistic Associative Memory based on Weights Distribution
Takahiro Hada and Yuko Osana (Tokyo University of Technology takahiro@osn.cs.teu.ac.jp, osana@cc.teu.ac.jp)

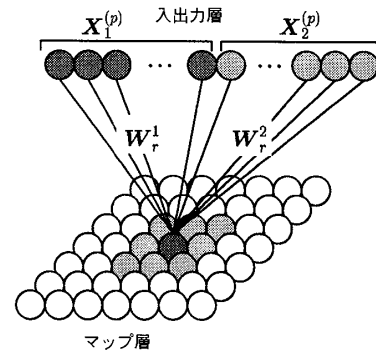


図 1: 提案モデルの構造

重みを持つ複数のニューロンの中からランダムに勝ちニューロンが選ばれることで、重みベクトルの分布に基づいた想起が可能となる。

2.1 構造

提案モデルは図 1 に示すように入出力層とマップ層から構成されており、入出力層は複数のパターンを表す部分に分けられている。図 1 の例では、 $X_1^{(p)}$ と $X_2^{(p)}$ 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。

2.2 学習過程

提案モデルでは、以下のように学習を行う。

- (1) ランダムに重みの初期値を選ぶ。
- (2) 学習ベクトル $X^{(p)}$ と重みベクトル W_i のユークリッド距離 $d(X^{(p)}, W_i)$ を計算する。
- (3) ユークリッド距離が最小となるニューロン r に関して $d(X^{(p)}, W_r) \leq \theta^t$ であれば、 $X^{(p)}$ は既学習であると判断し、(8) へ進む。未学習の場合には、(4) へ進む。
- (4) 重みが固定されたニューロンとその周辺の領域と重ならないように領域を確保できるようなニューロンのみを対象として、学習する領域の中心となるニューロン c を決定する。対象となるニューロンの中でユークリッド距離が最小となるニューロン




図 2: 重みベクトルの分布に基づいた想起が可能な KFM 連想メモリにおける学習する領域の中心となる座標の決定方法

が学習する領域の中心として選ばれる。従来の重みベクトルの分布に基づいた想起が可能な KFM 連想メモリでは、図 2 に示すような領域を候補として考えている。それに対し、提案モデルでは図 3 のように領域を確保できるニューロンのうち既学習の領域からの距離が短いニューロンのみを候補としている。このように、候補となるニューロンの数をしぼることで学習する領域の中心となるニューロンの決定にかかる時間が短縮され、学習が高速化できる。また、マップ層を効率的に使用することができるようになるため、記憶容量の増加にもつながる。

- (5) $d(\mathbf{X}^{(p)}, \mathbf{W}_c) > \theta^t$ のとき、ニューロン c を中心とする楕円領域に含まれるニューロンに結合する重みを以下のように更新する。

$$\mathbf{W}_i(t+1) = \mathbf{W}_i(t) + \alpha(t)(\mathbf{X}^{(p)} - \mathbf{W}_i(t)) \quad (1)$$

ここで、 $\alpha(t)$ は学習係数であり、

$$\alpha(t) = \frac{-\alpha_0(t-T)}{T} \quad (2)$$

のような単調減少関数で与えられる。ここで、 α_0 は $\alpha(t)$ の初期値、 T は最大の学習回数である。

- (6) $d(\mathbf{X}^{(p)}, \mathbf{W}_c) \leq \theta^t$ になるまで (5) を繰り返す。
 (7) 学習する領域の中心となるニューロン c に結合する重み \mathbf{W}_c を固定する。
 (8) 新しいパターンが入力されるたびに (2)~(7) を繰り返す。

2.3 想起過程

想起過程では、従来の重みベクトルの分布に基づいた想起が可能な KFM 連想メモリ [1] と同様の方法で想起を行う。




図 3: 提案モデルにおける学習する領域の中心となる座標の決定方法




図 4: 記憶容量

3 計算機実験

入出力層のニューロン数が 800、マップ層のニューロン数が 900 の提案モデルと従来の重みベクトルの分布に基づいた KFM 連想メモリの記憶容量を図 4 に示す。図 4 より、提案モデルの記憶容量が従来モデルより大きいことが分かる。

また、提案モデルの学習速度を調べる実験を行った。入出力層のニューロン数が 800、マップ層のニューロン数が 900 のネットワークにおいてパターンを学習させたところ、1つのパターンを学習するのにかかった時間の平均は 0.0794 秒であった。それに対し、従来モデルでは 1つのパターンを学習するのに平均 0.1669 秒かかることから、学習速度も高速化できていることが分かる。なお、実験は Pentium 4 (CPU 3GHz), Free BSD 6.3, gcc 3.4.6 の環境で行った。

参考文献

- [1] 小池昌弘, 長名優子: “重みベクトルの分布に基づいた想起が可能な KFM 連想メモリによる強化学習の実現,” 情報処理学会第 71 回全国大会論文集, 2009.