

# 動径基底 ART マップとサポートベクターマシンの協調

Collaboration of Radial-basis ART-map and Support vector Machines

徳永 章哲<sup>1</sup>  
Fumiaki Tokunaga

斎藤 利通<sup>1</sup>  
Toshimichi Saito

法政大学 理工学部 電気電子工学科<sup>1</sup>  
Electrical and Electronics Department, Faculty of Science and Engineering, Hosei University

## 1 まえがき

適応共鳴理論写像 (ART-Map)[1] とは適応共鳴理論ネットワークを教師あり学習に拡張したものであり、入力情報をカテゴリで分類する認知情報処理モデルの一種である。代表的な ART-Map にはカテゴリが長方形で記述される Fuzzy ART-Map[1]、楕円形で記述される Ellipsoid ART-Map[2]、円形で記述される ART-Map に、新しい適合関数であるビジランスパラメータを導入して、より簡素なアルゴリズムで学習を可能とした Radial Basis ART-Map(RBART)[3] などがあげられる。工学的応用としては、医療診断や信号処理などがあげられる。本稿では、単純パーセプトロンである RBART に中間層を挿入することで、より複雑な形状の学習をする階層 RBART[4] と SVM[5] を比較することで、階層 RBART の特徴を調べる。その結果は ART-Map の研究発展の基礎情報になると思われる。

## 2 階層型 RBART

RBART[3] では後述する Step1~8 で入力層の入力をカテゴリで分類し出力する。階層 RBART[4] では、Step9~11 で入力層で分類された円を入力として、RBART で分類し中間層に蓄える。そして、入力層で分類された円と中間層で分類された円を結合する。アルゴリズムは以下ようになる。

入力層には位置  $P_i = (X_i, Y_i)$  とクラス  $C_i = 1$  または  $C_i = -1$  によって特徴づけられている入力  $I_i$  が  $N$  個蓄えられている。ビジランスパラメータは  $\rho_1$  とする。離散時間を  $t$  とすると、中間層には中心座標  $P_j$  とカテゴリの半径  $r_j$  とクラス  $C_b = 1$  または  $C_b = -1$  の重みベクトル  $W_j(t) = (P_j, r_j, C_b)$  を持つ  $M(t)$  のカテゴリが有る。中間層のビジランスパラメータは  $\rho_2$  とする。

Step1(初期化)  $t = 0$  とする。入力層から初期入力  $I_t$  を提示しカテゴリを挿入する

Step2(入力)  $t = t + 1$  とする。入力層から入力  $I_t$  をランダムに提示する

Step3(維持) 入力が既存のカテゴリ内に入力された場合は step2 へ、そうでない場合は step4 を処理する。

Step4(勝者選択) 各カテゴリについて選択関数を  $T_j$  とし、入力に最も近いカテゴリを勝者カテゴリとして

Step5 へ向かう。

$$T_j = \sqrt{(x_j - X_i(t))^2 + (y_j - Y_i(t))^2} - kr_j \quad (1)$$

Step5(行動選択) 勝者カテゴリの選択関数  $T_j$  とビジラ

ンスパラメータ  $\rho_1$  を比較する。  $T_j$  が大きければ挿入として step7 へ。  $\rho_1$  が大きければ拡大として step6 へ。 Step6(拡大) 勝者カテゴリの位置と半径を更新する。以下に勝者カテゴリの重みベクトルの更新式を示す。

$$P_j = \frac{1}{2} \left( r_j \left( \frac{P_j - P_i(t)}{\sqrt{(x_j - X_i(t))^2 + (y_j - Y_i(t))^2}} \right) + P_j + P_i(t) \right) \quad (2)$$

$$r_j = \sqrt{(x_j - X_i(t))^2 + (y_j - Y_i(t))^2} \quad (3)$$

Step7(挿入) 入力座標を中心とした、半径 0、クラス  $I_i(t)$  の新たなカテゴリを挿入する。

Step8(終了判定)  $t < N$  の場合 Step2 へ、  $t = N$  の時、カテゴリ数を  $M$  として Step9 へ

以上が RBART のアルゴリズムである。以下からは中間層から出力層にかけてのカテゴリの統合を行う学習アルゴリズムである。

Step9(設定) 時間を  $t = 0$  とし中間層ビジランスパラメータ  $\rho_2$  を設定して Step10 へ

Step10(結合するカテゴリの決定) 中間層のカテゴリの中心を入力として step2 から学習を行う。  $t = M$  とするまでこれを繰り返す。

Step11(結合) 中間層に蓄えられたカテゴリの中心と、step9 で作成されたカテゴリが重なったとき、カテゴリを結合する。

## 3 数値実験

本稿の目的のため、UCI machine learning repository にある、データ数 768、次元数 2 のベンチマーク fourclass に対して数値実験を行った。入力データは全体の 80%(データ数 688) とする。パラメータは以下のように設定した。

ビジランスパラメータ  $\rho_1 = 0.2$ 、距離パラメータ  $K = -0.5$ 、中間層ビジランスパラメータ  $\rho_2 = 0.27$ 。

図 1 に RBART で分類化した実行結果とその階層化の実行結果を示す。×印はエラーが発生した箇所である。図 2 に図 1(a) である RBART の学習過程を示す。図 3 に図 1(b) である階層 RBART の学習過程を示す。評価方法は下の式で表すエラー率 (%)

$$\text{エラー率} = \left( \frac{\text{エラー数}}{\text{評価データ数}} \right) * 100 \quad (4)$$

とカテゴリ数で評価する。

これらの結果から、ART の結合によりエラー率が改善した。理由としてはカテゴリ間の空白を階層化したカテ

ゴリが埋めることにより、汎化能力が上昇したことがあげられる。またカテゴリの結合により少ないカテゴリで分類することができた。

次に、SVMとRBART、階層RBARTで最もエラー率が少ない時の実行結果を表1に示す。その時のカテゴリ数とサポートベクター(SV)数を表2に示す。SVMのプログラムはSVM-lightを使用する。カーネルはガウシアンカーネルを選択する。

表1 最少エラー率

ベンチマーク	RBART	階層 RBART	SVM
fourclass	2%	1.4%	0%

表2 最少エラー率の時のカテゴリ数とSVMのSV数

ベンチマーク	RBART	階層 RBART	SVM
fourclass	27個	14個	30個

表1から階層RBARTは少数のエラーを発生させてしまったが、SVMがプログラムの学習に時間がかかったのに対し、高速で処理することができた。表2から階層RBARTはもっとも少ないカテゴリ数で分類することができた。

4 むすび

SVMと階層RBARTの比較を行い、階層RBARTの特徴について考察した。学習過程の解析、大規模問題の適用などが課題である。

参考文献

- [1] G. A. Carpenter, S. Grossberg, & D. B. Rosen, Neural Networks, 1991.
- [2] G. C. Anagnostopoulos and M. Georgiopoulos, Proc. IJCNN, 2000.
- [3] Y. Enosawa, H. Matsushita, Y. Tanaka, N. Kuji and T. Saito, Journal of Signal Processing, 2012.
- [4] Y. Okamoto, and T. Saito, Proc. Technical Report of IE-ICE. NC, 2012-77.
- [5] V.N.Vapnik, Statistical Learning Theory, John Wiley & Sons, 1998.






図1 実行結果 (a)RBART. (b)RBARTの階層化




(a)




(b)

図2 RBARTの学習過程 (a) カテゴリ数 (b) エラー率



(a)



(b)

図3 階層RBARTの学習過程 (a) カテゴリ数の変化 (b) エラー率の変化