

動径基底ARTマップの分類能力について

江野澤, 瑠子 / ENOSAWA, Yoko

(発行年 / Year)

2012-03-24

(学位授与年月日 / Date of Granted)

2012-03-24

(学位名 / Degree Name)

修士(工学)

(学位授与機関 / Degree Grantor)

法政大学 (Hosei University)

2011年度 修士論文

論文題名 動径基底 ART マップの分類能力について

指導教授 斎藤 利通 教授

法政大学大学院工学研究科

電気工学専攻修士課程

学生証番号： 10R3109

エノサワ ヨウコ

氏名 江野澤 瑶子

あらまし

教師なし学習システムである適応共鳴理論ネットワーク (Adaptive Resonance Theory networks: ART-nets) は, 典型的な認知情報処理モデルであり, 入力と記憶の類似度に基づいてカテゴリを適応的に生成・拡大させるシステムである. 一般にニューラルネットワークの学習では, 新しいパターンを学習すると過去の記憶が失われ, 過去の記憶を重視すると新しいパターンの入手が困難になる問題が存在する. しかし ART ネットワークは, 入力と記憶の類似度をビジランスパラメータ (警戒パラメータ) と呼ばれる分類尺度を用いることにより, この問題を解決することに力点を置いている. 一方, ART ネットワークの教師あり学習システムとして, 2つの ART ネットワークをマップフィールドで結合した ART マップ (Adaptive Resonance Theory map: ART-map) があり, 入力データの環境変化に素早く対応できるなどの特徴を持っている.

本論文では, 教師なし学習システムである動径基底 ART ネットワーク (Radial Basis ART-nets) を教師あり学習システムに拡張した, 動径基底 ART マップを用いた分類アルゴリズム (RB-ARTM) を提案する. RB-ARTM は, 特徴空間上に分布したアナログデータを円形カテゴリにより分類する手法である. その RB-ARTM を与えられた分類問題に対し, 他の代表的な分類手法と分割に必要なデータ数について比較し, その基本特性を明らかにする. さらに, 2クラスの分類問題に特化した RB-ARTM を提案し, ベンチマークや実データに適用し, 分類機能について考察する.

Classification Capability of Radial Basis Adaptive Resonance Theory maps

Abstract

The adaptive resonance theory networks (ART-nets) are typical unsupervised learning systems having feature extraction function of objective environments. In order to improve the algorithm performance, several variants have been studied: hypersphere ART-nets, ellipsoid ART-nets, radial basis ART-nets, etc. The adaptive resonance theory maps (ART-maps) are supervised learning systems based on the ART-nets and have flexible classification functions. Applications of the ART-nets and ART-maps are many, including image-processing, adaptive anomaly detection and combinatorial optimization problems.

This paper presents a radial basis ART-map (RB-ARTM) and its application to classification problems. The RB-ARTM is based on the standard ART-maps and the radial basis ART-nets. In order to classify input data with class information, the RB-ARTM generates categories characterized by center, radius and class. The learning algorithm includes two key parameters: vigilance parameter ρ and distance parameter k . These parameters can control the number and size of categories. Using basic three benchmarks, we have confirmed that our algorithm is competitive at classification function with Fuzzy-ARTMAP and support vector machine (SVM). And we investigate the algorithm performance in basic numerical experiments for two example problems: classification of typical benchmarks, and classification of abdomen shapes of expectant mothers.

目次

第1章	まえがき	7
第2章	動径基底 ART マップ	10
2.1	まえがき	10
2.2	学習アルゴリズム	11
2.3	数値実験	13
2.3.1	基本特性の解析	13
2.3.2	空間分割における特徴	14
2.4	むすび	16
第3章	2クラス分類における動径基底 ART マップ	34
3.1	まえがき	34
3.2	学習アルゴリズム	35
3.3	数値実験	37
3.3.1	基本特性の解析	37
3.3.2	産科データの分類	39
3.4	むすび	40
第4章	むすび	54
	参考文献	56
	研究業績	58
	謝辞	60

目次

1.1	代表的な ART ネットワーク	7
1.2	ART ネットワークの構造	8
1.3	ART マップの構造	8
2.1	RB-ARTM のフローチャート	17
2.2	選択関数 T_j . (a) $k = -1$. (b) $k = 0$. (c) $k = +1$	18
2.3	$k = 0$ における学習. (a) 勝者の選択. (b) ビジランステスト. (c) マッチト ラッキング. (d) don't care	19
2.4	一致率の算出方法 (a) 学習結果. (b) エラー	20
2.5	RB-ARTM の学習結果の一例. (a) 入力データ: fourclass. (b) $k = -1$. (c) $k = 0$. (d) $k = +1$	21
2.6	k によるカテゴリ形成数の変化: fourclass	22
2.7	k によるカテゴリ形成数の変化: diabetes	23
2.8	k によるカテゴリ形成数の変化: austlian	24
2.9	ρ_0 によるカテゴリ形成数の変化: fourclass	25
2.10	ρ_0 によるカテゴリ形成数の変化: diabetes	26
2.11	ρ_0 によるカテゴリ形成数の変化: austlian	27
2.12	非線形 SVM による入力空間から高次元特徴空間への写像. (a) p 次元入 力空間. (b) r 次元特徴空間. (c) p 次元入力空間	28
2.13	分類結果例. (a) SVM. (b) RB-ARTM. (c) Fuzzy-ARTM	29
2.14	RB-ARTM の分類能力: CR	30
2.15	RB-ARTM の分類能力: #MD	31

2.16 RB-ARTM と SVM の分類能力の比較 : CR vs #MD	32
3.1 2 クラス分類に特化した RB-ARTM のフローチャート	41
3.2 学習過程. (a) 入力データ ($C_b = -1$). (b) ベースクラスを割付. (c) 残り一方のクラスを割付	42
3.3 3 つの分類問題. (a) Annulus. (b) Checkerboard. (c) Spirals	43
3.4 図 3.3(a) の Annulus によるシミュレーション結果例. (a) 入力データ. (b) 学習結果. (c) 分類結果	44
3.5 図 3.3(b) の Checkerboard によるシミュレーション結果例. (a) 入力データ. (b) 学習結果. (c) 分類結果	45
3.6 図 3.3(c) の Spirals によるシミュレーション結果例. (a) 入力データ. (b) 学習結果. (c) 分類結果	46
3.7 分類能力 : Spirals	47
3.8 分類能力 : Checkerboard	48
3.9 分類能力 : Spirals	49
3.10 妊婦の腹部の形. (a) 男児の例 1. (b) 男児の例 2. (c) 男児の例 3	50
3.11 妊婦の腹部の形. (a) 女児の例 1. (b) 女児の例 2. (c) 女児の例 3	51
3.12 産科データにおける RB-ARTM の適用. (a) 入力データ. (b) シミュレーション結果 ($C_b = +1$). (c) シミュレーション結果 ($C_b = -1$)	52

表 目 次

2.1 分類結果例の分類能力の比較	33
3.1 主成分分析	53

第1章 まえがき

適応共鳴理論ネットワーク (Adaptive Resonance Theory networks, ART-nets) は、自己組織的な学習に基づいて、単位平方面の特徴空間上の入力データの集合をさまざまな形にカテゴリ近似するカテゴリを生成する働きをもつ。基本的な ART システムは S. Grossberg によってヒトの認知情報処理理論として 1991 年に提唱された [1]。ART ネットワークの処理過程は、カテゴリ形成による集合的学習やパターン認識におけるリアルタイムニューラルネットワークモデルに展開される [2]。図 1.1 に表すように、カテゴリの形状によって学習過程が変化する長方形のカテゴリを持つ Fuzzy ART-nets[3]、楕円形のカテゴリを持つ Ellipsoid ART-nets[4]、円形のカテゴリを持つ Hypersphere ART-nets[5] などの ART システムが提唱されている。ART ネットワークの中でもっとも代

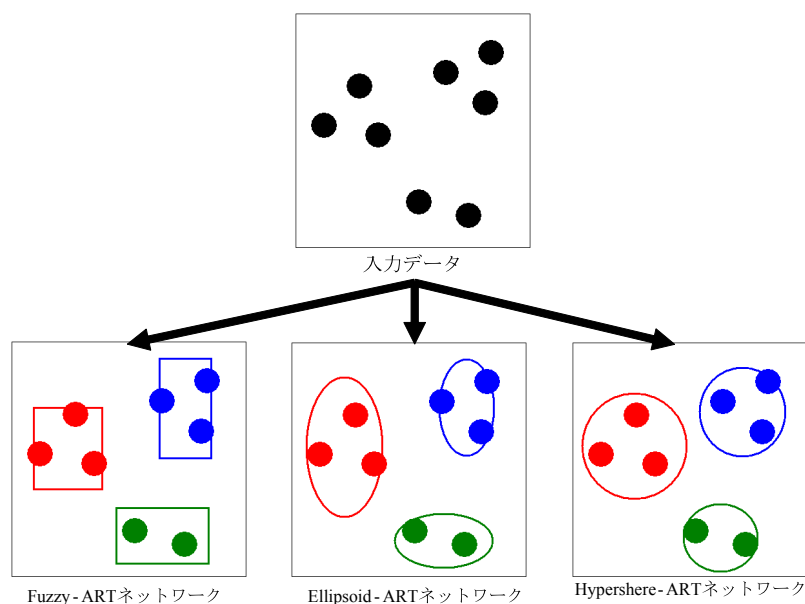


図 1.1: 代表的な ART ネットワーク

表的な Fuzzy ART-nets[3] は、G. A. Carpenter と S. Grossberg により提案された自己組織化教師なし学習ニューラルネットワークであり、入力パターンの記憶・クラスタリ

ング、連想の能力を有するニューラルネットワークである。一般に、ニューラルネットワークの学習では、新しいパターンを学習すると過去の記憶が失われ、過去の記憶の保持を重視すると新しいパターンの手法が困難になる問題が存在するが、ARTシステムはビジランスパラメータ（警戒パラメータ）を用いて、この問題を解決することに力点を置いている。図 1.2 では適応サブシステムが、警戒パラメータの働きを意味している。また、簡素な学習アルゴリズムで分類問題を解けるという特徴をもつ動径基底 ART ネットワーク（Radial Basis ART-nets, RBART-nets）は大木らにより提案され [6]、教師なし学習をベースとした円形で記述されるカテゴリの集合により、入力データの集合を近似する。カテゴリが円形で記述されることで、楕円形で記述される Ellipsoid ART-nets [4] や多角形で記述される ART システム [3][5] よりもメモリの消費量を低く抑えることができる特徴をもつ。

また適応共鳴理論写像（Adaptive Resonance Theory maps, ART-maps）は図 1.2 のような ART ネットワークをもとにした教師あり学習システムである。ここで ART マップの構造を図 1.3 に示す。この ART マップは ART_a と ART_b の対応付けを評価し、その成否に基づいてネットワーク構造を変更する、2 つの ART ネットワーク ART_a と ART_b をマップフィールドで結合した教師あり学習システムである。この ART マップは教師あり学習システムに拡張したことにより、分類問題において学習データの環境変化に素早く対応できるという特徴をもつ [7]-[8]。




図 1.2: ART ネットワークの構造

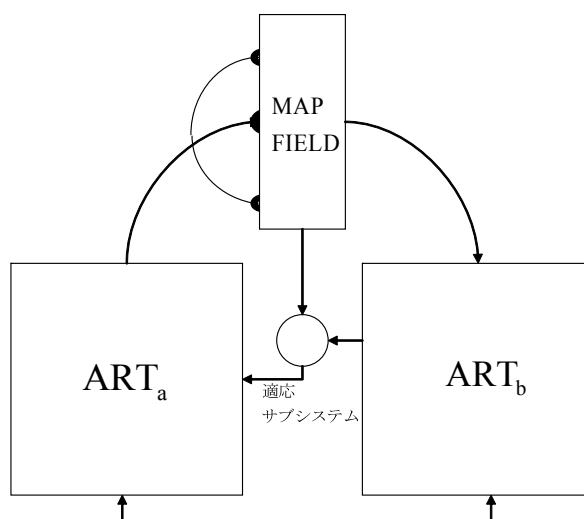


図 1.3: ART マップの構造

ARTシステムの利点は、適応する対象空間上のデータを集合的に捉えることで、安定した学習が可能なことである。さらにアルゴリズムが簡素であり、かつ学習が高速なことも大きな利点である。このARTシステムは応用例も多彩であり、画像処理 [8]、異常検出 [9]、基地局の被膜問題、ニューラルネットワークのパラメータ設定などが研究されてきた。また、ARTシステムのパラメータに依存した学習過程の解析も現在までに盛んに研究されている [6]。現在では計算の並列化をする学習アルゴリズムとしても応用され、新しい並列化学習アルゴリズムを確立する試みも研究されている [10]。

本論文では、RBART-nets を教師あり学習に拡張した RB-ARTM を提案し、その分類能力について考察する。教師あり学習に拡張することにより、環境変化に素早く対応でき、かつ簡素な学習アルゴリズムで分類問題を解くという特徴をもつ。

第2章では、提案する RB-ARTM の学習アルゴリズムについて示す。第2章の本編では、3つのベンチマークをもとに、基本的な数値実験を通しパラメータ設定による分割数の変化と、他手法との空間分割数について比較、考察をする。

第3章では2クラス分類問題に特化した RB-ARTM を提案し、3つの代表的なベンチマークをもとに、基本的な数値実験を通しパラメータ設定による分割数の変化を観察する。また実用的な医学データに RB-ARTM を適用することにより分類問題に取り組む。

第4章に本論文のまとめと今後の課題について述べる。

第2章 動径基底ARTマップ

2.1 まえがき

適応共鳴理論ネットワーク (Adaptive Resonance Theory networks, ART-nets) は典型的な教師なし学習システムであり, ある動作環境において対象とする特徴を抽出する機能をもっている. また, このARTネットワークの性能を改良するために, さまざまな研究がされている. その中で代表的なネットワークとして, 長方形カテゴリである Fuzzy ART-nets[3], 楕円形カテゴリである Ellipsoid ART-nets[4] や円形である動径基底ARTネットワーク [6] が挙げられる. 一方, 適応共鳴理論写像 (Adaptive Resonance Theory maps, ART-maps) はARTネットワークをもとにした教師あり学習システムであり, 分類問題において柔軟に対応できるという特徴をもつ. ARTネットワークとARTマップでは画像処理, 異常検出や最適化問題など, さまざまな応用が発表されている [7]-[10].

本章では, 教師なし学習であるRB-ARTネットワークを, 教師あり学習に拡張した動径基底適応共鳴理論写像 (Radial Basis Adaptive Resonance Theory maps, RB-ARTM) について提案し, その分類機能を考察する. このRB-ARTMは基本的なARTマップとRB-ARTネットワークをもとにしている. クラス情報をもつ入力データを分類するために, RB-ARTMは中心, 半径とクラス情報をもとに円形カテゴリを生成するという特徴がある. この学習アルゴリズムは, 警戒パラメータ ρ と距離パラメータ k という2つの重要なパラメータを用いている. これらのパラメータは, カテゴリの数と大きさを調整する役割をもつ. この分類機能を評価するために, 以下の2つの指標を導入する.

1. カテゴリのクラスと入力の一貫率 (CR)
2. すべてのカテゴリを分割できる最小データ数 (#MD)

ただし，サポートベクターマシン（Support Vector Machine，SVM）[11]では，サポートベクターの数が $\#MD$ と同じ意味をもつと考える． CR と $\#MD$ の影響を調査するために，ベンチマークを用いて基本的な数値実験を行う．その結果，距離パラメータ k は簡単に CR を増加させ，円形カテゴリによる分割は $\#MD$ を現象させることに適することがわかった．とくに， CR が 100% 付近では RB-ARTM の $\#MD$ がサポートベクターとほぼ等しいが，100% から遠ざかるにつれて SVM より RB-ARTM の方が効率的に近似分類を実現できることがわかった．

2.2 学習アルゴリズム

ここでは図 2.1 に示すような，RB-ARTM の学習アルゴリズムを定義する． M はクラス数を意味し， S_0 は N 次元の入力空間である．ここでは簡単化のため， $M = 2$ かつ $N = 2$ の場合に焦点をあてて考える． i 番目の入力 P_i は，位置 X_i とクラス C_i によって，以下のように特徴づけられる．

$$P_i = (X_i, C_i), X_i \equiv (X_i, Y_i) \in S_0, C_i \in \{-1, 1\}, i = 1 \sim N_p \quad (2.1)$$

ただし， N_p は入力数である．離散時間 t における j 番目のカテゴリ W_j は，中心 $x_j \equiv (x_j, y_j)$ ，半径 r_j かつクラス c_j によって特徴づけられる．

$$W_j(t) = (x_j(t), r_j(t), c_j(t)), x_j \in S_0, c_j \in \{-1, 1\}, j = 1 \sim N_c(t) \quad (2.2)$$

このアルゴリズム中では，カテゴリ数 $N_c(t)$ は変数である．

Step 1（初期化）:

各要素を $t = 0$ ， $N_c(t) = 1$ ($j = 1$) かつ $r_j(t) = 0$ とする．カテゴリの中心 $x_j(t) \in S_0$ は乱数を用いて初期化する．警戒パラメータ ρ は初期値 $\rho_0 \in [0, \sqrt{2}]$ によりセットされる．

Step 2（勝者の選択，図 2.2，図 2.3 (a)):

入力 P_i が与えられる．もし入力が既存のあるカテゴリに所属するならば Step 7 へ．さもなければ，入力ともっとも近い勝者カテゴリを以下の式をもとに探す．

$$T_j = \min_j(T_j(X_i)), T_j(X_i) = \|X_i - x_j(t)\| - k \times r_j(t) \quad (2.3)$$

ただし, T_j は j 番目の勝者選択関数である. $\|\cdot\|$ はユークリッド距離であり, $k \in [-1, 1]$ は距離パラメータである. もし $T_j > \rho$ ならば Step3 へ. もし $T_j \leq \rho$ ならば Step4 へ.

Step 3 (新しいカテゴリの生成):

$N_c(t) = N_c(t) + 1$ かつ $j = j + 1$ とし, また $N_c(t)$ は新しいカテゴリ $W_{N_c(t)} = (\mathbf{x}_{N_c(t)}, 0, c_{N_c(t)})$ の接尾辞である. 入力の位置に新しいカテゴリが生成され, $\mathbf{x}_{N_c(t)} = \mathbf{X}_i$ とする. 新しいカテゴリの半径は 0 である. また新しいカテゴリのクラスは入力 P_i と同じクラスであり, すなわち $c_{N_c(t)} = C_i$ である.

Step 4 (ビジランステスト, 図 2.3 (b)):

もし勝者カテゴリ W_j が入力と同じクラスならば, Step5 へ. さもなければ, Step6 へ. もし一致するカテゴリが存在しなければ, 新しいカテゴリが Step3 のように生成され Step7 へ進む.

Step 5 (カテゴリの拡大):

勝者カテゴリ $W_j(t)$ は入力 (\mathbf{X}, C) を含むように拡大したあと, Step7 へ.

$$\begin{aligned} W_j(t) &= (\mathbf{x}_j(t)^{(new)}, r_j(t)^{(new)}, c_j(t)), \\ \mathbf{x}_j(t)^{(new)} &= \frac{1}{2}(r_j(t)^{(old)}((\mathbf{x}_j(t)^{(old)} - \mathbf{X}_i)/\|\mathbf{x}_j(t)^{(old)} - \mathbf{X}_i\|) + \mathbf{x}_j(t)^{(old)} + \mathbf{X}_i, \\ r_j(t)^{(new)} &= \sqrt{(x_j(t)^{(new)} - X_i)^2 + (y_j(t)^{(new)} - Y_i)^2}. \end{aligned} \quad (2.4)$$

Step 6 (マッチトラッキング, 図 2.3 (c)):

$\rho = \rho - \Delta\rho$ と置き換える. ただし, $\Delta\rho \in [0, \rho_0]$ である. 着目している勝者カテゴリは, 図 2.3 (d) のように “don't care” と宣言され, Step2 へ.

Step 7 :

$t = t + 1$ として Step2 へ進み, $t = N_p$ となるまで学習を繰り返す.

カテゴリの割付:

もし入力が複数のカテゴリに存在しているならば, カテゴリの中心ともっとも近いカテゴリに分類されているとみなす.

2.3 数値実験

本実験ではRB-ARTMの分類能力を調べるため、ベンチマークによる基本的な数値実験を行い、その分類機能を考察する。この学習アルゴリズムは、警戒パラメータ ρ と距離パラメータ k という2つの重要なパラメータを用いて分類性能を調べる。ここで分類機能を評価するために、カテゴリのクラスと入力クラスの一致率 CR とすべてのカテゴリを分割できる最小データ数 $\#MD$ を導入し、考察する。

2.3.1 基本特性の解析

入力データとしてthe University of California at Irvine(UCI) machine learning repository[13]が提供している3種類のクラス $M = 2$ のベンチマークを使用した。fourclassはデータ数 $N_p = 862$ で次元数 $N = 2$ 、diabetesはデータ数 $N_p = 768$ で次元数 $N = 8$ 、またheartはデータ数 $N_p = 270$ で次元数 $N = 13$ である。ここで、学習結果を評価するため評価法を導入する。図2.4(a)はRB-ARTMAPによるカテゴリの学習結果を示したものである。赤い線はクラス+1のカテゴリ、青い線はクラス-1のカテゴリ、 \circ : クラス+1、 \square : クラス-1、 \times : エラーを示す。また、図2.4(b)はカテゴリと入力クラスが一致しないデータを示したものである。学習により形成されたカテゴリと入力クラスの一致数と総入力データ数 N_p の比率を一致率 CR として、以下に定義する。

$$CR = \frac{\text{カテゴリと入力クラスの一致数}}{\text{総入力データ数 } N_p} \quad (2.5)$$

図2.5に学習結果の一例を示す。図2.5(a)は入力データfourclassであり(b)から(d)は学習結果であり、距離パラメータ k の変化を表す。赤い線はクラス+1のカテゴリ、青い線はクラス-1のカテゴリ、 \circ : クラス+1、 \square : クラス-1、 \times : エラーを示す。ただし、 $\rho_0 = 0.4$ 、 $\Delta\rho = 0.4\rho_0$ と固定した。また3種類のベンチマークにおいて、 $\rho_0 = 0.3$ と $\Delta\rho = 0.4\rho_0$ を固定し、 k を変化させたときの試行回数50回の一致率を観察する。3種類のベンチマークfourclass、diabetesとaustlianをそれぞれ図2.6~図2.8として示す。青い点：最良値、赤い点：平均値、緑点：最悪値を示す。これらの図は k を変化させた

ときのカテゴリ数を表し， k が増加するにつれ，カテゴリ数が減少していることがわかる．一方， $k = 0$ と $\Delta\rho = 0.4\rho_0$ を固定し， ρ_0 を変化させたときの試行回数 50 回の一致率を観察する．3 種類のベンチマーク fourclass，diabetes と austlian をそれぞれ図 2.9～図 2.11 として示す．青い点：最良値，赤い点：平均値，緑点：最悪値を示す．これらの図は ρ_0 を変化させたときのカテゴリ数を表し， ρ_0 が増加するにつれ，カテゴリ数が指数関数的に減少していることがわかる．

2.3.2 空間分割における特徴

ここでは提案した RB-ARTM の分類能力を調べるため，ベンチマーク fourclass を用いて Fuzzy-ARTM と SVM との比較を行う．一般に，分類システムは与えられた入力データを分類するために，分類器が用いられている．ART マップではカテゴリ，SVM では分離超平面という分類器が用いられている．Fuzzy-ARTM は教師あり学習であり，長方形 ART マップである [7]．一般的な手法である Fast Commit Slow Record (FCSR) 法を用いることにより， $\beta = 1$ と設定した場合，細かな分類が可能で高速学習ができる．数値実験では，Fuzzy-ARTM として FCSR 法を用いて，解析を行った．一方，SVM は教師あり学習であり，サポートベクターに基づいて超平面を決める [11]．図 2.12 (a) のように線形分離不可能な入力データを図 2.12 (b) のように高次元特徴空間へ写像し分離超平面をもとに分類するが，ここでカーネル関数を用いることにより，その内積は低次元の内積で容易に計算できるという SVM の利点が挙げられる [12]．その後図 2.12 (c) のようにもとの入力空間へ逆写像すると，高次元特徴空間で分離超平面だった平面が入力空間では非線形境界となる．これが線形分離不可能な入力データを非線形分離した SVM の働きである．数値実験では，ソフトウェアは SVM-light[14] を用いて，解析を行った．

3 つの分類システムの $CR = 90\%$ 付近の分類結果例を図 2.13 に示す．赤いマークは $C_i = 1$ を，青いマークは $C_i = -1$ を表している．図 2.13 (a) は SVM の分類結果を，緑線

でイメージし非線形境界として示している。CR = 89.9% であり、サポートベクター数は 377 であった。図 2.13 (b) は RB-ARTM の分類結果例であり、CR = 89.8%、カテゴリ数は 10 であった。また図 2.13 (c) は Fuzzy-ARTM の分類結果例であり、CR = 88.3%、カテゴリ数は 8 であった。ここで次元を M と仮定すると、RB-ARTM ではカテゴリは中心と半径からなる円であり、1 つのカテゴリが $(N + 1)$ の数を持つ。また Fuzzy-ARTM では各要素の補数を入力データに含めるため、カテゴリが長方形となり $(2N)$ の数を持つ。一方、SVM はサポートベクターによって分離超平面を形成する決定関数が定まるため (サポートベクター数の N 倍) の数を持つ。分類能力を評価するために、 $\#MD$ を分類結果を描写するために必要な最小データ数と定義すると、それぞれの分類システムは以下のような $\#MD$ を取る。

$$\#MD = \begin{cases} \text{カテゴリ数} \times (N + 1) & \text{for RB-ARTM} \\ \text{カテゴリ数} \times (2N) & \text{for Fuzzy-ARTM} \\ \text{サポートベクター数} \times N & \text{for SVM} \end{cases} \quad (2.6)$$

そのため、表 2.1 に表すようにカテゴリ数は Fuzzy-ARTM の方が少ないが、 $\#MD$ は RB-ARTM の方が少ないことがわかる。これはカテゴリ数において比較した場合、RB-ARTM と Fuzzy-ARTM に大差がなくとも、 $\#MD$ において比較した場合、次元数 N が増加するにつれ大きな差が出てくることを示している。

図 2.14 と図 2.15 に 10 回試行したときの平均をそれぞれ CR と $\#MD$ に着目した分類結果を表す。ただし、初期状態と入力順序はランダムに取っている。初期警戒パラメータ ρ_0 はそれぞれ 0.1, 0.4, 0.8 の各値に、また $\Delta\rho = 0.4\rho_0$ で固定している。距離パラメータ k は変数である。 $\rho_0 = 0.1$ のとき、CR はほぼ 100% であるが $\#MD$ は大きな値を取っている。 $\rho_0 = 0.4$ のとき、 k が増加するにつれ、CR と $\#MD$ は減少している。CR が高く $\#MD$ が小さい値を取るということを実現のは難しく、トレードオフの関係となっている。 $\rho_0 = 0.8$ のとき、CR は 80% の下付近である。図 2.16 は、RB-ARTM と SVM で比較した CR と $\#MD$ の関係を表している。ただし、SVM では以下のようなガウシアンカーネルを用いた。

$$\text{Gaussiankernel} : K(\mathbf{x}, \mathbf{y}) = \exp\left(-\frac{1}{2\sigma^2}\|\mathbf{x} - \mathbf{y}\|^2\right) \quad (2.7)$$

カーネルにおける標準偏差 σ は変数とすることにより， CR とサポートベクター数を調節した．ただし，訓練エラーとマージンのトレードオフの関係は 1 としている．

数値実験により，以下のようなことがわかった．

(1) $\rho_0 = 0.1$ をとる RB-ARTM と SVM は， $CR = 100\%$ のときほぼ同じ $\#MD$ を必要とする．しかし $CR = 100\%$ から減少していくと，RB-ARTM の $\#MD$ は SVM より小さくなる．この結果から，SVM より RB-ARTM は効率的に分類近似ができるという特徴を示していることがわかった．注意すべき点は，Fuzzy-ARTM でも同様に調べ，RB-ARTM よりも $\#MD$ が大きくなることを確かめていることである．

(2) SVM はカーネルトリックを用いるが，RB-ARTM は円形カテゴリを用いることにより簡単に分類できる．

2.4 むすび

教師あり学習である RB-ARTM を提案し，距離パラメータ k と警戒パラメータ ρ という 2 つの重要なパラメータによる分類能力を調べた．数値実験により，RB-ARTM と SVM はほぼ $CR = 100\%$ を実現できるが， CR が減少すると RB-ARTM の分類の方が SVM より効率的に行えることがわかった．

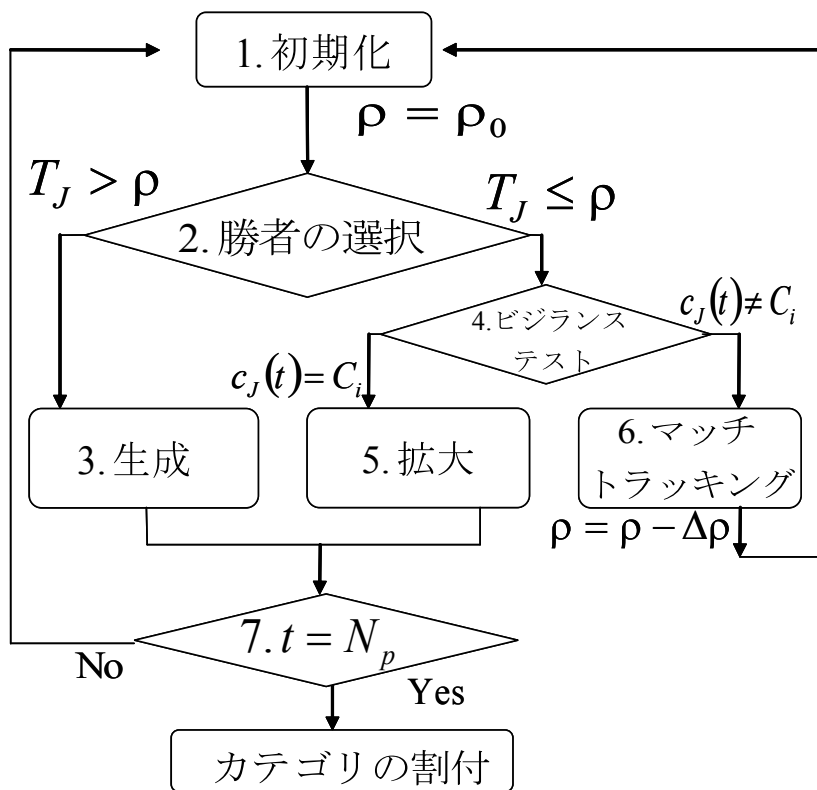


図 2.1: RB-ARTM のフローチャート




図 2.2: 選択関数 T_i . (a) $k = -1$. (b) $k = 0$. (c) $k = +1$

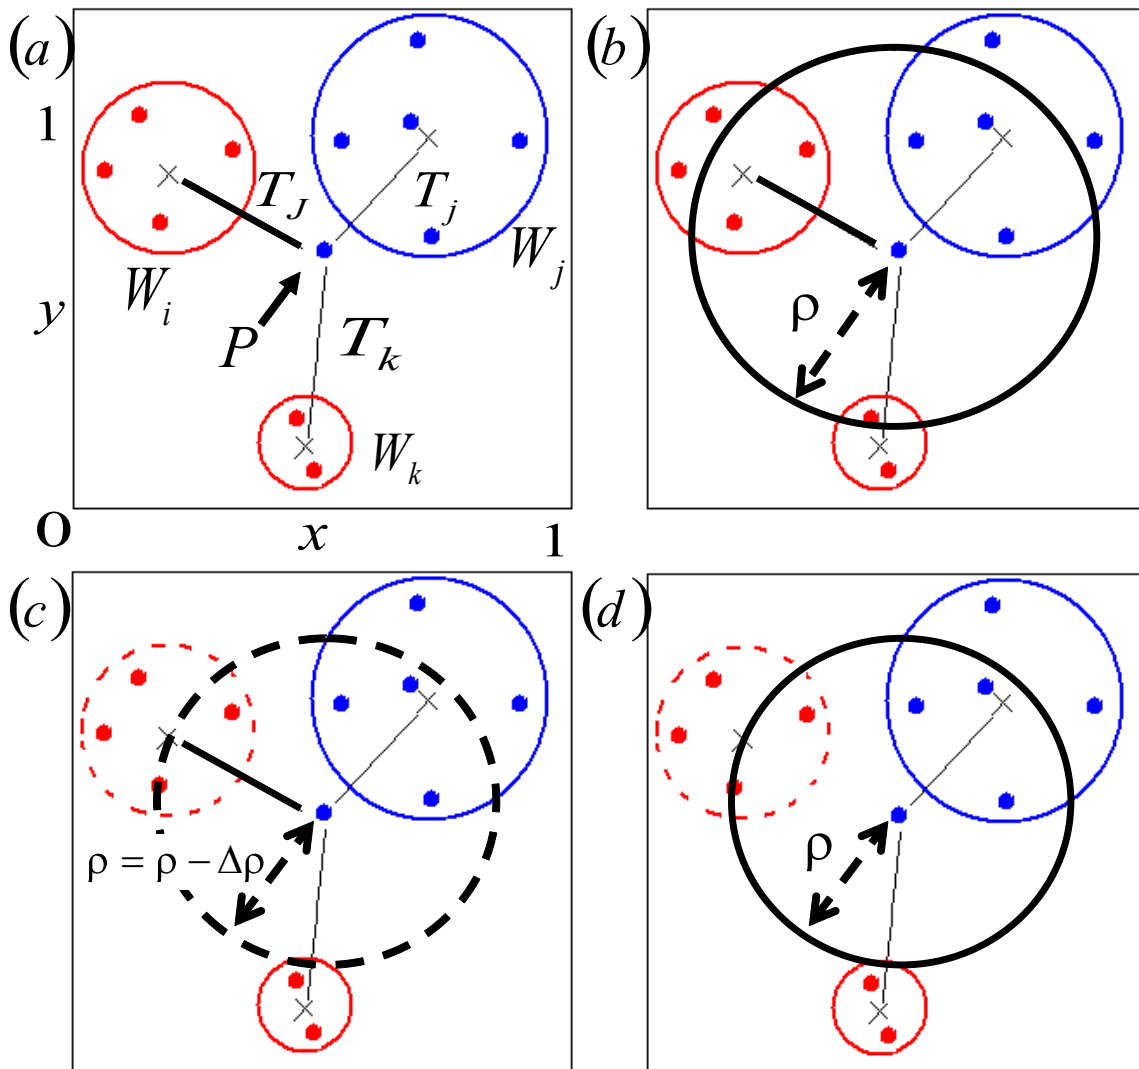


図 2.3: $k = 0$ における学習. (a) 勝者の選択. (b) ビジランステスト. (c) マッチトラッキング. (d) don't care




図 2.4: 一致率の算出方法 (a) 学習結果. (b) エラー




図 2.5: RB-ARTM の学習結果の一例. (a) 入力データ: fourclass. (b) $k = -1$. (c) $k = 0$. (d) $k = +1$




図 2.6: k によるカテゴリー形成数の変化 : fourclass




図 2.7: k によるカテゴリー形成数の変化 : diabetes




図 2.8: k によるカテゴリー形成数の変化 : austlian




図 2.9: ρ_0 によるカテゴリー形成数の変化 : fourclass




図 2.10: ρ_0 によるカテゴリ形成数の変化 : diabetes




図 2.11: ρ_0 によるカテゴリ形成数の変化 : austlian




図 2.12: 非線形 SVM による入力空間から高次元特徴空間への写像. (a) p 次元入力空間. (b) r 次元特徴空間. (c) p 次元入力空間

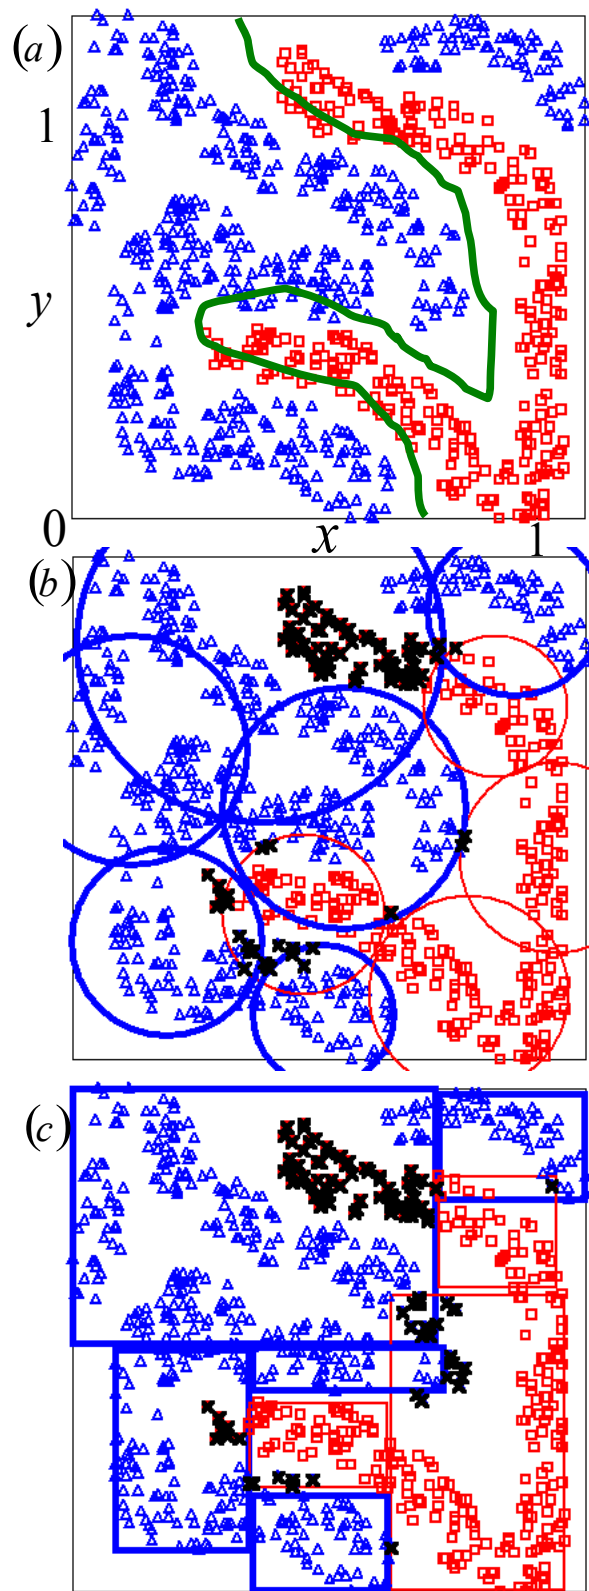


图 2.13: 分類結果例. (a) SVM. (b) RB-ARTM. (c) Fuzzy-ARTM




図 2.14: RB-ARTM の分類能力 : CR




図 2.15: RB-ARTM の分類能力：#MD

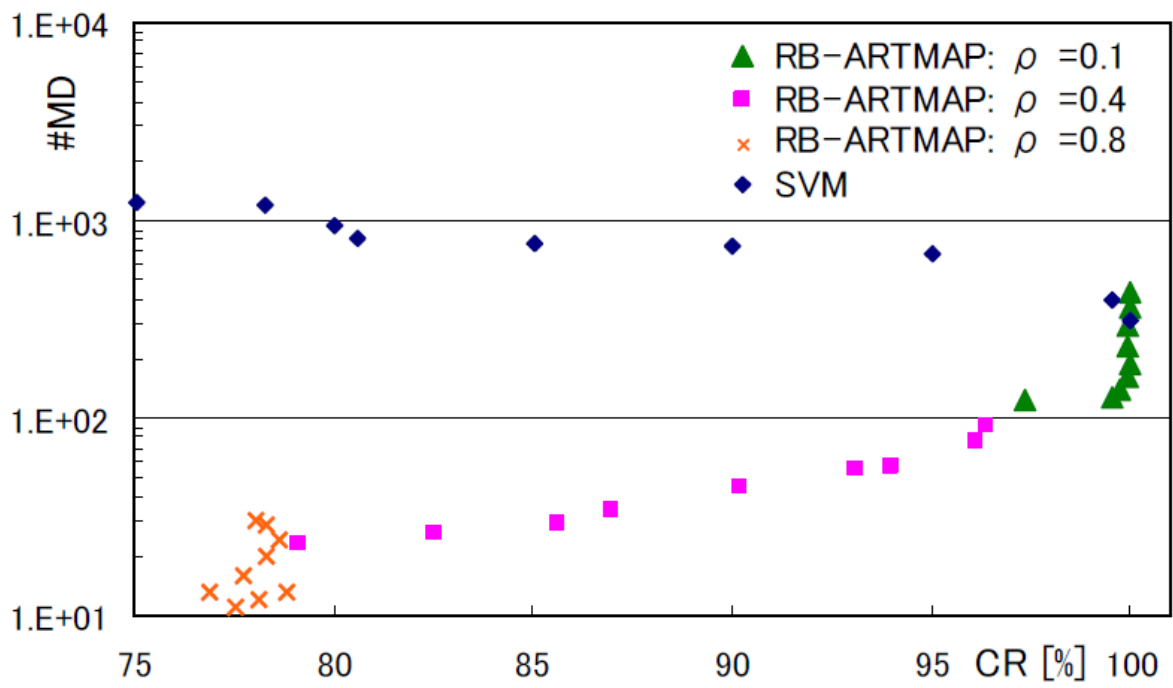


図 2.16: RB-ARTM と SVM の分類能力の比較 : CR vs #MD

表 2.1: 分類結果例の分類能力の比較

分類システム	カテゴリ数	#MD
SVM	377	754
RB-ARTM	10	30
Fuzzy-ARTM	8	32

第3章 2クラス分類における動径基底 ARTマップ

3.1 まえがき

現在，世の中には大量のデータ処理を必要とするデータベース応用分野が著しく拡大している．そして，複雑な分類問題を解こうとすれば，システムのデータ容量がさらに必要とされてきている．複数の分類候補から1つを決定する分類問題を特にマルチクラス分類問題と呼ぶ．それに対し，2クラス分類問題はもっとも基本的な分類問題であり，マルチクラスの学習手法と比較しさまざまな学習手法が行え，また汎用性をもっている．そこで本章では，2クラス分類に特化した教師あり学習に拡張した動径基底適応共鳴理論写像（Radial Basis Adaptive Resonance Theory maps，RB-ARTM）について提案し，分類問題に適用する．また学習アルゴリズムの性能を調べるため，典型的な3つのベンチマークによる分類，産科データによる分類という2つの問題例による基本的な数値実験を行う．そしてRB-ARTMの分類能力における警戒パラメータ ρ と距離パラメータ k という2つの重要なパラメータの影響を調べた．その結果，形成されたカテゴリが多い場合，必ずしも一致率が高いとは限らないことがわかった．また提案したシステムを，実用的なデータである産科データに適用し，RB-ARTMの特徴のひとつである分類結果を視覚的に認識可能な状態にすることにより，産科データのデータ構成を考察した．

3.2 学習アルゴリズム

図 3.1 に示すような、2 クラス分類に特化した RB-ARTM の学習アルゴリズムを以下に定義する。注意すべき点は、ここではベースクラス C_b という重要なパラメータを定義することにより、第 2 章で提案したアルゴリズムと比較し、より簡素なアルゴリズムとなっていることである。

M はクラス数を意味し、 S_0 は N 次元の入力空間である。ここでは簡単化のため、 $M = 2$ かつ $N = 2$ の場合に焦点をあてて考える。 i 番目の入力 P_i は、位置 X_i とクラス C_i によって、以下のように特徴づけられる。

$$P_i = (X_i, C_i), X_i \equiv (X_i, Y_i) \in S_0, C_i \in \{-1, 1\}, i = 1 \sim N_p \quad (3.1)$$

ただし、 N_p は入力数である。離散時間 t における j 番目のカテゴリ W_j は、中心 $x_j \equiv (x_j, y_j)$ 、半径 r_j かつクラス c_j によって特徴づけられる。

$$W_j(t) = (x_j(t), r_j(t), c_j(t)), x_j \in S_0, c_j \in \{-1, 1\}, j = 1 \sim N_c(t) \quad (3.2)$$

このアルゴリズム中では、カテゴリ数 $N_c(t)$ は変数である。学習後、RB-ARTM によって形成されたカテゴリをもとに、入力データは 2 つのクラスのうち 1 つに分類される。この分類のため、ベースクラス C_b という重要なパラメータを定義する。 C_b は 2 つのクラスのうち、一方に比べより多く存在するデータのクラスとして定義される。

Step 1 (初期化):

各要素を $t = 0$ 、 $N_c(0) = 1$ ($j = 1$) かつ $r_j(0) = 0$ とする。カテゴリの中心 $x_j(t) \in S_0$ は乱数を用いて初期化する。

Step 2 (ベースクラスの比較):

入力 P_i が与えられる。もし P_i がベースクラス C_b と同じクラスならば $C_i = C_b$ として、Step3 へ。さもなければ、Step6 へ。

Step 3 (勝者の選択):

もし入力が既存のあるカテゴリに所属するならば Step6 へ。さもなければ、入力 P_i と

もっとも近い勝者カテゴリ W_j を以下の式をもとに探す .

$$T_j = \min_j(T_j(\mathbf{X}_i)), T_j(\mathbf{X}_i) = \|\mathbf{X}_i - \mathbf{x}_j(t)\| - k \times r_j(t) \quad (3.3)$$

ただし , T_j は j 番目の勝者選択関数である . $\|\cdot\|$ はユークリッド距離であり , $k \in [-1, 1]$ は距離パラメータである . もし $T_j > \rho$ ならば Step4 へ . ただし , $\rho_0 \in [0, \sqrt{2}]$ は警戒パラメータである . さもなければ $T_j \leq \rho$ となり , Step5 へ .

Step 4 (新しいカテゴリの生成):

$N_c(t) = N_c(t) + 1$ かつ $j = j + 1$ とし , また $N_c(t)$ は新しいカテゴリ $W_{N_c(t)} = (\mathbf{x}_i, 0, c_i)$ の接尾辞である . 入力 P_i の位置に新しいカテゴリが生成され , 新しいカテゴリの半径は 0 である . また新しいカテゴリのクラスは入力 P_i と同じクラスである . Step6 へ .

Step 5 (カテゴリの拡大):

勝者カテゴリ W_j は入力 P_i を含むように拡大する .

$$\begin{aligned} W_j(t) &= (\mathbf{x}_j(t)^{(new)}, r_j(t)^{(new)}, c_j(t)), \\ \mathbf{x}_j(t)^{(new)} &= \frac{1}{2}(r_j(t)^{(old)}((\mathbf{x}_j(t)^{(old)} - \mathbf{X}_i)/\|\mathbf{x}_j(t)^{(old)} - \mathbf{X}_i\|) + \mathbf{x}_j(t)^{(old)} + \mathbf{X}_i, \\ r_j(t)^{(new)} &= \sqrt{(x_j(t)^{(new)} - X_i)^2 + (y_j(t)^{(new)} - Y_i)^2}. \end{aligned} \quad (3.4)$$

Step 6 :

$t = t + 1$ として Step2 へ進み , $t = N_p$ となるまで学習を繰り返す .

クラスの割付 :

学習後 , RB-ARTM によって形成されたカテゴリをもとに , 入力データは 2 つのクラスのうち 1 つに分類される . もしデータが 1 つ以上のカテゴリに含まれるならば , 図 3.2 (b) に示すようにそのクラスはベースクラス C_b とみなされる . またどのカテゴリにもデータが含まれないならば , 図 3.2 (c) に示すようにベースクラスではない残り一方のクラスに分類される .

3.3 数値実験

本実験では2クラス分類に特化した学習アルゴリズムを検討するため、基本的な実験と産科データにアルゴリズムを適用する。ここで、2クラスで構成される入力データを用い、ベースクラス C_b は2クラスのうちより多いデータのクラスから選択される。このアルゴリズムは、第2章で提案したRB-ARTMより少ないカテゴリ数で入力データを分類できる特徴をもつ。

3.3.1 基本特性の解析

RB-ARTMの性能評価をするため、図3.3に示すようにAnnulus, Checkerboard, Spiralsの3つの分類問題による基本的な数値実験を行った。入力空間の次元数は $N = 2$ であり、クラス数は $M = 2$ である。図3.3(a)に示すAnnulusは、 $(0.5, 0.5)$ を中心とし、半径0.4と0.2の環形である。図3.3(b)に示すCheckerboardは、9つの正方形に交互にクラスが所属している。図3.3(c)に示すSpiralsは、それぞれ半径0.15の3周期である。

訓練サンプルとテストサンプルという2種類のデータを導入する。訓練サンプルはカテゴリを形成する際に用いられ、すなわちRB-ARTMでは入力と捉えられているものである。一方、テストサンプルはシミュレーション結果を評価する際に用いられる。ここで、第2章とは別の一致率 (coincidence rate, cr) という尺度を定義する。 cr は、正答のクラスと一致するかどうかにより、求められるものである。ここでは、形成されたクラスとテストサンプルのクラスを比較する。もしテストサンプルと同じクラスならば、形成されたクラスは正答とみなされる。形成されたクラスの割付方法は、もしテストサンプルが複数のカテゴリに所属するならば、ベースクラス C_b のクラスとみなされ、さもなければクラスは残り一方のクラスとみなされる。

図3.4は、図3.3(a) Annulusのシミュレーション結果例を示している。図3.4(a)では、ランダムに1,000訓練サンプルが選ばれる。青い三角形は+1のクラスを意味し、赤い四角形は-1のクラスを意味している。また、ベースクラス $C_b = -1$ である。図3.4

(b) は学習結果を表している．赤い円で表されているカテゴリ数は7であり，ただし $k = 0$, $\rho = 0.2$ と固定されている．また一致率 cr を評価するため，図 3.4 (c) のようにランダムに 40,000 テストサンプルが選ばれている．黒い点はエラーを意味している．一致率 cr は 84.2% である．図 3.5 は，3.3 (b) Checkerboard のシミュレーション結果例を示している．図 3.5 (a) では，ランダムに 1,000 訓練サンプルが選ばれる．青い三角形は+1 のクラスを意味し，赤い四角形は-1 のクラスを意味している．また，ベースクラス $C_b = -1$ である．図 3.5 (b) は学習結果を表している．赤い円で表されているカテゴリ数は 11 であり，ただし $k = 0$, $\rho = 0.2$ と固定されている．また一致率 cr を評価するため，図 3.5 (c) のようにランダムに 40,000 テストサンプルが選ばれている．黒い点はエラーを意味している．一致率 cr は 84.2% である．図 3.6 は，3.3 (c) Spirals のシミュレーション結果例を示している．図 3.6 (a) では，ランダムに 1,000 訓練サンプルが選ばれる．青い三角形は+1 のクラスを意味し，赤い四角形は-1 のクラスを意味している．また，ベースクラス $C_b = -1$ である．図 3.6 (b) は学習結果を表している．赤い円で表されているカテゴリ数は 7 であり，ただし $k = 0$, $\rho = 0.2$ と固定されている．一致率 cr を評価するため，図 3.6 (c) のようにランダムに 40,000 テストサンプルが選ばれている．黒い点はエラーを意味している．一致率 cr は 57.3% である．

形成されたカテゴリ数と一致率の関係を調べるため， ρ と k という変数パラメータを用いてシミュレーションを行った．ここで警戒パラメータを $\rho = 0, 0.01, 0.02, \dots, \sqrt{2}$ と変化させ，かつ距離パラメータ $k = -1, +1, 0$ の別々のパラメータを組み合わせ，426 種類のパラメータをセットしてシミュレーションに用いた．Annulus , Checkerboard , Spirals はそれぞれ 100 訓練サンプルで構成されている．また，それぞれのパラメータを毎回 50 回ずつセットし，40,000 テストサンプルを用いることによって一致率は計算されている．図 3.7 ~ 図 3.9 は 3 つの分類問題 Annulus , Checkerboard , Spirals のシミュレーション結果をそれぞれ図 3.7 , 図 3.8 , 図 3.9 として示している．横軸は 50 回ずつ各パラメータをセットし，RB-ARTM によって形成されたカテゴリ数であり，縦軸は一致率 cr である．

数値実験から以下のような点がわかった．

(1) カテゴリ数が多い場合，必ずしも一致率が良いわけではない．カテゴリ数が少なくなるにつれ，一致率にばらつきがある．

(2) 警戒パラメータ ρ と距離パラメータ k という2つのパラメータだけがRB-ARTMでは重要である．RB-ARTMの動作はこれら2つのパラメータによって制御できる．

(3) RB-ARTMのシミュレーション結果は入力データの形に強く依存する．

3.3.2 産科データの分類

産科の実用データにおける分類問題にこのアルゴリズムを適用させる．基本データとして，以下のような46人分の妊婦のデータをセットする．

1. 妊娠38, 39週目の腹部の形
2. 新生児の性別

図3.10と図3.11は180プロットからなる男児女児の腹部の形の例を示している．簡素に腹部の特徴を表すために，後ろ M_b ，前 M_f ，右 M_r ，左 M_l という4つの特徴点を導入する．これらの点は，重心 $G_p = (X_g, Y_g)$ を中心とする極座標 (r, θ) によって以下のように定義される．

- M_b : G_p からもっとも近い点 for $\theta \in [-\pi/2, \pi/2]$
- M_f : G_p からもっとも遠い点 for $\theta \in [\pi/2, 3\pi/2]$
- M_r : G_p からもっとも近い点 for $\theta \in [\pi/2, \pi]$
- M_l : G_p からもっとも近い点 for $\theta \in [\pi, 3\pi/2]$

このデータ内の構成を明らかにするため，主成分分析 (Principal Component Analysis, PCA) を適用する．PCAは固有ベクトルをもととし，簡単に多変量解析を行う手法のひとつである [15]．表3.1はPCAの結果を示している．この表より，第1主成分と第2主成分で構成される累積寄与率は90.7%となり，データ内の構成の大部分を占めてい

ることがわかる．ここから，第1主成分と第2主成分のを構成している M_f と M_l について調べる．

RB-ARTM を適用するため，図 3.12 (a) に表すような M_f vs. M_l 平面に分布させる． M_f と M_l は以下のように標準化する．

$$m_f = \frac{M_f - M_{f\min}}{M_{f\max} - M_{f\min}}, m_l = \frac{M_l - M_{l\min}}{M_{l\max} - M_{l\min}} . \quad (3.5)$$

ただし， $M_{f\min}$ と $M_{f\max}$ はそれぞれ最小点と最大点を意味する．同様に， $M_{l\min}$ と $M_{l\max}$ はそれぞれ最小点と最大点を意味する．また各点は，男児の新生児を 22 個の青い点 $C_i = +1$ ，女児の新生児を 24 個の赤い点 $C_i = -1$ で表している．図 3.12 (b)(c) は，2 クラス分類に特化した RB-ARTM を適用したときの学習結果例を示している．ただし，警戒パラメータ $\rho = 0.2$ ，距離パラメータ $k = 0$ である．図 3.12 (b) は男児の新生児をベースクラス $C_b = +1$ と設定したときの分類結果例である．また図 3.12 (c) は女児の新生児をベースクラス $C_b = -1$ と設定したときの分類結果例である．図 3.12 (b) と (c) を比較することにより，女児カテゴリの m_f は男児の m_f に比べ，平均とばらつきが大きいことがわかった．

3.4 むすび

2 クラス分類に特化した RB-ARTM を提案し，RB-ARTM の分類能力における警戒パラメータ ρ と距離パラメータ k という 2 つの重要なパラメータの影響を調べた．典型的なベンチマークと産科データという 2 つの分類問題により基本的な数値実験を行い，形成されたカテゴリが多い場合，必ずしも一致率が高いとは限らないことがわかった．また提案したシステムを，実用的なデータである産科データに適用し，RB-ARTM の特徴のひとつである分類結果を視覚的に認識可能な状態にすることにより，産科データのデータ構成を考察した．

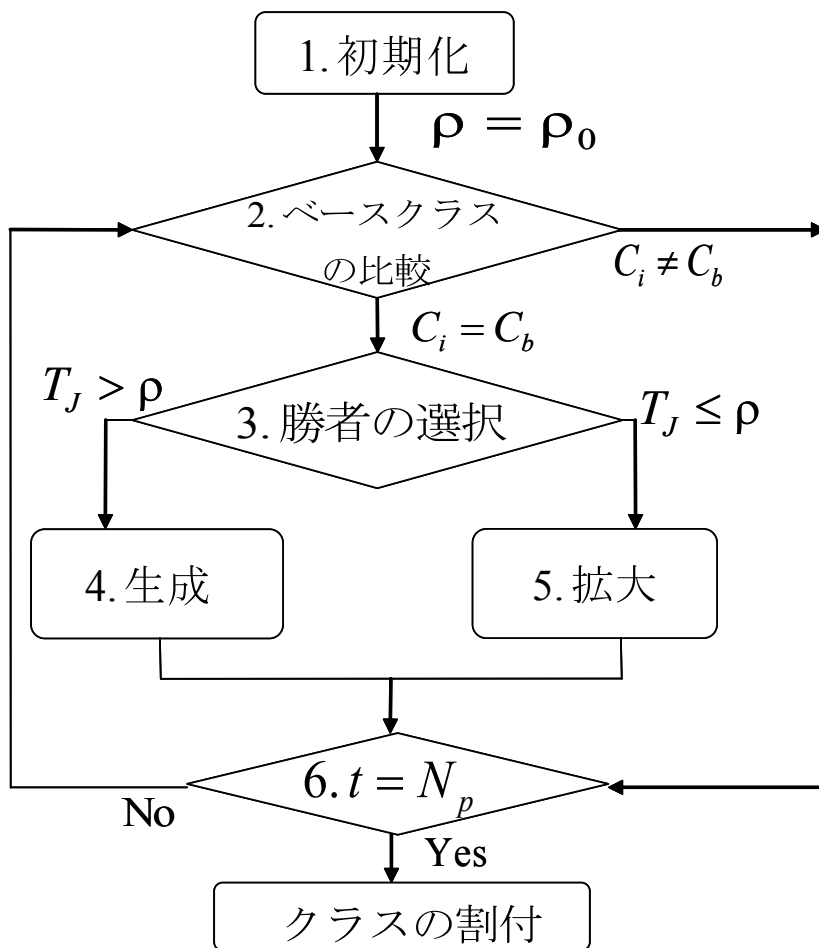


図 3.1: 2 クラス分類に特化した RB-ARTM のフローチャート




図 3.2: 学習過程. (a) 入力データ ($C_b = -1$). (b) ベースクラスを割付. (c) 残り一方のクラスを割付




図 3.3: 3 つの分類問題. (a) Annulus. (b) Checkerboard. (c) Spirals

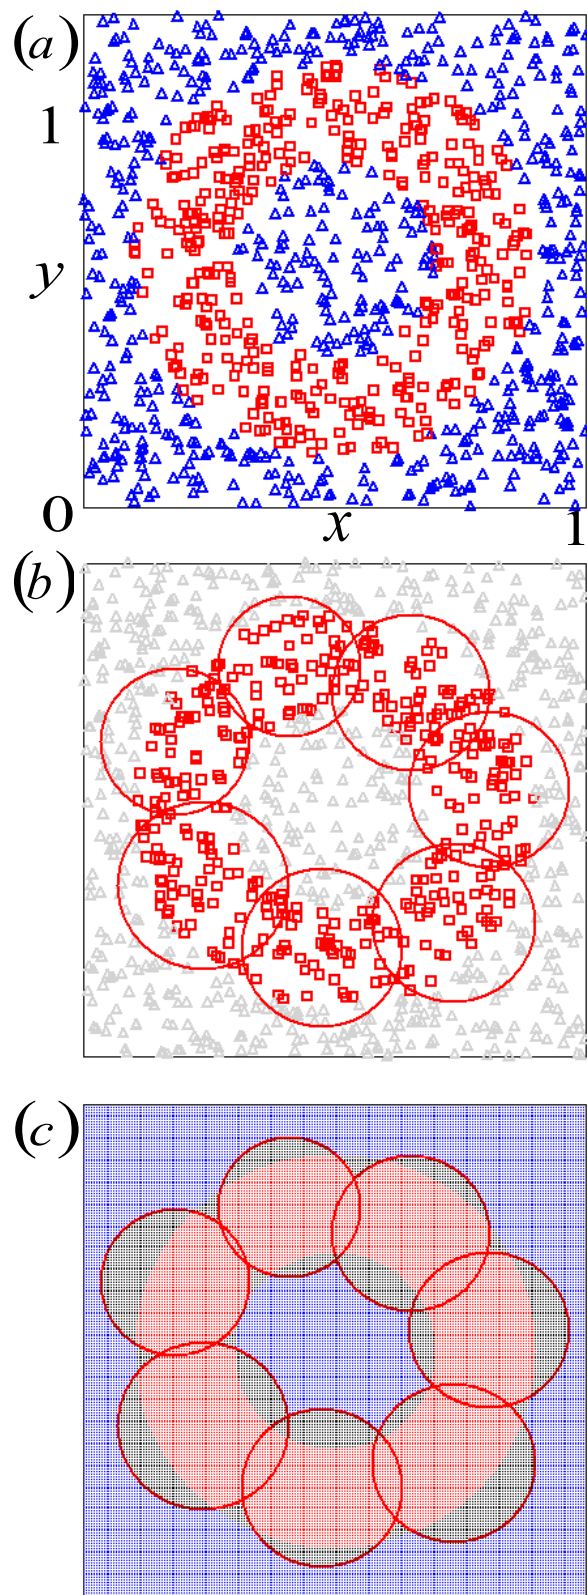


図 3.4: 図 3.3(a) の Annulus によるシミュレーション結果例. (a) 入力データ. (b) 学習結果. (c) 分類結果

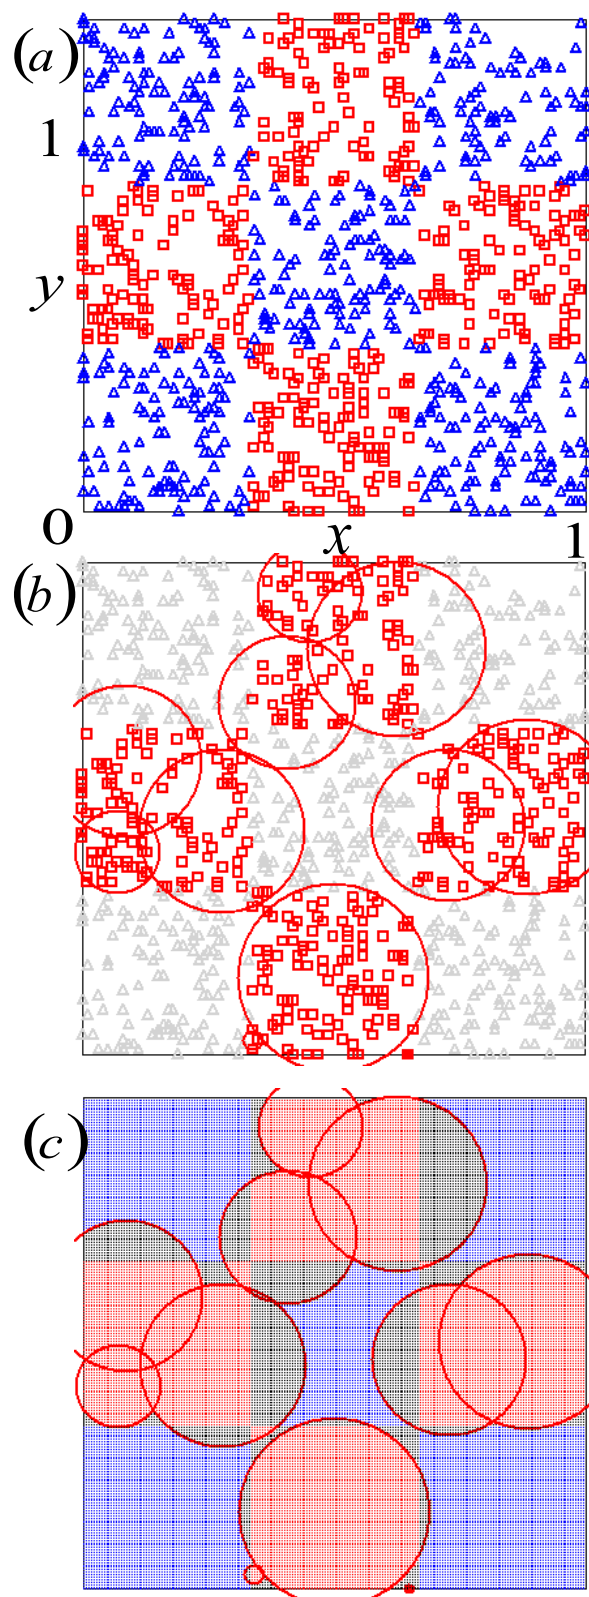


図 3.5: 図 3.3(b) の Checkerboard によるシミュレーション結果例. (a) 入力データ. (b) 学習結果. (c) 分類結果

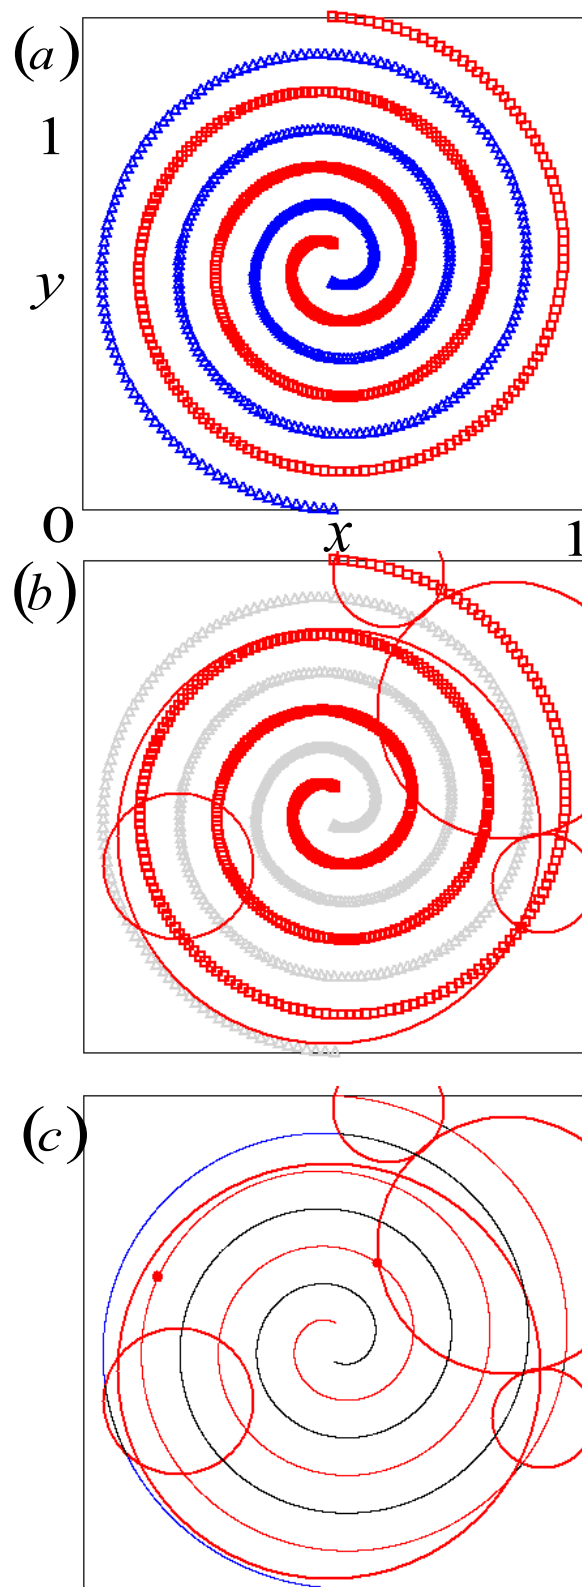


図 3.6: 図 3.3(c) の Spirals によるシミュレーション結果例. (a) 入力データ. (b) 学習結果. (c) 分類結果

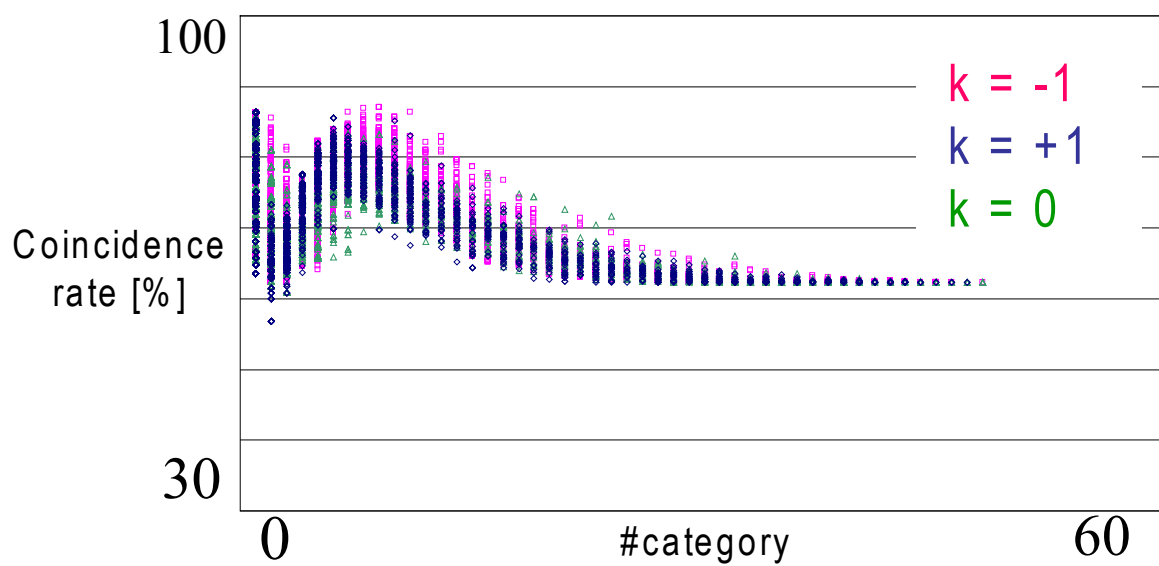


図 3.7: 分類能力 : Spirals

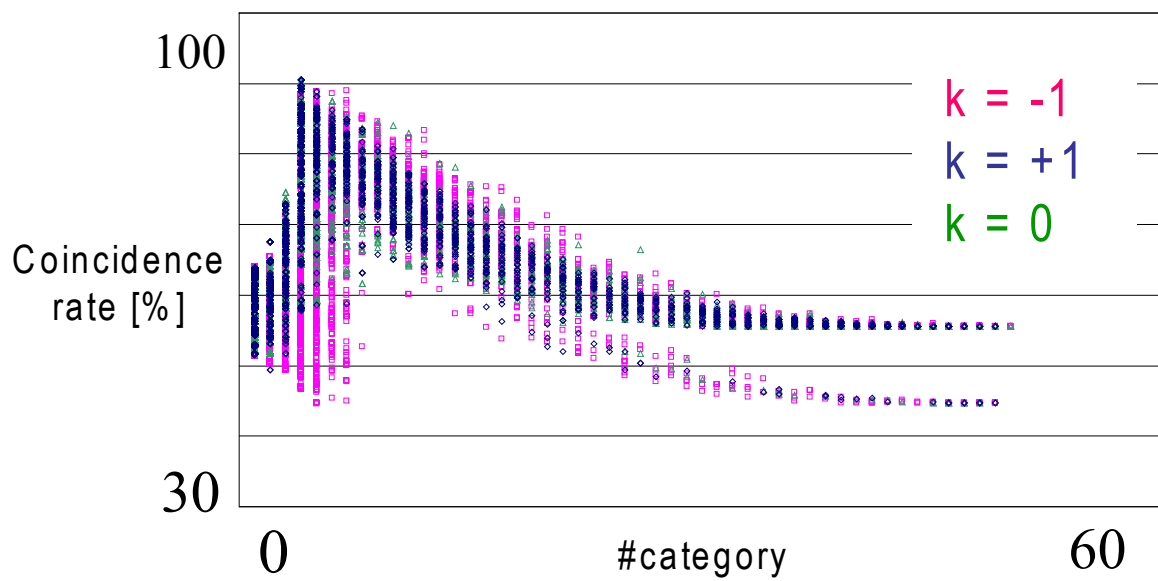


图 3.8: 分類能力 : Checkerboard

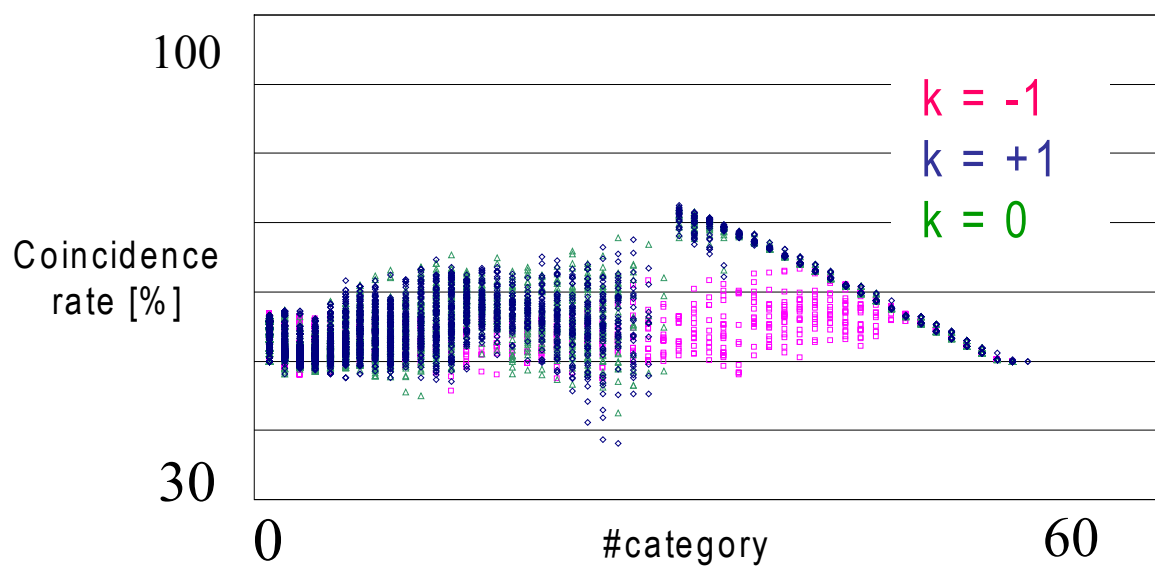


図 3.9: 分類能力 : Spirals

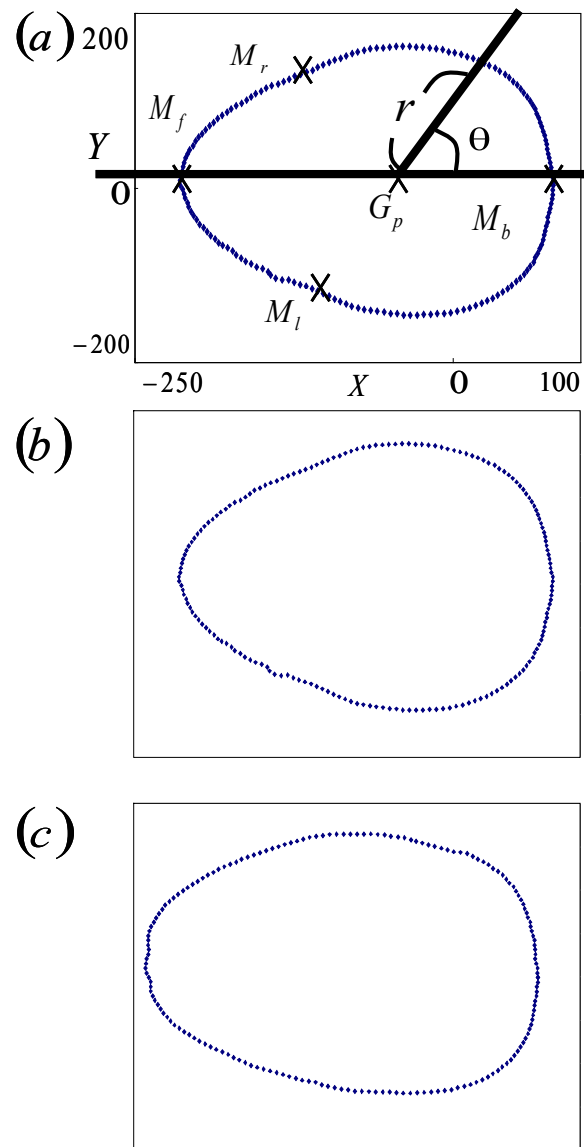


図 3.10: 妊婦の腹部の形. (a) 男児の例 1. (b) 男児の例 2. (c) 男児の例 3

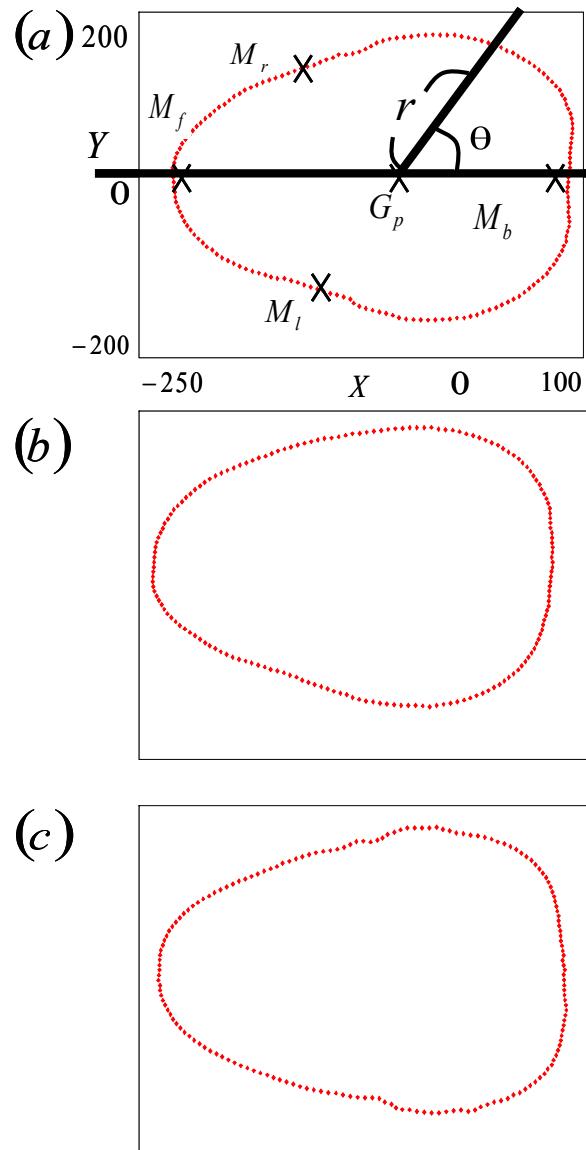


図 3.11: 妊婦の腹部の形. (a) 女兒の例 1. (b) 女兒の例 2. (c) 女兒の例 3

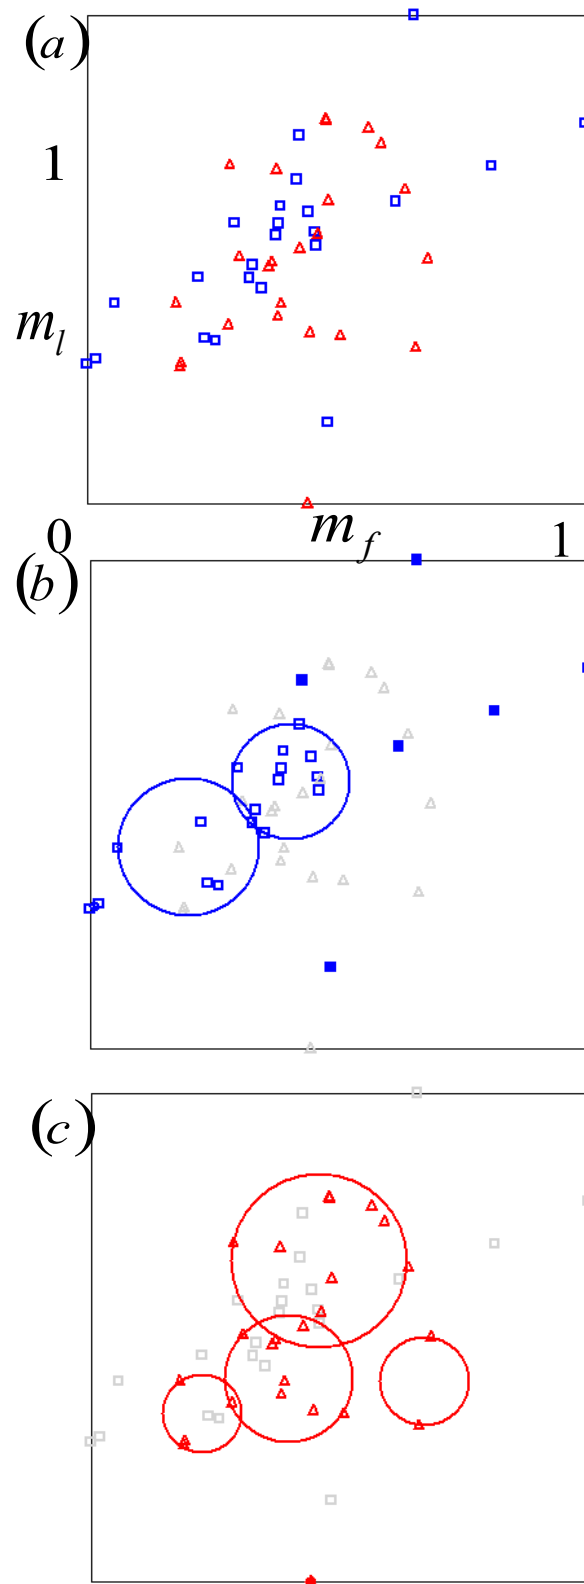


図 3.12: 産科データにおける RB-ARTM の適用. (a) 入力データ. (b) シミュレーション結果 ($C_b = +1$). (c) シミュレーション結果 ($C_b = -1$)

表 3.1: 主成分分析

<i>n</i> -th principal component	1st	2nd	3rd	4th	
Eigenvalue	2.80	0.83	0.24	0.13	
eigenvector	M_b	-3.89E-06	-6.27E-05	-2.83E-07	1.00E+00
	M_r	4.57E-06	-1.12E-11	1.00E+00	-2.83E-07
	M_f	1.00E+00	-4.04E-08	-4.57E-05	3.89E-06
	M_l	4.02E-08	1.00E+00	2.71E-11	6.27E-05
Contribution ratio	70.0	20.7	5.95	3.32	

第4章 むすび

本論文では，教師あり学習システムに拡張した，動径基底 ART マップを用いた分類アルゴリズムを提案した．このシステムは簡素な学習アルゴリズムで，入力と記憶の類似度に基づいてカテゴリを適応的に生成・拡大させるシステムである．クラス情報をもつ入力データを分類するために，RB-ARTM は中心，半径とクラス情報をもとに円形カテゴリを生成するという特徴がある．数値実験結果から，RB-ARTM は警戒パラメータ ρ と距離パラメータ k という，2つのパラメータのみで，分類の影響度を調節できることがわかった．このことより，パラメーター設定次第で対象とする問題へ柔軟に対応することができると言える．

第2章では，提案する RB-ARTM の学習アルゴリズムについて示した．第2章の本編では，基本的な3つのベンチマークをもとに基本的な数値実験を通し，パラメータ設定による分割数の変化と，他手法との空間分割数について比較考察を行った．数値実験の結果から以下のことが言える．

- 警戒パラメータと距離パラメータを増加させると，カテゴリ数は反比例的に減少する
- SVM より RB-ARTM は効率的に分類近似ができる
- SVM はカーネルトリックを用いるが，RB-ARTM は円形カテゴリを用いることにより簡単に分類できる

第3章では2クラス分類問題に特化した RB-ARTM を提案し，3つの代表的なベンチマークをもとに基本的な数値実験を通し，パラメータ設定による分割数の変化を観察した．また実用的な産科データに RB-ARTM を適用することにより分類問題に取り組んだ．数値実験の結果から以下のことが言える．

- 形成されたカテゴリ数が多い場合，必ずしも一致率が良くなるわけではない
- 入力データの形に提案システムは強く依存する

今後の課題としては，最適なパラメーターの自動設定，探索過程の解析，様々な ART マップとの比較，実用的な問題への応用がある．

参考文献

- [1] S. Grossberg, “Adaptive pattern classification and universal recoding, II: Feedback, expectation, olfaction, and illusions,” *Biological Cybernetics*, 23, 187-202, 1976.
- [2] G. A. Carpenter, S. Grossberg, “A massively parallel architecture for a selforganizing, neural pattern recognition machine,” *Computer Vision, Graphics, and Image Processing*, 37, 54–115, 1987.
- [3] G. A. Carpenter, S. Grossberg, D. B. Rosen, “Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system,” *Neural Networks*, 4, 759–771, 1991.
- [4] G. C. Anagnostopoulos, M. Georgiopoulos, “Ellipsoid ART and ARTMAP for Incremental Clustering and Classification,” in *Proc. IEEE-INNS Int’l. Joint Conf. Neural Networks*, 2, 1221–1226, 2001.
- [5] G. C. Anagnostopoulos, M. Georgiopoulos, “Hypersphere ART and ARTMAP for Un-supervised and Supervised, Incremental Learning,” in *Proc. IEEE-INNS Int’l. Joint Conf. Neural Networks*, 6, 59–64, 2000.
- [6] M. Ohki, H. Torikai, T. Saito, “Basic characteristics of a simple radial basis ART network and its application,” In *Proc. Int’l. Conf. Cogni. Neur. Syst.*, 83, 2004.
- [7] G. A. Carpenter, S. Grossberg, N. Markuzon, J. H. Reynolds, D. B. Rosen, “Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps,” *IEEE Trans. Neural Networks*, 3, 5, 698–713, 1992.

- [8] O. Parsons, G. A. Carpenter, "ARTMAP neural networks for information fusion and data mining: map production and target recognition methodologies," *Neural Networks*, 16, 1075–1089, 2003.
- [9] Y. Liao, V. R. Vemuri, A. Pasos, "Adaptive anomaly detection with evolving connectionist systems," *IEEE Trans. Neural Networks, Journal of Network and Computer Applications*, 30, 60–80, 2005.
- [10] M. Takanashi, H. Torikai, T. Saito, "An approach to fusion of growing self-organizing maps and adaptive resonance theory maps," *IEICE Trans. Fundamentals*, E90-A, 9, 2047–2050, 2007.
- [11] C. Cortes, V. Vapnik, "Support-Vector Networks," *Machine Learning*, 20, 273–297, 1995.
- [12] N. Cristianini, J. Shawe-Taylor, "An Introduction to Support Vector Machines and other kernel-based learning methods," *Cambridge*, 2005.
- [13] UCI Databases, <http://www.ics.uci.edu/mllearn/MLRepository.html>
- [14] SVMlight Support Vector Machine, <http://svmlight.joachims.org/>
- [15] H. Harold, "Simplified calculation of principal components," *Psychometrika*, 1, 27–35, 1935.

研究業績

(国際会議)

Y. Enosawa, H. Matsushita and T. Saito, “An Approach to Collaboration of ART and ACA Classification System based on Collaboration of Adaptive Resonance Theory Maps and Learning Vector Quantization”, Proc. of NOLTA, pp. 611-614, 2010

Y. Enosawa, H. Matsushita, Y. Tanaka, N Kuji, and T. Saito, “Classification Function of Radial Basis Adaptive Resonance Theory Maps and its application”, Proc. of RISP International Workshop on NCSP, 2012, (accepted)

(国内発表)

江野澤瑶子, 小清水宏, 斎藤利通, “ART と LVQ の融合によるクラスタリングシステム”, 電子情報通信学会総合大会, A-2-10, 仙台, 2010-3

Y. Enosawa, H. Matsushita, and T. Saito, “Analysis of Classification Precision with Radial Basis ARTMAP and Nonlinear SVM”, Proc. of IEEE Workshop on Nonlinear Circuit Networks , pp. 64-65, 2010-12

A. Takahashi, Y. Enosawa, H. Matsushita, and T. Saito, “Radial Basis ART and its Basic Application”, Proc. of IEEE Workshop on Nonlinear Circuit Networks , pp. 62-63, 2010-12

江野澤瑶子, 松下春奈, 斎藤利通, “動径基底 ART マップによる分類機能について”, 電子情報通信学会技術研究報告, NC2010-201, 2011-3

岡本祐輔, 江野澤瑶子, 斉藤 利通, “動径基底 ART ネットワークとその応用”, 電子情報通信学会ソサイエティ大会, A-2-13, 2011-9

岡本祐輔, 中山雄太, 江野澤瑶子, 斉藤 利通, “ART-Map に基づく論理合成”, 電子情報通信学会技術研究報告, NLP2011-89, 2011-10

Y. Enosawa, H. Matsushita, and T. Saito, “Classification Function of Radial Basis Adaptive

Resonance Theory Maps”, Proc. of IEEE Workshop on Nonlinear Circuit Networks , pp.
133-136, 2011-12

謝辞

本論文は著者が法政大学大学院工学研究科電気工学専攻に在学中の2年間，同大学理工学部電気電子工学科教授斎藤利通博士の指導下で行ったものである．研究活動を遂行するにあたり，同教授から終始懇切に御指導，御鞭撻下さった同博士に深謝致します．

また，研究活動中に貴重な御助言・御討論を賜りました香川大学工学部信頼性情報システム工科学科助教松下春奈博士には感謝の意を表明いたします．ここに深く感謝します．

最後に法政大学理工学部電気電子工学科斎藤利通研究室の皆様にはいろいろな有益な御討論・ご助言を戴きました．ここに深謝致します．