

pdi-BoostingG での指向型バーチャルデータの提案

A Proposal of Directional Virtual Data in pdi-BoostingG

○ 入江 穂乃香, 林 勲
○ Honoka Irie, Isao Hayashi
関西大学大学院
Kansai University

Abstract: We have proposed pdi-BoostingG that generates virtual data as a kind of ensemble learning. In this method, region G is set to generate additional fuzzy rules around misclassified data, and virtual data is generated within this region G . Generated virtual data and added fuzzy rules are inherited among layers of ensemble learning. In this paper, we propose a method to generate virtual data with a normal distribution around the internal division points of different classes of misclassified data, with directivity to the central position of the class. Since generated virtual data is inherited between layers together with fuzzy rules, deep inference of fuzzy rules is realized. We discuss here how to generate virtual data and discuss the features of the proposed method from the results of the discrimination rate using numerical examples.

1. はじめに

パターン分類問題に対して、複数個の弱判別器を統合的に組み合わせて全体の識別精度を向上させるアンサンブル法 [1] に対する関心が高まっている。アンサンブル学習の判別器結合モデルで逐次的タイプの一つにブースティング法 (Boosting Methods) [2] がある。我々は弱判別器にファジィ推論 [3] を用い、学習時に生成したバーチャルデータを学習データに追加して、識別精度を向上させるバギング法 (pdi-Bagging) やブースティング法 (pdi-Boosting) を提案している [4–8]。バーチャルデータの追加で学習時にデータ量が増えるので、クラス間でデータ量の偏りがなくなり、判別線の同定精度が向上する。特に、ファジィルールの追加領域の位置を規則化した pdi-BoostingG [9] では、前層で学習された判別器のファジィルールを次層に引き継ぐルール継承を行い、バーチャルデータも次層に継承するので、識別精度が向上することが期待される。

本論文では、従来の pdi-BoostingG に加えて、範囲 G 内で指向性を考慮しながらバーチャルデータを発生する新たな pdi-BoostingG を提案する。全体のアルゴリズムでは、全空間のファジィルールの広域学習と範囲 G 内の追加ファジィルールの局所学習を交互に繰り返す多層構造となっている。まず、全空間の広域学習では、前層から次層へ移行する際に、全空間のファジィルール集合とバーチャルデータ集合を次層に継承する。ファジィルールの継承は、前層の学習後のファジィルールが次層のファジィルールの学習時の初期値として用いられる。また、バーチャルデータの継承は、前層で発生したバーチャルデータの個数に継承率を乗じた個数が次層でもバーチャルデータとして用いられ、新たなバーチャルデータを発生する。

一方、範囲 G 内の個別学習では、誤判別データが判別された場合、その誤判別データに最も近い異クラスの 2 個のデータを求め、これらの内挿点を源データとしてファジィ数のメンバシップ関数により異クラスのバーチャルデータを発生し、範囲内のファジィルールを学習する。ただし、範囲 G は、誤判別データ、異クラスの 2 個のデータ、バーチャルデータを含む最小範囲で設定される。ここでは、ファジィ推論のメンバシップ関数は直角台形型を採用するので、 G の範囲は変化せず、範囲 G 内のファジィルールはクラスを識別する局所的なルールとなる。なお、前層から次層へ移行する際、範囲 G のファジィルールは継承するが、バーチャルデータは全空間ですでに継承されているので、範囲 G では継承しない。このように、全空間と範囲 G の 2 種類の学習による多層構造により、最終結果の識別率は向上する。

ここでは、指向性を考慮したバーチャルデータの発生方法を議論し、2 群識別の数値例を用いて、pdi-BoostingG の特性を明らかにして、他手法との比較から本手法の有用性を議論する。

2. pdi-BoostingG

pdi-BoostingG の概念を図 1 に示す。pdi-BoostingG では、全データ集合から確率的に抽出された学習データ (TRD) を用いてファジィ推論の弱判別器 M_0 を学習し、 TRD の識別率を算出する。次ステップ (層) では、誤判別データを中心とした範囲 G を設定し、メンバシップ関数を用いてバーチャルデータを範囲 G 内で発生して継承率を乗じた量を TRD に追加させて、ファジィ推論の弱判別器 M_1 により TRD の識別率を算出する。 TRD を

増加させることによって弱判別器の識別精度が向上する。終了判定が満足されるまでこの一連の操作を L 回繰り返す。最終的に、評価データ (CHD) を L 個の弱判別器 $M_0, M_1, \dots, M_l, \dots, M_L$ に入力して、多数決により最終結果を得る。

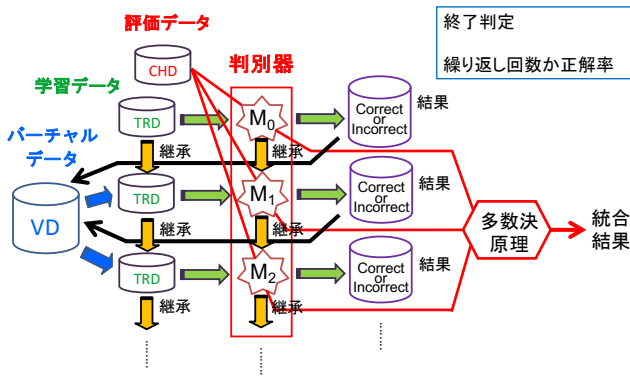


図 1: pdi-BoostingG

pdi-BoostingG では、弱判別器として簡易型ファジィ推論 [3, 10] によるファジィクラスタリングを用いる。ただし、三角型のメンバシップ関数を一般化した正規な台形型ファジィ集合を用いる。いま、入力 $\mathbf{x} = (x_1, x_2, \dots, x_n)$ と出力クラス C_k の値 z が得られたとする。ファジィ推論の結果 \hat{z} とクラス C は次式から求める。

$$\begin{aligned} \mu_i(\mathbf{x}) &= \mu_{F_{i1}}(x_1) \cdot \mu_{F_{i2}}(x_2) \cdot \dots \cdot \mu_{F_{in}}(x_n) \\ \hat{z} &= \frac{\sum_{i=1}^R \mu_i(\mathbf{x}) \cdot p_i}{\sum_{i=1}^R \mu_i(\mathbf{x})} \\ C &= \{C_k \mid \min |\hat{z} - z|\} \end{aligned}$$

ただし、 $\mu_i(\mathbf{x})$ は、入力データ \mathbf{x} を第 i 番目のファジィルール r_i の前件部に入力したときの前件部の適合度である。

ここで、 W 個のデータのデータ集合 D の第 d 番目のデータを $\mathbf{x}^D(d) = (x_1^D(d), x_2^D(d), \dots, x_j^D(d), \dots, x_n^D(d))$ で表す。バーチャルデータの発生では、学習データ $\mathbf{x}^D(d)$ のクラスが弱判別器により誤判別と判別された場合、その誤判別データ $\mathbf{x}^E(d)$ から最も近い異クラスの 2 個のデータ $\mathbf{x}^{K1}(d)$ と $\mathbf{x}^{K2}(d)$ を求め、これらの内挿点 $\mathbf{x}^R(d)$ を源データとして、ファジィ数 F のメンバシップ関数 $\mu_F(x_j)$ を用いて、異クラスのバーチャルデータ $\mathbf{x}^V(d)$ を発生する。また、誤判別データ $\mathbf{x}^E(d)$ 、異クラスの 2 個のデータ $\mathbf{x}^{K1}(d)$ と $\mathbf{x}^{K2}(d)$ 、バーチャルデータ $\mathbf{x}^V(d)$ を含むように最小な範囲 G を設定する。

$\mathbf{x}^V(d)$ の第 j 属性目目のバーチャルデータ $x_j^V(d)$ の発生は、ある実数 h , $0 \leq h \leq 1$ が与えられると、ファジィ数

F のメンバシップ関数 $\mu_F(x_j)$ を用いて発生する。

$$\begin{aligned} x_j^V(d) &= \{x_j \mid \mu_F(x_j) = h, \mu_F(x_j^R(d)) = 1\} \\ h &\sim N(1, 1), \quad 0 \leq h \leq 1 \\ x^R(d) &= \frac{n\mathbf{x}^{K1}(d) + m\mathbf{x}^{K2}(d)}{m+n} \end{aligned}$$

ただし、 $x^R(d)$ は $\mathbf{x}^{K1}(d)$ と $\mathbf{x}^{K2}(d)$ を $m:n$ に内分する内挿点を表し、メンバシップ関数 $\mu_F(x_j)$ は、ファジィ数 F の中心が $x_j^R(d)$ であり、標準偏差が σ である次の正規分布で定義する。

$$\mu_F(x_j) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x_j - x_j^E(d))^2}{2\sigma^2}\right)$$




図 2: Generation of Virtual Data and Fuzzy Rules in Region G

3. 継承と範囲 G

pdi-BoostingG において、全空間のファジィルール継承では、前層で識別率が最大となったファジィルールのメンバシップ関数のパラメータを次層のファジィルール学習の初期設定のパラメータとして設定する。また、全空間のバーチャルデータの継承では、各層で発生した全空間のバーチャルデータを次層の学習データに追加して学習データの量を増加させる単率継承を行う。第 l 層の v_l 個のバーチャルデータから継承率 ξ を用いた乱数サンプリングによって、 v_{l+1} 個のバーチャルデータを第 $l+1$ 層へ継承する。

$$\begin{aligned} v_{l+1} &= \xi \times v_l \\ W_{l+1}^{TRD} &= W_l^{TRD} + v_{l+1} \end{aligned}$$

ただし、 W_l^{TRD} と W_{l+1}^{TRD} はそれぞれ第 l 層目と第 $l+1$ 層目の学習データである。

図 2 に範囲 G での指向性をもつバーチャルデータの発生とファジィルールの設定方法を表す。誤判別データ $\mathbf{x}^E(d)$ から最も近い異クラスの 2 個のデータ $\mathbf{x}^{K1}(d)$ と $\mathbf{x}^{K2}(d)$ の内挿点 $\mathbf{x}^R(d)$ を源データとして、ファジィ数 F のメンバシップ関数 $\mu_F(x_j)$ を用いて、バーチャルデータ $\mathbf{x}^{V(E)}(d)$ を発生する。なお、範囲 G は、誤判別データ $\mathbf{x}^E(d)$ 、異クラスの 2 個のデータ $\mathbf{x}^{K1}(d)$ と $\mathbf{x}^{K2}(d)$ 、バーチャルデータ $\mathbf{x}^{V(E)}(d)$ を含むように、最小の幅 2λ の範囲 $G \subset [0, 1]$ を設定する。

$$\{\mathbf{x}^E(d), \mathbf{x}^{K1}(d), \mathbf{x}^{K2}(d), \mathbf{x}^{V(E)}(d)\} \in G$$

$$G = \{x_l | x_l^E(d) - \lambda \leq x_l \leq x_l^E(d) + \lambda\}, \quad 0 \leq \lambda \leq 1$$

$$G = \{x_l | x_l^E(d) \leq x_l \leq x_l^E(d) + 2\lambda\}, \quad 0 \leq \lambda \leq 1$$

ここで、 λ は範囲 G の大きさを指定する定数である。

ただし、範囲 G を固定するため、範囲 G の両端では、直角台形型メンバシップ関数を設定し、範囲 G 内に設定した全てのメンバシップ関数は、学習後も範囲内に留まるように制限した。なお、 $\mathbf{x}^{V(E)}(d)$ は全空間の広域学習に継承され、次層以降の範囲 G の学習では使用しないので、学習後に破棄する。pdi-Boosting における全空間の広域学習と範囲 G の局所学習の構造を図 3 に示す。pdi-Boosting は 5 層構造としている。各層で全空間の広域学習と範囲 G 内の局所学習により判別線が推定される。なお、継承率 ξ が $\xi = 0.0$ の場合には、層間ではファジィルールもバーチャルデータも継承されないので、pdi-Boosting は pdi-Bagging と同じ構造となることに注目すべきである。

pdi-Bagging のアルゴリズムを次のように定式化する。

Step 1 計測データ D (個数: W 個) を学習データ D^{TRD} (個数: W^{TRD} 個) と評価データ D^{CHD} (個数: W^{CHD} 個) に分割する。また、全空間を学習するための弱判別器のファジィルールの集合を Q で表し、 D^{TRD} から構成する全空間を学習するためのバーチャルデータを $D^V (= D^{V(C)} + D^{V(E)})$ で表す。ただし、 $D^{V(C)}$ は D^{TRD} の誤判別データ $\mathbf{x}^E(d)$ が弱判別器の学習により正判別となった場合のバーチャルデータを表し、 $D^{V(E)}$ は学習後も誤判別であった場合のバーチャルデータを表す。

Step 2 第 0 層目として、全空間のメンバシップ関数をもつ弱判別器 M_0 に D^{TRD} を入力し弱判別器 M_0 を学習する。第 0 層目の結果 R_0 の識別率 r_0^{TRD} を得る。学習された全空間のファジィルールの Q に追加する。

Step 3 第 l 層目での範囲 G の生成のため、 D^{TRD} の誤判別データ $\mathbf{x}^E(d)$ を抽出し、その $\mathbf{x}^E(d)$ が第 $l-1$ 層以前で抽出されたとしても、誤判別データ $\mathbf{x}^E(d)$ から最も近い異クラスの 2 個のデータ $\mathbf{x}^{K1}(d)$ と $\mathbf{x}^{K2}(d)$ を求め、これらの内挿点を源データ $\mathbf{x}^R(d)$ として、ファジィ数 F のメンバシップ関数 $\mu_F(x_j)$ を用いて、異クラスのバーチャルデータ $\mathbf{x}^{V(E)}(d)$ を発生する。また、誤判別データ $\mathbf{x}^E(d)$ 、異クラスの 2 個のデータ $\mathbf{x}^{K1}(d)$ と $\mathbf{x}^{K2}(d)$ 、バーチャルデータ $\mathbf{x}^{V(E)}(d)$ を含むように、最小の幅 2λ をもつ範囲 $G \subset [0, 1]$ を設定する。バーチャルデータ $\mathbf{x}^{V(E)}(d)$ は全空間の広域学習のために $D^{V(E)}$ に保存する。

Step 4 範囲 G で弱判別器のファジィルールのメンバシップ関数を設定し、第 l 層目の弱判別器 M_l^G に $\mathbf{x}^E(d)$ と $\mathbf{x}^{V(E)}(d)$ 、範囲 G 内の D^{TRD} を入力し、弱判別器 M_l^G を学習する。ただし、範囲 G を固定するため、範囲 G の両端には、直角台形型メンバシップ関数を設定し、範囲 G 内に設定する全てのメンバシップ関数には、学習後も範囲内に留まる制限が設定される。 $\mathbf{x}^{V(E)}(d)$ は次層以降の範囲 G の学習では使用しないので破棄する。学習されたファジィルールを全空間の広域学習のための Q に追加する。

Step 5 第 l 層目での全空間の弱判別器の学習のため、弱判別器 M_l に D^{TRD} と $D^{V(C)}$ 、 $D^{V(E)}$ を入力し、 Q に存在する全てのファジィルールを用いて弱判別器 M_l を学習し、 Q の全ルールを更新する。

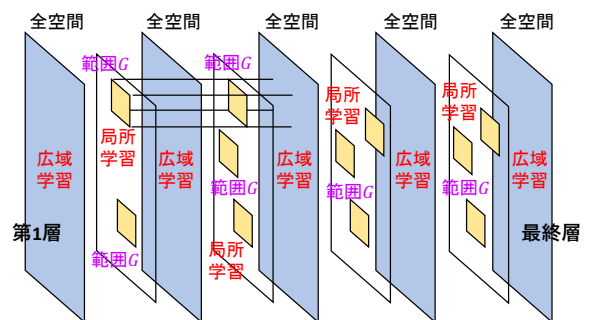


図 3: Learning Mechanism of pdi-BoostingG

Step 6 第 l 層目の全空間の弱判別器の学習によって、正判別データ $\mathbf{x}^C(d)$ が誤判別となった場合、過去に $\mathbf{x}^C(d)$ から生成した $\mathbf{x}^{V(C)}(d)$ も含めて全ての $\mathbf{x}^{V(C)}(d)$ を $D^{V(C)}$ から $D^{V(E)}$ へ移動する。一方、誤判別データ $\mathbf{x}^E(d)$ が正判別となった場合、過去に $\mathbf{x}^E(d)$ から生成した $\mathbf{x}^{V(E)}(d)$ も含めて全ての $\mathbf{x}^{V(E)}(d)$ を $D^{V(E)}$ から $D^{V(C)}$ へ移動する。なお、過去の $\mathbf{x}^E(d)$ が再び誤判別 $\mathbf{x}^E(d)$ となり、かつ、単率継承の場合には、 $\mathbf{x}^{V(E)}$ は $D^{V(E)}$ から取り除くが、複率継承では、 $\mathbf{x}^{V(E)}$ は $D^{V(E)}$ に存続させる。ただし、 $\mathbf{x}^{V(E)}$ は発生した第 l 層目から第 $l + \phi$ 層目まで存続するとし、第 $l + \phi + 1$ 層目で $D^{V(C)}$ と $D^{V(E)}$ から取り除く。 D^{TRD} に対する第 l 層目の結果 R_l の識別率 r_l^{TRD} を得る。

Step 7 第 l 層目のバーチャルデータ $D^{V(C)}$ と $D^{V(E)}$ に対して、全ての $\mathbf{x}^{V(C)}$ と $\mathbf{x}^{V(E)}$ のクラス k^* を求める。

$$k^* = \{k \mid \min_k E^k = \min_k (w_1 E_1^k + w_2 E_2^k + w_3 E_3^k)\}$$

ただし、 E_1^k, E_2^k, E_3^k は、それぞれクラス決定のための評価基準であり、 E^k は全体の評価値である。また、 w_1, w_2, w_3 は各評価値の重みである。

Step 8 第 l 層目での v_l^C 個の $D^{V(C)}$ と v_l^E 個の $D^{V(E)}$ が、継承率 ξ^C と ξ^E と乱数サンプリングによって、第 $l + 1$ 層目では、それぞれ、 v_{l+1}^C 個の $D^{V(C)}$ と v_{l+1}^E 個の $D^{V(E)}$ に継承される。

$$\begin{aligned} v_{l+1}^C &= \xi^C \times v_l^C \\ v_{l+1}^E &= \xi^E \times v_l^E \end{aligned}$$

Step 9 $l = l + 1$ として、Step3 から 8 までを繰り返し、しきい値 θ に対して $r_l^{CHD} \geq \theta$ を満足した $K = l$ の時点、あるいは、弱判別器の個数 L と繰り返し回数 K 、 $K \leq L$ に対して $l \geq K$ を満足した時点でアルゴリズムを終了する。

Step 10 M_K に D^{CHD} を適用し、多数決により最終の結果の識別率 r_K^{CHD} を得る。

4. 数値データによる検証と考察

検証に用いる数値データは、学習データと評価データでそれぞれ 200 個である。学習データと評価データに用いる数値データを図 4 に示す。これらの数値データは、基本データに乱数で最大 ± 0.05 の増減値を加えて生成した。

ここでは、2 入力 1 出力の 2 群判別問題として、ファジィ推論の 2 群クラスの実数値を 2.0 (赤・○印) と 3.0 (青・△印) に設定した。弱判別器には簡易型ファジィ推論を用いる。各入力区間 $[0, 1]$ に 5 種類の台形型メンバシップ関数を設定するので、全空間では 25 個のルールとなる。範囲 G では、3 種類のメンバシップ関数を台形型で設定し、範囲 G 内の各次元の両端では直角台形型メンバシップ関数を設定し、範囲 G 内のメンバシップ関数は学習後も範囲内に留まる制限を設ける。この結果、範囲 G の 9 個のルールは領域内で集中的に学習される。

ファジィ推論の前件部の初期値設定は既定法とし、前件部と後件部の学習順序は、後件部 \rightarrow 前後件部交互学習とする。学習では、各入力の台形型メンバシップ関数の上底の 2 頂点の x 座標 x_b と x_c 、および、上底と下底の x 座標の差 α と β の学習係数 $K_b, K_\alpha, K_c, K_\beta$ [3] を同一とし 0.01 に設定する。また、後件部のシングルTONの学習係数 K_p は、最初の後件部学習では 0.4 に設定し、交互学習の後件部学習では 0.6 とする。後件部と前後件部交互学習のエポック回数をそれぞれ 10 回と (10, 10) 回に設定した。バーチャルデータ発生時のメンバシップ関数 $\mu_F(x_j)$ は正規分布とし、標準偏差は $\sigma = 0.2$ とする。また、2 個の異クラス $\mathbf{x}^{K1}(d)$ と $\mathbf{x}^{K2}(d)$ の内分点で源データ $\mathbf{x}^R(d)$ を求める内分比は $m = n = 1/2$ とする。バーチャルデータの発生個数は 1 個とする。バーチャルデータのクラス推定のための評価値の重みを $(w_1, w_2, w_3) = (0.01, 0.495, 0.495)$ とする。アルゴリズムの終了規範は繰り返し判定として、回数は $K = 5$ とする。なお、継承率は $\xi = 0.6$ とした、また、結果の識別率は 10 試行の識別率の平均値とした。

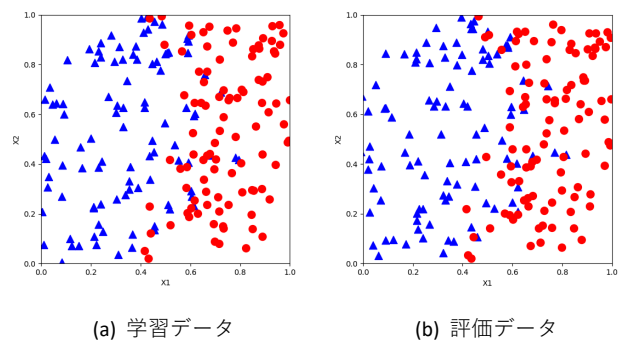


図 4: Training Data and Testing Data

結果を表 1 に示す。まず、範囲 G の λ を数種類に固定してバーチャルデータ (VD) を発生する従来法の pdi-BoostingG の識別率を示した。ルール継承方法とバーチャルデータ継承方法の組み合わせにより、5 種類の方法が提

表 1: Discriminant Rates of pdi-BoostingG with Directional Virtual Data

範囲 G λ	Directional pdi-BoostingG		pdi-BoostingG					pdi- Bagging	Adaboost J48	Adaboost Random Forest
	中心	端点	ルール初期化 ルール非追加 VD 再発生	ルール継承 ルール非追加 VD 非再発生	ルール継承 ルール非追加 VD 再発生	ルール 継承 ルール 追加 VD 非再発生	ルール継承 ルール追加 VD 再発生			
0.025	—	—	90.90	90.85	91.45	91.55	90.95	—	—	—
0.05	—	—	91.65	92.40	92.60	92.40	92.20	—	—	—
0.075	—	—	90.80	90.45	90.40	90.80	90.75	—	—	—
0.1	—	—	90.69	90.60	91.30	90.55	90.60	—	—	—
平均	91.45	88.95	91.00	91.08	91.44	91.33	91.13	90.55	83.00	83.00

案できるが、識別率の高い組み合わせを下線で示した [9]。また、pdi-Bagging や Adaboost [2] と比較した。なお、判別器のファジィ推論単体の識別率は 89.00% であり、範囲 G を設定しない pdi-Boosting の識別率は 89.25% であった。図 5 に、範囲 G の λ の $0.01 \leq \lambda \leq 0.1$ の変化に対する pdi-BoostingG の識別率を示す。 $\lambda = 0.05$ で最大識別率 92.60% を得た。

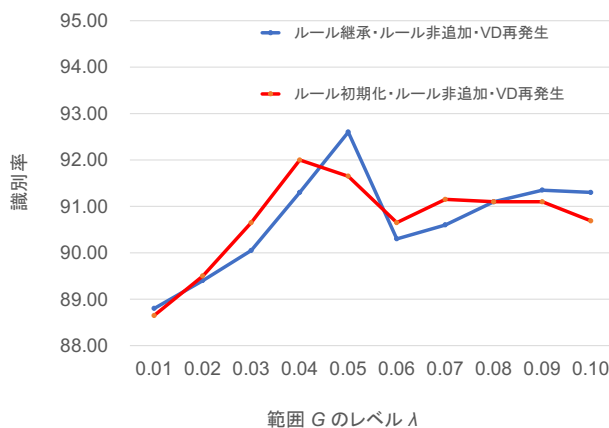


図 5: Discriminant Rate due to Size Change in Range G

一方、指向性をもつバーチャルデータ発生法の pdi-Boosting の識別率も表 1 に示す。指向性をもつバーチャルデータの発生は、誤判別データが範囲 G の中心となる場合と端点となる場合の 2 種類である。ただし、バーチャルデータの個数は従来手法の pdi-BoostingG の 1/3 程度としている。中心発生方式が、バーチャルデータの個数が少ないにも関わらず、単体のファジィ推論よりも高く、従来手法の pdi-BoostingG と同程度であることがわかる。

表 1 から、識別率には次の特性があることがわかる。

- 1) pdi-Boosting や pdi-Bagging 等のバーチャルデータを発生する手法は、Adaboost と比較して、識別率が 5% 以上も高い。この結果から、バーチャルデータの発生の効果が現れているといえる。
- 2) 範囲 G をもつ pdi-BoostingG と範囲 G をもたない pdi-Boosting や pdi-Bagging と比較すると、範囲 G をもつ手法の方が識別率が高い。この結果から、範囲 G のルール発生とバーチャルデータの発生が識別率の向上に有用であるといえる。広域学習では特異点の学習データが無視される傾向がある。一方、範囲 G の生成によって、誤判別データ周辺は局所的に特異点となるクラスを構成することが可能となる。階層構造では、これらの 2 種類の広域学習と局所学習が交互に繰り返されるので、個々の誤判別データが減少することで識別精度が向上したといえる。
- 3) 従来法の pdi-BoostingG では、範囲 G 内のファジィルールを次層に継承する識別率は高く、ファジィルールを追加しない場合に、さらに識別率が高くなる。
- 4) 従来法の pdi-BoostingG では、「ルール非追加」のバーチャルデータ再発生の方が識別率が高い。一方、「バーチャルデータ非再発生」のルール追加と非追加の識別率は大差がない。一方、「ルール非追加+バーチャルデータ再発生」は「ルール追加+バーチャルデータ再発生」よりも識別率が高い。したがって、ルールは追加せず、バーチャルデータのみを再発生させる方式が良いと考えられる。
- 5) 指向性バーチャルデータ発生型と従来手法の pdi-BoostingG を比較すると、平均識別率では、指向性バーチャルデータの中心発生方式が、バーチャル

データの個数が少ないにも関わらず、従来法の pdi-BoostingG と同程度であることがわかる。一方、端点発生方式の識別率は高くない。この理由として、中心発生方式は範囲 G が端点発生方式よりも大きくなり、バーチャルデータの発生による影響度が高くなるからと考えられる。

- 6) 範囲 G レベルの $\lambda = 0.05$ で、識別率が 92.60% と最大識別率となった。このように、識別率は範囲 G の大きさに依存していることがわかる。

これらの考察から、指向性バーチャルデータ発生型 pdi-BoostingG の中心発生方式は、識別率やバーチャルデータの個数の点から他手法よりも有用であることがわかった。端点発生方式と比較して、中心発生方式が高いのは、範囲 G の大きさによる局所学習の精度の違いが影響していると考えられる。一方で、範囲 G の λ の変化に対して、識別率は変動する。このように、範囲 G の大きさがバーチャルデータの発生に影響し、また、 λ の変化が局所学習に大きく関与していることがわかった。

5. おわりに

本論文では、従来型の pdi-BoostingG に加えて、バーチャルデータを指向性を保ちながら発生させる pdi-BoostingG を定式化し、その有用性を議論した。特に、誤判別データが発生した場合の範囲 G での発生方式について議論し、2 群識別の数値例により指向性バーチャルデータ発生型 pdi-BoostingG の有用性を議論した。指向性バーチャルデータ発生型 pdi-BoostingG は、指向性をもつバーチャルデータの発生により外乱に対するロバスト性に優れているが、今後、判別線の同定精度を向上させるため、より効率的な範囲 G の発生方法やバーチャルデータの発生方式、サンプリング方法、継承率の調整法、ファジールールの継承法について議論する必要がある。

なお、本研究の一部は、科学研究費補助金基盤研究 (C) 一般「バーチャルデータ発生型ファジィバギングを用いた放送映像の卓球戦略獲得ボードの開発」(No.20K11981, 2020 年～2025 年)、及び、JST 次世代研究者挑戦的研究プログラム (JPMJSP2150) の助成を得た。

参考文献

- [1] R.Polikar: Ensemble Based Systems in Decision Making, *IEEE Circuits and Systems Magazine*, Vol.6, No.3, pp.21-45 (2006).
- [2] Y.Freund, R.E.Schapire: A Decision-theoretic Generalization of On-line Learning and An Application to Boosting, *Journal of Computer and System Sciences*, Vol.55, No.1, pp.119-139 (1997).
- [3] 入江, 林: 台形型メンバシップ関数による学習型ファジィ推論の設計評価, *知能と情報*, Vol.31, No.6, pp.908-917 (2019)
- [4] 林, 鶴背: 確率的データ補間を用いた BCI のための Boosting アルゴリズムの提案, *信学技報*, Vol.109, No.461, pp.303-308 (2010)
- [5] 入江, 林, 堅多: pdi-Bagging を用いた大規模屋外駐車場での車種識別, *インテリジェント・システム・シンポジウム 2021 講演論文集*, pp.207-212 (2021)
- [6] 入江, 林: バーチャルデータとルールを継承するアンサンブル学習 pdi-Boosting の提案, 第 37 回ファジィシステムシンポジウム講演論文集, pp.118-123 (2021)
- [7] H.Irie, I.Hayashi: pdi-Bagging: A Proposal of Bagging-type Ensemble Method Generating Virtual Data, *Proc. of the 15th International Conference on Agents and Artificial Intelligence (ICAART2023)*, Vol.3, pp.956-963 (2023).
- [8] 入江, 林: pdi-Bagging の定式化とその評価, *知能と情報*, Vol.35, No.1, pp.603-614 (2023)
- [9] 入江, 林: アンサンブル学習 pdi-BoostingG の定式化とその評価, 第 38 回ファジィシステムシンポジウム講演論文集, pp.394-401 (2022)
- [10] 市橋, 渡邊: 簡略ファジィ推論を用いたファジィモデルによる学習型制御, *日本ファジィ学会誌*, Vol.2, No.3, pp.429-437 (1990)

[連絡先]

林 勲 関西大学大学院 総合情報学研究科
〒 569-1095 大阪府高槻市霊仙寺町 2-1-1
tel. 072-690-2448
fax. 072-690-2491
e.mail ihaya@kansai-u.ac.jp