

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

A Proposal of Ensemble Learning “pdi-Boosting” Inheriting Virtual Data and Fuzzy Rules

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

Abstract: Recently, we have been increasing interest in ensemble learning. In particular, Bagging and Boosting are useful methods. Bagging is a method of learning more than one classifier independently for training data, and Boosting is a method of learning more than one classifier dependent on each other. In this paper, we propose a new ensemble learning “pdi-Boosting,” which inherits virtual data and fuzzy rules between classifiers of pdi-Bagging. In pdi-Boosting, the discrimination rate is improved, and the robustness against noise data is also improved because of increasing the amount of data due to the inheritance of virtual data. We define here the inheritance method for virtual data and fuzzy rules, and formulate pdi-Boosting. We will also discuss the usefulness of pdi-Boosting.

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 [1,2] 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の逐次的タイプの一つにブースティング法 (Boosting Methods) [3] がある。ブースティングは、逐次的に弱判別器を学習させ、識別率を向上させる手法であり、AdaBoost [3,4] は特に有用で、データ集合の特徴量を解析しやすい利点がある。また、学習データの分割法 [5] の提案や 2 クラス識別器の Gentle Boosting [6] をマルチクラスに拡張した Joint Boosting [7] なども提案されている。なお、バギングとブースティングを統合したアンサンブル法も提案されている [8,9]。我々は弱判別器の同定の際に、仮想的に生成したデータを観測データに追加して学習データを構成し、判別線の精度を向上させる新たなバギング法を提案している。このバギング法を pdi-Bagging と呼び、仮想的に生成したデータをバーチャルデータと呼んでいる [10-13]。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。しかし、バギングでは、最適化したファジィルールや発生したバーチャルデータが次層に引き続かれず、全体の認識精度が改善されない。

本論文では、多層構造における前層から次層にファジィルールやデータ集合を継承する新たなブースティング法 (pdi-Boosting: Possibilistic Data Interpolation-Boosting) を提案する。ここでの継承とは、1) ルールの継承、2) バーチャルデータの量的継承、3) バーチャルデータの質的継承をいう。ルールの継承とは、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ことをいう。バーチャルデータの量的継承とは、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ための継承法をいう。ただし、前層までの継承を単層と定義するか累積層と定義するかによって構成法が異なる。バーチャルデータの質的継承とは、前層から次層へ継承するバーチャルデータクラスを再決定する方法やサンプリングの方法をいう。ここでは、ルールの継承とバーチャルデータの量的継承について議論する。ファジィルールの継承では、弱判別器を学習する際に、前層で学習した最小誤差のファジィルールデータを次層のファジィルール学習の初期値として設定する。バーチャルデータの継承では、前層で発生したバーチャルデータの量に継承率を乗じたデータ量を次層の学習データに追加して全体の学習データを構成する。ファジィルールとバーチャルデータの継承により最終結果の識別率は向上する。しかし、最終の識別率とファジィルールやバーチャルデータの継承が相関関係にあるとは限らない。そのため、ここでは、ファジィルールの継承とバーチャルデータの量的継承を組み入れた新たな pdi-Boosting を定式化し、2 群識別の数値例を用いて、識別率とファジィルールやバーチャルデータの継承との関係について議論する。

2. pdi-Boosting

pdi-Boosting 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、メンバシップ関数を用いてバーチャルデータを特定の観測データの近傍に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。 pdi-Boosting の概念図を図 1 に示す。




Fig.1: pdi-Boosting

pdi-Boosting では、弱判別器として簡易型ファジィ推論 [14,15] 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、出力変数を z 、後件部のシングルトンに p_i を表すと、ファジィルール r_i , $i = 1, 2, \dots, R$ は次のようになる。

$$r_i : \text{if } x_1 \text{ is } \mu_{F_{i1}}(x_1) \text{ and } \dots \text{ and } x_n \text{ is } \mu_{F_{in}}(x_n) \\ \text{then } C = \{C_{ik} \mid z = p_i\}$$

ただし、 C は出力クラスの変数であり、 C_{ik} はルール r_i のクラス値が C_k であることを示す。

いま、入力データ $\mathbf{x} = (x_1, x_2, \dots, x_n)$ が得られたとしよう。第 i 番目のファジィルール r_i の前件部に入力データ \mathbf{x} を入力し、前件部の適合度 $\mu_i(\mathbf{x}) = \mu_{F_{i1}}(x_1) \cdot \mu_{F_{i2}}(x_2) \cdot \dots \cdot \mu_{F_{in}}(x_n)$ を計算する。ファジィ推論の結果 \hat{z} とクラス C は次式から求める。

$$\hat{z} = \frac{\sum_{i=1}^R \mu_i(\mathbf{x}) \cdot p_i}{\sum_{i=1}^R \mu_i(\mathbf{x})} \\ C = \{C_k \mid \min |\hat{z} - z|\}$$

バーチャルデータの発生では、 W 個のデータからなるデータ集合 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 $\mathbf{x}^V(d)$ は、ある特定の正判別データ $\mathbf{x}^C(d)$ や誤判別データ $\mathbf{x}^E(d)$ の周辺に発生する。 $\mathbf{x}^V(d)$ を構成する第 j 属性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 $\mu_F(x_j)$ を用いて次のように発生する。

$$x_j^V(d) = \{x_j \mid \mu_F(x_j) = h, \mu_F(x_j^S(d)) = 1\} \\ h \sim N(1, 1), \quad 0 \leq h \leq 1$$

ただし、 $x_j^S(d)$ は正判別データ $x_j^C(d)$ または誤判別データ $x_j^E(d)$ を意味し、メンバシップ関数 $\mu_F(x_j)$ は、ファジィ数 F の中心が $x_j^S(d)$ であり、標準偏差が σ である次の正規分布で定義する。

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

バーチャルデータの発生方法として次の 5 種類を提案する。

(1) 正判別全領域型 (CA)

全領域の任意の学習データ $\mathbf{x}^S(d)$ のクラスが弱判別器により正判別と判別された場合、その正判別データ $\mathbf{x}^C(d)$ の周辺にバーチャルデータ $\mathbf{x}^V(d)$ を発生する。

(2) 正判別クラスター中心型 (CC)

任意の学習データ $\mathbf{x}^S(d)$ 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 $\mathbf{x}^E(d)$ の真のクラス (教師クラス) と同クラスに属する $\mathbf{x}^E(d)$ からの最近傍の正判別データと最遠方の正判別データの midpoint を求め、その midpoint に最近傍の正判別データ $\mathbf{x}^C(d')$ の周辺にバーチャルデータ $\mathbf{x}^V(d')$ を発生する。

(3) 誤判別型 (E)

任意の学習データ $\mathbf{x}^S(d)$ 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 $\mathbf{x}^E(d)$ の周辺にバーチャルデータ $\mathbf{x}^V(d)$ を発生する。

(4) 混合判別全領域型 (MA)

バギングの各層で正判別全領域型と誤判別型を交互に用いて、バーチャルデータ $\mathbf{x}^V(d)$ を $\mathbf{x}^C(d)$ や $\mathbf{x}^E(d)$ の周辺に発生する。

(5) 混合判別クラスター中心型 (MC)

バギングの各層で正判別クラスター中心型と誤判別型を交互に用いて、バーチャルデータ $\mathbf{x}^V(d)$ を $\mathbf{x}^C(d)$ や $\mathbf{x}^E(d)$ の周辺に発生する。

3. 継承と定式化

pdi-Boosting の識別率をより向上させるため、前層から次層にルールやデータ集合を継承する。ここでの継承問題とは、次の 3 種類の継承を対象とする。

(1) ルールの継承

判別器によって学習された前層のルールを次層に引き継ぐための継承法をいう。前層の識別率が最大となる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する。前層の最適ファジィルールが次層で継続して学習されるので、ファジィルールがより深化に学習され識別率の向上が期待できる。

(2) パーシャルデータの量的継承

各層で発生したパーシ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ための継承法をいう。パーシャルデータの量的継承には 2 つの方法がある。

(a) パーシャルデータ量の単率継承法

第 l 層の v_l 個のパーシ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} 個のパーシャルデータを第 $l+1$ 層へ継承する。

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

ここで、 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。

(b) パーシャルデータ量の複率継承法

第 1 層から第 l 層までの $\sum_{k=1}^l v_k$ 個のパーシ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} 個のパーシャルデータを第 $l+1$ 層へ継承する。

$$\begin{aligned} v_{l+1} &= \xi \times \sum_{k=1}^l v_k \\ W_{l+1}^{TRD} &= W_l^{TRD} + v_{l+1} \end{aligned} \quad (2)$$

(3) パーシャルデータの質的継承

層間で継承したパーシャルデータのクラスを再決定することとサンプリング方法をいう。特に、パーシャルデータのクラスは前層の学習データやパーシャルデータを考慮して決定すべきである。しかし、この議論は今後の課題としたい。

pdi-Boosting における継承を図 2 に示す。pdi-Boosting を 3 層構造としている。各層で全領域のファジィルールと特定領域内の追加ファジィルールを用いたファジィ推論を判別器として判別線が推定されている。層間でファジィルールとパーシャルデータが継承されている。なお、継承率 ξ が $\xi = 0.0$ の場合には、pdi-Boosting は pdi-Bagging と同じ構造となることに注目すべきである。

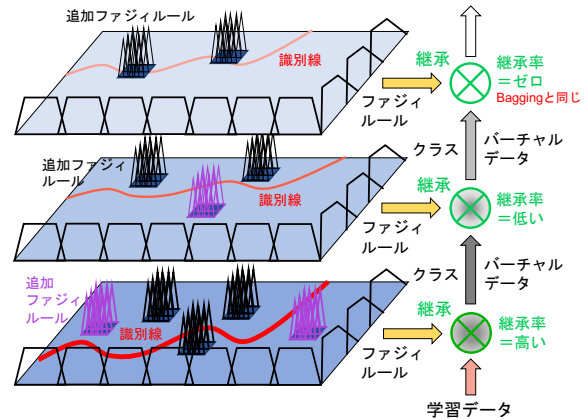


Fig.2: pdi-Boosting における継承

pdi-Bagging のアルゴリズムを次のように定式化する。

- Step 1** 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、 D^{TRD} から構成されるパーシャルデータを D^V で表す。
- Step 2** 第 $l-1$ 層目の弱判別器 M_{l-1} の最適ファジィルールを第 l 層目の弱判別器 M_l に継承し、第 l 層目の弱判別器 M_l に D^{TRD} を入力して、第 l 層目の結果 R_l の識別率 r_l^{TRD} を得る。
- Step 3** 正判別あるいは誤判別された第 d 番目のデータを D^{TRD} から一時的に抽出する。正判別あるいは誤判別データ $\mathbf{x}^S(d)$ の第 j 番目の属性値 $x_j^S(d)$ に対して、メンバシップ関数 $\mu_F(x_j)$ によりパーシャルデータ $x_j^V(d)$ を発生する。
- Step 4** 論文 [13] によりパーシャルデータ $\mathbf{x}^V(d)$ のクラス k^* を求め、 $l > 1$ の第 l 層目の D^V にクラス k^* のパーシャルデータ $\mathbf{x}^V(d)$ を追加する。
- Step 5** 継承率 ξ を用いて、式 (1) や式 (2) のパーシャルデータの個数 v_l を決定する。乱数によって、 D^V から v_l 個のパーシャルデータを D^{TRD} に加え、第 $l-1$ 層目から第 l 層目にパーシャルデータを継承する。

Step 6 $l = l+1$ として Step2 から 5 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 7 $M_0, M_1, \dots, M_l, \dots, M_K$ に D^{CHD} を適用し、多数決により結果の識別率 r_K^{CHD} を得る。




Fig.3: 学習データと評価データ

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を同一とし 200 個である。学習データと評価データを図 3 に示す。2 入力 1 出力の 2 群判別問題として、乱数により各入力値を $[0, 1]$ 内で発生し、2 群クラスの実数値を 2.0 (赤・○印) と 3.0 (青・△印) に設定した。データ空間の全領域に 25 個のルールを設定し、特定領域を G_1, G_2 として、 $G_1 = \{(x_1, x_2) \mid [0.4, 0.7] \times [0.4, 0.7]\}$ に 49 個のルールを追加し、また、 $G_2 = \{(x_1, x_2) \mid [0.7, 0.8] \times [0.3, 0.7]\}$ に 4 個のルールを追加した。その結果、ルール数は合計 78 個となった。なお、ファジィルールの各次元の両端ではメンバシップ関数を直角台形型に設定した。また、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→前後件部交互学習とした。さらに、各入力の 5 種類のメンバシップ関数の学習係数は同一とし 0.01 に設定し、後件部のシングルトンの学習係数は最初の後件部学習では 0.4、交互学習の後件部学習では 0.6 とした。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, 10, 10), (10, 20, 20), (10, 30, 30) の 3 種類に設定した。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 $(w_1, w_2, w_3) = \{(1/3, 1/3, 1/3), (0.2, 0.4, 0.4), (0.5, 0.25, 0.25)\}$ とする。バーチャルデー

タの発生個数は 1 個とした。アルゴリズムの終了規範は繰り返し判定として、 $K = 5$ とした。ただし、混合判別型は、奇数層を誤判別型とし、偶数層を正判別型とする。また、継承率を $\xi = 0.0, 0.2, 0.4, 0.6, 0.8, 1.0$ とした、なお、結果の識別率は 10 試行の識別率の平均値とした。

pdi-Bagging と pdi-Boosting のルール継承、バーチャルデータ (VD) の継承、ルールとバーチャルデータ (VD) の継承の識別率の比較を表 1 に示し、評価指標の重み (0.2, 0.4, 0.4) での継承率変化による識別率を図 4 に示す。なお、判別器のファジィ推論単体の識別率は 89.43% であった。表 1 と図 4 の結果から識別率には次の特性があることがわかる。


- 1) pdi-Bagging と pdi-Boosting の識別率を比較すると、全ての VD 発生法において、pdi-Boosting の識別率の方が高い。特に、VD 継承では、正判別クラスター中心型 (CC) と混合判別クラスター中心型 (MC) の評価指標の重みが (0.2, 0.4, 0.4) の場合、1.35% の差があった。また、ルール・VD 継承でも、CC や MC で 1.0% の以上の差を得た。したがって、VD 継承が識別率の向上に大きく寄与していることがわかる。
- 2) ルール継承と VD 継承やルール・VD 継承の識別率の比較では、CA 以外の VD 発生法において、VD 継承やルール・VD 継承の方が識別率が高い。したがって、CA 以外では、VD を継承することによって識別率が高くなることがわかる。
- 3) 正判別全領域型 (CA) では、VD 継承やルール・VD 継承の継承率が 0.0 の場合、識別率が 92.00% と高くなった。継承率 0.0 は pdi-Bagging と同じであり、継承率が 0.0 の場合に識別率が高くなるのは CA のみであるので、pdi-Bagging は CA で識別率が高くなることがわかる。また、継承率が 0.5 以下で識別率が高くなっていることから、CA では、VD 継承よりもルール継承が識別率の向上に寄与していることがわかる。
- 4) 正判別クラスター中心型 (CC) では、ルール継承の識別率は高くなかった。また、継承率が高い VD 継承やルール・VD 継承は識別率が高くなる傾向があることから、VD の継承が識別率の向上に寄与していることがわかる。
- 5) 正判別型以外の誤判別型に関わる手法 (E, MA, MC) では、VD 継承やルール・VD 継承において、高い継承率で識別率が最大となる場合が多く見られた。ここでは、継承率 0.7 以上で高い識別率となっている。

表 1: pdi-Boosting と pid-Bagging の識別率の比較


手法	評価指標の重み	pdi-Bagging	pdi-Boosting(ルール継承)	pdi-Boosting(VD 継承)		pdi-Boosting(ルール・VD 継承)	
				識別率	継承率	識別率	継承率
CA	1/3, 1/3, 1/3	91.50	91.95	91.55	0.1, 0.5	91.95	0.0
	0.2, 0.4, 0.4	91.65	92.00	91.65	0.0	92.00	0.0, 0.1
	0.5, 0.25, 0.25	91.50	91.80	91.50	0.0, 0.1	91.85	1.0
	平均	91.55	91.92	91.57	–	91.93	–
CC	1/3, 1/3, 1/3	91.30	91.95	92.20	0.8	92.45	0.9
	0.2, 0.4, 0.4	91.20	91.85	92.55	0.8	92.30	0.2
	0.5, 0.25, 0.25	91.75	92.10	92.10	0.7	92.35	0.5
	平均	91.42	91.97	92.28	–	92.37	–
E	1/3, 1/3, 1/3	91.35	91.45	92.35	0.9	92.10	0.2, 1.0
	0.2, 0.4, 0.4	91.75	91.80	92.15	0.9	92.55	0.9
	0.5, 0.25, 0.25	91.55	91.55	92.45	0.4	92.40	0.5
	平均	91.55	91.60	91.60	–	92.35	–
MA	1/3, 1/3, 1/3	91.35	91.50	92.20	0.4	92.05	0.1
	0.2, 0.4, 0.4	91.40	92.00	92.00	0.9	92.25	0.8
	0.5, 0.25, 0.25	91.25	91.55	92.05	0.4	91.95	0.7
	平均	91.33	91.68	92.08	–	92.08	–
MC	1/3, 1/3, 1/3	91.65	91.55	92.35	0.8	92.40	0.5
	0.2, 0.4, 0.4	91.35	91.90	92.70	1.0	92.25	0.8
	0.5, 0.25, 0.25	91.20	91.90	92.40	1.0	92.20	0.6
	平均	91.40	91.78	92.48	–	92.28	–

- 6) 全手法で識別率が最も高いのは、混合判別クラスター中心型 (MC) の VD 継承の継承率 1.0 で評価指標の重みが (0.2, 0.4, 0.4) の場合の 92.70% であった。
- 7) pdi-Boosting の平均識別率の比較では、ルール継承は CC が最も高く、VD 継承は MC、ルール・VD 継承では CC が高かった。CC や MC の奇数層では、VD は判別線からクラス中心付近で発生する。多数のルールが重なっているこれらの領域付近で VD が発生することによって学習が促進されたと考えられる。

これらの結果から、全ての VD 発生法において、pdi-Boosting の方が pdi-Bagging よりも識別率が高く、pdi-Boosting が優れた手法であるといえる。また、CA 以外の VD 発生法では、ルール継承よりも VD 継承やルール・VD 継承の方が識別率が高く、VD の継承が識別率に寄与していることがわかる。VD を継承する場合は、CA 以外の VD 発生法を採用すべきである。特に、誤判別型に関わる手法 (E, MA, MC) では、VD を継承した場合、高い継承率で識別率が最大となる場合が多く見られ、ここでは、継承率 0.7 以上で高い識別率となった。なお、識別率が最も高い VD 発生法と継承法は、混合判別クラスター中心型 (MC) の継承率 1.0 の VD 継承であった。



(a) VD継承



(b) ルール・VD継承

Fig.4: 継承率変化による識別率

5. おわりに

本論文では、弱判別器としてファジィ推論を用いて、バーチャルデータを発生する新たなブースティング法 (pdi-Boosting) を定式化し、その有用性を議論した。特に、ファジィルールとバーチャルデータの継承について議論し、2 群識別の数値例により pdi-Boosting の有用性を議論した。pdi-Boosting は、バーチャルデータの追加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、より効率的なバーチャルデータの発生法やクラス決定法、サンプリング方法、継承率の調整法、ファジィ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、関西大学研究拠点形成支援経費「Harmonized Fitness：音楽運動のアンサンブルによる健康づくりのスマート化」(2021 年～2022 年) および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) の助成を得た。

参考文献

- [1] 上田：アンサンブル学習，情報処理学会論文誌，Vol.46, No.SIG15(CVIM12)，pp.11-20 (2005)
- [2] R.Polikar: Ensemble Based Systems in Decision Making, *IEEE Circuits and Systems Magazine*, Vol.6, No.3, pp.21-45 (2006).
- [3] 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).
- [4] 三田：AdaBoost の基本原理と顔検出への応用，情報処理学会研究報告，Vol.42(CVIM-159)，pp.265-272 (2007)
- [5] 堀内，大町，阿曾：AdaBoost アルゴリズムを用いた識別手法の統合，電子情報通信学会論文誌，Vol.J91-D, No.4，pp.1168-1171 (2008)
- [6] J.Friedman, T.Hastie, R.Tibshirani: Additive Logistic Regression: A Statistical View of Boosting, *Annals of Statistics*, Vol.28, No.2, pp.337-374 (2000).
- [7] A.Torralba, K.P.Murphy, W.T.Freeman: Sharing Features: Efficient Boosting Procedures for Multi-class Object Detection, *Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp.762-769 (2004).
- [8] 高橋：クラス所属確率を用いた事例ごとの分類器選択，言語処理学会第 15 回年次大会発表論文集，pp.709-712 (2009)
- [9] 安村，上原：Bagging と Boosting を統合したアンサンブル学習方法，第 19 回人工知能学会全国大会予稿集，No.3F1-01 (2005)
- [10] 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)
- [11] I.Hayashi, S.Tsuruse, J.Suzuki, R.T.Kozma: A Proposal for Applying pdi-Boosting to Brain-Computer Interfaces, *Proceedings of 2012 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE2012) in 2012 IEEE World Congress on Computational Intelligence (WCCI2012)*, pp.635-640 (2012).
- [12] 入江，林：正誤バーチャルデータの発生による pdi-Bagging の特性評価，第 29 回インテリジェント・システム・シンポジウム講演論文集，Paper ID:No.A3-3 (2019)
- [13] 入江，林：pdi-Bagging による発生バーチャルデータのクラス決定法の提案，第 34 回人工知能学会全国大会講演論文集，Paper ID:No.103-GS-8-04 (2020)
- [14] 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)
- [15] 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)

[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