

オンライン学習アルゴリズムのファジィ識別器への応用と性能比較

Application of Online Learning Algorithms to Fuzzy Classifiers and its Performance Evaluation

中島 智晴 炭谷 剛志
Tomoharu Nakashima Takeshi Sumitani

大阪府立大学
Osaka Prefecture University

Online learning algorithm for fuzzy classifiers is studied. It is assumed in this paper that not all training patterns are given a priori for training classifiers, but are gradually made available over time. It is also assumed that the previously available training patterns can not be used afterwards. Thus, it is required that already constructed classifiers are modified using the currently available training patterns. Online learning algorithms are applied to fuzzy classifiers for this task. A series of computational experiments are conducted in order to examine the performance fuzzy classifiers with online learning algorithms.

1. はじめに

ファジィIf-Then ルールに基づいたファジィ識別器は非線形問題に高い識別性能を持っていることが知られている [1]. また, ルールの前件部に言語的な意味を持たせることができるので, 識別器の入出力関係を言語的に理解できるという特徴もある. 情報処理において, 一度に膨大な量のデータを効果的かつ効率的に処理することは難しい. また問題によっては断続的に得られるデータを処理する必要がある. これらの問題を解決する方法としてオンライン学習がある. しかしながら, オンライン学習をファジィ識別器に適用する研究は進んでいない. 本論文では, CW 学習をファジィ識別器に適用し, オンラインファジィ識別器の性能を調査する.

2. ファジィ識別器

2.1 ファジィIf-Then ルール

n 次元 2 クラスパターン識別問題に対するファジィIf-Then ルールについて説明する [1]. 本研究で取り扱うファジィ識別器は, 以下のファジィIf-Then ルールで構成される.

$$R_q : \text{If } x_1 \text{ is } A_{q1} \text{ and } \dots \text{ and } x_n \text{ is } A_{qn} \\ \text{then } y_q, \quad q = 1, 2, \dots, N \quad (1)$$

ここで, R_q はルールのラベル, $\vec{A}_q = (A_{q1}, A_{q2}, \dots, A_{qn})$ は前件部ファジィ集合, y_q はルールの後件部実数を表す. また, N はファジィ識別器を構成するファジィIf-Then ルールの総数を表す. 前件部ファジィ集合は図 1 に示す三角型メンバシップ関数により規定されることとする.




図 1: 三角型メンバシップ関数 (3 分割の場合)

連絡先: 中島 智晴, 大阪府立大学 工学研究科,
大阪府堺市中区学園町 1-1, 072-254-9825,
tomoharu.nakashima@kis.osakafu-u.ac.jp

2.2 未知パターンの識別

未知パターン $\vec{x} = (x_1, x_2, \dots, x_n)$ は以下の規則に従って識別される.

$$\vec{x} \text{ は } \begin{cases} \text{クラス 1} & \text{if } 0 < \sum_{q=1}^N \mu_q(\vec{x}) \cdot y_q \\ \text{クラス 2} & \text{if } 0 > \sum_{q=1}^N \mu_q(\vec{x}) \cdot y_q \\ \text{識別不能} & \text{otherwise} \end{cases} \quad (2)$$

ここで, $\mu_q(\vec{x})$ はファジィIf-Then ルール R_q の \vec{x} に対する適合度であり, 以下の積演算により求められる.

$$\mu_q(\vec{x}) = \mu_{A_{q1}}(x_1) \cdot \mu_{A_{q2}}(x_2) \cdot \dots \cdot \mu_{A_{qn}}(x_n) \quad (3)$$

ここで, $\mu_{A_{qi}}(x_i), i = 1, \dots, n$ は R_q における第 i 属性のファジィ集合 A_{qi} に対する x_i の適合度である.

2.3 CW 学習によるルール実数値の決定

線形識別のオンライン学習手法の一つである Confidence-Weighted (CW) 学習 [2] をファジィ識別器に適用するために, 式 (1) における実数値出力 y_q にガウス分布を導入する. $\vec{y} = (y_1, y_2, \dots, y_q)$ とする. ルール R_q の実数値出力 y_q は平均 μ_q , 分散 σ_q のガウス分布に従うものとする. 時刻 t における実数値出力ベクトル \vec{y} の更新は以下の最適化問題から得られる.

$$\begin{aligned} (\vec{\mu}_{t+1}^y, \vec{\Sigma}_{t+1}^y) = \\ \arg \min_{(\vec{\mu}, \vec{\Sigma})} D_{KL}(N(\vec{\mu}, \vec{\Sigma}) || N(\vec{\mu}_t^y, \vec{\Sigma}_t^y)) \\ \text{s.t. } Pr_{\vec{y} \sim N(\vec{\mu}, \vec{\Sigma})} [y_t(\vec{y} \cdot \vec{x}_t) \geq 0] \geq \eta \\ (0.5 \leq \eta \leq 1.0) \end{aligned} \quad (4)$$

ここで y_t は教師出力 (1 or -1) を表す. また $\vec{\mu}_t^y, \vec{\Sigma}_t^y$ はそれぞれ, \vec{y} の平均と分散を表す. 式 (4) の最適化問題を解くことにより更新式が得られる.

3. 実世界識別問題への適用

オンライン学習を実装したファジィ識別器を実世界の識別問題に適用し、識別性能を調査する。本実験では UCI repository から使用できるデータを用いて実験を行う。実験では 2 クラス問題のみを扱う。

3.1 実験設定

本実験では、オンラインファジィ識別器の性能を調査するため、全ての学習用パターンを一度に与えるのではなく、1 回の学習につき学習用パターン 1 つを与え学習を行う。実験手順を以下に記す。

- Step 1: 重複なしでランダムに学習用パターンを選択
- Step 2: Step 1 の学習用パターンに対して学習
- Step 3: 全てのパターンが選択されるまで繰り返す

識別性能を評価するために 10CV を 10 回行い、評価用パターンに対する平均正答率を性能評価の指標として用いることとする。実験で使用したデータの詳細を表 1 に示す。

3.2 実験結果

実験結果を表 2 に示す。表 2 は CW 学習を用いたファジィ識別器と線形識別器の正答率の平均を示している。実験結果から、3 つのデータセットにおいてファジィ識別器の正答率が線形識別器より高いことがわかる。この結果から、ファジィ識別器に CW 学習をうまく適用できたと考えられる。

表 1: UCI Repository データ

Data set	Dimensionality	# of patterns	
		Class1	Class2
Abalone	8	3787	391
Breastcancer	10	458	242
Pima-indians	8	501	268
Transfusion	4	571	178

表 2: 実験結果

Data set	Fuzzy	Linear
Abalone	0.8772	0.8671
Breastcancer	0.9591	0.9213
Pima-indians-diabetes	0.6766	0.5706
Transfusion	0.7061	0.7319

4. 行動パターン異常検知への適用

高齢者見守りシステムの異常検知に適用し、性能を調査する。

4.1 実験設定

本実験では、入力 8 次元、出力 2 クラスの問題として CW 学習を用いたファジィ識別器と比較手法に適用する。実験手順を以下に記す。

- Step 1: 重複なしでランダムに学習用パターンを選択
- Step 2: Step 1 の学習用パターンに対して学習
- Step 3: テストパターン 1 つに対して性能評価
- Step 4: 全てのパターンが選択されるまで繰り返す

学習用パターンは正常と定義されたパターン 1000 個と異常と定義されたパターンを 1000 個用意する。本実験では異常パターンを 100 個使用するものと 1000 個全て使用する場合で状況を変えて実験を行う。またテストパターンは正常パターン 100 個と異常パターン 200 個の計 300 個用意する。

4.2 実験結果

正答率の推移を図 2, 3 に示す。これらの図において、横軸は時間、縦軸は正答率を表している。いずれの結果に対しても PA 学習よりも CW 学習の識別性能が高いことがわかる。

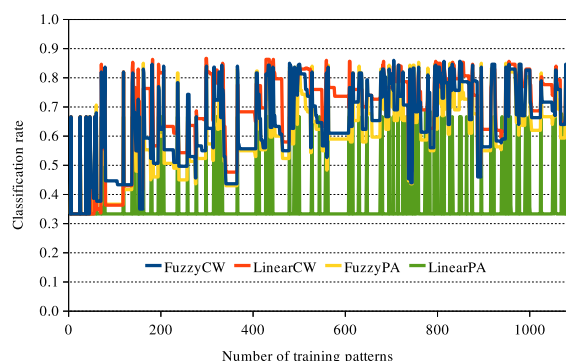


図 2: 実験結果 (異常パターン数 100)

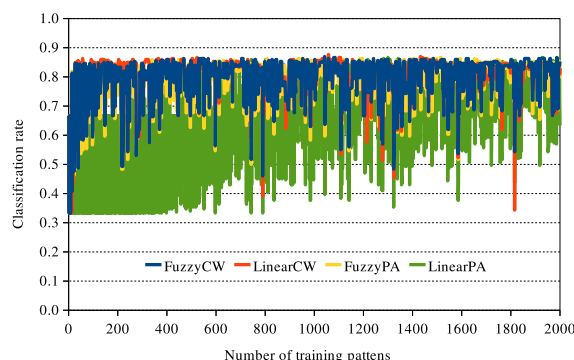


図 3: 実験結果 (異常パターン数 1000)

5. おわりに

本論文では、ファジィ識別器にオンライン学習の一つである Confidence-Weighted 学習を適用し、性能を調査した。様々な問題に対して、既存手法と比較し、CW 学習を用いたファジィ識別器の識別性能における有効性を示した。

参考文献

- [1] H. Ishibuchi, T. Nakashima and M. Nii, *Classification and Modeling with Linguistic Information Granules*, Springer, 2003.
- [2] M. Dredze, K. Crammer, and F. Pereira, "Confidence-Weighted Linear Classification," *Proc. of the 25th International Conference On Machine Learning*, pp. 264–271, 2008.