

飽和型 RealAdaBoost の提案とその性能評価

井坂 諭^{†1} 林 豊洋^{†1}
榎田 修一^{†1} 江島 俊朗^{†1}

実応用において注目されている分類器に AdaBoost を基にして弱識別器の構成法に改善を加えた RealAdaBoost がある。しかし, RealAdaBoost は確率密度分布に基づき弱学習器を構成しているため, 密度が低い箇所において推定誤差に敏感となり精度の低下を招いてしまう。本研究ではこの短所を補うことを目的として, 推定誤差に対して抑圧的に働く特性を組み入れた飽和型 RealAdaBoost を提案する。飽和型 RealAdaBoost は二つの飽和特性を弱識別器に組み込むことにより, 識別器構成時における分布推定誤差による影響を軽減している。顔画像を対象とする識別実験を通して弱識別器に組み込んだ飽和特性の有効性を示す。

A RealAdaBoost with Saturated Weak Learners

SATOSHI ISAKA,^{†1} TOYOHIRO HAYASHI,^{†1}
SHUICHI ENOKIDA^{†1} and TOSIAKI EJIMA^{†1}

RealAdaBoost, which is an improved version of AdaBoost, is an attracting classifier in real application. However, RealAdaBoost becomes sensitive to sampling error and decreases precision at a point of low density. In this paper, for the purpose of making up for this weak point, we propose Saturated RealAdaBoost which has two suppression characteristics for sampling error at a point of low density. We have shown the superiority of Saturated RealAdaBoost through an experiment of face direction estimation, in which several kinds of Boosting algorithms including Saturated RealAdaBoost, RealAdaBoost, etc., are compared in their precision ratio.

^{†1}九州工業大学
Kyushu Institute of Technology

1. はじめに

分類器として有名なものに, Y.Freund らが考案した AdaBoost がある¹⁾。これは多数の弱学習器を集めることでできる一つの強分類器で, 顔検出への応用が特に有名である²⁾。この AdaBoost を基にして R.E.Shapire らが弱識別器の構成法に改善を加えたものが, 実応用において注目されている RealAdaBoost である³⁾。これは二値だった弱学習器の出力を連続値とすることで入力に対する柔軟性を持たせ, 精度の向上を図っている。しかし RealAdaBoost は確率密度分布に基づいて弱学習器を構成しているため, 密度が低い箇所において推定誤差に対して敏感となり精度の低下を招くという短所がある。

そこで本論文ではこの短所を補う目的として, 推定誤差に対して抑制的に働く特性を組み入れた飽和型 RealAdaBoost を提案する。これは非線形性, バイアスに関する二種類の飽和特性を弱識別器に組み込むことにより, 弱識別器構成時における確率密度分布の推定誤差による影響を軽減させる狙いがある。さらにこれらの飽和特性を調整するためのパラメータを設定し, それらを変化させることで性能にどのような影響を与えるかの実験を行った。

2. AdaBoost

AdaBoost 分類器は Y.Freund らが考案した分類器で, ある入力に対して二つの出力を返す二クラス分類器である。AdaBoost は顔検出において有名な手法²⁾⁵⁾⁶⁾ で, 精度の低い弱学習器を多数組み合わせることで一つの高精度の強分類器を作るブースティングアルゴリズムである。各弱学習器は自分の前までの弱学習器が誤分類したものに対して重みをおいて学習する。最終的な評価は各弱学習器の重み付き多数決

$$H(x) = \text{sign}\left(\sum_{t=1}^T \alpha_t h_t(x)\right) \quad (1)$$

によって表される。このとき x は入力, T は学習回数, α は弱学習器の重みである。

以下は弱学習器のアルゴリズムである。決められた学習回数だけループして弱学習器が作られる。

2.1 弱学習器の生成

全ての学習用画像から特徴量を抽出し, 画像の重みを反映させた上でそれらの重心を算出する。この重心が分類する際の指標となる。つまり, 入力を与えられた時, その特徴量がどちらの重心に近いことによって分類される。入力に対して各重心からの距離を求め, その差を

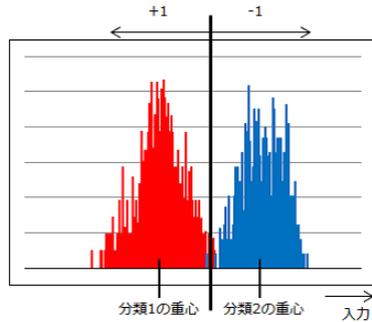


図1 弱学習器の分類方法
Fig. 1 Weak classifiers method.

もって弱学習器の評価とする。

2.2 重みの決定と正規化

生成した弱学習器を使い、サンプル集合の画像全てを分類する。全ての分類が終わったら、その誤識別率と式 (2) より弱学習器の重みを決定する。

$$\alpha_t = \log \frac{1}{\beta_t} \quad (2)$$

ただし、

$$\beta = \frac{\varepsilon}{1 - \varepsilon} \quad (3)$$

このとき ε は誤識別率である。この時重みが 0、つまり分類器として使えないものが作成されたら、その弱学習器は破棄し、最初から作り直す。また、サンプル集合の画像については式 (4) により重みが更新される。

$$W_{t+1,i} = W_{t,i} \beta_t^{1-e_i} \quad (4)$$

このとき e_i は正しい分類をされた時に 0、間違った分類をされた時に 1 となる。式 (4) を使うと、正しい分類をされた画像は軽くなり、式 (5) によって正規化を行うことで、間違った分類をされた画像は相対的に重みが大きくなる。

$$W_{t,i} = \frac{W_{t,i}}{\sum_{j=1}^N W_{t,j}} \quad (5)$$

このとき t は現在の学習回数、 i は画像の番号、 N は画像の数である。

1. 前処理
 N 個の学習サンプル x_1, \dots, x_N
 クラスに対応したラベル $y \in \{+1, -1\}$ の用意
2. 学習サンプルの重み D_1 を初期化
 $D_1(n) = 1/N$
3. For $t = 1, 2, \dots, T$ T 回の学習回数
 For $m = 1, 2, \dots, M$ M 個の弱識別器
 3.1 弱識別器 h_t の確率密度分布 W_t の作成

$$W_t^+ = \sum_{i: y_i = +1} D_t(i)$$

$$W_t^- = \sum_{i: y_i = -1} D_t(i)$$
 3.2 弱識別器候補

$$h(x) = \frac{1}{2} \ln \frac{W_t^+ + \varepsilon}{W_t^- + \varepsilon}$$
 3.3 弱識別器候補の評価値を算出

$$Z_m = 2 \sum_j \sqrt{W_t^+ W_t^-}$$
 4. 弱識別器候補から最も Z が小さい弱識別器を選択

$$h_t = \arg \min Z_{t,m}$$
 5. 学習サンプルの重み $D_t(i)$ の更新

$$D_{t+1}(i) = D_t(i) \exp[-y_i h_t(x_i)]$$
 6. 学習サンプルの重み $D_t(i)$ の正規化
7. 強識別器

$$H(x) = \text{sign} \left(\sum_{t=1}^T h_t(x) \right)$$

図2 RealAdaBoost のアルゴリズム
Fig. 2 Boosting algorithm of RealAdaBoost.

ここまでで一つの弱学習器の処理は終わり、新しい弱学習器の処理へと移る。

3. RealAdaBoost と S-RealAdaBoost

3.1 RealAdaBoost

RealAdaBoost は AdaBoost を基に R.E.Schapire らが发展させた分類器である。弱学習器の構成法に改善を加えており、弱学習器の出力が連続値となっている。図 2 に RealAdaBoost のアルゴリズムを示す。

RealAdaBoost は出力が実数となることで入力の変化に対して柔軟な対応が可能となり、精度の向上に繋がっている。

3.2 S-RealAdaBoost

RealAdaBoost により, 高速かつ精度の高い識別器が構成可能となった. しかし, RealAdaBoost は弱学習器を確率密度分布に基づいて構成しているため, 生起確率の低い箇所, つまり W_+, W_- のどちらかが極端に小さくなってしまった場合に弱学習器の出力が無限大に発散してしまう. これにより学習サンプルの重みが極端な値になってしまい, 以降の学習ラウンドに多大な影響を及ぼしてしまう. そこで谷川らによって考案されたものが, 飽和関数を導入した手法⁷⁾である(本論文ではこの手法を S-RealAdaBoost と呼ぶことにする). これは弱学習器に飽和関数を加えることで, その出力を一定の値に収めて無限大に発散しないようにしている.

3.2.1 飽和関数

S-RealAdaBoost は RealAdaBoost に飽和関数を導入することで, 弱学習器の出力を $[+1, -1]$ の範囲に抑えている. 飽和関数には式 (6) を用いた.

$$S(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \quad (6)$$

この x に RealAdaBoost の弱学習器の出力を代入すると式 (7) となる.

$$\begin{aligned} S\left(\frac{1}{2} \log \frac{W_+}{W_-}\right) &= \frac{e^{\frac{1}{2} \log \frac{W_+}{W_-}} - e^{-\frac{1}{2} \log \frac{W_+}{W_-}}}{e^{\frac{1}{2} \log \frac{W_+}{W_-}} + e^{-\frac{1}{2} \log \frac{W_+}{W_-}}} \\ &= \frac{\left(\frac{W_+}{W_-}\right)^{\frac{1}{2}} - \left(\frac{W_+}{W_-}\right)^{-\frac{1}{2}}}{\left(\frac{W_+}{W_-}\right)^{\frac{1}{2}} + \left(\frac{W_+}{W_-}\right)^{-\frac{1}{2}}} \\ &= \frac{W_+ - W_-}{W_+ + W_-}. \end{aligned} \quad (7)$$

この値を弱学習器の出力とすることで, 図 3 のように一定範囲外の入力に対しては出力が $+1, -1$ に収束される.

この飽和関数の導入によって, ある弱学習器が誤った出力をした場合でも他の弱学習器の出力による補正効果が働くので, 最終的な強分類器の精度は向上する.

4. 飽和型 RealAdaBoost

S-RealAdaBoost により弱識別器構成時の例外処理が行われ汎化性能が向上した. ここで更なる汎化性能及び精度の向上のために, 推定誤差に対して抑制的に働く二つの特性を RealAdaBoost に組み込んだ.

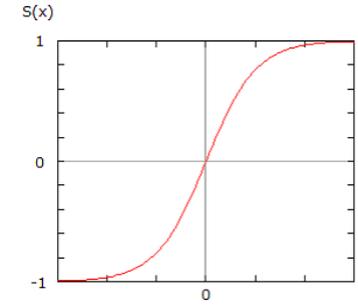


図 3 飽和関数
Fig. 3 Saturated function.

4.1 非線形性に関する飽和特性

第一の飽和特性は非線形性に関するもので, 飽和関数に組み込んで図 3 の非線形の範囲を調整するための特性である. 調整パラメータは α で表し, 組み込んだ時の飽和関数は式 (8) となる.

$$S_\alpha(x) = \frac{e^{\alpha x} - e^{-\alpha x}}{e^{\alpha x} + e^{-\alpha x}}. \quad (8)$$

この x に RealAdaBoost の弱学習器の出力を代入すると式 (9) となる.

$$\begin{aligned} S_\alpha\left(\frac{1}{2} \log \frac{W_+}{W_-}\right) &= \frac{e^{\frac{\alpha}{2} \log \frac{W_+}{W_-}} - e^{-\frac{\alpha}{2} \log \frac{W_+}{W_-}}}{e^{\frac{\alpha}{2} \log \frac{W_+}{W_-}} + e^{-\frac{\alpha}{2} \log \frac{W_+}{W_-}}} \\ &= \frac{\left(\frac{W_+}{W_-}\right)^{\frac{\alpha}{2}} - \left(\frac{W_+}{W_-}\right)^{-\frac{\alpha}{2}}}{\left(\frac{W_+}{W_-}\right)^{\frac{\alpha}{2}} + \left(\frac{W_+}{W_-}\right)^{-\frac{\alpha}{2}}} \\ &= \frac{W_+^\alpha - W_-^\alpha}{W_+^\alpha + W_-^\alpha}. \end{aligned} \quad (9)$$

ここで α を変化させると図 4 のように変化する. α の値によって非線形の範囲が決定され, 大きくなると狭く, 小さくなると広がっている. この飽和特性を組み込むことで入力 x に対する出力の幅が広がり, より柔軟な対応が可能となる.

4.2 バイアスに関する飽和特性

第二の飽和特性はバイアスに関するもので, 調整パラメータは ϵ で表し, 組み込んだ時の

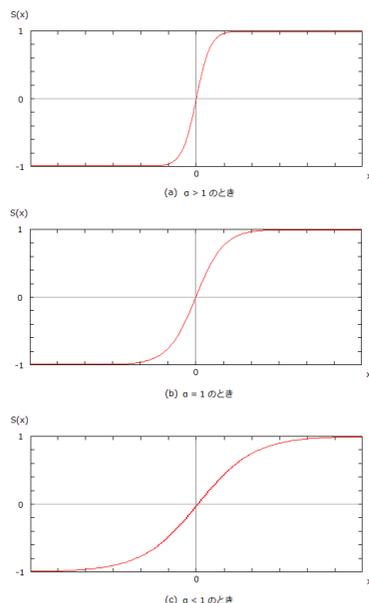


図 4 α を変化させた時の飽和関数
Fig.4 Saturated function at changing α .

弱学習器の出力は式 (10) となる .

$$h^{(\alpha, \epsilon)}(x) = \frac{W_+^\alpha - W_-^\alpha}{W_+^\alpha + W_-^\alpha + \epsilon^\alpha} \quad (10)$$

ここで $\max\{W_+^\alpha, W_-^\alpha\} < \frac{1}{n}\epsilon^\alpha$ のときには $h(x) < \frac{1}{n}$ となり, 図 5 のようになる .

このように ϵ によって上限, 下限が変化する . この時 ϵ を変化させることで図 6 のように $\frac{1}{n}$ に押さえこまれる領域も変化する .

この飽和特性を組み込むことで式 (10) の分母が 0 になることを防ぐとともに, W_+, W_- がどちらも極端に小さい時にそれらの少しの変化でも出力が大きく変わってしまうのを防いでいる .

ここで α, ϵ を式 (11) のように定義する .

$$\alpha = 10^{-\eta}, \epsilon = \left(\frac{1}{N}\right)^{10\theta} \quad (11)$$

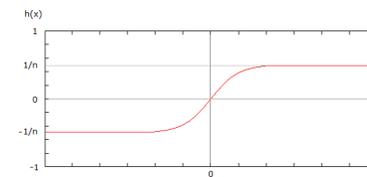


図 5 ϵ によって変化した飽和関数
Fig.5 Saturated function changed by ϵ .

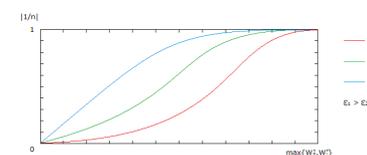


図 6 ϵ を変化した時の上限値
Fig.6 Upper limit at changing ϵ .

この時 N は学習用データの数である . この η, θ を変化させて飽和特性が識別に及ぼす効果を評価する .

5. 実 験

5.1 非線形性の飽和特性による性能評価

5.1.1 実験概要

組み込んだ二つの飽和特性を評価するために, 提案した飽和型 RealAdaBoost で顔の向き推定の実験を行った . 分類するのは右 90° と右 45° の顔画像で, 同環境で撮られた各 300 枚を学習用データ 270 枚とテストデータ 30 枚にわけて入れ替えることで計 600 枚の顔画像の分類を行った . ここでは $\theta = 0$ と固定し, η の値のみを変化させてその効果を評価した .

5.1.2 実験結果

図 7 は η を変化した時の誤識別率である .

η の値によって誤識別率は滑らかに変化しており, $\eta = 3$ の値を極小値とする下に凸な構造となった . なお, 従来法は $\eta = 0$ の時に該当するので, η を変化させることで精度を向上させることができた .

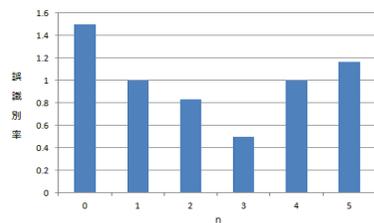


図 7 η を変化させた時の誤識別率
Fig. 7 Error rate at changing η.

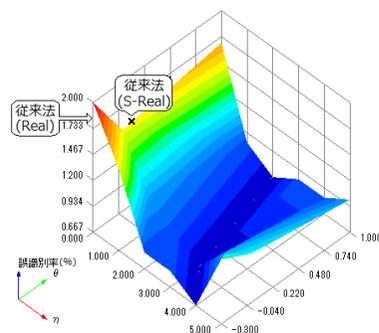


図 8 η, θ を変化させた時の誤識別率
Fig. 8 Error rate at changing η and θ.

5.2 バイアスの飽和特性を加えた性能評価

5.2.1 実験概要

5.1 と同じ環境で固定していた θ を変化させて実験を行った。

5.2.2 実験結果

図 8 は η, θ を変化させた時の誤識別率である。

どの θ においても η の値の変化によって誤識別率は滑らかに変化しており、極小値の表れる下に凸な構造となった。また、θ の値が変化しても誤識別率に大きな変化はなく、横ばいとなった。極小値をとる η の値は θ の値によって変化し、θ が大きくなるに従い η は小さくなっている。なお、従来法は η = 0, θ = 0 の時に該当しており、図 8 の x の位置となっている。よって、従来法に比べ η, θ の値を変化させることで精度を向上させることができた。

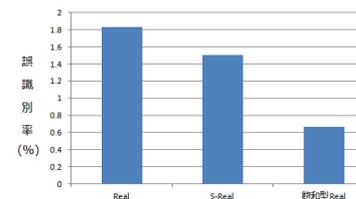


図 9 RealAdaBoost, S-RealAdaBoost, 飽和型 RealAdaBoost の誤識別率
Fig. 9 Error rate of RealAdaBoost, S-RealAdaBoost and Saturated Model RealAdaBoost

5.3 従来法との比較

従来法となる RealAdaBoost, S-RealAdaBoost の誤識別率は図 8 に示したが、実際に並べて比較したものが図 9 である。

RealAdaBoost が 1.833 %, S-RealAdaBoost が 1.5 % なのに対し、提案した飽和型 RealAdaBoost は 0.667 % と従来法に比べて低い誤識別率となった。これにより導入した二つの飽和特性が精度向上に繋がることが確認できた。

5.4 考察

調整パラメータ η に関しては、変化させることで精度が大きく変化した。これは非線形範囲を変化させることで、入力のばらつきに対しても適切な値を出力することができたからである。下に凸な構造となったのは η が大きすぎると出力が +1 と -1 のみとなってしまい、小さすぎると飽和関数のグラフがほぼ横ばいとなってしまい入力の変化に対して出力が同じ値を返してしまうので精度の低下を招いてしまうからである。一方、θ に関しては、今回の実験ではあまり変化は見られなかった。これはバイアスに関する飽和特性が本来は確率密度の低い箇所に対して強く働くものであり、今回の実験ではテストデータでの学習がよく為されていたために密度の低い選択が行われなかったので飽和特性の効果自体があまり表れなかったからである。誤識別率については、図 8 でわかるようにどの θ でも η が 2, 3 のあたりで特に低くなっていた。これより今回の分類において調整パラメータ η の適正值は 3 付近であり、θ の適正值は 0.3 付近であるといえる。

6. まとめ

本研究では RealAdaBoost の短所を補うために二種類の飽和特性を組み込んだ飽和型 RealAdaBoost を提案し、それらを調整するためのパラメータを設定してその性能を評価した。二つの調整パラメータを変化させることでその性能は変化し、誤識別率が低くなる領域

が広く存在する船底型構造となることがわかった。また、調整パラメータを適切な値に設定することで、固定値だった従来法に比べ高い識別精度を実現できた。今後は他の種類のデータに適用した場合にも調整パラメータを適切に設定することで高い精度を得られるかという普遍性の調査と、調整パラメータの推定方法が課題となる。

参 考 文 献

- 1) Yoav Freund and Robert E. Schapire, "decision-theoretic generalization of on-line learning and an application to boosting" Journal of computer and system sciences 55, 119-139, 1997.
- 2) Paul Viola and Michael J. Jones, "Robust Real-Time Face Detection" International Journal of Computer Vision 57(2), 137-154, 2004.
- 3) Robert E. Schapire and Yoram Singer, "Improved Boosting Algorithms Using Confidence-rated Predictions" Machine Learning 37(3), 297-336, 1999.
- 4) Chang HUANG, Bo WU, Haizhou AI and Shihong LAO, "OMNI-DIRECTIONAL FACE DETECTION BASED ON REAL ADABOOST" ICIP, 2004.
- 5) 林伸治, 長谷川修, "低解像度画像からの顔検出" 画像電子学会誌 第34巻, 2005.
- 6) 三田雄志, "AdaBoost の基本原理と顔検出への応用" CVIM-159(32), 265-272, 2007.
- 7) 谷川昌司, 日高章理, 佐野夏樹, 西田健次, 栗田多喜夫, "矩形特徴による弱識別器のブースティングによる対象検出手法の汎化性能向上のための工夫と車載カメラの映像中の車の検出への応用" 第11回画像センシングシンポジウム講演論文集 E-10, pp139-142, 2005.