

情報生命科学基礎 I

情報生命科学演習

7月10／17日

森下

演習内容

- 7月10日の講義
AdaBoost アルゴリズムの説明
- 7月10日の演習
プログラム例を紹介
- 7月17日
Jones and Pevzner
An Introduction to Bioinformatics Algorithms
Chapter 4 Exhaustive Search
- レポートの〆切 7月31日
あて先 齊藤助教 leo@cb.k.u-tokyo.ac.jp

AdaBoost の応用例

Marcel Dettling and Peter Bühlmann

Boosting for tumor classification with gene expression data

Bioinformatics, Jun 2003; 19: 1061 - 1069.

Jinyan Li, Huiqing Liu, See-Kiong Ng, and Limsoon Wong

Discovery of significant rules for classifying cancer diagnosis data

Bioinformatics, Sep 2003; 19: 93 - 102.

Manuel Middendorf, Anshul Kundaje, Chris Wiggins, Yoav Freund, and Christina Leslie

Predicting genetic regulatory response using classification

Bioinformatics, Aug 2004; 20: i232 - i240.

Pål Sætrom

Predicting the efficacy of short oligonucleotides in antisense and RNAi experiments with boosted genetic programming

Bioinformatics, Advance Access published on June 16, 2004; doi:
10.1093/bioinformatics/bth364.

三人寄れば文殊の知恵

Boosting とは正答率の低いクラス分類器を組合せて、高い正答率を示すクラス分類器を構成する技法。

参考文献

Yoav Freund and Robert E. Schapire. A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of Computer and System Sciences*, 55(1):119-139, 1997.

訓練用データ

	T1	T2	T3	T4	目標属性	
\vec{x}_1	1	0	1	1	1	(\vec{x}_1, y_1)
	1	0	1	1	1	
	1	1	1	1	1	
	1	1	1	0	0	\vdots
	1	0	1	0	0	
	1	1	0	1	0	
	1	0	0	1	0	(\vec{x}_N, y_N)
	1	1	0	1	0	
	0	1	0	1	1	
	0	0	1	1	1	
	0	1	0	1	1	
	0	1	0	1	1	
	0	0	0	1	1	
	0	0	1	0	0	
	0	1	0	0	0	
	0	0	1	0	0	

AdaBoost の基本的考え方

- 初期状態では各レコードに均等な重みを割当てる
- 次のステップを繰り返す
 1. ランダムに推測するよりは正答率の高い(50%を超える)クラス分類器を生成
 2. 目標属性の値の予測を誤ったレコードの重みを相対的に上げる(予測が困難であることを覚えておく)

註: 参考論文中ではクラス分類器(classifier)のことを仮説(hypothesis)と呼んでいる

クラス分類器

T1	T2	T3	T4	目標	重み	if T1=1 then Ob=0 else Ob=1	新しい 重み
1	0	1	1	1	■	0	■
1	0	1	1	1	■	0	■
1	1	1	1	1	■	0	■
1	1	1	0	0	■	0	■
1	0	1	0	0	■	0	■
1	1	0	1	0	■	0	■
1	0	0	1	0	■	0	■
1	1	0	1	0	■	0	■

■ の大きさが重みを表現

新たな
クラス分類器

T1	T2	T3	T4	目標	重み	if <u>T3</u> =1 then Ob=1 else Ob=0	新しい 重み
1	0	1	1	1	■	1	■
1	0	1	1	1	■	1	■
1	1	1	1	1	■	1	■
1	1	1	0	0	■	1	■
1	0	1	0	0	■	1	■
1	1	0	1	0	■	0	■
1	0	0	1	0	■	0	■
1	1	0	1	0	■	0	■

新たな
クラス分類器

T1	T2	T3	T4	目標	重み	if <u>T4</u> =1 then Ob=1 else Ob=0	新たな 重み
1	0	1	1	1	■	1	■
1	0	1	1	1	■	1	■
1	1	1	1	1	■	1	■
1	1	1	0	0	■	0	■
1	0	1	0	0	■	0	■
1	1	0	1	0	■	1	■
1	0	0	1	0	■	1	■
1	1	0	1	0	■	1	■

					クラス分類器				
					if T1=1	if T3=1	if T4=1	単純な	
					then Ob=0	then Ob=1	then Ob=1	多数決	
T1	T2	T3	T4	Ob	else Ob=1	else Ob=0	else Ob=0		
1	0	1	1	1	0	1	1	1	
1	0	1	1	1	0	1	1	1	
1	1	1	1	1	0	1	1	1	
1	1	1	0	0	0	1	0	0	
1	0	1	0	0	0	1	0	0	
1	1	0	1	0	0	0	1	0	
1	0	0	1	0	0	0	1	0	
1	1	0	1	0	0	0	1	0	

AdaBoost は重みを使った多数決

AdaBoost アルゴリズム

入力

訓練データ $(\vec{x}_1, y_1), \dots, (\vec{x}_N, y_N)$

初期の重み $w_i^1 = D(i) = \frac{1}{N}$ for each $i = 1, 2, \dots, N$

WeakLearn : エラー率が0.5未満の
クラス分類器を常に出力する学習アルゴリズム

T : 最終的に使うクラス分類器の個数

各 $t=1, \dots, T$, について以下のステップを繰り返す:

1: 各データの重みを正規化し、分布 p_i^t を計算

$$p_i^t = w_i^t / \sum_{i=1}^N w_i^t$$

2: **WeakLearn** を呼び出し次の条件を満たすクラス分類器 h_t を生成

$$\varepsilon_t = \sum_{i=1}^N p_i^t |h_t(\vec{x}_i) - y_i| < 1/2$$

$$|h_t(\vec{x}_i) - y_i| = \begin{cases} 0 & h_t \text{ が } \vec{x}_i \text{ の正解を返す場合} \\ 1 & \text{otherwise} \end{cases}$$

3: 重みを更新 重みは正解だと軽くなり、不正解だとそのまま

$$\beta_t = \varepsilon_t / (1 - \varepsilon_t) \quad \beta_t < 1 \quad w_i^{t+1} = w_i^t \beta_t^{1 - |h_t(\vec{x}_i) - y_i|}$$

$$\varepsilon_t \rightarrow 0, \beta_t \rightarrow 0 \quad \varepsilon_t \rightarrow 1/2, \beta_t \rightarrow 1$$

出力: 最終のクラス分類器 h_f (h_t の重みつき多数決)

$$h_f(\vec{x}) = \begin{cases} 1 & \text{if } \sum_{t=1}^T (-\log \beta_t) h_t(\vec{x}) \geq \sum_{t=1}^T (-\log \beta_t) \frac{1}{2} \quad \dots (*) \\ 0 & \text{otherwise} \end{cases}$$

$$\varepsilon_t \rightarrow 0, \beta_t \rightarrow 0, (-\log \beta_t) \rightarrow +\infty \quad \varepsilon_t \rightarrow 1/2, \beta_t \rightarrow 1, (-\log \beta_t) \rightarrow 0$$

エラー率が低い予測を尊重する

定義 $\varepsilon = \sum_{\{i \mid h_f(\vec{x}_i) \neq y_i\}} D(i)$

最終クラス分類器 h_f の
初期分布に対するエラー率
 $D(i) = 1/N$

定理 $\varepsilon \leq \prod_{t=1}^T 2\sqrt{\varepsilon_t(1-\varepsilon_t)} = \prod_{t=1}^T \sqrt{1-(1-2\varepsilon_t)^2}$

$$\varepsilon_t < 1/2, \quad 1-2\varepsilon_t < 1, \quad \sqrt{1-(1-2\varepsilon_t)^2} < 1$$

レポートの内容

1. プログラムのソースコード
 サンプルプログラムを与える
 自ら考えて実装した場合は可以上の評価
 サンプルプログラムをそのまま使用した場合は可以下の評価
2. データ構造と手続きの流れの説明
3. サンプルデータ(2値)から計算された分類器を示すこと
4. 重み、エラー率の変動についての解析
5. データ数を 100, 1000 と増加させた例を作って計算時間とエラー率を測定する
6. WeakLearn が新しいクラス分類器を出力できない例
7. WeakLearn が $(T1=1)$ かつ $(T2=0)$ のように2つの属性を使ったクラス分類器を出力できるように拡張する

サンプルデータ (2値)

T1	T2	T3	T4	目標属性
1	0	1	1	1
1	0	1	1	1
1	1	1	1	1
1	1	1	0	0
1	0	1	0	0
1	1	0	1	0
1	0	0	1	0
1	1	0	1	0

T1	T2	T3	T4	目標属性
1	0	1	1	1
1	0	1	1	1
1	1	1	1	1
1	1	1	0	0
1	0	1	0	0
1	1	0	1	0
1	0	0	1	0
1	1	0	1	0
0	1	0	1	1
0	0	1	1	1
0	1	0	1	1
0	1	0	1	1
0	0	0	1	1
0	0	1	0	0
0	1	0	0	0
0	0	1	0	0

Boosting 性の証明

定義 $\varepsilon = \sum_{\{i \mid h_f(\vec{x}_i) \neq y_i\}} D(i)$

最終クラス分類器 h_f の
初期分布に対するエラー率

定理 $\varepsilon \leq \prod_{t=1}^T 2\sqrt{\varepsilon_t(1-\varepsilon_t)} = \prod_{t=1}^T \sqrt{1-(1-2\varepsilon_t)^2}$

$$\varepsilon_t < 1/2, \quad 1-2\varepsilon_t < 1, \quad \sqrt{1-(1-2\varepsilon_t)^2} < 1$$

証明のロードマップ

$$\begin{aligned}\varepsilon \left(\prod_{t=1}^T \beta_t \right)^{1/2} &\leq \sum_{i=1}^N w_i^{T+1} \\ &\leq \left(\sum_{i=1}^N w_i^T \right) \times 2\varepsilon_t \\ &\vdots \\ &\leq \left(\sum_{i=1}^N w_i^1 \right) \prod_{t=1}^T 2\varepsilon_t\end{aligned}$$

補題 2 最終回の重みの総和の下限值

補題 3 $\sum_{i=1}^N w_i^{t+1} \leq \left(\sum_{i=1}^N w_i^t \right) \times 2\varepsilon_t$
重みの総和は $2\varepsilon_t$ 倍以下になる

$\sum_{i=1}^N w_i^1 = 1$ 補題3の繰返し適用

$$w_i^1 = D(i) = 1/N$$

$$\varepsilon \leq \prod_{t=1}^T \left(2\varepsilon_t \times \beta_t^{-1/2} \right) = \prod_{t=1}^T 2\sqrt{\varepsilon_t(1-\varepsilon_t)}$$

$\beta_t = \varepsilon_t / (1 - \varepsilon_t)$ に注意

$$\text{補題 2} \quad \sum_{i=1}^N w_i^{T+1} \geq \varepsilon \left(\prod_{t=1}^T \beta_t \right)^{1/2}$$

最終回の重みの総和の下限值

$$\begin{aligned} \sum_{i=1}^N w_i^{T+1} &\geq \sum_{\{i | h_f(\bar{x}_i) \neq y_i\}} w_i^{T+1} && \text{最終クラス分類器 } h_f \text{ が誤るレコードの重みの総和} \\ &= \sum_{\{i | h_f(\bar{x}_i) \neq y_i\}} \left(D(i) \prod_{t=1}^T \beta_t^{1-|h_t(\bar{x}_i)-y_i|} \right) && w_i^{t+1} = w_i^t \beta_t^{1-|h_t(\bar{x}_i)-y_i|} \text{ より} \\ &\geq \sum_{\{i | h_f(\bar{x}_i) \neq y_i\}} \left(D(i) \left(\prod_{t=1}^T \beta_t \right)^{1/2} \right) && \text{補題 1 より} \\ &= \left(\sum_{\{i | h_f(\bar{x}_i) \neq y_i\}} D(i) \right) \left(\prod_{t=1}^T \beta_t \right)^{1/2} && \begin{array}{l} \text{最終クラス分類器 } h_f \text{ が誤る} \\ \text{レコードの重みは} \\ (\beta_1 \cdots \beta_T)^{1/2} \\ \text{以上になる(あまり減らない)} \end{array} \end{aligned}$$

$$h_f(\vec{x}) = \begin{cases} 1 & \text{if } \sum_{t=1}^T (-\log \beta_t) h_t(\vec{x}) \geq \sum_{t=1}^T (-\log \beta_t) \frac{1}{2} \quad \dots (*) \\ 0 & \text{otherwise} \end{cases}$$

$$\text{補題1 } h_f(\vec{x}_i) \neq y_i \text{ ならば } \prod_{t=1}^T \beta_t^{1-|h_t(\vec{x}_i)-y_i|} \geq \left(\prod_{t=1}^T \beta_t \right)^{1/2}$$

コメント 最終のクラス分類機で予測が失敗するデータでは重みが十分に減らない

両辺のlogをとった

$$\sum_{t=1}^T (\log \beta_t)(1-|h_t(\vec{x}_i)-y_i|) \geq \sum_{t=1}^T (\log \beta_t) \frac{1}{2} \quad \text{を証明}$$

$h_f(\vec{x}_i) = 1, y_i = 0$ ならば: $\sum_{t=1}^T (\log \beta_t)$ を(*)の両辺に加算.

$$\sum_{t=1}^T (\log \beta_t)(1-h_t(\vec{x}_i)) \geq \sum_{t=1}^T (\log \beta_t) \frac{1}{2}$$

さらに $1-h_t(\vec{x}_i) = 1-|h_t(\vec{x}_i)-y_i|$ に注意

$h_f(\vec{x}_i) = 0, y_i = 1$ ならば: $\sum_{t=1}^T (-\log \beta_t) h_t(\vec{x}_i) < \sum_{t=1}^T (-\log \beta_t) \frac{1}{2}$

$$\sum_{t=1}^T (\log \beta_t) h_t(\vec{x}_i) > \sum_{t=1}^T (\log \beta_t) \frac{1}{2}$$

さらに $h_t(\vec{x}_i) = 1-|h_t(\vec{x}_i)-y_i|$ に注意

補題3

$$\sum_{i=1}^N w_i^{t+1}$$

$$= \sum_{i=1}^N w_i^t \beta_t^{1-|h_t(\vec{x}_i) - y_i|}$$

$$\leq \sum_{i=1}^N w_i^t (1 - (1 - \beta_t)(1 - |h_t(\vec{x}_i) - y_i|))$$

$$\alpha^\gamma \leq 1 - (1 - \alpha)\gamma,$$

if $\alpha \leq 1$ and $\gamma = 0$ or 1 .

$$= \sum_{i=1}^N w_i^t - (1 - \beta_t) \underbrace{\sum_{i=1}^N w_i^t (1 - |h_t(\vec{x}_i) - y_i|)}_{\text{正解する重みの和}}$$

$$\begin{aligned} 1 - \varepsilon_t &= \sum_{i=1}^N p_i^t - \sum_{i=1}^N p_i^t |h_t(\vec{x}_i) - y_i| \\ &= \sum_{i=1}^N p_i^t (1 - |h_t(\vec{x}_i) - y_i|) \\ &= \sum_{i=1}^N w_i^t (1 - |h_t(\vec{x}_i) - y_i|) / \left(\sum_{i=1}^N w_i^t \right) \end{aligned}$$

$$= \left(\sum_{i=1}^N w_i^t \right) (1 - (1 - \beta_t)(1 - \varepsilon_t))$$

$$= \left(\sum_{i=1}^N w_i^t \right) \bullet 2\varepsilon_t$$

$$1 - \beta_t = 1 - \frac{\varepsilon_t}{1 - \varepsilon_t} = \frac{1 - 2\varepsilon_t}{1 - \varepsilon_t}$$