

クラス分類の技法

AdaBoost

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	y_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	

(\vec{x}_1, y_1)
 \vdots
 (\vec{x}_N, y_N)

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			単純な 多数決
					if T1=1	if T3=1	if T4=1	
					then Ob=0	then Ob=1	then Ob=1	
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

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: 各レコードの重みを正規化して各レコードの分布 p_i^t を計算

$$p_i^t = \begin{cases} w_i^t / \sum_{i=1}^N w_i^t & \text{if } \sum_{i=1}^N w_i^t > 0 \\ 0 & \text{otherwise} \end{cases}$$

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

$$\varepsilon_t = \sum_{i=1}^N p_i^t |h_t(\vec{x}_i) - y_i| < 1/2 \quad \text{重み付き誤り率} < 1/2$$

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

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

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

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

出力: 最終のクラス分類器 h_f (h_t の重みつき多数決)

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

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

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

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

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

$$\sum_{i=1}^N w_i^{T+1} \geq \sum_{\{i \mid h_f(\vec{x}_i) \neq y_i\}} w_i^{T+1} \quad \text{最終クラス分類器 } h_f \text{ が誤るレコードの重みの総和}$$

$$= \sum_{\{i \mid h_f(\vec{x}_i) \neq y_i\}} \left(D(i) \prod_{t=1}^T \beta_t^{1-|h_t(\vec{x}_i)-y_i|} \right) \quad w_i^{t+1} = w_i^t \beta_t^{1-|h_t(\vec{x}_i)-y_i|} \quad \text{より}$$

$$\geq \sum_{\{i \mid h_f(\vec{x}_i) \neq y_i\}} \left(D(i) \left(\prod_{t=1}^T \beta_t \right)^{1/2} \right)$$

補題 1 より

$$= \left(\sum_{\{i \mid h_f(\vec{x}_i) \neq y_i\}} D(i) \right) \left(\prod_{t=1}^T \beta_t \right)^{1/2}$$

最終クラス分類器 h_f が誤る
レコードの重みは
 $(\beta_1 \cdots \beta_T)^{1/2}$

以上になる(あまり減らない)

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

補題1 $h_f(\vec{x}_i) \neq y_i$ 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

$h_f(\vec{x}_i) = 1, y_i = 0$ 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

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

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

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

$$\begin{array}{l} \alpha^\gamma \leq 1 - (1 - \alpha)\gamma, \\ \text{if } \alpha \leq 1 \text{ and } \gamma = 0 \text{ or } 1. \end{array}$$

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

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

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

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

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

ACM, Paris Kanellakis Theory and Practice Award

2004

Yoav Freund, *Columbia University* Robert Schapire, *Princeton University*

For the development of the theory and practice of boosting and its applications to machine learning.

2001

Eugene W. Myers University of Arizona/Celera Genomics/ UCB

For distinguished contributions to the theory of sequence analysis and its application to the sequencing of the human genome and the development of BLAST.

1996

Leonard Adleman, Whitfield Diffie, Martin Hellman, Ralph Merkle, Ronald Rivest, Adi Shamir

Public-Key Cryptography