

Adaboost导论

七月算法 邹博

2015年4月11日

提升方法

- 一个概念如果存在一个多项式的学习算法能够学习它，并且正确率很高，那么，这个概念是强可学习的；
- 一个概念如果存在一个多项式的学习算法能够学习它，并且学习的正确率仅比随机猜测略好，那么，这个概念是弱可学习的；
- 强可学习与弱可学习是等价的。
- 在学习中，如果已经发现了“弱学习算法”，能否将他提升为“强学习算法”。



Adaboost

- 设训练数据集 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$
- 初始化训练数据的权值分布

$$D_1 = (w_{11}, w_{12}, \dots, w_{1i}, \dots, w_{1N}), \quad w_{1i} = \frac{1}{N}, \quad i = 1, 2, \dots, N$$



Adaboost: 对于 $m=1,2,\dots,M$

- 使用具有权值分布 D_m 的训练数据集学习, 得到基本分类器

$$G_m(x): \mathcal{X} \rightarrow \{-1,+1\}$$

- 计算 $G_m(x)$ 在训练数据集上的分类误差率

$$e_m = P(G_m(x_i) \neq y_i) = \sum_{i=1}^N w_{mi} I(G_m(x_i) \neq y_i)$$

- 计算 $G_m(x)$ 的系数

$$\alpha_m = \frac{1}{2} \log \frac{1 - e_m}{e_m}$$



Adaboost: 对于 $m=1,2,\dots,M$

□ 更新训练数据集的权值分布

$$D_{m+1} = (w_{m+1,1}, w_{m+1,2}, \dots, w_{m+1,i}, \dots, w_{m+1,N}),$$

$$w_{m+1,i} = \frac{w_{mi}}{Z_m} \exp(-\alpha_m y_i G_m(x_i)), \quad i = 1, 2, \dots, N$$

□ 这里, Z_m 是规范化因子

$$Z_m = \sum_{i=1}^N w_{mi} \exp(-\alpha_m y_i G_m(x_i))$$

■ 它的目的仅仅是使 D_{m+1} 成为一个概率分布

$$w_{m+1,i} = \frac{w_{mi}}{Z_m} \exp(-\alpha_m y_i G_m(x_i)) \Rightarrow Z_m w_{m+1,i} = w_{mi} \exp(-\alpha_m y_i G_m(x_i)) \Rightarrow Z_1 w_{2,i} = w_{1i} \exp(-\alpha_1 y_i G_1(x_i))$$



Adaboost

- 构建基本分类器的线性组合

$$f(x) = \sum_{m=1}^M \alpha_m G_m(x)$$

- 得到最终分类器

$$G(x) = \text{sign}(f(x)) = \text{sign}\left(\sum_{m=1}^M \alpha_m G_m(x)\right)$$



举例

□ 给定下列训练样本，试用AdaBoost算法学习一个强分类器。

序号	1	2	3	4	5	6	7	8	9	X
X	0	1	2	3	4	5	6	7	8	9
Y	1	1	1	-1	-1	-1	1	1	1	-1



解

□ 初始化训练数据的权值分布

$$D_1 = (w_{11}, w_{12} \cdots w_{1i} \cdots, w_{1N}), w_{1i} = \frac{1}{N}, i = 1, 2, \cdots, N$$

□ $w_{1i} = 0.1$



m=1	序号	1	2	3	4	5	6	7	8	9	X
	X	0	1	2	3	4	5	6	7	8	9
	Y	1	1	1	-1	-1	-1	1	1	1	-1

- 对于m=1
- 在权值分布为D1的训练数据上，阈值v取2.5时误差率最低，故基本分类器为：

$$G_1(x) = \begin{cases} 1, & x < 2.5 \\ -1, & x > 2.5 \end{cases}$$



m=1

□ $G_1(x)$ 在训练数据集上的误差率

$$e_1 = P(G_1(x_i) \neq y_i) = 0.3$$

□ 计算 G_1 的系数:

$$\alpha_1 = \frac{1}{2} \log \frac{1-e_1}{e_1} = 0.4236$$



m=1

□ 更新训练数据的权值分布：

$$D_{m+1} = (w_{m+1,1}, w_{m+1,2}, \dots, w_{m+1,i}, \dots, w_{m+1,N}),$$

$$w_{m+i} = \frac{w_{mi}}{Z_m} \exp(-\alpha_m y_i G_m(x_i)), \quad i = 1, 2, \dots, N$$

□ $D_2 = (0.0715, 0.0715, 0.0715, 0.0715, 0.0715, 0.0715, 0.1666, 0.1666, 0.1666, 0.0715)$

■ 计算 D_2 ，是为下一个基本分类器使用

□ $f_1(x) = 0.4236 * G_1(x)$

□ 分类器 $\text{sign}(f_1(x))$ 在训练数据集上有3个误分类点。



m=2	X	0	1	2	3	4	5	6	7	8	9
	Y	1	1	1	-1	-1	-1	1	1	1	-1
	w	0.0715	0.0715	0.0715	0.0715	0.0715	0.0715	0.1666	0.1666	0.1666	0.0715

- 对于m=2
- 在权值分布为D2的训练数据上，阈值v取8.5时误差率最低，故基本分类器为：

$$G_2(x) = \begin{cases} 1, & x < 8.5 \\ -1, & x > 8.5 \end{cases}$$



m=2

- G2(x)在训练数据集上的误差率
 $e_2 = P(G_2(x_i) \neq y_i) = 0.2143(0.0715 * 3)$
- 计算G2的系数:

$$\alpha_2 = \frac{1}{2} \log \frac{1 - e_2}{e_2} = 0.6496$$



m=2

□ 更新训练数据的权值分布：

$$D_{m+1} = (w_{m+1,1}, w_{m+1,2}, \dots, w_{m+1,i}, \dots, w_{m+1,N}),$$

$$w_{m+i} = \frac{w_{mi}}{Z_m} \exp(-\alpha_m y_i G_m(x_i)), \quad i = 1, 2, \dots, N$$

□ $D_3 = (0.0455, 0.0455, 0.0455, 0.1667, 0.1667, 0.01667, 0.1060, 0.1060, 0.1060, 0.0455)$

□ $f_2(x) = 0.4236G_1(x) + 0.6496G_2(x)$

□ 分类器 $\text{sign}(f_2(x))$ 在训练数据集上有3个误分类点。



m=3	X	0	1	2	3	4	5	6	7	8	9
	Y	1	1	1	-1	-1	-1	1	1	1	-1
	w	0.0455	0.0455	0.0455	0.1667	0.1667	0.1667	0.1060	0.1060	0.1060	0.0455

- 对于m=3
- 在权值分布为D3的训练数据上，阈值v取5.5时误差率最低，故基本分类器为：

$$G_3(x) = \begin{cases} 1, & x > 5.5 \\ -1, & x < 5.5 \end{cases}$$



m=3

- G3(x)在训练数据集上的误差率
 $e_3 = P(G_3(x_i) \neq y_i) = 0.1820(0.0455 * 4)$
- 计算G3的系数:

$$\alpha_3 = \frac{1}{2} \log \frac{1 - e_3}{e_3} = 0.7514$$



m=3

□ 更新训练数据的权值分布：

$$D_{m+1} = (w_{m+1,1}, w_{m+1,2}, \dots, w_{m+1,i}, \dots, w_{m+1,N}),$$

$$w_{m+1,i} = \frac{w_{mi}}{Z_m} \exp(-\alpha_m y_i G_m(x_i)), \quad i = 1, 2, \dots, N$$

□ $D_4 = (0.125, 0.125, 0.125, 0.102, 0.102, 0.102, 0.065, 0.065, 0.065, 0.125)$

□ $f_3(x) = 0.4236G_1(x) + 0.6496G_2(x) + 0.7514G_3(x)$

□ 分类器 $\text{sign}(f_3(x))$ 在训练数据集上有 0 个误分类点。



误差上限

$$\frac{1}{N} \sum_{i=1}^N I(G(x_i) \neq y_i) \leq \frac{1}{N} \sum_i \exp(-y_i f(x_i)) = \prod_m Z_m$$

□ 当 $G(x_i) \neq y_i$ 时, $y_i * f(x_i) < 0$, 因而 $\exp(-y_i * f(x_i)) \geq 1$, 前半部分得证。



后半部分

$$\begin{aligned}\frac{1}{N} \sum_i \exp(-y_i f(x_i)) &= \sum_i \frac{1}{N} \exp\left(-\sum_{m=1}^M \alpha_m y_i G_m(x_i)\right) \\ &= \sum_i w_{1i} \exp\left(-\sum_{m=1}^M \alpha_m y_i G_m(x_i)\right) = \sum_i w_{1i} \prod_{m=1}^M \exp(-\alpha_m y_i G_m(x_i)) \\ &= \sum_i w_{1i} \exp(-\alpha_1 y_i G_1(x_i)) \prod_{m=2}^M \exp(-\alpha_m y_i G_m(x_i)) \\ &= \sum_i Z_1 \prod_{m=2}^M \exp(-\alpha_m y_i G_m(x_i)) = Z_1 \sum_i \prod_{m=2}^M \exp(-\alpha_m y_i G_m(x_i)) \\ &= Z_1 \sum_i w_{2i} \prod_{m=2}^M \exp(-\alpha_m y_i G_m(x_i)) \\ &= Z_1 Z_2 \sum_i w_{3i} \prod_{m=3}^M \exp(-\alpha_m y_i G_m(x_i)) \\ &= Z_1 Z_2 \cdots Z_{M-1} \sum_i w_{Mi} \exp(-\alpha_M y_i G_M(x_i)) \\ &= \prod_{m=1}^M Z_m\end{aligned}$$

$$w_{m+1,i} = \frac{w_{mi}}{Z_m} \exp(-\alpha_m y_i G_m(x_i))$$

$$\Rightarrow Z_m w_{m+1,i} = w_{mi} \exp(-\alpha_m y_i G_m(x_i))$$

$$\Rightarrow Z_1 w_{2,i} = w_{1i} \exp(-\alpha_1 y_i G_1(x_i))$$



训练误差界

$$\prod_{m=1}^M Z_m = \prod_{m=1}^M \left(2\sqrt{e_m(1-e_m)} \right) = \prod_{m=1}^M \sqrt{1-4\gamma_m^2} \leq \exp\left(-2\sum_{m=1}^M \gamma_m^2\right)$$

$$\gamma_m = \frac{1}{2} - e_m$$



训练误差界

$$\begin{aligned}Z_m &= \sum_{i=1}^N w_{mi} \exp(-\alpha_m y_i G_m(x_i)) \\&= \sum_{y_i = G_m(x_i)} w_{mi} e^{-\alpha_m} + \sum_{y_i \neq G_m(x_i)} w_{mi} e^{\alpha_m} \\&= (1 - e_m) e^{-\alpha_m} + e_m e^{\alpha_m} \\&= 2\sqrt{e_m(1 - e_m)} & \alpha_m &= \frac{1}{2} \log \frac{1 - e_m}{e_m} \\&= \sqrt{1 - 4\gamma_m^2} & \gamma_m &= \frac{1}{2} - e_m\end{aligned}$$



取 $\gamma_1, \gamma_2 \dots$ 的最小值，记做 γ

$$\frac{1}{N} \sum_{i=1}^N I(G(x_i) \neq y_i) \leq \exp(-2M\gamma^2)$$



Adaboost算法解释

- AdaBoost算法是模型为加法模型、损失函数为指数函数、学习算法为前向分步算法时的二类学习方法。



前向分步算法

□ 考虑加法模型

$$f(x) = \sum_{m=1}^M \beta_m b(x; \gamma_m)$$

□ 其中：

- 基函数： $b(x; \gamma_m)$
- 基函数的参数 γ_m
- 基函数的系数： β_m



前向分步算法的含义

- 在给定训练数据及损失函数 $L(y, f(x))$ 的条件下，学习加法模型 $f(x)$ 成为**经验风险极小化**即**损失函数极小化**问题：

$$\min_{\beta_m, \gamma_m} \sum_{i=1}^N L \left(y_i, \sum_{m=1}^M \beta_m b(x_i; \gamma_m) \right)$$

- 算法简化：如果能够从前向后，每一步只学习一个基函数及其系数，逐步逼近上式。

即：每步只优化损失函数：
$$\min_{\beta, \gamma} \sum_{i=1}^N L(y_i, \beta b(x_i; \gamma))$$



前向分步算法的算法框架

□ 输入:

- 训练数据集 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$
- 损失函数 $L(y, f(x))$
- 基函数集 $\{b(x; \gamma)\}$

□ 输出:

- 加法模型 $f(x)$

□ 算法步骤:



前向分步算法的算法框架

□ 初始化 $f_0(x) = 0$

□ 对于 $m=1, 2, \dots, M$

■ 极小化损失函数 $(\beta_m, \gamma_m) = \arg \min_{\beta, \gamma} \sum_{i=1}^N L(y_i, f_{m-1}(x_i) + \beta b(x_i; \gamma))$

□ 得到参数 β_m, γ_m

■ 更新当前模型:

$$f_m(x) = f_{m-1}(x) + \beta_m b(x; \gamma_m)$$

□ 得到加法模型 $f(x) = f_M(x) = \sum_{m=1}^M \beta_m b(x; \gamma_m)$



前向分步算法与AdaBoost

- AdaBoost算法是前向分步算法的特例，这时，模型是基本分类器组成的**加法模型**，损失函数是**指数函数**。
- 损失函数取：

$$L(y, f(x)) = \exp(-yf(x))$$



证明

- 假设经过 $m-1$ 轮迭代，前向分步算法已经得到 $f_{m-1}(x)$:
$$f_{m-1}(x) = f_{m-2}(x) + \alpha_{m-1} G_{m-1}(x)$$
$$= \alpha_1 G_1(x) + \dots + \alpha_{m-1} G_{m-1}(x)$$
- 在第 m 轮迭代得到 α_m , $G_m(x)$ 和 $f_m(x)$
- 目标是使前向分步算法得到的 α_m 和 $G_m(x)$ 使 $f_m(x)$ 在训练数据集 T 上的指数损失最小，即

$$(\alpha_m, G_m(x)) = \arg \min_{\alpha, G} \sum_{i=1}^N \exp(-y_i (f_{m-1}(x_i) + \alpha G(x_i)))$$



证明

□ 进一步：

$$(\alpha_m, G_m(x)) = \arg \min_{\alpha, G} \sum_{i=1}^N \bar{w}_{mi} \exp(-y_i \alpha G(x_i))$$

□ 其中： $\bar{w}_{mi} = \exp(-y_i f_{m-1}(x_i))$

□ \bar{w}_{mi} 既不依赖 α 也不依赖 G ，所以与最小化无关。但 \bar{w}_{mi} 依赖于 $f_{m-1}(x)$ ，所以，每轮迭代会发生变化。



基本分类器 $G^*(x)$

□ 首先求分类器 $G^*(x)$

□ 对于任意 $\alpha > 0$, 是上式最小的 $G(x)$ 由下式得到:

$$G_m^*(x) = \arg \min_G \sum_{i=1}^N \bar{w}_{mi} I(y_i \neq G(x_i))$$

□ 其中, $\bar{w}_{mi} = \exp(-y_i f_{m-1}(x_i))$



权值的计算

□ 求权值：

$$\begin{aligned} & \sum_{i=1}^N \bar{w}_{mi} \exp(-y_i \alpha G(x_i)) \\ &= \sum_{y_i = G_m(x_i)} \bar{w}_{mi} e^{-\alpha} + \sum_{y_i \neq G_m(x_i)} \bar{w}_{mi} e^{\alpha} \\ &= (e^{\alpha} - e^{-\alpha}) \sum_{i=1}^N \bar{w}_{mi} I(y_i \neq G(x_i)) + e^{-\alpha} \sum_{i=1}^N \bar{w}_{mi} \end{aligned}$$

□ 将 $G^*(x)$ 带入： $G_m^*(x) = \arg \min_G \sum_{i=1}^N \bar{w}_{mi} I(y_i \neq G(x_i))$

□ 求导，得到

$$\alpha_m = \frac{1}{2} \log \frac{1 - e_m}{e_m}$$



分类错误率

□ 分类错误率为：

$$e_m = \frac{\sum_{i=1}^N \bar{w}_{mi} I(y_i \neq G(x_i))}{\sum_{i=1}^N \bar{w}_{mi}} = \sum_{i=1}^N \bar{w}_{mi} I(y_i \neq G(x_i))$$



权值的更新

□ 由模型

$$f_m(x) = f_{m-1}(x) + \alpha_m G_m(x)$$

□ 以及权值

$$\bar{w}_{mi} = \exp(-y_i f_{m-1}(x_i))$$

□ 可以方便的得到：

$$\bar{w}_{m+1,i} = \bar{w}_{m,i} \exp(-y_i \alpha_m G_m(x))$$



权值和错误率的关键解释

- 事实上，根据Adaboost的构造过程，权值调整公式为：

$$w_{m+1,i} = \begin{cases} \frac{w_{mi}}{Z_m} e^{-\alpha_m} & G_m(x_i) = y_i \\ \frac{w_{mi}}{Z_m} e^{\alpha_m} & G_m(x_i) \neq y_i \end{cases}$$

- 二者做除，得到 $e^{2\alpha_m} = \frac{e_m}{1-e_m}$

- 从而：
$$\alpha_m = \frac{1}{2} \log \frac{1-e_m}{e_m}$$



总结

- AdaBoost的训练误差是以指数速率下降的
- AdaBoost算法不需要事先知道下界 γ ，AdaBoost具有自适应性，它能适应若分类器格子的训练误差率。（“适应”Adaptive的由来）



我们在这里

□ 更多算法面试题在 **7** | 七月算法官网

■ <http://www.julyedu.com/>

□ 免费视频

□ 直播课程

□ 问答社区

□ contact us: 微博

■ @研究者July

■ @七月问答

■ @邹博_机器学习



感谢大家!

恳请大家批评指正!

