



SVM-作业讲解

华东师范大学 计算机科学与技术学院

张志忠 副研究员





- 方法回顾
- Code一些解释

回顾一下SMO 算法:



例 7.1 数据与例 2.1 相同. 已知一个如图 7.4 所示的训练数据集, 其正例点是 $x_1 = (3, 3)^T$, $x_2 = (4, 3)^T$, 负例点是 $x_3 = (1, 1)^T$, 试求最大间隔分离超平面.




图 7.4 间隔最大分离超平面示例

原始
形式

$$\begin{aligned} \min_{w, b} \quad & \frac{1}{2} \|w\|^2 \\ \text{s.t.} \quad & y_i(w \cdot x_i + b) - 1 \geq 0, \quad i = 1, 2, \dots, N \end{aligned}$$

对偶
形式

$$\begin{aligned} \min_{\alpha} \quad & \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) - \sum_{i=1}^N \alpha_i \\ \text{s.t.} \quad & \sum_{i=1}^N \alpha_i y_i = 0 \\ & \alpha_i \geq 0, \quad i = 1, 2, \dots, N \end{aligned}$$

□ 原始问题

$$\begin{aligned} \min_{w,b} \quad & \frac{1}{2} \|w\|^2 \\ \text{s.t.} \quad & y_i(w \cdot x_i + b) - 1 \geq 0, \quad i=1,2,\dots,N \end{aligned}$$



$$\begin{aligned} \min_{\alpha} \quad & \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) - \sum_{i=1}^N \alpha_i \\ \text{s.t.} \quad & \sum_{i=1}^N \alpha_i y_i = 0 \\ & \alpha_i \geq 0, \quad i=1,2,\dots,N \end{aligned}$$

□ 拉格朗日函数

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \alpha_i y_i (w \cdot x_i + b) + \sum_{i=1}^N \alpha_i$$

□ 求偏导

$$\begin{aligned} \nabla_w L(w, b, \alpha) = w - \sum_{i=1}^N \alpha_i y_i x_i = 0 & \quad \longrightarrow \quad w = \sum_{i=1}^N \alpha_i y_i x_i \\ \nabla_b L(w, b, \alpha) = \sum_{i=1}^N \alpha_i y_i = 0 & \quad \longrightarrow \quad \sum_{i=1}^N \alpha_i y_i = 0 \end{aligned}$$

$$\nabla_x L(x^*, \alpha^*, \beta^*) = 0$$

$$\nabla_{\alpha} L(x^*, \alpha^*, \beta^*) = 0$$

$$\nabla_{\beta} L(x^*, \alpha^*, \beta^*) = 0$$

$$\alpha_i^* c_i(x^*) = 0, \quad i=1,2,\dots,k$$

$$c_i(x^*) \leq 0, \quad i=1,2,\dots,k$$

$$\alpha_i^* \geq 0, \quad i=1,2,\dots,k$$

$$h_j(x^*) = 0 \quad j=1,2,\dots,l$$

KTT 条件



算法 7.2 (线性可分支持向量机学习算法)

输入: 线性可分训练集 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$, 其中 $x_i \in \mathcal{X} = \mathbf{R}^n$, $y_i \in$

$\mathcal{Y} = \{-1, +1\}$, $i = 1, 2, \dots, N$;

输出: 分离超平面和分类决策函数.

(1) 构造并求解约束最优化问题

$$\min_{\alpha} \quad \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) - \sum_{i=1}^N \alpha_i$$

$$\text{s.t.} \quad \sum_{i=1}^N \alpha_i y_i = 0$$

$$\alpha_i \geq 0, \quad i = 1, 2, \dots, N$$

求得最优解 $\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_N^*)^T$.

(2) 计算

$$w^* = \sum_{i=1}^N \alpha_i^* y_i x_i$$

并选择 α^* 的一个正分量 $\alpha_j^* > 0$, 计算

并选择 α^* 的一个正分量 $\alpha_j^* > 0$, 计算

$$b^* = y_j - \sum_{i=1}^N \alpha_i^* y_i (x_i \cdot x_j)$$

(3) 求得分离超平面

$$w^* \cdot x + b^* = 0$$

分类决策函数:

$$f(x) = \text{sign}(w^* \cdot x + b^*)$$

对偶形式

$$\min_{\alpha} \quad \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) - \sum_{i=1}^N \alpha_i$$

$$\text{s.t.} \quad \sum_{i=1}^N \alpha_i y_i = 0$$

$$\alpha_i \geq 0, \quad i=1, 2, \dots, N$$

多项式核:

$$K(x, z) = (x \cdot z + 1)^p$$

高斯核:

$$K(x, z) = \exp\left(-\frac{\|x - z\|^2}{2\sigma^2}\right)$$

分情况讨论

维度转换函数 T

$$\begin{array}{l} \vec{x}_i = (x_{i1}, x_{i2}) \\ \vec{x}_j = (x_{j1}, x_{j2}) \end{array} \xrightarrow{T} \begin{array}{l} T(\vec{x}_i) = (x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) \\ T(\vec{x}_j) = (x_{j1}, x_{j2}, x_{j3}, \dots, x_{jn}) \end{array} \xrightarrow{\text{点积}} \sum_{m=1}^n x_{im} x_{jm}$$

核函数 $K(\vec{x}_i, \vec{x}_j)$

$$T(\vec{x}_i) \cdot T(\vec{x}_j) = K(\vec{x}_i, \vec{x}_j)$$

直接计算
点积结果

☞ 输入: 训练数据集 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$

☞ $x_i \in \mathcal{X} = \mathbf{R}^n$ $y_i \in \mathcal{Y} = \{-1, +1\}$, $i = 1, 2, \dots, N$, 精度 ε

☞ 输出: 近似解 α

(1) 取初值 $\alpha^{(0)} = 0$, 令 $k = 0$

(2) 选取优化变量 $\alpha_1^{(k)}, \alpha_2^{(k)}$, 解析求解两个变量的最优化问题
求得最优解 $\alpha_1^{(k+1)}, \alpha_2^{(k+1)}$, 更新 α 为 $\alpha^{(k+1)}$;

(3) 若在精度 ε 范围内满足停机条件

$$\sum_{i=1}^N \alpha_i y_i = 0$$

$$0 \leq \alpha_i \leq C, \quad i = 1, 2, \dots, N$$

$$y_i \cdot g(x_i) = \begin{cases} \geq 1, & \{x_i \mid \alpha_i = 0\} \\ = 1, & \{x_i \mid 0 < \alpha_i < C\} \\ \leq 1, & \{x_i \mid \alpha_i = C\} \end{cases}$$

则转 (4); 否则令 $k = k + 1$, 转 (2); $g(x_i) = \sum_{j=1}^N \alpha_j y_j K(x_j, x_i) + b$

(4) 取 $\hat{\alpha} = \alpha^{(k+1)}$

SMO 算法:

$$\min_{\alpha} \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) - \sum_{i=1}^N \alpha_i$$

$$\text{s.t.} \quad \sum_{i=1}^N \alpha_i y_i = 0$$


$$0 \leq \alpha_i \leq C, \quad i=1, 2, \dots, N$$

经剪辑后 α_2 的解是

$$\alpha_2^{\text{new}} = \begin{cases} H, & \alpha_2^{\text{new,unc}} > H \\ \alpha_2^{\text{new,unc}}, & L \leq \alpha_2^{\text{new,unc}} \leq H \\ L, & \alpha_2^{\text{new,unc}} < L \end{cases}$$

选取两个变量

$$\min_{\alpha_1, \alpha_2} W(\alpha_1, \alpha_2) = \frac{1}{2} K_{11} \alpha_1^2 + \frac{1}{2} K_{22} \alpha_2^2 + y_1 y_2 K_{12} \alpha_1 \alpha_2 - (\alpha_1 + \alpha_2) + y_1 \alpha_1 \sum_{i=3}^N y_i \alpha_i K_{i1} + y_2 \alpha_2 \sum_{i=3}^N y_i \alpha_i K_{i2} \quad (7.101)$$



$$\min_{\alpha_1, \alpha_2} W(\alpha_1, \alpha_2) = \frac{1}{2} K_{11} \alpha_1^2 + \frac{1}{2} K_{22} \alpha_2^2 + y_1 y_2 K_{12} \alpha_1 \alpha_2$$

$$-(\alpha_1 + \alpha_2) + y_1 \alpha_1 \sum_{i=3}^N y_i \alpha_i K_{i1} + y_2 \alpha_2 \sum_{i=3}^N y_i \alpha_i K_{i2} \quad (7.101)$$

$$v_i = \sum_{j=3}^N \alpha_j y_j K(x_i, x_j)$$

∞ 目标函数写成:

$$W(\alpha_1, \alpha_2) = \frac{1}{2} K_{11} \alpha_1^2 + \frac{1}{2} K_{22} \alpha_2^2 + y_1 y_2 K_{12} \alpha_1 \alpha_2$$

$$-(\alpha_1 + \alpha_2) + y_1 v_1 \alpha_1 + y_2 v_2 \alpha_2$$

∞ 由 $\alpha_1 y_1 = \zeta - \alpha_2 y_2$ 及 $y_i^2 = 1$

$$\alpha_1 = (\zeta - y_2 \alpha_2) y_1$$

$$W(\alpha_2) = \frac{1}{2} K_{11} (\zeta - \alpha_2 y_2)^2 + \frac{1}{2} K_{22} \alpha_2^2 + y_2 K_{12} (\zeta - \alpha_2 y_2) \alpha_2$$

$$-(\zeta - \alpha_2 y_2) y_1 - \alpha_2 + v_1 (\zeta - \alpha_2 y_2) + y_2 v_2 \alpha_2$$

Minimize:

$$W(\alpha_2) = \frac{1}{2}K_{11}(s - \alpha_2 y_2)^2 + \frac{1}{2}K_{22}\alpha_2^2 + y_2 K_{12}(s - \alpha_2 y_2)\alpha_2 - (s - \alpha_2 y_2)y_1 - \alpha_2 + v_1(s - \alpha_2 y_2) + y_2 v_2 \alpha_2$$



偏导数置为 0

 将 $\eta = K_{11} + K_{22} - 2K_{12}$ 代入:

$$\alpha_2^{\text{new,unc}} = \alpha_2^{\text{old}} + \frac{y_2(E_1 - E_2)}{\eta}$$

$$g(x) = \sum_{i=1}^N \alpha_i y_i K(x_i, x) + b$$



$$E_i = g(x_i) - y_i = \left(\sum_{j=1}^N \alpha_j y_j K(x_j, x_i) + b \right) - y_i, \quad i=1,2$$

根据不等式条件 α_2^{new} 的取值范围:

$$L \leq \alpha_2^{\text{new}} \leq H$$

左图: $L = \max(0, \alpha_2^{\text{old}} - \alpha_1^{\text{old}})$ $H = \min(C, C + \alpha_2^{\text{old}} - \alpha_1^{\text{old}})$

右图: $L = \max(0, \alpha_2^{\text{old}} + \alpha_1^{\text{old}} - C)$ $H = \min(C, \alpha_2^{\text{old}} + \alpha_1^{\text{old}})$



$$\alpha_2^{\text{new}} = \begin{cases} H, & \alpha_2^{\text{new,unc}} > H \\ \alpha_2^{\text{new,unc}}, & L \leq \alpha_2^{\text{new,unc}} \leq H \\ L, & \alpha_2^{\text{new,unc}} < L \end{cases}$$

$$\alpha_1^{\text{new}} = \alpha_1^{\text{old}} + y_1 y_2 (\alpha_2^{\text{old}} - \alpha_2^{\text{new}})$$

如何选取两个变量:

1. 第 1 个变量的选择

SMO 称选择第 1 个变量的过程为外层循环. 外层循环在训练样本中选取违反 KKT 条件最严重的样本点, 并将其对应的变量作为第 1 个变量. 具体地, 检验训练样本点 (x_i, y_i) 是否满足 KKT 条件, 即

$$\alpha_i = 0 \Leftrightarrow y_i g(x_i) \geq 1 \quad (7.111)$$

2. 第 2 个变量的选择

SMO 称选择第 2 个变量的过程为内层循环. 假设在外层循环中已经找到第 1 个变量 α_1 , 现在要在内层循环中找第 2 个变量 α_2 . 第 2 个变量选择的标准是希望能使 α_2 有足够大的变化.

由式 (7.106) 和式 (7.108) 可知, α_2^{new} 是依赖于 $|E_1 - E_2|$ 的, 为了加快计算速度, 一种简单的做法是选择 α_2 , 使其对应的 $|E_1 - E_2|$ 最大. 因为 α_1 已定, E_1 也确定了. 如果 E_1 是正的, 那么选择最小的 E_i 作为 E_2 ; 如果 E_1 是负的, 那么选择最大的 E_i 作为 E_2 . 为了节省计算时间, 将所有 E_i 值保存在一个列表中.

先检查



$$\begin{aligned} \alpha_i = 0 &\Leftrightarrow y_i g(x_i) \geq 1 \\ 0 < \alpha_i < C &\Leftrightarrow y_i g(x_i) = 1 \\ \alpha_i = C &\Leftrightarrow y_i g(x_i) \leq 1 \\ g(x_i) &= \sum_{j=1}^N \alpha_j y_j K(x_i, x_j) + b \end{aligned}$$

更新完了alpha 后，还需要更新E 和b:

$$b_1^{\text{new}} = -E_1 - y_1 K_{11}(\alpha_1^{\text{new}} - \alpha_1^{\text{old}}) - y_2 K_{21}(\alpha_2^{\text{new}} - \alpha_2^{\text{old}}) + b^{\text{old}} \quad (7.115)$$

同样，如果 $0 < \alpha_2^{\text{new}} < C$ ，那么，

$$b_2^{\text{new}} = -E_2 - y_1 K_{12}(\alpha_1^{\text{new}} - \alpha_1^{\text{old}}) - y_2 K_{22}(\alpha_2^{\text{new}} - \alpha_2^{\text{old}}) + b^{\text{old}} \quad (7.116)$$

如果 $\alpha_1^{\text{new}}, \alpha_2^{\text{new}}$ 同时满足条件 $0 < \alpha_i^{\text{new}} < C$, $i=1,2$ ，那么 $b_1^{\text{new}} = b_2^{\text{new}}$ 。如果 $\alpha_1^{\text{new}}, \alpha_2^{\text{new}}$ 是 0 或者 C ，那么 b_1^{new} 和 b_2^{new} 以及它们之间的数都是符合 KKT 条件的阈值，这时选择它们的中点作为 b^{new} 。

在每次完成两个变量的优化之后，还必须更新对应的 E_i 值，并将它们保存在列表中。 E_i 值的更新要用到 b^{new} 值，以及所有支持向量对应的 α_j ：

$$E_i^{\text{new}} = \sum_S y_j \alpha_j K(x_i, x_j) + b^{\text{new}} - y_i \quad (7.117)$$

其中， S 是所有支持向量 x_j 的集合。

☞ 输入: 训练数据集 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$

☞ $x_i \in \mathcal{X} = \mathbf{R}^n$ $y_i \in \mathcal{Y} = \{-1, +1\}$, $i = 1, 2, \dots, N$, 精度 ε

☞ 输出: 近似解 α

(1) 取初值 $\alpha^{(0)} = 0$, 令 $k = 0$

(2) 选取优化变量 $\alpha_1^{(k)}, \alpha_2^{(k)}$, 解析求解两个变量的最优化问题
求得最优解 $\alpha_1^{(k+1)}, \alpha_2^{(k+1)}$, 更新 α 为 $\alpha^{(k+1)}$;

(3) 若在精度 ε 范围内满足停机条件

$$\sum_{i=1}^N \alpha_i y_i = 0 \quad y_i \cdot g(x_i) = \begin{cases} \geq 1, & \{x_i \mid \alpha_i = 0\} \\ = 1, & \{x_i \mid 0 < \alpha_i < C\} \\ \leq 1, & \{x_i \mid \alpha_i = C\} \end{cases}$$

$$0 \leq \alpha_i \leq C, \quad i = 1, 2, \dots, N$$

则转 (4); 否则令 $k = k + 1$, 转 (2); $g(x_i) = \sum_{j=1}^N \alpha_j y_j K(x_j, x_i) + b$

(4) 取 $\hat{\alpha} = \alpha^{(k+1)}$



谢谢
Thank You