

支持向量机

七月算法 邹博

2015年4月18日

复习：对偶问题

□ 一般优化问题的Lagrange乘子法

$$\text{minimize } f_0(x), \quad x \in \mathbf{R}^n$$

$$\text{subject to } f_i(x) \leq 0, \quad i = 1, \dots, m$$

$$h_j(x) = 0, \quad j = 1, \dots, p$$

□ Lagrange函数

$$L(x, \lambda, \nu) = f_0(x) + \sum_{i=1}^m \lambda_i f_i(x) + \sum_{j=1}^p \nu_j h_j(x)$$

- 对固定的 x ，Lagrange函数 $L(x, \lambda, \nu)$ 为关于 λ 和 ν 的仿射函数



复习：Lagrange对偶函数(dual function)

□ Lagrange对偶函数

$$g(\lambda, \nu) = \inf_{x \in D} L(x, \lambda, \nu) = \inf_{x \in D} (f_0(x) + \sum_{i=1}^m \lambda_i f_i(x) + \sum_{i=1}^p \nu_i h_i(x))$$

□ 若没有下确界，定义：

$$g(\lambda, \nu) = -\infty$$

□ 根据定义，显然有：对 $\forall \lambda > 0$, $\forall \nu$, 若原优化问题有最优值 p^* , 则

$$g(\lambda, \nu) \leq p^*$$

□ 进一步：Lagrange对偶函数为凹函数。



线性方程的最小二乘问题

□ 原问题 minimize $x^T x$, $x \in \mathbf{R}^n$

subject to $Ax = b$

□ Lagrange函数

$$L(x, v) = x^T x + v^T (Ax - b)$$

□ Lagrange对偶函数

$$g(v) = -\frac{1}{4} v^T A A^T v - b^T v$$

■ 对L求x的偏导, 带入L

■ 对g求v的偏导



强对偶条件

□ 若要对偶函数的最大值即为原问题的最小值，考察需要满足的条件：

$$\begin{aligned} f_0(x^*) &= g(\lambda^*, \nu^*) \\ &= \inf_x \left(f_0(x) + \sum_{i=1}^m \lambda_i^* f_i(x) + \sum_{i=1}^p \nu_i^* h_i(x) \right) \\ &\leq f_0(x^*) + \sum_{i=1}^m \lambda_i^* f_i(x^*) + \sum_{i=1}^p \nu_i^* h_i(x^*) \\ &\leq f_0(x^*). \end{aligned}$$



Karush-Kuhn-Tucker (KKT)条件

$$\begin{aligned} f_0(x^*) &= g(\lambda^*, \nu^*) = \inf_x \left(f_0(x) + \sum_{i=1}^m \lambda_i^* f_i(x) + \sum_{i=1}^p \nu_i^* h_i(x) \right) \\ &\leq f_0(x^*) + \sum_{i=1}^m \lambda_i^* f_i(x^*) + \sum_{i=1}^p \nu_i^* h_i(x^*) \\ &\leq f_0(x^*) \end{aligned}$$

$$f_i(x^*) \leq 0, \quad i = 1, \dots, m$$

$$h_i(x^*) = 0, \quad i = 1, \dots, p$$

$$\lambda_i^* \geq 0, \quad i = 1, \dots, m$$

$$\lambda_i^* f_i(x^*) = 0, \quad i = 1, \dots, m$$

$$\nabla f_0(x^*) + \sum_{i=1}^m \lambda_i^* \nabla f_i(x^*) + \sum_{i=1}^p \nu_i^* \nabla h_i(x^*) = 0$$

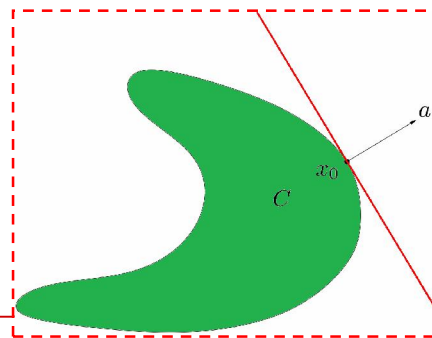


主要内容和目标

- 理解支持向量机SVM的原理和目标
- 掌握支持向量机的计算过程和算法步骤
- 对线性不可分的数据，理解软间隔最大化的含义
- 了解核函数的思想
- 了解SMO算法的过程




支撑超平面



- 设集合 C ， x_0 为 C 边界上的点。若存在 $a \neq 0$ ，满足对任意 $x \in C$ ，都有 $a^T x \leq a^T x_0$ 成立，则称超平面 $\{x \mid a^T x = a^T x_0\}$ 为集合 C 在点 x_0 处的支撑超平面。
- 凸集边界上任意一点，均存在支撑超平面。
- 反之，若一个闭的非中空(内部点不为空)集合，在边界上的任意一点存在支撑超平面，则该集合为凸集。



分割超平面



- 设C和D为两不相交的凸集，则存在超平面P，P可以将C和D分离。


$$\forall x \in C, a^T x \leq b \text{ 且 } \forall x \in D, a^T x \geq b$$

- 注意上式中可以取等号：
 - 所以：逆命题：“若两个凸集C和D的分割超平面存在，C和D不相交”为假命题。
 - 加强条件：若两个凸集至少有一个是开集，那么当且仅当存在分割超平面，它们不相交。

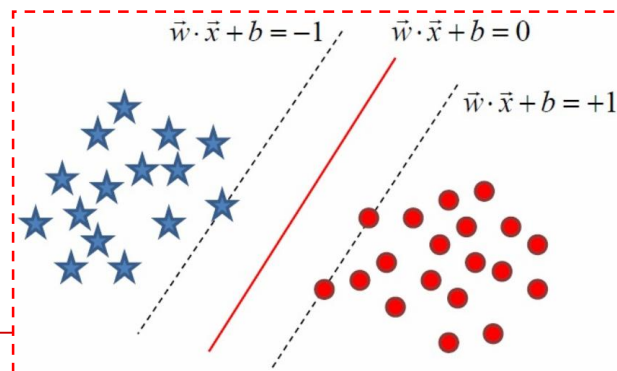


分割超平面的构造

- 两个集合的距离，定义为两个集合间元素的最短距离。
- 做集合C和集合D最短线段的垂直平分线。




分割超平面的思考



- 如何定义两个集合的“最优”分割超平面？
 - 找到集合“边界”上的若干点，以这些点为“基础”计算超平面的方向；以两个集合边界上的这些点的平均作为超平面的“截距”
 - 支持向量：support vector
- 若两个集合有部分相交，如何定义超平面，使得两个集合“尽量”分开？
 - 注：上述“集合”不一定是凸集，可能是由若干离散点组成。若一组集合为 $(\mathbf{x}, 1)$ ，另一组集合为 $(\mathbf{x}, 2)$ ，则为机器学习中的分类问题。



线性分类问题



输入数据

- 假设给定一个特征空间上的训练数据集
 $T = \{(x_1, t_1), (x_2, t_2), \dots, (x_N, t_N)\}$
 - 其中, $x_i \in R^n$, $t_i \in \{+1, -1\}$, $i=1, 2, \dots, N$ 。
- x_i 为第*i*个实例(若 $n>1$, x_i 为向量);
- t_i 为 x_i 的类标记;
 - 当 $t_i=+1$ 时, 称 x_i 为正例;
 - 当 $t_i=-1$ 时, 称 x_i 为负例;
- (x_i, t_i) 称为样本点。



各种概念

□ 线性可分支持向量机

- 硬间隔最大化hard margin maximization
- 硬间隔支持向量机

□ 线性支持向量机

- 软间隔最大化soft margin maximization
- 软间隔支持向量机

□ 非线性支持向量机

- 核函数kernel function

- 注：以上概念的提法，各个文献并不十分统一。



线性可分支持向量机

- 给定线性可分训练数据集，通过**间隔最大化**得到的分离超平面为

$$y(\mathbf{x}) = \mathbf{w}^T \phi(\mathbf{x}) + b$$

相应的分类决策函数 $f(x) = \text{sign}(w^T \Phi(x) + b)$

该决策函数称为线性可分支持向量机。

- $\phi(x)$ 是某个确定的特征空间转换函数，它的作用是将 x 映射到(更高的)维度。

- 最简单直接的： $\phi(x) = x$

- 稍后会看到，求解分离超平面问题可以等价于求解相应的**凸二次规划问题**。




整理符号


- 分割平面: $y(\mathbf{x}) = \mathbf{w}^T \phi(\mathbf{x}) + b$
- 训练集: $\mathbf{X}_1, \dots, \mathbf{X}_N$
- 目标值: $t_1, \dots, t_N, t_n \in \{-1, 1\}$
- 新数据的分类: $\text{sign}(y(\mathbf{x}))$



二维平面上线性分类问题




线性可分支持向量机



使用(高斯)核，解决线性不可分

- 粗线是分割超“平面”
- 其他线是 $y(x)$ 的等高线
- 绿色圈点是支持向量点



推导目标函数

□ 根据题设, $y(\mathbf{x}_n) > 0 \iff t_n = +1$

$y(\mathbf{x}_n) < 0 \iff t_n = -1$

$\implies t_n y(\mathbf{x}_n) > 0$

□ w, b 等比例缩放, 则 t^*y 的值同样缩放, 从


而:

$$\frac{t_n y(\mathbf{x}_n)}{\|\mathbf{w}\|} = \frac{t_n (\mathbf{w}^T \phi(\mathbf{x}_n) + b)}{\|\mathbf{w}\|}$$




最大间隔分离超平面 $\frac{t_n y(\mathbf{x}_n)}{\|\mathbf{w}\|} = \frac{t_n (\mathbf{w}^T \phi(\mathbf{x}_n) + b)}{\|\mathbf{w}\|}$

□ 目标函数: $\arg \max_{\mathbf{w}, b} \left\{ \frac{1}{\|\mathbf{w}\|} \min_n [t_n (\mathbf{w}^T \phi(\mathbf{x}_n) + b)] \right\}$



函数间隔和几何间隔 $\frac{y(\mathbf{x}_n)}{\|\mathbf{w}\|}$

- 目标函数: $y(\mathbf{x}) = \mathbf{w}^T \phi(\mathbf{x}) + b$
- 总可以通过等比例缩放 \mathbf{w} 的方法, 使得两类点的函数值都满足 $|y| \geq 1$



建立目标函数

□ 总可以通过等比例缩放 w 的方法，使得两类的函数值都满足 $|y| \geq 1$

□ 约束条件： $t_n (\mathbf{w}^T \phi(\mathbf{x}_n) + b) = 1$

□ 原目标函数：

$$\arg \max_{\mathbf{w}, b} \left\{ \frac{1}{\|\mathbf{w}\|} \min_n [t_n (\mathbf{w}^T \phi(\mathbf{x}_n) + b)] \right\}$$

□ 新目标函数：

$$\arg \min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2$$



建立目标函数：(若不考虑核函数)

$$\max_{w,b} \frac{1}{\|w\|}$$

$$s.t. \quad y_i(w \cdot x_i + b) \geq 1, \quad i = 1, 2, \dots, N$$

$$\min_{w,b} \frac{1}{2} \|w\|^2$$

$$s.t. \quad y_i(w \cdot x_i + b) \geq 1, \quad i = 1, 2, \dots, N$$



拉格朗日乘子法

$$L(\mathbf{w}, b, \mathbf{a}) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{n=1}^N a_n \{t_n(\mathbf{w}^T \phi(\mathbf{x}_n) + b) - 1\}$$

□ 原问题是极小极大问题

$$\min_{w,b} \max_{\alpha} L(w, b, \alpha)$$

□ 原始问题的对偶问题，是极大极小问题

$$\max_{\alpha} \min_{w,b} L(w, b, \alpha)$$



$$L(\mathbf{w}, b, \mathbf{a}) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{n=1}^N a_n \{t_n(\mathbf{w}^T \phi(\mathbf{x}_n) + b) - 1\}$$

□ 将拉格朗日函数 $L(\mathbf{w}, b, \mathbf{a})$ 分别对 \mathbf{w} , b 求偏导并令其为0:

$$\frac{\partial \mathcal{L}}{\partial \mathbf{w}} = 0 \Rightarrow \mathbf{w} = \sum_{n=1}^N a_n t_n \phi(\mathbf{x}_n)$$

$$\frac{\partial \mathcal{L}}{\partial b} = 0 \Rightarrow 0 = \sum_{n=1}^N a_n t_n$$



$$L(\mathbf{w}, b, \mathbf{a}) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{n=1}^N a_n \{t_n(\mathbf{w}^T \phi(\mathbf{x}_n) + b) - 1\}$$

□ 代入 $L(\mathbf{w}, b, \alpha)$ 中，得到：

$$\begin{aligned} \mathcal{L}(\mathbf{w}, b, \alpha) &= \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \alpha_i [y_i (\mathbf{w}^T \mathbf{x}_i + b) - 1] \\ &= \frac{1}{2} \mathbf{w}^T \mathbf{w} - \mathbf{w}^T \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i - b \sum_{i=1}^n \alpha_i y_i + \sum_{i=1}^n \alpha_i \\ &= \frac{1}{2} \mathbf{w}^T \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i - \mathbf{w}^T \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i - b \cdot 0 + \sum_{i=1}^n \alpha_i \\ &= \sum_{i=1}^n \alpha_i - \frac{1}{2} \left(\sum_{i=1}^n \alpha_i y_i \mathbf{x}_i \right)^T \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i \\ &= \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \end{aligned}$$

$$\tilde{L}(\mathbf{a}) = \sum_{n=1}^N a_n - \frac{1}{2} \sum_{n=1}^N \sum_{m=1}^N a_n a_m t_n t_m k(\mathbf{x}_n, \mathbf{x}_m)$$



继续求 $\min_{w,b} L(w,b, \alpha)$ 对 α 的极大

$$\max_{\alpha} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j$$

$$s.t. \alpha_i \geq 0, i = 1, 2, \dots, n$$

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



整理目标函数：添加负号

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

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

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



线性可分支持向量机器学习算法

□ 构造并求解约束最优化问题

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

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

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

□ 求得最优解 α^*



线性可分支持向量机器学习算法

□ 计算

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

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

□ 求得分离超平面


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

□ 分类决策函数

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



举例



□ 给定3个数据点：正例点 $x_1=(3,3)^T$ ， $x_2=(4,3)^T$ ，负例点 $x_3=(1,1)^T$ ，求线性可分支持向量机。

□ 目标函数：

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

$$= \frac{1}{2} (18\alpha_1^2 + 25\alpha_2^2 + 2\alpha_3^2 + 42\alpha_1\alpha_2 - 12\alpha_1\alpha_3 - 14\alpha_2\alpha_3) - \alpha_1 - \alpha_2 - \alpha_3$$

$$s.t. \alpha_1 + \alpha_2 - \alpha_3 = 0$$

$$\alpha_i \geq 0, \quad i = 1, 2, 3$$



将约束带入目标函数，化简计算

- 将 $\alpha_1 + \alpha_2 = \alpha_3$
- 带入目标函数，得到关于 α_1, α_2 的函数：
$$s(\alpha_1, \alpha_2) = 4\alpha_1^2 + \frac{13}{2}\alpha_2^2 + 10\alpha_1\alpha_2 - 2\alpha_1 - 2\alpha_2$$
- 对 α_1, α_2 求偏导并令其为0，易知 $s(\alpha_1, \alpha_2)$ 在点 $(1.5, -1)$ 处取极值。而该点不满足条件 $\alpha_2 \geq 0$ ，所以，最小值在边界上达到。
- 当 $\alpha_1 = 0$ 时，最小值 $s(0, 2/13) = -2/13 = -0.1538$
- 当 $\alpha_2 = 0$ 时，最小值 $s(1/4, 0) = -1/4 = -0.25$
- 于是 $s(\alpha_1, \alpha_2)$ 在 $\alpha_1 = 1/4, \alpha_2 = 0$ 时达到最

分离超平面

□ $\alpha_1 = \alpha_3 = 1/4$ 对应的点 x_1, x_3 是支持向量。


□ 带入公式: $w^* = \sum_{i=1}^N \alpha_i^* y_i x_i$

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

□ 得到 $w_1 = w_2 = 0.5$, $b = -2$

□ 因此, 分离超平面为 $\frac{1}{2}x_1 + \frac{1}{2}x_2 - 2 = 0$

□ 分离决策函数为 $f(x) = \text{sign}\left(\frac{1}{2}x_1 + \frac{1}{2}x_2 - 2\right)$



线性支持向量机

- 若数据线性不可分，则增加松弛因子 $\xi_i \geq 0$ ，使函数间隔加上松弛变量大于等于 1。这样，约束条件变成

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i$$

- 目标函数：
$$\min_{w,b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i$$



线性SVM的目标函数

$$\min_{w,b,\xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i$$

$$s.t. \quad y_i (w \cdot x_i + b) \geq 1 - \xi_i, \quad i = 1, 2, \dots, N$$

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



拉格朗日函数

□ 拉格朗日函数

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

□ 对 w, b, ξ 求偏导

$$\frac{\partial \mathcal{L}}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^n \alpha_i y_i x_i$$

$$\frac{\partial \mathcal{L}}{\partial b} = 0 \Rightarrow \sum_{i=1}^n \alpha_i y_i = 0$$

$$C - \alpha_i - \mu_i = 0$$



带入目标函数

□ 将三式带入L中，得到

$$\min_{w,b,\xi} L(w,b,\xi,\alpha,\mu) = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) + \sum_{i=1}^N \alpha_i$$

□ 对上式求关于 α 的极大，得到：

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

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

$$C - \alpha_i - \mu_i = 0$$

$$\alpha_i \geq 0$$

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

$$0 \leq \alpha_i \leq C$$



最终的目标函数

□ 整理，得到对偶问题：

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

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

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



线性支持向量机学习算法

□ 构造并求解约束最优化问题

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

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

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

□ 求得最优解 α^*



线性支持向量机学习算法

□ 计算

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

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

- 注意：计算 b^* 时，需要使用满足条件 $0 < \alpha_j < C$ 的向量
- 实践中往往取支持向量的所有值取平均，作为 b^*

□ 求得分离超平面 $w^* x + b^* = 0$



□ 分类决策函数

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



损失函数分析

- 黑色：误分类率
- 蓝色：SVM合页损失
- 绿色：误差平方和



核函数

□ 可以使用核函数，将输入空间映射到特征空间，从而，使得原本线性不可分的样本可以在特征空间可分。

□ 在实际应用中，往往依赖先验领域知识才能选择有效的核函数

□ 多项式核函数 $\kappa(\mathbf{x}_1, \mathbf{x}_2) = (\langle \mathbf{x}_1, \mathbf{x}_2 \rangle + R)^d$

□ 高斯核函数

$$\kappa(\mathbf{x}_1, \mathbf{x}_2) = \exp \left\{ -\frac{\|\mathbf{x}_1 - \mathbf{x}_2\|^2}{2\sigma^2} \right\}$$


□ 字符串核函数

■ 如：两个字符串的字符串编辑距离

■ 将文档使用TF-IDF转换成向量，然后求向量夹角余弦




核函数映射



高斯核

- 粗线是分割超“平面”
- 其他线是 $y(x)$ 的等高线
- 绿色圈点是支持向量点



SVM中系数的求解：SMO

- 序列最小最优化
 - Sequential Minimal Optimization
- 有多个拉格朗日乘子
- 每次只选择其中两个乘子做优化，其他因子认为是常数。
 - 将N个解问题，转换成两个变量的求解问题：并且目标函数是凸的。



SMO

□ 考察目标函数，假设 α_1 和 α_2 是变量，其他是定值：

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

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

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


$$\min_{\alpha_1, \alpha_2} W(\alpha_1, \alpha_2)$$

$$= \frac{1}{2} K_{11} \alpha_1^2 + \frac{1}{2} K_{22} \alpha_2^2 + y_1 y_2 \alpha_1 \alpha_2 - (\alpha_1 + \alpha_2) \quad s.t. \quad \alpha_1 y_1 + \alpha_2 y_2 = - \sum_{i=3}^N y_i \alpha_i = \zeta$$

$$+ y_1 \alpha_1 \sum_{i=3}^N y_i \alpha_i K_{i1} + y_2 \alpha_2 \sum_{i=3}^N y_i \alpha_i K_{i2} \quad 0 \leq \alpha_i \leq C$$



二变量优化问题



$$\begin{cases} L = \max\{0, \alpha_j - \alpha_i\} \\ H = \max\{C, C + \alpha_j - \alpha_i\} \end{cases}, y_i \neq y_j$$
$$\begin{cases} L = \max\{0, \alpha_j + \alpha_i - C\} \\ H = \max\{C, \alpha_j - \alpha_i\} \end{cases}, y_i = y_j$$



SMO的迭代公式

□ 迭代公式:
$$\alpha_j^{\text{new}} = \alpha_j^{\text{old}} + \frac{y_j(E_i - E_j)}{\eta}$$

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

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



SMO算法

- 1. 取初值 $\alpha^{(0)}=0$ ，令 $k=0$
- 2. 选择优化变量 $\alpha_1^{(k)}$ ， $\alpha_2^{(k)}$ ，解析求解两个变量的优化问题，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 范围内满足退出条件(下一页)，则转4；否则， $k++$ ，转2
- 4. 取 $\alpha = \alpha^{(k+1)}$



退出条件

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

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

$$y_i \cdot g(x_i) = \begin{cases} \geq 1, & \{x_i | \alpha_i = 0\} // \text{落在边界外} \\ = 1, & \{x_i | 0 < \alpha_i < C\} // \text{落在边界上} \\ \leq 1, & \{x_i | \alpha_i = C\} // \text{落在边界内} \end{cases}$$

$$g(x_i) = \sum_{j=1}^N y_j \alpha_j K(x_j, x_i) + b$$



思考

- SVM可以用来划分多类别嘛？
- SVM和Logistic回归的比较
 - 经典的SVM，直接输出类别，不给出后验概率；
 - Logistic回归，会给出属于哪个类别的后验概率。



参考文献

- Christopher M. Bishop, Pattern Recognition and Machine Learning, Springer Press, 2006
- 统计学习方法, 李航著, 清华大学出版社, 2012年
- Convex Optimization, Stephen Boyd, Lieven Vandenberghe, Cambridge University Press, 2004
 - 中译本: 王书宁, 许鋆, 黄晓霖译, 凸优化, 清华大学出版社, 2013
- Support Vector Machines, Charlie Frogner, 2011
- Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines, John C. Platt. 1998
- Support Vector Machines, Andrew W. Moore, 2001
- http://blog.csdn.net/v_july_v/article/details/7624837



我们在这里

□ 更多机器学习问题在 **7** | 七月算法

■ <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!

