

第七章

支持向量机

张志忠 华东师范大学

- 1、支持向量机回顾**
- 2、支持向量机对偶形式**
- 3、软间隔支持向量机**
- 4、非线性支持向量机**
- 5、作业**

1、支持向量机回顾

• 支持向量机

函数间隔: $\hat{\gamma}_i = y_i(w \cdot x_i + b)$

几何间隔: $\gamma_i = y_i \left(\frac{w}{\|w\|} \cdot x_i + \frac{b}{\|w\|} \right)$

$\max_{w,b} \gamma$ 几何间隔

s.t. $y_i \left(\frac{w}{\|w\|} \cdot x_i + \frac{b}{\|w\|} \right) \geq \gamma, \quad i=1,2,\dots,N$

$\max_{w,b} \frac{\hat{\gamma}}{\|w\|}$

函数间隔

取 $\gamma = 1$

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

∞ 线性可分支持向量机学习的最优化问题

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

s.t. $y_i(w \cdot x_i + b) - 1 \geq 0, \quad i=1,2,\dots,N$





图 7.4 间隔最大分离超平面示例

• 支持向量机

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

$$\begin{aligned} \min_{w,b} \quad & \frac{1}{2}(w_1^2 + w_2^2) \\ \text{s.t.} \quad & 3w_1 + 3w_2 + b \geq 1 \\ & 4w_1 + 3w_2 + b \geq 1 \\ & -w_1 - w_2 - b \geq 1 \end{aligned}$$

凸优化问题:

对于约束优化问题

$$\begin{aligned} \min f(x) \\ \text{s.t.} \quad g_j(x) \leq 0 \quad j = 1, 2, \dots, m \end{aligned}$$

若 $f(x)$ $g_j(x)$ 都为凸函数, 则此问题为凸规划。

凸规划的任何局部最优解就是全局最优解

2、支持向量机对偶形式

拉格朗日对偶

如何求解: (7.13) ~ (7.14) **1**

在约束最优化问题中，常常利用拉格朗日对偶性 (Lagrange duality) 将原始问题转换为对偶问题，通过解对偶问题得到原始问题的解

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

$$\begin{aligned} \min_{x \in \mathbb{R}^n} \quad & f(x) \\ \text{s.t.} \quad & c_i(x) \leq 0, \quad i = 1, 2, \dots, k \\ & h_j(x) = 0, \quad j = 1, 2, \dots, l \end{aligned}$$

引进拉格朗日函数 α_i, β_j 为乘子 $\alpha_i \geq 0$

$$L(x, \alpha, \beta) = f(x) + \sum_{i=1}^k \alpha_i c_i(x) + \sum_{j=1}^l \beta_j h_j(x)$$

[【数之道】支持向量机SVM是什么, 八分钟直觉理解其本质 哔哩哔哩 bilibili](#)


拉格朗日对偶

原始问题

$$\begin{aligned} \min_{x \in \mathbb{R}^n} f(x) \\ \text{s.t. } c_i(x) \leq 0, \quad i=1,2,\dots,k \\ h_j(x) = 0, \quad j=1,2,\dots,l \end{aligned}$$

对偶问题

$$\min_x \max_{\alpha, \beta: \alpha_i \geq 0} L(x, \alpha, \beta)$$



$$\max_{\alpha, \beta: \alpha_i \geq 0} \min_x L(x, \alpha, \beta)$$

极小极大问题

极大极小问题

x^* , 和 α^* , β^* 分别是原始问题和对偶问题的解的充分必要条件是 x^* , 和 α^* , β^* 满足 karush-Kuhn-Tucker (KKT) 条件:

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

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

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

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

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

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

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

互补条件



$$\begin{aligned} g_1(x) = a - x \leq 0 \\ g_2(x) = x - b \leq 0 \end{aligned}$$



$$\begin{aligned} h_1(x, a_1) = g_1(x) + a_1^2 = a - x + a_1^2 = 0 \\ h_2(x, b_1) = g_2(x) + b_1^2 = x - b + b_1^2 = 0 \end{aligned}$$

$$\min f(x)$$

$$\text{s.t. } g_1(x) = a - x \leq 0$$

$$g_2(x) = x - b \leq 0$$

$$L(x, a_1, b_1, \mu_1, \mu_2) = f(x) + \mu_1(a - x + a_1^2) + \mu_2(x - b + b_1^2)$$

$$\min f(x)$$

$$s.t. g_1(x) = a - x \leq 0$$

$$g_2(x) = x - b \leq 0$$

$$\begin{cases} g_1(x) = a - x \leq 0 \\ g_2(x) = x - b \leq 0 \end{cases}$$



$$\begin{cases} h_1(x, a_1) = g_1(x) + a_1^2 = a - x + a_1^2 = 0 \\ h_2(x, b_1) = g_2(x) + b_1^2 = x - b + b_1^2 = 0 \end{cases}$$

$$L(x, a_1, b_1, \mu_1, \mu_2) = f(x) + \mu_1(a - x + a_1^2) + \mu_2(x - b + b_1^2)$$

$$\frac{\partial F}{\partial a_1} = 2\mu_1 a_1 = 0, \quad \frac{\partial F}{\partial b_1} = 2\mu_2 b_1 = 0,$$

对于 $\mu_1 a_1 = 0$, 我们有两种情况:

互补松弛条件:

情形1: $\mu_1 = 0, a_1 \neq 0$

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

此时由于乘子 $\mu_1 = 0$, 因此 g_1 与其相乘为零, 可以理解为约束 g_1 不起作用, 且有

$$g_1(x) = a - x < 0.$$

情形2: $\mu_1 \geq 0, a_1 = 0$

此时 $g_1(x) = a - x = 0$ 且 $\mu_1 > 0$, 可以理解为约束 g_1 起作用, 且有 $g_1(x) = 0$.

合并情形1和情形2得: $\mu_1 g_1 = 0$, 且在约束起作用时 $\mu_1 > 0, g_1(x) = 0$; 约束不起作用时 $\mu_1 = 0, g_1(x) < 0$.

学习的对偶算法

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

$$\text{s.t. } y_i(w \cdot x_i + b) - 1 \geq 0, \quad i = 1, 2, \dots, N$$

定义拉格朗日函数

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

原问题：极小极大，对偶问题：极大极小

$$\min_x \theta_p(x) = \min_x \max_{\alpha, \beta: \alpha_i \geq 0} L(x, \alpha, \beta)$$



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

拉格朗日目标函数:

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

2
$$\min_{w, b} L(w, b, \alpha) \quad \rightarrow \quad \text{求偏导}$$

3
$$\nabla_w L(w, b, \alpha) = w - \sum_{i=1}^N \alpha_i y_i x_i = 0 \quad \rightarrow \quad w = \sum_{i=1}^N \alpha_i y_i x_i$$

$$\nabla_b L(w, b, \alpha) = \sum_{i=1}^N \alpha_i y_i = 0 \quad \rightarrow \quad \sum_{i=1}^N \alpha_i y_i = 0 \quad \rightarrow \quad \text{新的约束条件}$$

4
$$L(w, b, \alpha) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) - \sum_{i=1}^N \alpha_i y_i \left(\left(\sum_{j=1}^N \alpha_j y_j x_j \right) \cdot x_i + b \right) + \sum_{i=1}^N \alpha_i$$

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

学习的对偶算法

求 $\min_{w,b} L(w,b,\alpha)$ 对 α 的极大，即是对偶问题：

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

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

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



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

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

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

对偶形式能够便于我们求解非线性问题

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

定理： 设 $\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_N^*)$ 是上述最优化问题的最优解，存在下标 j ，使得 $\alpha_j^* > 0$ 并可按下式求解原始问题的最优解 w^*, b^*

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

证明:

由 KKT 条件:

$$\nabla_w L(w^*, b^*, \alpha^*) = w^* - \sum_{i=1}^N \alpha_i^* y_i x_i = 0 \quad (7.27)$$



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

$$\nabla_b L(w^*, b^*, \alpha^*) = -\sum_{i=1}^N \alpha_i^* y_i = 0$$

$$\alpha_i^* (y_i (w^* \cdot x_i + b^*) - 1) = 0, \quad i=1, 2, \dots, N$$

$$y_i (w^* \cdot x_i + b^*) - 1 \geq 0, \quad i=1, 2, \dots, N$$

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

证明: 由

$$w^* = \sum_i \alpha_i^* y_i x_i, \quad \text{其中至少有一个 } \alpha_j^* > 0$$

反证法:

假设: $\alpha^* = 0$ 由 (7.27) 可知 $w^* = 0$,

因为数据集有正类和负类点, 所以 $(w, b) = (0, b)$ 不是最优可行解

但这不是原始优化问题的解, 产生矛盾

对此: j 有 $y_j (w^* \cdot x_j + b^*) - 1 = 0 \quad (7.28)$

互补松弛条件

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

将式 (7.25) 代入式 (7.28) 并注意到 $y_j^2 = 1$,

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

学习的对偶算法

由此定理可知，分离超平面可以写成：

$$\sum_{i=1}^N \alpha_i^* y_i (x \cdot x_i) + b^* = 0$$

分类决策函数可以写成：

$$f(x) = \text{sign} \left(\sum_{i=1}^N \alpha_i^* y_i (x \cdot x_i) + b^* \right)$$

这就是说，分类决策函数只依赖于输入 x 和训练样本输入的内积，上式称为线性可分支持向量机的对偶形式。

线性可分支持向量机器学习算法

⌘ 输入：线性可分训练数据集 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$

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

⌘ 输出：最大间隔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：

$$\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_N^*)^T$$

线性可分支持向量机器学习算法

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

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

3、求得分离超平面

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

分类决策函数

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

支持向量

- 考虑原始优化问题和对偶优化问题，
- 将数据集中对应于 $\alpha_j^* > 0$ 的样本 (x_i, y_i) 的实例 $x_i \in \mathbf{R}^n$
- 称为支持向量

支持向量一定在分割边界上，由KKT互补条件：


$$\alpha_i^* (y_i (w^* \cdot x_i + b^*) - 1) = 0, \quad i = 1, 2, \dots, N$$

对应于 $\alpha_j^* > 0$ 的样本 x_i

$$y_i (w^* \cdot x_i + b^*) - 1 = 0$$

或

$$w^* \cdot x_i + b^* = \pm 1$$



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

$$\begin{aligned} \min_{w,b} \quad & \frac{1}{2}(w_1^2 + w_2^2) \\ \text{s.t.} \quad & 3w_1 + 3w_2 + b \geq 1 \\ & 4w_1 + 3w_2 + b \geq 1 \\ & -w_1 - w_2 - b \geq 1 \end{aligned}$$

请写出对偶形式, 并求解

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

例子：

正例点 $x_1 = (3,3)^T$, $x_2 = (4,3)^T$ 负例点 $x_3 = (1,1)^T$

解：对偶形式

$$\begin{aligned} \min_{\alpha} \quad & \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) - \sum_{i=1}^N \alpha_i \\ & = \frac{1}{2} (18\alpha_1^2 + 25\alpha_2^2 + 2\alpha_3^2 + 42\alpha_1\alpha_2 - 12\alpha_1\alpha_3 - 14\alpha_2\alpha_3) - \alpha_1 - \alpha_2 - \alpha_3 \\ \text{s.t.} \quad & \alpha_1 + \alpha_2 - \alpha_3 = 0 \\ & \alpha_i \geq 0, \quad i = 1, 2, 3 \end{aligned}$$

将 $\alpha_3 = \alpha_1 + \alpha_2$ 带入目标函数并记为

$$s(\alpha_1, \alpha_2) = 4\alpha_1^2 + \frac{13}{2}\alpha_2^2 + 10\alpha_1\alpha_2 - 2\alpha_1 - 2\alpha_2$$

例子：

- 对 α_1, α_2 求偏导数，并令其为0，易知 $s(\alpha_1, \alpha_2)$ 在 $\left(\frac{3}{2}, -1\right)^T$
- 取极值，但该点不满足约束条件 $\alpha_2 \geq 0$ ，所以最小值应在边界上达到
- 当 $\alpha_1 = 0$ 时，最小值 $s\left(0, \frac{2}{13}\right) = -\frac{2}{13}$
- 当 $\alpha_2 = 0$ 时，最小值 $s\left(\frac{1}{4}, 0\right) = -\frac{1}{4}$
- 于是 $s(\alpha_1, \alpha_2)$ 在 $\alpha_1 = \frac{1}{4}, \alpha_2 = 0$ 获得极小， $\alpha_3 = \alpha_1 + \alpha_2 = \frac{1}{4}$
- 这样 $\alpha_1^* = \alpha_3^* = \frac{1}{4}$ 对应的实例向量为支持向量

例子：

计算得：

$$w_1^* = w_2^* = \frac{1}{2}$$

$$b^* = -2$$

分离超平面为：

$$\frac{1}{2}x^{(1)} + \frac{1}{2}x^{(2)} - 2 = 0$$

分类决策函数为：

$$f(x) = \text{sign}\left(\frac{1}{2}x^{(1)} + \frac{1}{2}x^{(2)} - 2\right)$$

软间隔支持向量机

二、线性支持向量机与软间隔最大化


- 训练数据中有一些特异点（outlier），不能满足函数间隔大于等于1的约束条件。
- 解决方法：对每个样本点 (x_i, y_i) 引进一个松弛变量 $\xi_i \geq 0$
- 使得函数间隔加上松弛变量大于等于1，约束条件变为

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

目标函数变为：

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

$C > 0$ 为惩罚参数



线性支持向量机与软间隔最大化

线性不可分的线性支持向量机的学习问题：

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

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

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

3

可证明 w 的解是唯一的， b 不是，

设该问题的解是 w^*, b^* ，可得到分离超平面和决策函数

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

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

线性支持向量机与软间隔最大化

原始问题 3 的拉格朗日函数:

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

其中: $\alpha_i \geq 0, \mu_i \geq 0$

对偶问题是拉格朗日函数的极大极小问题

首先求 $L(w, b, \xi, \alpha, \mu)$ 对 w, b, ξ 的极小, 由一致的

$$\nabla_w L(w, b, \xi, \alpha, \mu) = w - \sum_{i=1}^N \alpha_i y_i x_i = 0$$

$$\nabla_b L(w, b, \xi, \alpha, \mu) = -\sum_{i=1}^N \alpha_i y_i = 0$$

$$\nabla_{\xi} L(w, b, \xi, \alpha, \mu) = C - \alpha_i - \mu_i = 0$$

得:

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

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

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

带

新的条件



线性支持向量机与软间隔最大化

得：

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

再对 $\min_{w, b, \xi} L(w, b, \xi, \alpha, \mu)$ 求 α 的极大，得到对偶问题：

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

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

$$C - \alpha_i - \mu_i = 0 \quad \longrightarrow \quad 0 \leq \alpha_i \leq C$$

$$\alpha_i \geq 0$$

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

线性支持向量机与软间隔最大化

原始问题 3 的对偶问题:

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

4

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

定理:

设 $\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_N^*)^T$ 是对偶问题 4 的一个解, 若存在 α^* 的一个分量 α_j^* , $0 < \alpha_j^* < C$, 则原始问题的解 w^*, b^*

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

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

线性支持向量机学习算法

⌘ 输入：线性不可分训练数据集 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$

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

⌘ 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

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

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

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

求得最优解：

$$\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_N^*)^T$$

线性支持向量机学习算法

2、计算

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

并选择 α^* ，适合条件 $0 < \alpha_j^* < C$ ，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

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

线性不可分的情况下

$\alpha_i^* > 0$ 的样本点 (x_i, y_i) 的实例 x_i 称为支持向量 (软间隔的支持向量)

KKT 条件:

$$\alpha_i^* (y_i (w^* \cdot x_i + b^*) - 1 + \xi_i^*) = 0$$

$$\mu_i^* \xi_i^* = 0$$

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

若 $\alpha_i^* < C$, 则 $\xi_i = 0$

若 $\alpha_i^* = C$, $0 < \xi_i < 1$

若 $\alpha_i^* = C$, $\xi_i = 1$

若 $\alpha_i^* = C$, $\xi_i > 1$




图 7.5 软间隔的支持向量

合页损失函数hinge loss function


线性支持向量机学习还有另外一种解释，就是最小化以下目标函数：

$$\sum_{i=1}^N [1 - y_i (w \cdot x_i + b)]_+ + \lambda \|w\|^2$$

第一项： $L(y(w \cdot x + b)) = [1 - y(w \cdot x + b)]_+$

称为合页损失函数

$$[z]_+ = \begin{cases} z, & z > 0 \\ 0, & z \leq 0 \end{cases}$$



合页损失函数hinge loss function

线性支持向量机原始最优化问题:

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

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


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



等价于:

$$\min_{w,b} \quad \sum_{i=1}^N [1 - y_i(w \cdot x_i + b)]_+ + \lambda \|w\|^2$$

线性SVM： 处理线性可分问题



非线性可分问题

∞ 非线性问题往往不好求解，所以希望能用解**线性分类问题的方法**解决这个问题。

∞ 采取的方法是进行一个**非线性变换**，将非线性问题变换为线性问题，通过解变换后的线性问题的方法求解原来的非线性问题。

∞ 原空间:

$$\mathcal{X} \subset \mathbf{R}^2, x = (x^{(1)}, x^{(2)})^T \in \mathcal{X}$$

∞ 新空间:

$$\mathcal{Z} \subset \mathbf{R}^2, z = (z^{(1)}, z^{(2)})^T \in \mathcal{Z} \quad z = \phi(x) = ((x^{(1)})^2, (x^{(2)})^2)^T$$

$$w_1(x^{(1)})^2 + w_2(x^{(2)})^2 + b = 0 \quad \longrightarrow \quad w_1z^{(1)} + w_2z^{(2)} + b = 0$$

$$\vec{x} = (x_1, x_2) \xrightarrow{T} T(\vec{x}) = (1, \sqrt{2}x_1, \sqrt{2}x_2, x_1^2, x_2^2, \sqrt{2}x_1x_2) \quad \text{二维转六维}$$

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

$$\vec{x} = (x_1, x_2) \xrightarrow{T} T(\vec{x}) = (1, \sqrt{2}x_1, \sqrt{2}x_2, x_1^2, x_2^2, \sqrt{2}x_1x_2) \quad \text{二维转六维}$$

大家计算一下 $\langle T(X1), T(X2) \rangle$?

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

维度转换函数 T

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

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

$$\vec{x} = (x_1, x_2) \xrightarrow{T} T(\vec{x}) = (1, \sqrt{2}x_1, \sqrt{2}x_2, x_1^2, x_2^2, \sqrt{2}x_1x_2) \quad \text{二维转六维}$$

大家计算一下 $\langle T(x_1), T(x_2) \rangle$?

方法1

$$\vec{x} = (x_1, x_2) \xrightarrow{T} T(\vec{x}) = (1, \sqrt{2}x_1, \sqrt{2}x_2, x_1^2, x_2^2, \sqrt{2}x_1x_2) \quad \text{二维转六维}$$

$$T(\vec{x}_i) \cdot T(\vec{x}_j) = (1, \sqrt{2}x_{i1}, \sqrt{2}x_{i2}, x_{i1}^2, x_{i2}^2, \sqrt{2}x_{i1}x_{i2}) \cdot (1, \sqrt{2}x_{j1}, \sqrt{2}x_{j2}, x_{j1}^2, x_{j2}^2, \sqrt{2}x_{j1}x_{j2})$$

$$= 1 + 2x_{i1}x_{j1} + 2x_{i2}x_{j2} + x_{i1}^2x_{j1}^2 + x_{i2}^2x_{j2}^2 + 2x_{i1}x_{i2}x_{j1}x_{j2} \quad \text{六维向量点积}$$

方法2

$$K(\vec{x}_i, \vec{x}_j) = (1 + \vec{x}_i \cdot \vec{x}_j)^2 = (1 + x_{i1}x_{j1} + x_{i2}x_{j2})^2 = 1 + 2x_{i1}x_{j1} + 2x_{i2}x_{j2} + x_{i1}^2x_{j1}^2 + x_{i2}^2x_{j2}^2 + 2x_{i1}x_{i2}x_{j1}x_{j2}$$

直接使用二维向量点积结果计算

多项式核

非线性支持向量机与核函数

- 用线性分类方法求解非线性分类问题分为两步：
 - 首先使用一个变换将原空间的数据映射到新空间；
 - 然后在新空间里用线性分类学习方法从训练数据中学习分类模型。
- 核技巧**就属于这样的方法
 - 核技巧应用到支持向量机，其基本想法：
 - 通过一个非线性变换将输入空间(欧氏空间 \mathbb{R}^n 或离散集合)对应于一个特征空间(希尔伯特空间)，使得在输入空间中的超曲面模型对应于特征空间中的超平面模型(支持向量机)。分类问题的学习任务通过在特征空间中求解**线性支持向量机**就可以完成。

非线性支持向量机与核函数

核函数定义:

设 X 是输入空间(欧氏空间 R^n 的子集或离散集合), 又设 H 为特征空间(希尔伯特空间), 如果存在一个从 X 到 H 的映射

$$\phi(x): X \rightarrow H$$

使得对所有

$$x, z \in X$$

函数 $K(x, z)$ 满足条件 $K(x, z) = \phi(x) \cdot \phi(z)$

则称 $K(x, z)$ 为核函数, $\phi(x)$ 为映射函数,

式中 $\phi(x) \cdot \phi(z)$ 为 $\phi(x)$ 和 $\phi(z)$ 的内积

非线性支持向量机与核函数

核技巧的想法是：

在学习与预测中只定义核函数 $K(x,z)$ ，而不显式地定义映射函数，通常，直接计算 $K(x,z)$ 比较容易，而通过 $\phi(x)$ 和 $\phi(z)$ 计算 $K(x,z)$ 并不容易。

注意： ϕ 是输入空间 R^n 到特征空间 H 的映射，特征空间 H 一般是高维，映射可以不同。

非线性支持向量机与核函数

☞例:

☞假设输入空间是 \mathbf{R}^2 , 核函数是 $K(x, z) = (x \cdot z)^2$, 试找出其相关的特征空间 \mathcal{H} 和映射 $\phi(x): \mathbf{R}^2 \rightarrow \mathcal{H}$

☞解:

取特征空间 $\mathcal{H} = \mathbf{R}^3$, 记 $x = (x^{(1)}, x^{(2)})^T$, $z = (z^{(1)}, z^{(2)})^T$

$$(x \cdot z)^2 = (x^{(1)}z^{(1)} + x^{(2)}z^{(2)})^2 = (x^{(1)}z^{(1)})^2 + 2x^{(1)}z^{(1)}x^{(2)}z^{(2)} + (x^{(2)}z^{(2)})^2$$

☞可以取: $\phi(x) = ((x^{(1)})^2, \sqrt{2}x^{(1)}x^{(2)}, (x^{(2)})^2)^T$

☞容易验证: $\phi(x) \cdot \phi(z) = (x \cdot z)^2 = K(x, z)$

非线性支持向量机与核函数

☞例:

☞假设输入空间是 \mathbf{R}^2 , 核函数是 $K(x, z) = (x \cdot z)^2$, 试找出其相关的特征空间 \mathcal{H} 和映射 $\phi(x): \mathbf{R}^2 \rightarrow \mathcal{H}$

☞解:

☞同样:

$$\phi(x) = \frac{1}{\sqrt{2}} ((x^{(1)})^2 - (x^{(2)})^2, 2x^{(1)}x^{(2)}, (x^{(1)})^2 + (x^{(2)})^2)^T$$

$$\phi(x) = ((x^{(1)})^2, x^{(1)}x^{(2)}, x^{(1)}x^{(2)}, (x^{(2)})^2)^T$$

☞都满足条件。

核函数在支持向量机的应用

☞注意到:

☞线性支持向量机对偶问题中，无论是目标函数还是决策函数都只涉及输入实例和实例之间的内积。

☞目标函数中的内积 $x_i \cdot x_j$ 用核函数 $K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j)$ 代替，目标函数:

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

☞决策函数:

$$f(x) = \text{sign} \left(\sum_{i=1}^{N_s} a_i^* y_i \phi(x_i) \cdot \phi(x) + b^* \right) = \text{sign} \left(\sum_{i=1}^{N_s} a_i^* y_i K(x_i, x) + b^* \right)$$

正定核

问题：

已知映射函数 ϕ ，可以通过 $\phi(x)$ 和 $\phi(z)$ 的内积求得核函数 $K(x,z)$.

不用构造映射 ϕ ，能否直接判断一个给定的函数 $K(x,z)$ 是不是核函数？

或者说，函数 $K(x,z)$ 满足什么条件才能成为核函数？

假设 $K(x,z)$ 是定义在 $X \times X$ 上的对称函数，并且对任意的

$$x_1, x_2, \dots, x_m \in X$$

$K(x,z)$ 关于 x_1, x_2, \dots, x_m 的Gram矩阵是半正定的，可以依据函数 $K(x,z)$ ，构成一个希尔伯特空间(Hilbert space)；**判断的依据**

其步骤是首先定义**映射** ϕ ，并构成**向量空间** S ，然后在 S 上定义内积构成**内积空间**；最后将 S 完备化构成**希尔伯特空间**.

常用核函数

☞1、多项式核函数 (Polynomial kernel function)

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

☞对应的支持向量机为P次多项式分类器，分类决策函数：

$$f(x) = \text{sign} \left(\sum_{i=1}^{N_s} a_i^* y_i (x_i \cdot x + 1)^p + b^* \right)$$

☞2、高斯核函数 (Gaussian Kernel Function)

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

$$f(x) = \text{sign} \left(\sum_{i=1}^{N_s} a_i^* y_i \exp \left(-\frac{\|x - z\|^2}{2\sigma^2} \right) + b^* \right)$$

$$K_d(\vec{x}_i, \vec{x}_j) = (c + \vec{x}_i \cdot \vec{x}_j)^d$$

常数项是非常关键的

$$c = 1, d = 2$$

$$K_d(\vec{x}_i, \vec{x}_j) = (1 + \vec{x}_i \cdot \vec{x}_j)^2 = (1 + x_{i1}x_{j1} + x_{i2}x_{j2})^2 = 1 + \underbrace{2x_{i1}x_{j1} + 2x_{i2}x_{j2}}_{\text{一次项点积部分}} + \underbrace{x_{i1}^2x_{j1}^2 + x_{i2}^2x_{j2}^2 + 2x_{i1}x_{i2}x_{j1}x_{j2}}_{\text{二次项点积部分}}$$

$$K'_2(\vec{x}_i, \vec{x}_j) = (\vec{x}_i \cdot \vec{x}_j)^2 = (x_{i1}x_{j1} + x_{i2}x_{j2})^2 = \underbrace{x_{i1}^2x_{j1}^2 + x_{i2}^2x_{j2}^2 + 2x_{i1}x_{i2}x_{j1}x_{j2}}_{\text{二次项点积部分}}$$

$$(c = 0, d = 1) + (c = 0, d = 2)$$

$$K'_1(\vec{x}_i, \vec{x}_j) + K'_2(\vec{x}_i, \vec{x}_j) = \vec{x}_i \cdot \vec{x}_j + (\vec{x}_i \cdot \vec{x}_j)^2 = (x_{i1}x_{j1} + x_{i2}x_{j2}) + (x_{i1}x_{j1} + x_{i2}x_{j2})^2 \\ = \underbrace{x_{i1}x_{j1} + x_{i2}x_{j2}}_{\text{一次项点积部分}} + \underbrace{x_{i1}^2x_{j1}^2 + x_{i2}^2x_{j2}^2 + 2x_{i1}x_{i2}x_{j1}x_{j2}}_{\text{二次项点积部分}}$$

$$\vec{x} = (x_1, x_2) \xrightarrow{T} T(\vec{x}) = (a_1x_1, a_1x_2, a_1x_1x_2, a_2x_1^2, a_2x_2^2, \dots, a_nx_2^n, a_nx_1^n, \dots, \infty) \quad \text{二维转无穷维}$$

方法1

$$T(\vec{x}_i) \cdot T(\vec{x}_j) = \infty \cdot \infty \quad \text{不可行}$$

方法2

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

$$K(\vec{x}_i, \vec{x}_j) = e^{-\gamma \|\vec{x}_i - \vec{x}_j\|^2} \quad \text{高斯核函数 RBF}$$

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

$$= e^{-\frac{\|\vec{x}_i - \vec{x}_j\|^2}{2}}$$

$$= e^{-\frac{1}{2}(\vec{x}_i - \vec{x}_j) \cdot (\vec{x}_i - \vec{x}_j)}$$

$$= e^{-\frac{1}{2}(\vec{x}_i \cdot \vec{x}_i + \vec{x}_j \cdot \vec{x}_j - 2\vec{x}_i \cdot \vec{x}_j)}$$

$$= e^{-\frac{1}{2}(\|\vec{x}_i\|^2 + \|\vec{x}_j\|^2 - 2\vec{x}_i \cdot \vec{x}_j)}$$

$$= e^{-\frac{1}{2}(\|\vec{x}_i\|^2 + \|\vec{x}_j\|^2)} e^{\vec{x}_i \cdot \vec{x}_j}$$

$$= C e^{\vec{x}_i \cdot \vec{x}_j}$$

$$e^{-\frac{1}{2}(\|\vec{x}_i\|^2 + \|\vec{x}_j\|^2)} = C$$

$$e^x = 1 + \frac{x}{1!} + \frac{x^2}{2!} + \frac{x^3}{3!} + \dots = \sum_{n=0}^{\infty} \frac{x^n}{n!}$$

$$K(\vec{x}_i, \vec{x}_j) = C e^{\vec{x}_i \cdot \vec{x}_j} = C \sum_{n=0}^{\infty} \frac{\vec{x}_i \cdot \vec{x}_j^n}{n!} = C \sum_{n=0}^{\infty} \frac{K_{Poly(n)}(\vec{x}_i, \vec{x}_j)}{n!}$$

非线性支持向量机器学习算法

输入：线性不可分训练数据集 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$

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

输出：分类决策函数

1、选取适当的核函数和参数C，构造最优化问题：

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

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

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

求得最优解：

$$\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_N^*)^T$$

非线性支持向量机器学习算法

2、 并选择 α^* ，适合条件 $0 < \alpha_j^* < C$ ， 计算

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

3、

3、 构造决策函数

$$f(x) = \text{sign} \left(\sum_{i=1}^N \alpha_i^* y_i K(x \cdot x_i) + b^* \right)$$

当 $K(x,z)$ 是正定核函数时， **5** 是凸二次规划问题，解是存在的。



Q & A