

# 第8章 支持向量机

# 目录

## CONTENTS

8.1 SVM简介

8.2 线性SVM算法实现

8.3 非线性SVM与核函数

8.4 SVM回归

8.5 SVM算法实现



8.6 本章小结

## 8.1 SVM简介

支持向量机是Cortes和Vapnik于1995年提出的一种基于统计学习的二分类模型。它是一种监督学习方法，在学习过程中通过最大化分类间隔使得结构风险最小化。

图8-1所示是两类线性可分的样本数据分布及划分的示例。图中的线段就是对样本分隔的超平面。

从图8-2可以看出，能将不同样本分开的超平面有很多，但只有一条超平面位于两类样本的“正”中间，这个超平面通常用一个方程 $d(X)=0$ 来表示， $d(X)$ 被称为判决函数或决策函数。



## 8.1 SVM简介

### 1. 感知机模型


假设输入样本空间  $X$ ，输出空间是  $Y = \{+1, -1\}$ ，输入样本  $x$  表示样本的特征向量，即输入空间的样本点；输出  $y$  表示样本的类别。从输入样本空间到输出样本空间的函数可表示为：
$$f(x) = \text{sign}(w \cdot x + b)$$

该函数称为感知机（Perceptron），其中， $w \in R^n$  称为权值（Weight）或权值向量（Weight Vector）， $b \in R$  称为偏置（Bias）， $\text{sign}$  为符号函数：
$$\text{sign}(x) = \begin{cases} +1 & x \geq 0 \\ -1 & x < 0 \end{cases}$$

## 8.1 SVM简介

### 判决函数

若 $f(x) > 0$ ，则属于正例；若 $f(x) < 0$ ，则属于负例。在特征空间中，令判决函数 $g(x) = w \cdot x + b$ ，线性方程 $w \cdot x + b = 0$ 是一个超平面 $S$ ，其中 $w$ 是超平面的法向量， $b$ 是超平面的截距。这个超平面将特征空间划分为两部分，这两部分的样本点分别被分成正、负两例，超平面 $S$ 就是分离超平面。



## 8.1 SVM简介

### 2 模型参数学习

任意一点  $(x, y)$  到直线  $Ax + By + C = 0$  的距离为  $\frac{|Ax + By + C|}{\sqrt{A^2 + B^2}}$  ,

因此二维样本  $(x, y)$  到线性方程  $w^T x + b = 0$  的距离为  $\frac{|w^T x + b|}{\|w\|_2}$  ,  $\|w\|_2 = \sqrt{w_1^2 + w_2^2 + \dots + w_n^2}$

其中, 对于误分样本点  $(x_i, y_i)$ ,  $w^T x_i + b > 0$  ,  $y_i = -1$  , 有  $w^T x_i + b < 0$  ; 当  $y_i = 1$  时,

$-y_i(w^T x_i + b) > 0$  。因此,  $-\frac{1}{\|w\|_2} y_i(w^T x_i + b)$

于是误分样本点到超平面S的距离为:

因此  $-\frac{1}{\|w\|_2} \sum_{i=1}^N y_i(w^T x_i + b)$  为误分样本点到超平面S的总距离为:

## 8.1 SVM简介

采用随机梯度下降法（Stochastic Gradient Descent, SGD）学习参数 $w$ 和 $b$ ：

$$\frac{\partial \text{Loss}(w, b)}{\partial w} = -\sum_{i=1}^N y_i x_i$$

$$\frac{\partial \text{Loss}(w, b)}{\partial b} = -\sum_{i=1}^N y_i$$

参数 $w$ 和 $b$ 的迭代更新公式：

$$w \leftarrow w - \eta \frac{\partial \text{Loss}(w, b)}{\partial w} = w + \eta y_i x_i$$

$$b \leftarrow b - \eta \frac{\partial \text{Loss}(w, b)}{\partial b} = b + \eta y_i$$

## 8.1 SVM简介

输入：训练数据集 $D=\{(x_1,y_1),(x_2,y_2),\dots,(x_N,y_N)\}$ 、迭代次数、学习率，  
其中： $x \in X$ ， $Y=\{+1,-1\}$ 。

过程：

(1) 初始化参数： $w=(0,0,\dots,0)^T$ ， $b=0$ 。

(2) 对于 $j=1,2,\dots,N$ ，当 $X=\{(x_i,y_i) \mid y_i(w \cdot x_i + b) \leq 0\}$ 为空集，即没有误分样本点，  
则结束循环，否则转到第(3)步执行。


(3) 任意取 $X$ 中的样本点 $(x_i,y_i)$ 更新参数。

输出：感知机模型参数 $w$ 和 $b$ ，并利用 $f(x)=\text{sign}(w \cdot x + b)$  计算分类的准确率。



## 8.1 SVM简介

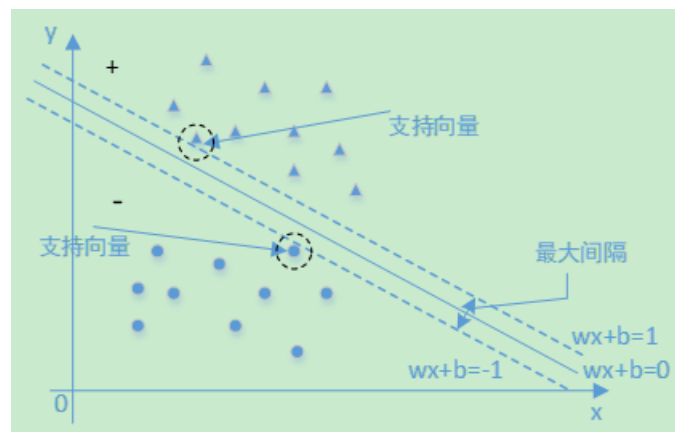
利用以上感知机算法对样本进行分类，其散点图及分类结果如图8-4所示。



## 8.1 SVM简介

### 1. 间隔最大化

在对样本数据分类时，超平面离数据点的间隔越大，产生误差的可能性就会越小，也就是分类的确信度越大。因此，为了使分类的确信度尽可能高，需要让选择的超平面尽可能地最大化这个间隔。以最大间隔把两类样本分开的超平面，称之为最大间隔超平面。分类问题中的最大间隔、支持向量表示如图8-5所示。



## 8.1 SVM简介

支持向量就是离最大间隔超平面最近的样本点，根据前面得到的支持向量到超平面的距离为

$$\begin{cases} \frac{w^T x + b}{\|w\|_2} \geq d, & y = 1 \\ \frac{w^T x + b}{\|w\|_2} \leq -d, & y = -1 \end{cases}$$

将上式进行变换，进而有：

$$\begin{cases} \frac{w^T x + b}{\|w\|_2 d} \geq 1, & y = 1 \\ \frac{w^T x + b}{\|w\|_2 d} \leq -1, & y = -1 \end{cases}$$

$$y(w^T x + b) \geq 1$$

$$d = \frac{y(w^T x + b)}{\|w\|_2}$$

## 8.1 SVM简介

SVM算法的目标就是最大化这个几何间隔d：

$$\max \frac{2y(w^T x + b)}{\|w\|_2}, \quad s.t., y_i(w^T x_i + b) \geq 1$$

间隔最大化问题就是求最优化问题：

$$\min \frac{\|w\|_2^2}{2}, \quad s.t., y_i(w^T x_i + b) \geq 1$$

## 8.1 SVM简介

这是一个凸二次规划问题，不容易求解，可用拉格朗日乘子法对其对偶问题进行求解。对上面的公式构造拉格朗日函数：

$$L(w, b, \lambda) = \frac{\|w\|_2^2}{2} - \sum_{i=1}^N \lambda_i (y_i (w^T x_i + b) - 1)$$

其中， $\lambda_i \geq 0$ 。原问题与对偶问题有相同的解：

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

调整 $w$ 和 $b$ ，使拉格朗日函数取最小值。

$$\frac{\partial L}{\partial w} = w - \sum_{i=1}^N \lambda_i y_i x_i = 0$$

$$\frac{\partial L}{\partial b} = \sum_{i=1}^N \lambda_i y_i = 0$$

以上内容仅为本文档的试下载部分，为可阅读页数的一半内容。如要下载或阅读全文，请访问：  
<https://d.book118.com/726123034235010235>