



本课件仅用于教学使用。未经许可，任何单位、组织和个人不得将课件用于该课程教学之外的用途(包括但不限于盈利等)，也不得上传至可公开访问的网络环境

1

# 新媒体大数据分析

## New Media Big Data Analysis

### 第三章 数据建模

黄振亚，朱孟潇，张凯

课程主页：

<http://staff.ustc.edu.cn/~huangzhy/Course/NM2024.html>

助教：陈宗阳

[bigdata\\_2024@163.com](mailto:bigdata_2024@163.com)

12/3/2024



# 分类与预测

71

- 有监督学习：分类与预测
- 常用方法
  - 规则方法
  - 决策树
  - 最近邻方法
  - 支持向量机 (SVM)
  - 集成方法
- 分类的评价指标
- 类不平衡问题

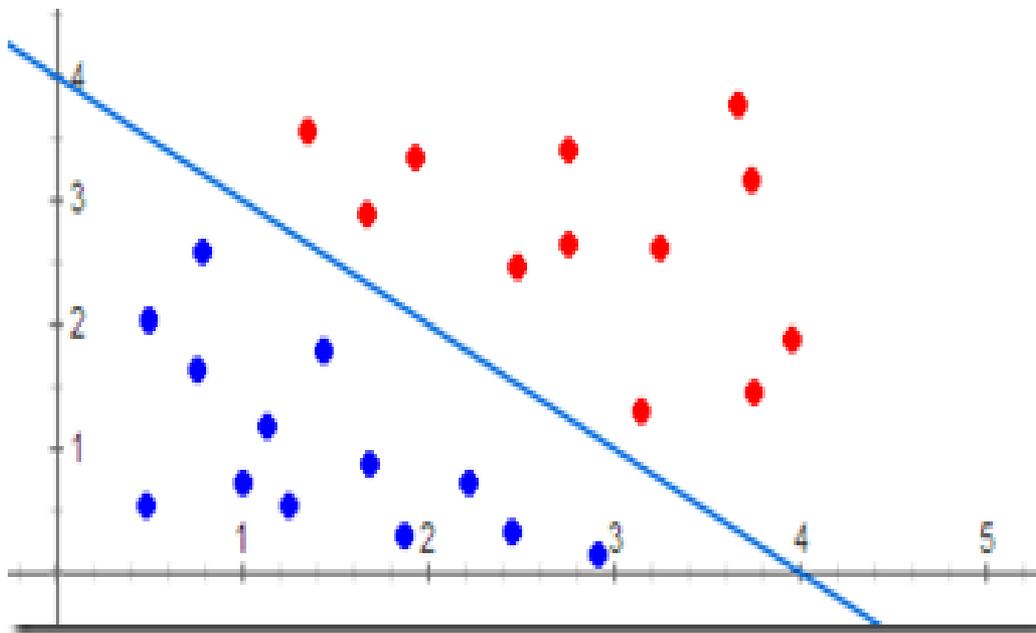


# 分类：感知机

72

## □ 分类——感知机 (perceptron)

- 目标：寻找一条直线 $S$ （高维时是超平面）划分不同类别的数据
- 输入：样本的特征向量 $X=\{x\}$ ,  $x \in R^d$
- 输出：样本类别 $y \in \{-1, +1\}$





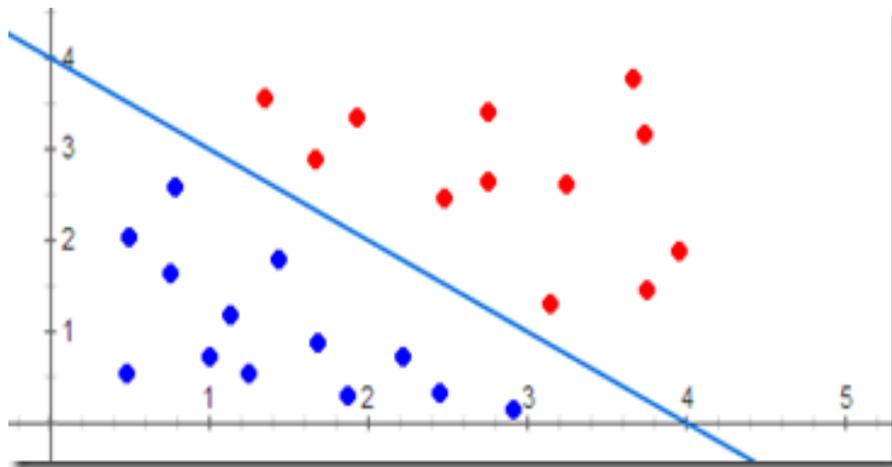
# 分类：感知机

73

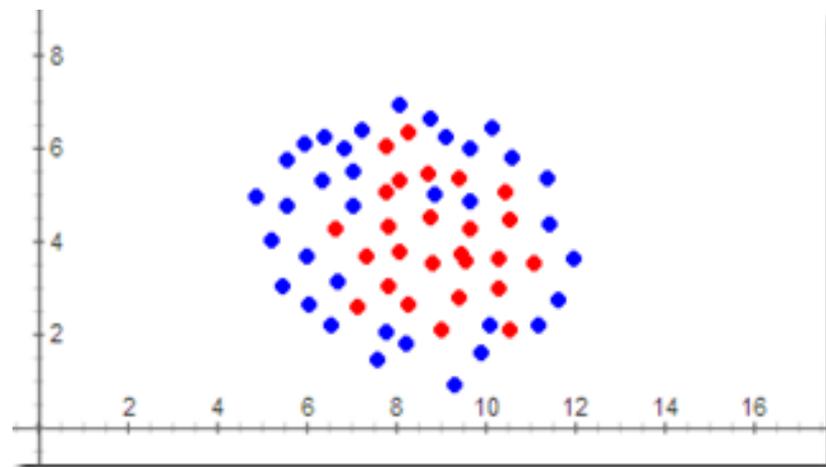
## □ 分类——感知机 (perceptron)

- 1957年由Rosenblatt提出，是神经网络与支持向量机的基础
- 感知机的前提：样本空间线性可分

- 左例中，可以用一条直线将+1类和-1类完美分开，称这个样本空间是线性可分的
- 右例的样本是线性不可分的，感知机不能处理这种情况



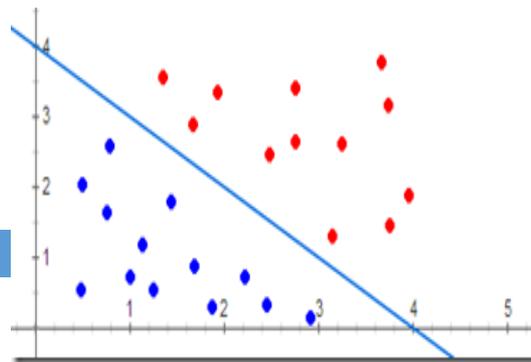
线性可分



线性不可分



# 分类：感知机



74

## 感知机的基本概念

模型：符号函数  $f(x) = \text{sign}(w \cdot x + b) = \begin{cases} +1, & w \cdot x + b \geq 0 \\ -1, & w \cdot x + b < 0 \end{cases}$

分界超平面  $S: w \cdot x + b = 0$

学习目标：最小化 误分类点 到 超平面 的 总距离

点  $(x_0, y_0)$  到超平面  $S: w \cdot x + b = 0$  的距离  $\frac{1}{\|w\|} |w \cdot x_0 + b|$

推导过程省略

误分类点  $(x_i, y_i)$  到超平面  $S: w \cdot x_i + b = 0$  的距离为  $-\frac{1}{\|w\|} y_i (w \cdot x_i + b)$

$x_i$  错分时，若  $y_i$  为 -1，则计算的  $(w \cdot x_i + b) > 0$   
若  $y_i$  为 +1，则计算的  $(w \cdot x_i + b) < 0$

损失函数：  $\underset{w, b}{\operatorname{argmin}} L(w, b) = -\sum_{x_i \in M} y_i (w \cdot x_i + b)$

学习策略：找到参数  $w$  和  $b$ ，使得损失函数最小

它是连续可导的，这就使得我们比较容易求得其最小值



# 分类：感知机

75

## 感知机学习算法：梯度下降 — 课后学习

$$\min_{w,b} L(w, b) = - \sum_{x_i \in M} y_i (w \cdot x_i + b)$$

- 随机初始化 $w_0$ 和 $b_0$
- 梯度下降不断地极小化损失函数
  - 每次随机选取一个误分类点对 $w$ 和 $b$ 进行更新。
  - 设误分类点为 $(x_i, y_i)$ ，那么损失函数 $L(w, b)$ 的梯度为：

$$\nabla_w L(w, b) = -y_i \cdot x_i$$

$$\nabla_b L(w, b) = -y_i$$

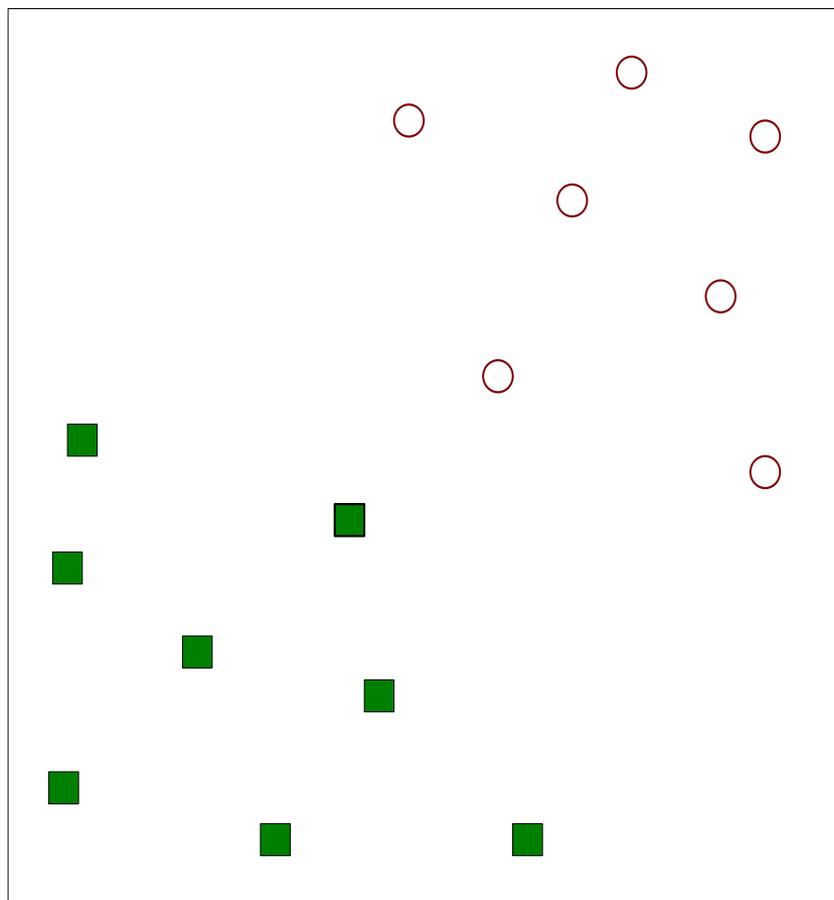
- 接下来对 $w, b$ 进行更新 $w \leftarrow w + \gamma y_i \cdot x_i, b \leftarrow b + \gamma y_i$ ，其中 $\gamma (0 \leq \gamma \leq 1)$ 为步长，也、称为学习速率 (learning rate) 。
- 通过迭代，直到损失函数为0 (无误分点)



# 分类：支持向量机

76

## □ 分类——支持向量机 (Support Vector Machine)



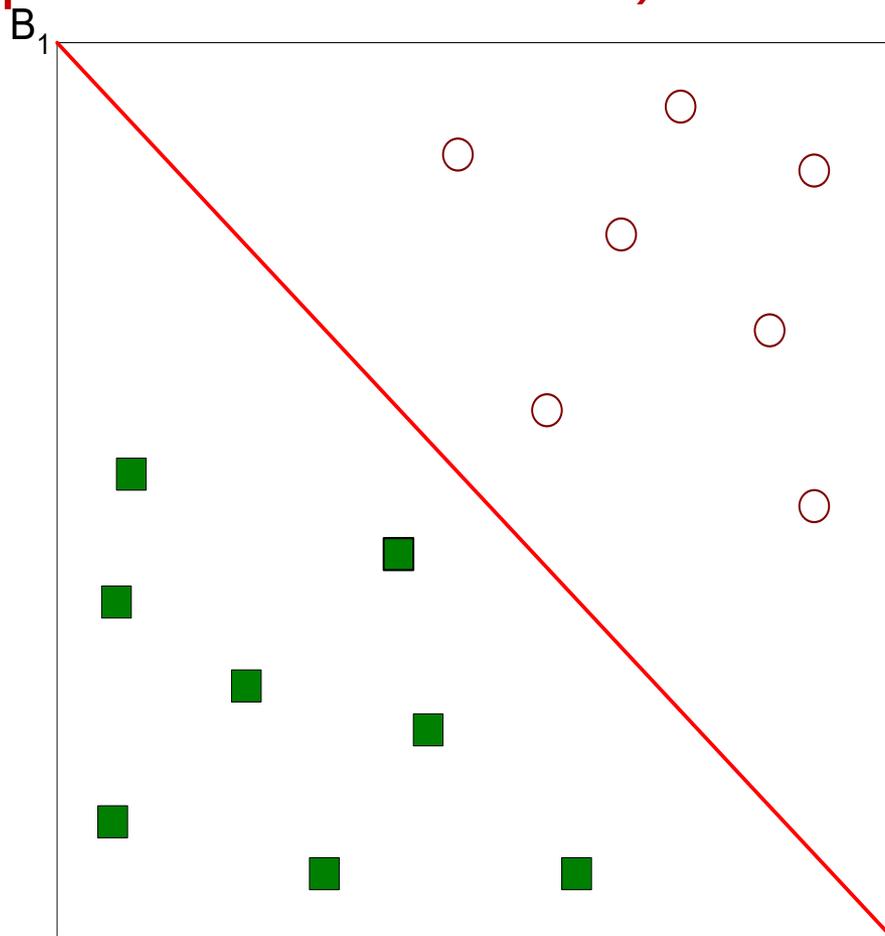


# 分类：支持向量机

77

## □ 分类——支持向量机 (Support Vector Machine)

一个可行解



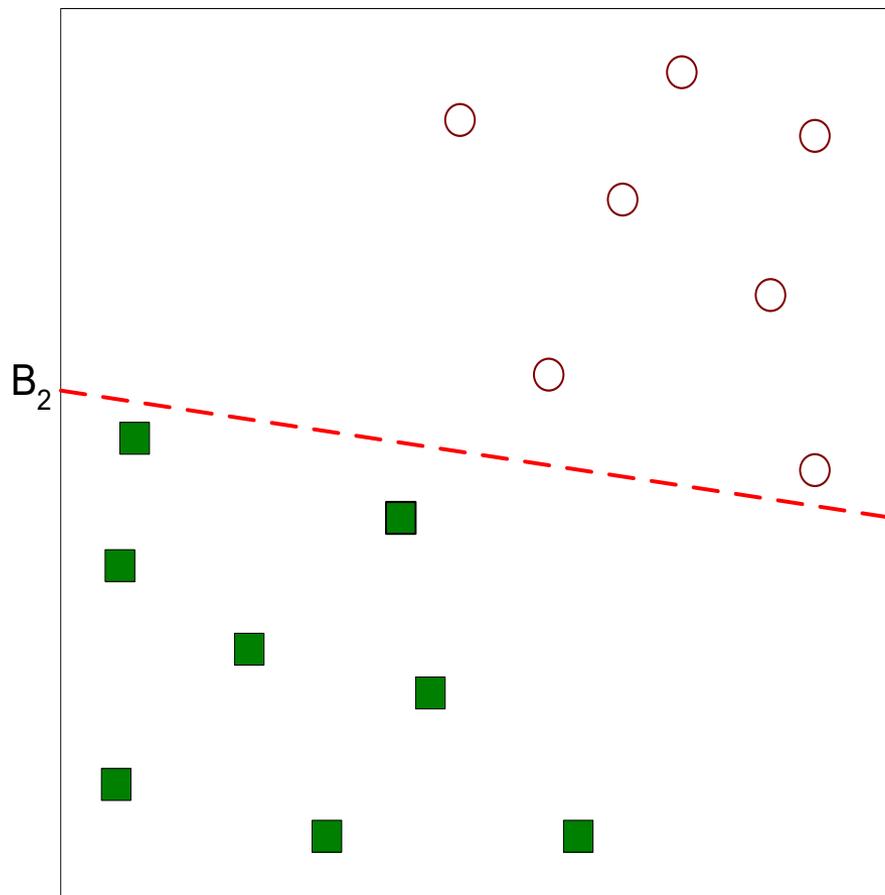


# 分类：支持向量机

78

## □ 分类——支持向量机 (Support Vector Machine)

另一个可行解

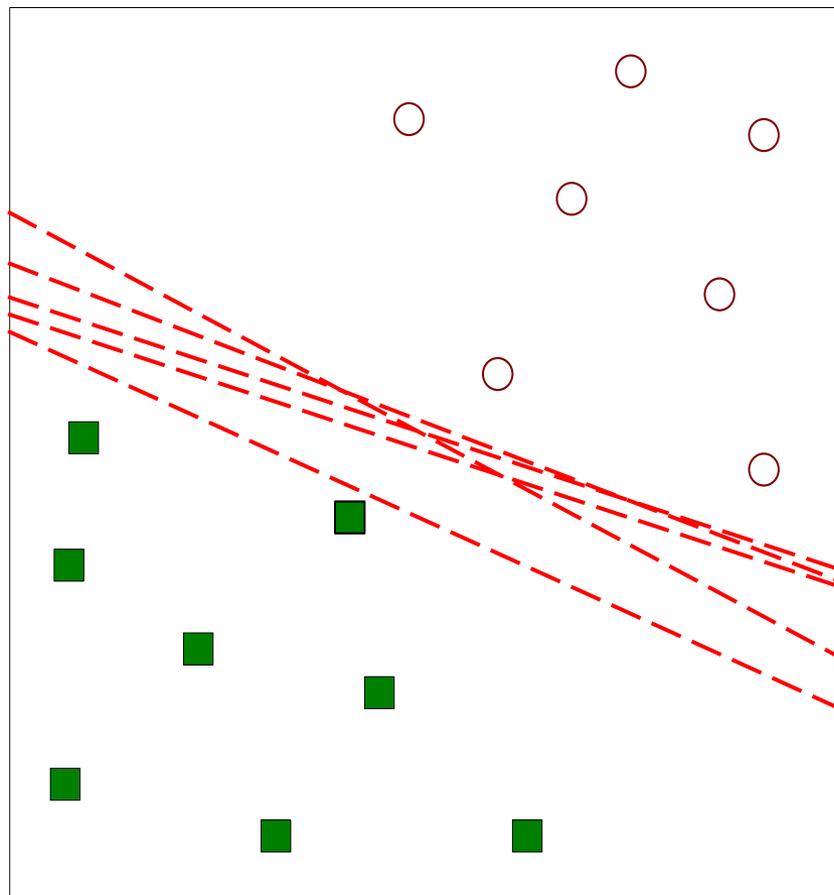




# 分类：支持向量机

## □ 分类——支持向量机 (Support Vector Machine)

其他可行解





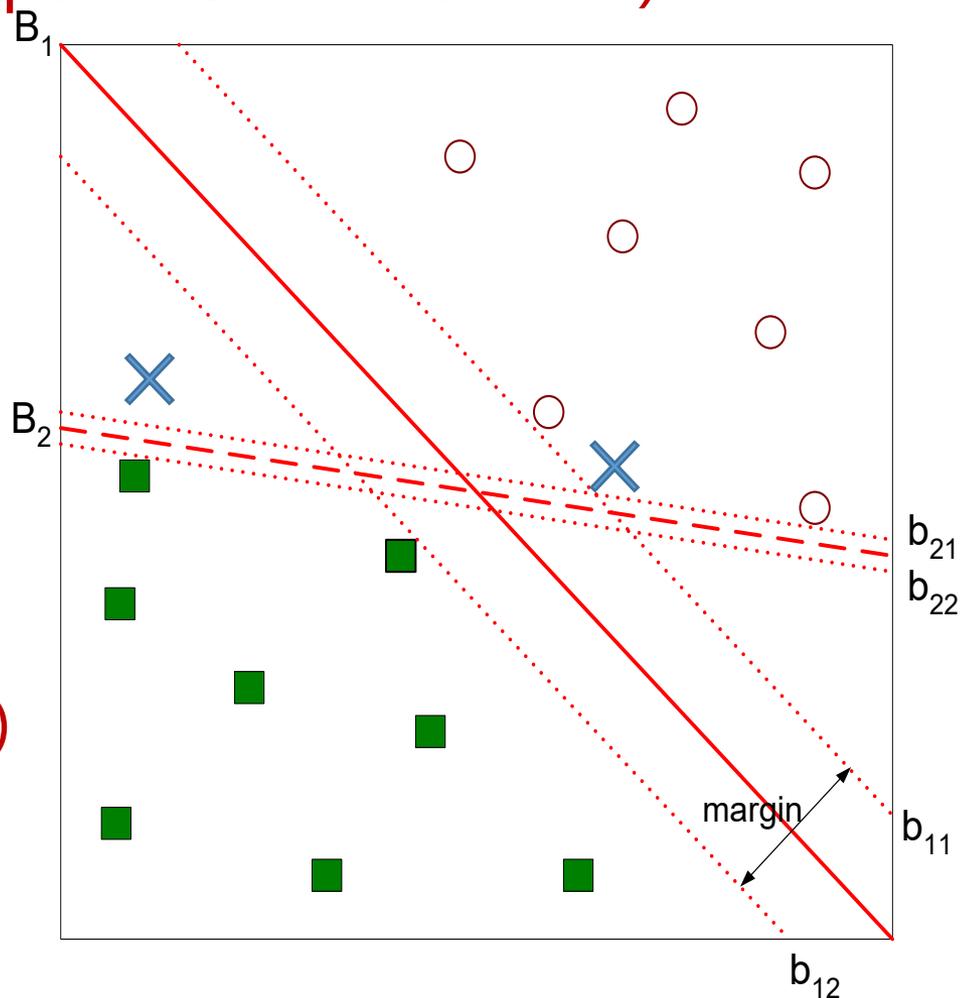
# 分类：支持向量机

## 分类——支持向量机 (Support Vector Machine)

B1与B2，哪个更好？

B1 保证分类正确 (区分)

分类间隔大 (更容易区分)



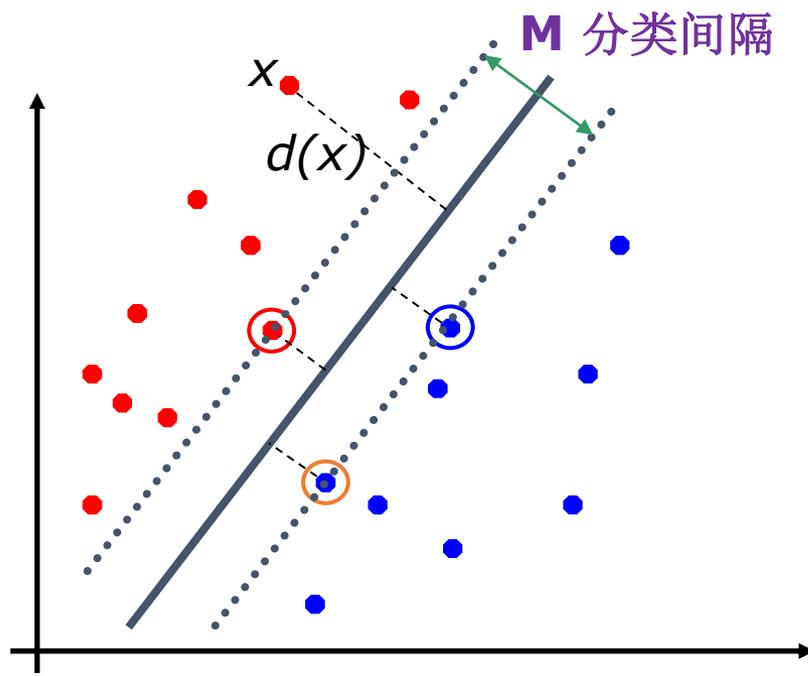


# 分类：支持向量机

## □ 分类——支持向量机

- 因此，应该选择“正中”的最大间隔超平面（分类间隔最大）
  - 容忍性好，泛化能力强
  - 在线性可分的条件下，符合这样条件的超平面“存在且唯一”
- 问题：如何找到最优的超平面？

## □ 最大化分类间隔





# 分类：支持向量机

82

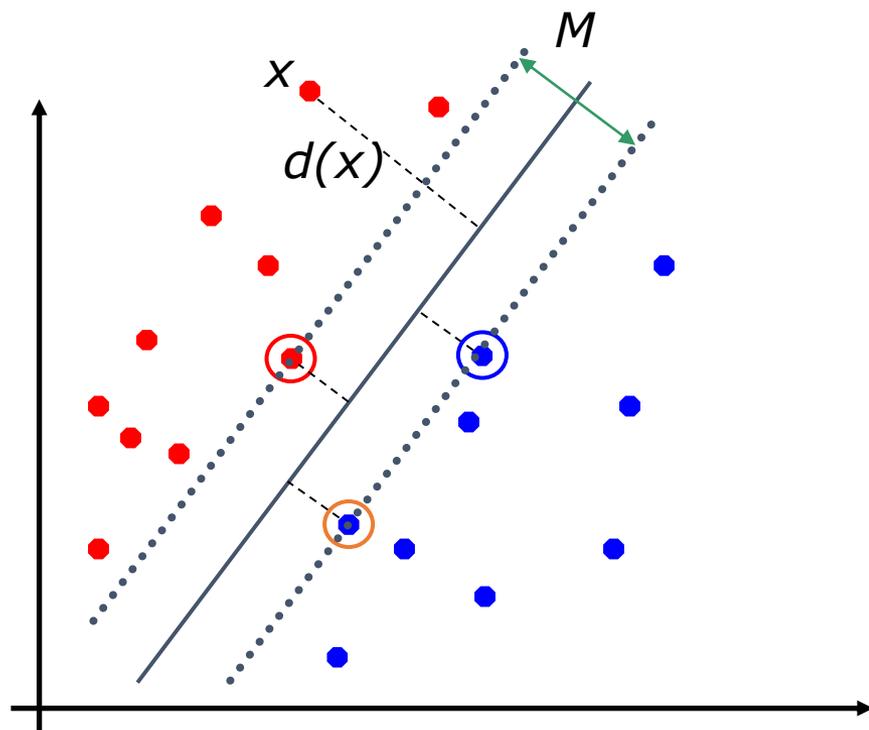
## □ 分类——支持向量机

### □ 理解：最大化分类间隔

- 区分能力更强
- 概率的角度: 最难的点置信度最大
- 即使我们在选边界的时候犯了小错误, 使得边界有偏移, 仍然有很大概率保证可以正确分类绝大多数样本
- 很容易实现交叉验证, 因为边界只与极少数的样本点有关
- 有一定的理论支撑
- 实验结果验证了其有效性

保证分类正确性—当前

保证分类质量—未来



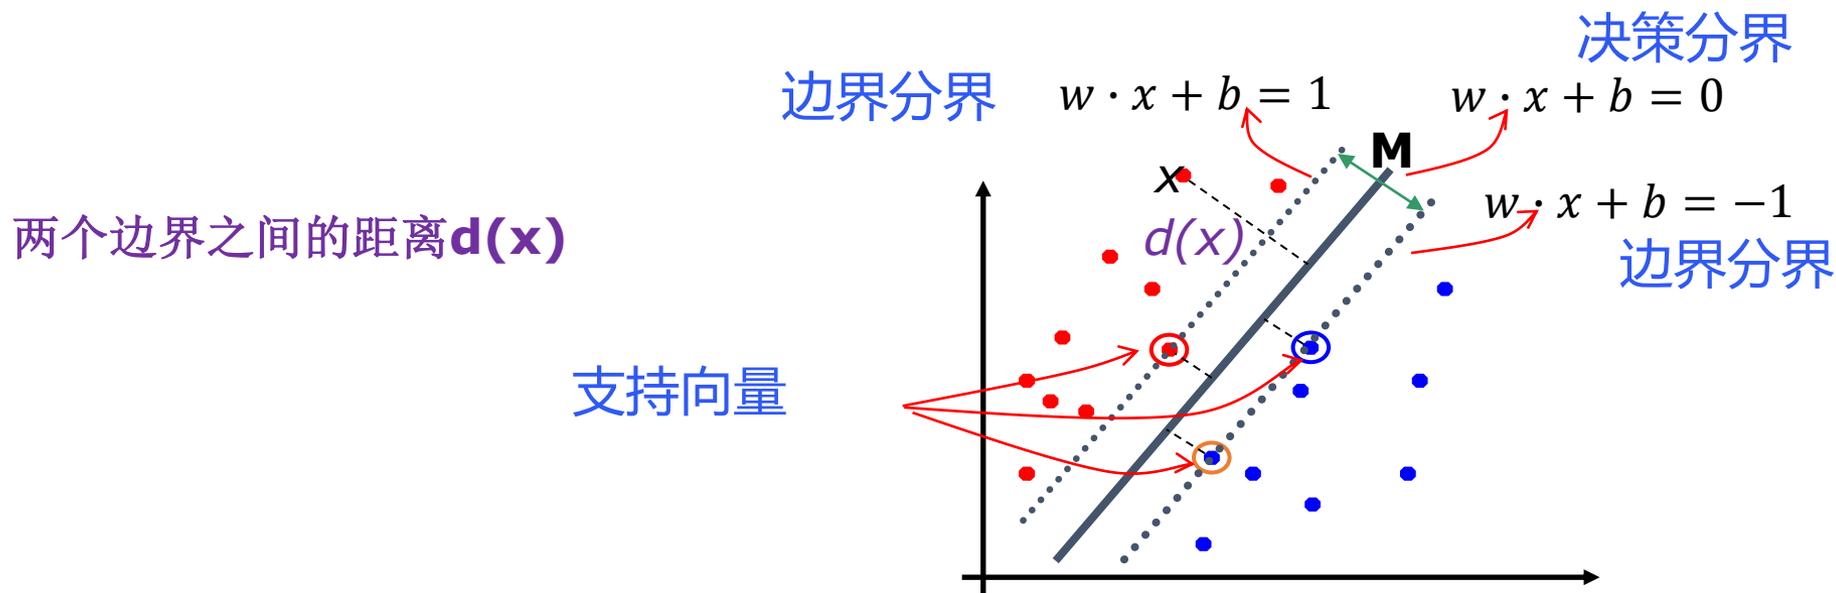


# 分类：支持向量机

83

## 支持向量机的基本概念

- 模型：符号函数  $y = \text{sign}(w \cdot x + b) = \begin{cases} +1, w \cdot x + b \geq 0 \\ -1, w \cdot x + b < 0 \end{cases}$
- 决策分界面(Decision Boundary):  $w \cdot x + b = 0$
- 边界分界面(Margin Boundary):  $w \cdot x + b = \pm 1$
- 支持向量(Support Vectors): 满足  $w \cdot x + b = \pm 1$  的样本





# 分类：支持向量机

84

## 支持向量机

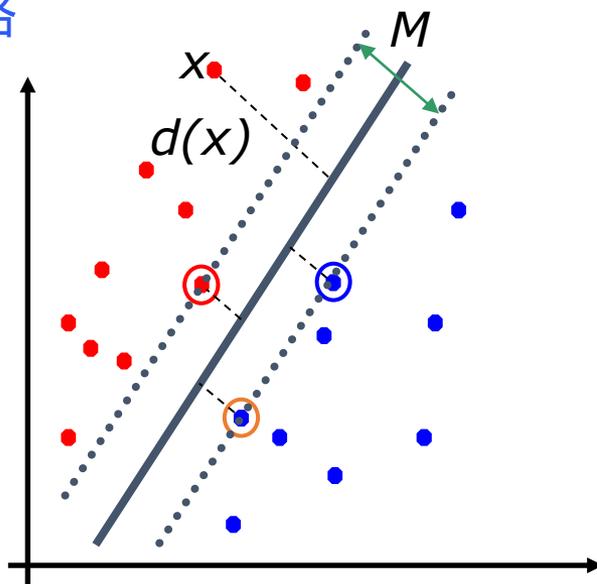
### 两个边界之间的距离 $d(x)$ ：支持向量到决策分界面的距离

- 点 $x_i$ 到平面 $w \cdot x + b = 0$ 的距离为 $\frac{1}{\|w\|} y_i (w \cdot x_i + b)$
- 支持向量到决策平面的距离为 $\frac{1}{\|w\|}$

**最大化** 两个边界之间的距离： $\frac{2}{\|w\|}$  推导过程省略

- 目标函数： $\operatorname{argmax}_{w,b} L(w,b) = \frac{2}{\|w\|}$
- 学习策略：找到参数 $w$ 和 $b$ ，使得目标最大

$$\operatorname{argmax}_{w,b} L(w,b) = \frac{2}{\|w\|}$$
$$s.t. \quad y_i (w^T \cdot x_i + b) \geq 1, \quad i = 1, 2, \dots, m$$





# 分类：支持向量机

## 支持向量机学习算法

优化任务转化

$$\operatorname{argmax}_{w,b} L(w,b) = \frac{2}{\|w\|}$$

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

优化目标：平方和系数都是为了求导方便



$$\operatorname{argmin}_{w,b} L(w,b) = \frac{1}{2} \|w\|^2$$

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

- (课后学习)注意到，该形式符合凸二次规划问题特征，可以借助拉格朗日对偶性，通过求解对偶问题加以求解
- (课后学习)具体而言，求解方式可采用序列最小优化算法 (SMO)

```
from sklearn.svm import LinearSVC
```

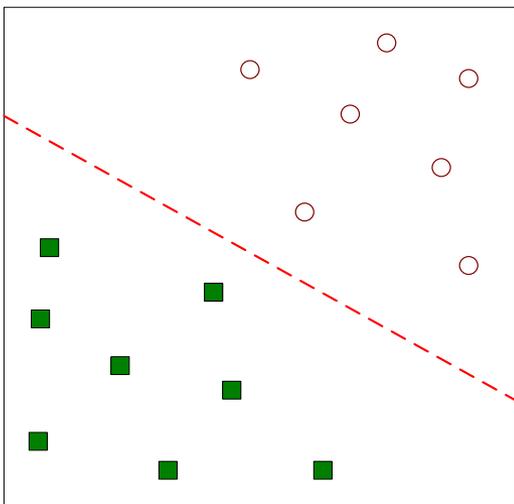


# 分类：支持向量机

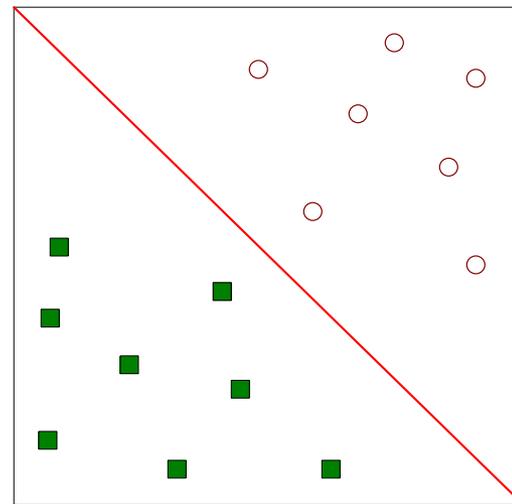
## 感知机与支持向量机对比

- 相同点：均采用模型  $f(x) = \text{sign}(w \cdot x + b)$
- 不同点：采用不同的优化目标

感知机



SVM



优化目标:

$$\min_{w,b} L(w,b) = - \sum_{x_i \in M} y_i (w \cdot x_i + b)$$

$$\begin{aligned} \min_{w,b} L(w,b) &= \frac{1}{2} \|w\|^2 \\ \text{s.t. } y_i (w^T x_i + b) &\geq 1 \end{aligned}$$



# SVM总结

87

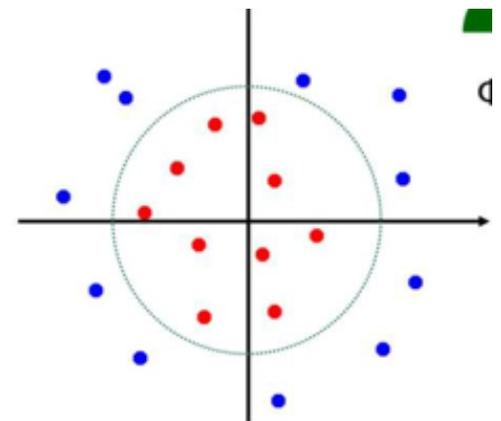
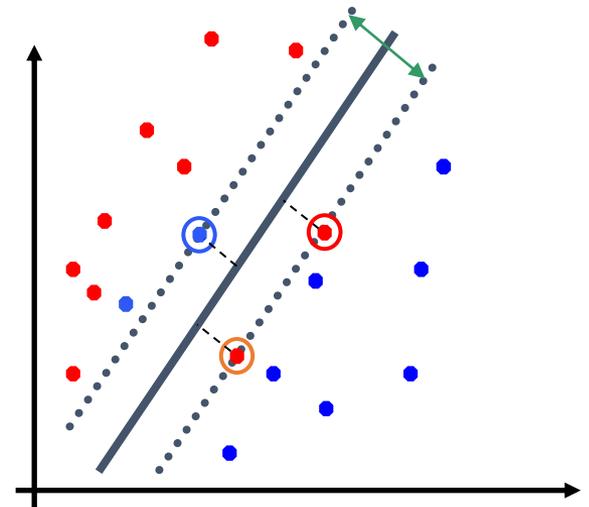
## 支持向量机

### 优点：强分类器

- 区分分类结果
- 最大化间隔：更容易区分分类结果
- 有数学理论保证
- 只有支持向量在影响，优化简单

### 缺点： Hard Margin SVM

- 只能处理线性可分问题
- 线性不可分
  - 软间隔：soft margin SVM (课后学习)
- 线性完全不可分





# 线性不可分问题

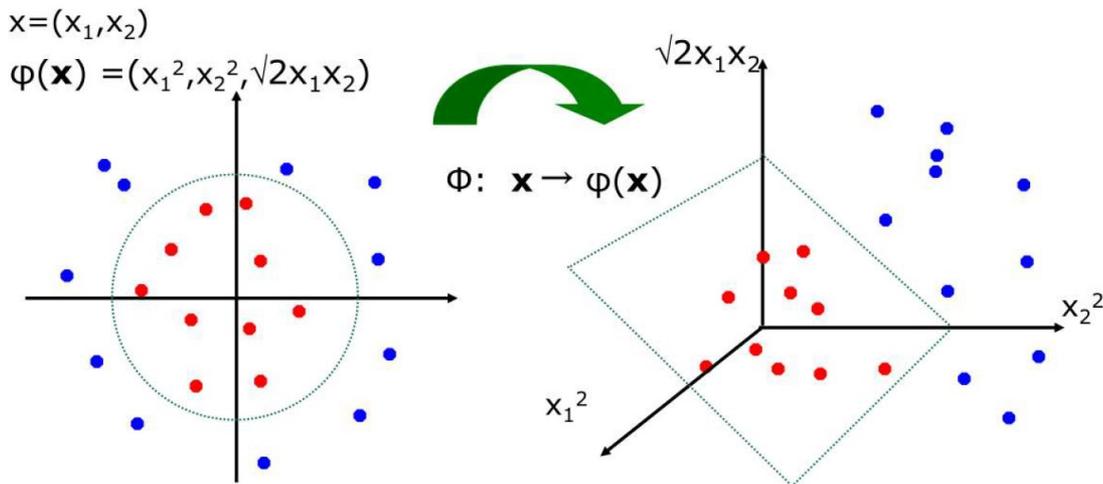
88

## 线性不可分问题

- 如果数据集线性不可分，不存在这样一个超平面，怎么办？
  - 解决方法：将样本映射到一个更高维的特征空间，使得在这个特征空间线性可分

## 核函数：

- 核函数的目的，在于将高维空间下的SVM求解时需要的内积运算转化为低维空间下的核函数计算，从而避免可能遇到的“维度灾难”问题





# 核函数

89

## 线性不可分问题与核函数——（课后学习）

常见的核函数如下表所示

名称	表达式	参数
线性核	$\kappa(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^\top \mathbf{x}_j$	
多项式核	$\kappa(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i^\top \mathbf{x}_j)^d$	$d \geq 1$ 为多项式的次数
高斯核	$\kappa(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\ \mathbf{x}_i - \mathbf{x}_j\ ^2}{2\delta^2}\right)$	$\delta > 0$ 为高斯核的带宽(width)
拉普拉斯核	$\kappa(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\ \mathbf{x}_i - \mathbf{x}_j\ }{\delta}\right)$	$\delta > 0$
Sigmoid核	$\kappa(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\beta \mathbf{x}_i^\top \mathbf{x}_j + \theta)$	$\tanh$ 为双曲正切函数, $\beta > 0, \theta < 0$

其中，线性核函数与高斯核函数（径向基）是最为常用的

常见挑选核函数方法一般为以下两种：

- 穷举法：一个个试过来，选择效果最好的一种
- 混合法：将多个不同的核函数混合起来使用



# 分类与预测

90

- 有监督学习：分类与预测
- 常用方法
  - 规则方法
  - 决策树
  - 最近邻方法
  - 感知机，支持向量机 (SVM)
  - 集成方法
- 分类的评价指标
- 类不平衡问题



# 分类：集成学习

91

## □ 分类——集成学习

- 思想：集成多个模型的能力，得到比单一模型更好的效果
- 为什么能够提升效果？

- 增强模型的表达能力

- 单个感知机无法正确分类数据能用三个感知机完成

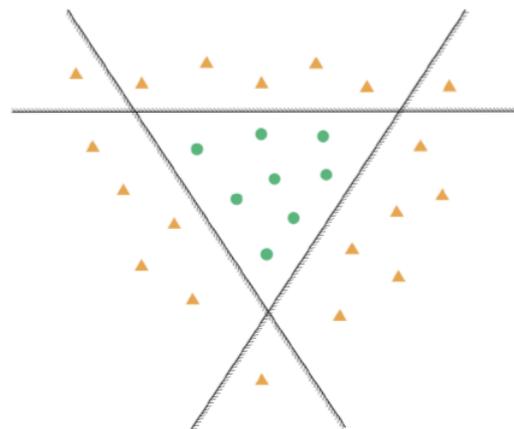
- 降低误差

- 假设单个分类器误差 $p$ ，有 $T$ 个独立的分类器采用投票进行预测，得到集成模型  $H$

- 集成分类器误差为

$$Error_H = \sum_{k \leq \frac{T}{2}} C_T^k \cdot p^{T-k} \cdot (1-p)^k$$

- $T = 5, p = 0.1$ 时,  $Error_H < 0.01$





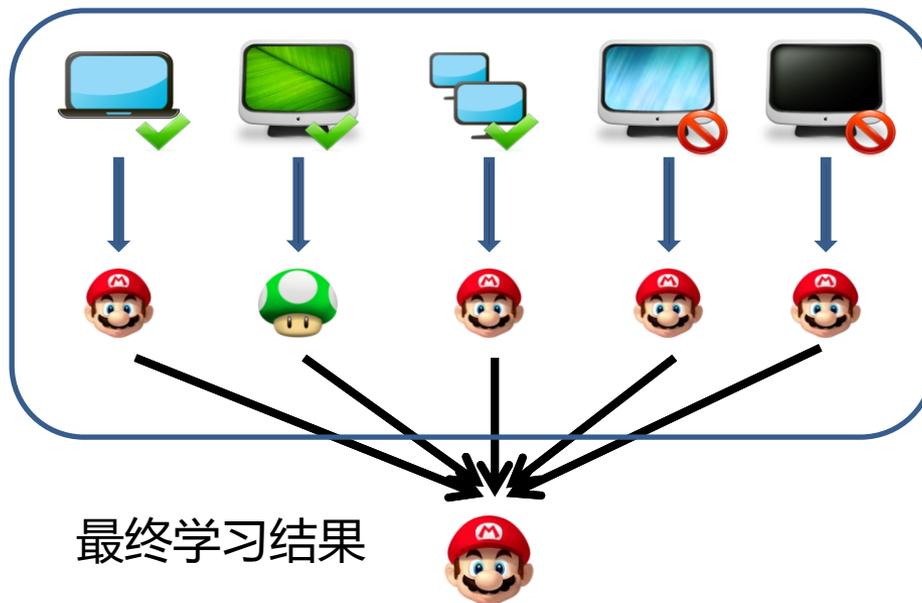
# 分类：集成学习

## 分类——集成学习

### 集成过程

学习器

各自学习结果



投票

最终学习结果

此类方法经常用在数据挖掘竞赛中(如KDD CUP, CCF-BDCI)

- KDD Cup2021 MAG240M-LSC赛道第一名集成了30个模型
- KDD Cup2021 WikiKG90M-LSC赛道第三名集成了15个模型



# 分类：集成学习

93

## □ 常见集成学习方法

### □ Bagging (Bootstrap Aggregating)

- 对样本或特征随机取样，学习产生多个独立的模型，然后平均所有模型的预测值
- 主要减小方差
- 典型代表：随机森林

### □ Boosting

- 串行训练多个模型，后面的模型是基于前面模型的训练结果（误差）
- 主要减小偏差
- 典型代表：AdaBoost



# 随机森林

94

## 集成学习算法：随机森林

- 最典型的Bagging算法：算法思想

- 随机：每棵树，保证各棵树之间的独立性，采用两到三层的随机性

  - 随机有放回的抽取样本作为训练集

样本和特征尽可能不同

  - 随机选取m个特征作为树节点的划分特征

  - 随机选择特征取值进行分割 (不遍历特征所有取值)

- 森林：多颗决策树集成

  - 假设使用三棵决策树组合成随机森林，每各不相同且预测结果相互独立，每棵树的预测错误率为40%。那么两棵树以及上预测错误的概率下降为：三三棵全部错误+两棵树错误一个正确 =  $0.4^3 + 3 * 0.4^2 * (1 - 0.4) = 0.352$

`sklearn.ensemble.RandomForestClassifier`



# AdaBoost

95

## 集成学习算法：AdaBoost

- 最有代表性的Boosting算法

- 算法思想**：利用同一训练样本的不同加权版本，训练一组弱分类器，然后把这些弱分类器以加权的形式集成起来，形成一个最终的强分类器：

- 在每一步迭代过程中，会给训练集中的样本赋予一个权重 $w_1, w_2, \dots, w_n$
- 样本的初始权重都一样，设置为 $\frac{1}{n}$ ；
- 在每一步迭代过程中，
  - 被当前弱分类器**分错的样本**的权重会相应得到**提高**
  - 被当前弱分类器**分对的样本**的权重则会相应**降低**；
- 弱分类器的权重则根据当前分类器的加权错误率来确定。

```
from sklearn.ensemble import AdaBoostClassifier
```



# 分类与预测

96

- 有监督学习：分类与预测
- 常用方法
  - 规则方法
  - 决策树
  - 最近邻方法
  - 支持向量机 (SVM)
  - 集成方法
- 分类的评价指标



# 分类模型的评价

97

- 如何评价分类模型的效果？——以二分类为例
  - 基本概念
    - T/F: True or False, 表示二分类结果的正确与否
    - P/N: Positive or Negative, 表示算法对样本的判断
  - 四种简写的含义:
    - 真正(True Positive, TP): 样本为正例, 预测为正, (正确)
    - 假负(False Negative, FN): 样本为正例, 预测为负, (错误)
    - 假正(False Positive, FP): 样本为负例, 预测为正, (错误)
    - 真负(True Negative, TN): 样本为负例, 预测为负, (正确)



# 分类模型的评价

- 如何评价分类模型的效果？——指标Accuracy
  - 通常用混淆矩阵表示：TP、FN、FP、 TP

		PREDICTED (预测) CLASS	
		Class=Yes	Class=No
ACTUAL (真实) CLASS	Class=Yes	a (TP)	b (FN)
	Class=No	c (FP)	d (TN)

- 评价指标1:  $Accuracy = \frac{a+d}{a+b+c+d} = \frac{TP+TN}{TP+TN+FP+FN}$



# 分类模型的评价

- 如何评价分类模型的效果？——指标Accuracy
  - 举例：假设一共有200个测试数据样本，以下是使用分类模型得到的分类结果，请问Accuracy是多少？

		PREDICTED (预测) CLASS	
		Class=Yes	Class=No
ACTUAL (真实) CLASS	Class=Yes	60 <b>(TP)</b>	40 <b>(FN)</b>
	Class=No	20 <b>(FP)</b>	80 <b>(TN)</b>

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{60 + 80}{60 + 80 + 20 + 40} = 0.7$$



# 分类模型的评价

## 如何评价分类模型的效果？ — Accuracy的局限性

样本不均衡时，评估结果可能不合理

例子：考虑2分类问题

假设10000个数据样本中，类别0的样本数为 9990，类别1的样本数为 10

假设模型将所有样本均预测为0

计算  $Accuracy = 9990/10000 = 99.9\%$

Accuracy很高，表明模型很好？

结论：模型不好

原因：10个正例均预测错误

分析：这个例子中，显然我们关注类别为1的样本，但Accuracy被类别为0的样本影响了

Count	PREDICTED CLASS		
	Class=Yes	Class=No	
ACTUAL CLASS	Class=Yes	a	b
	Class=No	c	d



# 分类模型的评价

- 如何评价分类模型的效果？——分类问题的常用指标
  - 准确率(查准率)  $\text{Precision}(p) = \frac{a}{a+c} = \frac{TP}{TP+FP}$ ：预测为Yes中正确的比例
    - 正确预测的个体总数 / 预测出的个体总数
  - 召回率(查全率)  $\text{Recall}(r) = \frac{a}{a+b} = \frac{TP}{TP+FN}$ ：真实为Yes中被预测正确的比例
    - 正确预测的个体总数 / 测试集中Yes的个体总数

Count	PREDICTED CLASS		
	Class=Yes	Class=No	
ACTUAL CLASS	Class=Yes	a (TP)	b (FN)
	Class=No	c (FP)	d (TN)



# 分类模型的评价

102

## □ 分类模型的其他指标——分类问题的常用指标

□ F值 =  $\frac{2PR}{P+R} = \frac{2a}{2a+b+c}$  : 正确率和召回率的调和平均值

□ 意义: 不同应用场景中, 对于准确率和召回率有着不同的侧重

- 邮件分类: 宁愿放过一些垃圾邮件, 也不能错杀正常邮件
  - 牺牲召回率, 保证较高准确率
- 智慧医疗: 宁愿多判断一些疑似患者, 不能漏掉一个病人
  - 牺牲准确率, 保证较高召回率

Count	PREDICTED CLASS		
	Class=Yes	Class=No	
ACTUAL CLASS	Class=Yes	a	b
	Class=No	c	d



# 分类模型的评价

## 分类问题的常用指标——课堂练习

- 在一次垃圾邮件检测中，使用某分类模型认为有100篇邮件是垃圾邮件，后经过专家判定，其中真是垃圾邮件的为60篇，其余的40篇为误分类，那么请问本次分类的准确率Precision就等于\_\_\_\_\_。
- 假如专家发现邮件样本集里还有90篇垃圾邮件，由于各种原因而未被检出（漏检），那么按照上述公式，本次分类的查全率Recall就等于\_\_\_\_\_，F1值等于\_\_\_\_\_。

$$\text{Precision}(P) = \frac{a}{a+c}$$

$$\text{Recall}(R) = \frac{a}{a+b}$$

$$\text{F值} = \frac{2PR}{P+R} = \frac{2a}{2a+b+c}$$

		PREDICTED CLASS	
		Class=Yes	Class=No
ACTUAL CLASS	Class=Yes	a (TP)	b (FN)
	Class=No	c (FP)	d (TN)



# 分类模型的评价

104

## □ 分类模型的其他指标—ROC与AUC

### □ ROC(Receiver Operating Characteristic)与AUC(Area Under the ROC curve)

- 背景：发展于20世纪50年代的信号检测理论，用于分析噪声信号
- 两者的关系：ROC曲线的面积就是AUC

### □ 基本概念

- **真正例率TPR**(True Positive Rate) =  $TP/(TP+FN)$ 
  - **预测为正且实际为正的样本占有所有正样本的比例**
- **假正例率FPR**(False Positive Rate)= $FP/(TN+FP)$ 
  - **预测为正但实际为负的样本占有所有负样本的比例**

		PREDICTED CLASS	
		Class=Yes	Class=No
ACTUAL CLASS	Class=Yes	a (TP)	b (FN)
	Class=No	c (FP)	d (TN)

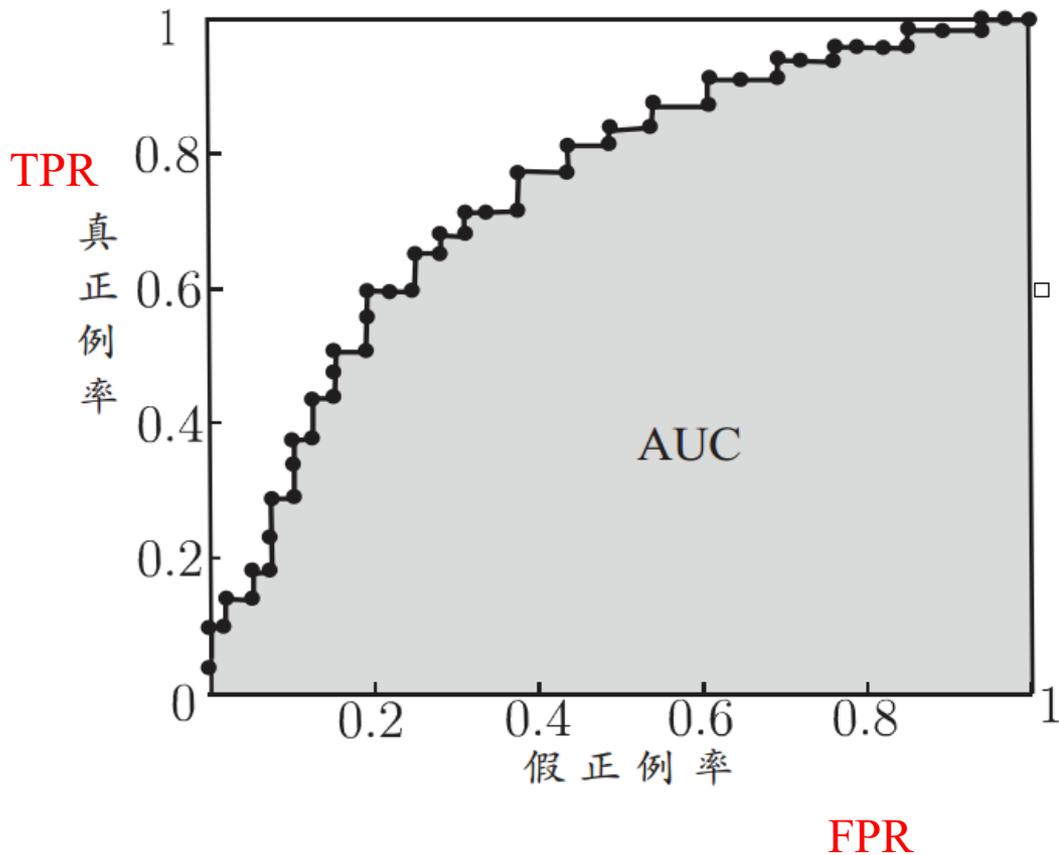


# 分类模型的评价

## ROC曲线

特点:

- 对角线表示区分能力为0，即随机猜测
- 在对角线上端越远，效果越好
- 低于对角线的结果无意义（无区分度）

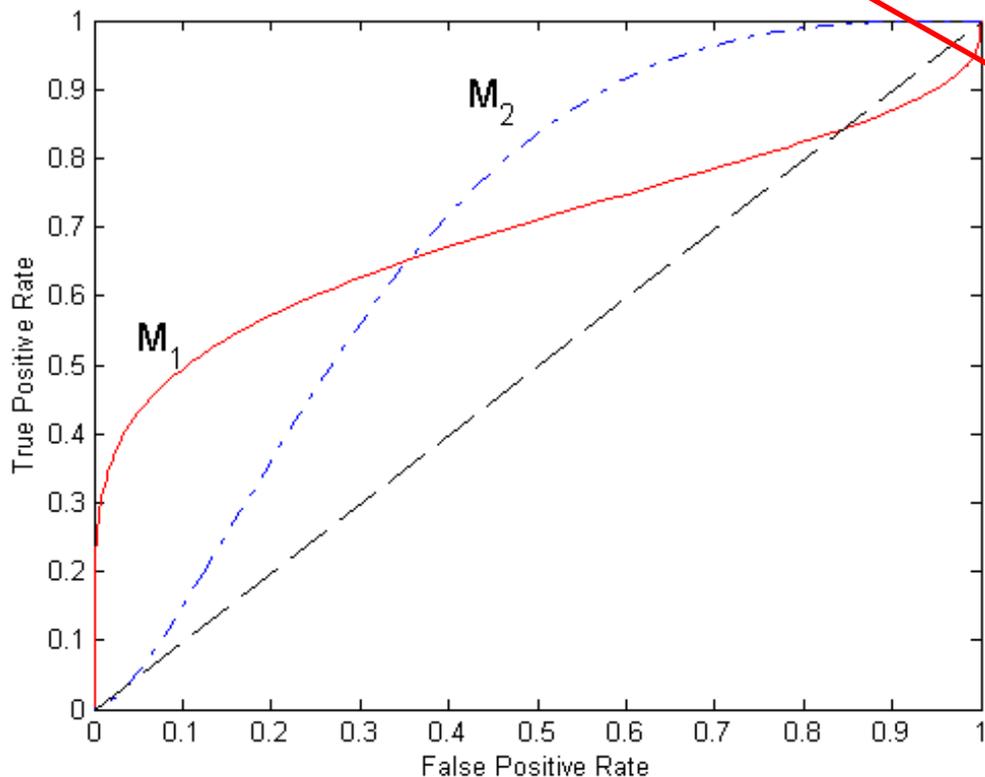




# 分类模型的评价

## 如何基于ROC曲线比较模型好坏？

- 一般而言，模型A的ROC曲线将模型B的完全包住，则模型A更好
- 但往往并不会完全包住



对比ROC曲线发现，两个模型都不是一直表现得好

- $M_1$ 在FPR较小时表现好
- $M_2$ 在FPR较大时表现好



# 分类模型的评价

107

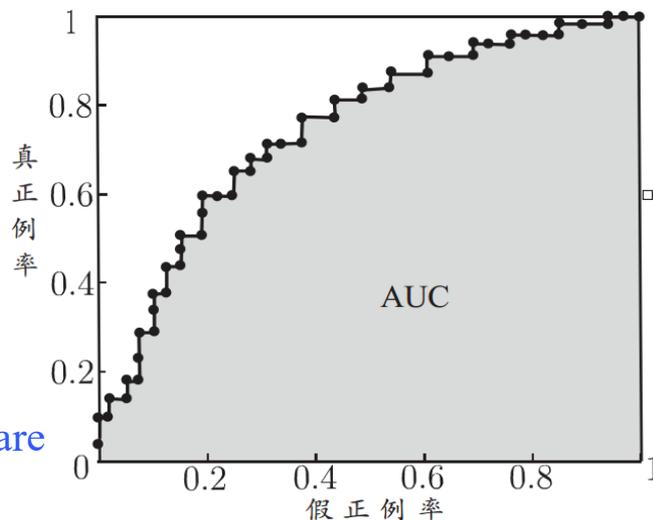
## □ ROC不能量化——AUC量化指标

- AUC定义为ROC曲线的面积，可以直接计算如下
- 假设ROC曲线由 $\{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m), x_1 = 0, x_m = 1\}$ 的点按序连接而形成，则AUC为：

$$AUC = \frac{1}{2} \sum_{i=1}^{m-1} (x_{i+1} - x_i) \cdot (y_{i+1} + y_i)$$

**AUC越大，结果越好**

**AUC衡量了样本预测的排序质量**





# 分类模型的评价

108

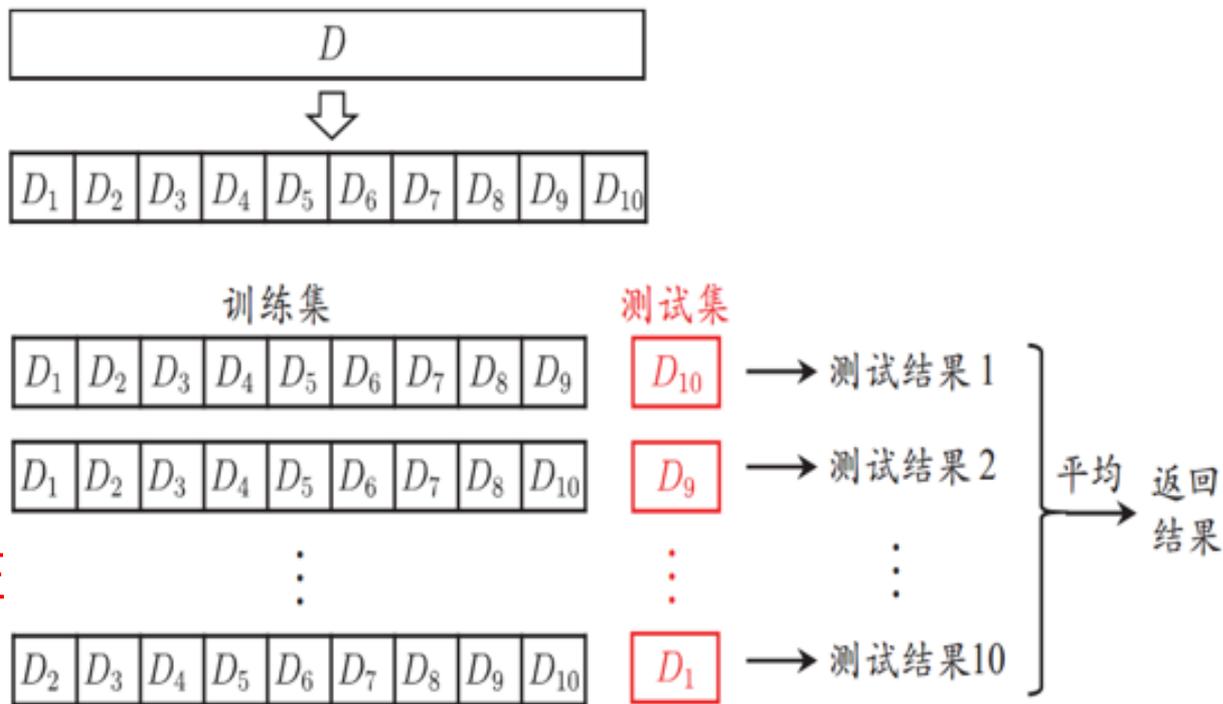
- 如何评价分类模型的效果？—分类模型的比较方法
  - 关于性能比较：
    - 测试性能并不等于泛化性能
    - 测试性能随着测试集的变化而变化
    - 很多机器学习算法本身有一定的随机性
      - 例如，对两个模型：
        - M1: accuracy = 85%, 在30个样本上测试
        - M2: accuracy = 75%, 在5000个样本上测试
  - 常常进行**假设检验**，判断不同模型的性能差别是否具有统计意义
    - 假设检验为学习器性能比较提供了重要依据，基于其结果我们可以推断出：若在测试集上观察到学习器A比B好，则A的泛化性能是否在统计意义上优于B，以及这个结论的把握有多大。



# 分类模型的验证

## 分类模型的验证方法 —— 增加结果的可靠性

- 交叉验证法 (Cross Validation) : 将数据集分层采样划分为k个大小相似的互斥子集, 每次用k-1个子集的并集作为训练集, 余下的子集作为测试集, 最终返回k个测试结果的均值, k最常用的取值是10.



10折交叉验证



# 分类与预测

110

- 有监督学习：分类与预测
- 常用方法
  - 规则方法
  - 决策树
  - 最近邻方法
  - 支持向量机 (SVM)
  - 集成方法
- 分类的评价指标