



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/NM2025.html>

助教：齐畅，朱家骏
bigdata_2025@163.com

11/23/2025



决策树剪枝

58

□ 3. 决策树剪枝

- 在生成决策树之后，我们还将根据实际情况，对决策树进行剪枝
 - 剪枝的原因在于训练过程的“过拟合”问题
 - 如果训练集与测试集效果都不好，说明出现“欠拟合”
 - 如果训练集效果好，而测试集效果不好，说明出现“过拟合”
- 过拟合出现的原因：训练过程中过度迁就训练数据特性，而导致构造出过于复杂、过于细枝末节的决策树，泛化能力较差
- 解决这一问题的办法在于对已生成的决策树进行简化，即“剪枝”
 - 包括两种策略：预剪枝、后剪枝




决策树剪枝

59

□ 3. 决策树剪枝：预剪枝

□ 在生成决策树的过程中即进行剪枝，称作“预剪枝”

- 每个节点划分前，衡量当前节点的划分能否提高决策树的泛化能力
- 通过提前停止生成分枝对决策树进行剪枝，可以利用信息增益等测度来对分枝生成情况（优劣）进行评估






决策树剪枝

60

□ 3. 决策树剪枝：后剪枝

- 在生成决策树之后再进行剪枝，称作“后剪枝”
- 自底向上 考察每个非叶子节点，考虑将该节点替换成叶子节点后能否提高泛化性能

剪枝前






决策树剪枝

61

□ 3. 决策树剪枝：后剪枝

- 自底向上 考察每个非叶子节点，考虑将该节点替换成叶子节点后能否提高泛化性能

剪枝后





决策树剪枝

62

□ 3. 决策树剪枝：比较两种剪枝策略

- 从过程上看，后剪枝方法经过了“构建”到“剪枝”这样的过程，显然它要比事前剪枝需要更多的计算时间
- 对应的，**后剪枝可以获得更可靠的决策树**
- 实际使用时：先剪枝可以与后剪枝方法相结合，从而构成一个混合的剪枝方法



分类与预测

63

- 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
- 类不平衡问题
- 分类的评价指标




分类：K近邻方法

64

□ 分类——K近邻方法

- 问题：判断测试样本是什么动物？






分类：K近邻方法

65

□ 分类——K近邻方法

- 对数据空间内的样本，可提出相似样本假设
 - 表征上相近的样本应该属于同一个类别
- K近邻思想：用K个最相似样本的类别来预测未知样本的类别(投票方法)
- 核心问题：距离度量、K的取值





K近邻方法：距离度量

66

□ K近邻方法核心问题：距离度量

- K近邻分类的效果严重依赖于距离度量
- 对于高维空间而言，最基本的度量方式为欧式距离

$$d(x, x') = \sqrt{\sum_i (x_i - x'_i)^2}$$

- 离散0/1向量，则可使用汉明距离（Hamming）代替
- 除此之外，对于文本而言（如采用TF-IDF），可使用余弦相似度
- 其他可采用的度量如马氏距离等

回顾第二章：数据集成




K近邻方法：K的取值

67


□ K近邻方法核心问题：K的取值

□ K近邻分类的效果同样严重依赖于 K 的取值 **(即邻居的数量)**


- K太小，容易受噪声干扰；
- K太大，可能导致错误涵盖其他类别样本



(a) 1-nearest neighbor



(b) 2-nearest neighbor



(c) 3-nearest neighbor

不同的K值，结果不同



分类：K近邻方法

68

□ K近邻方法的特点


- K近邻方法是一种典型的**基于实例**的学习
 - 使用具体实例进行预测，而不需要对数据进行抽象（如提取特征）
- K近邻方法是一种**消极学习**，不需要模型，但分类过程开销很大
 - 相比之下，积极学习方法训练模型较为费时费力，但基于模型分类很快
- K近邻方法基于局部信息进行判别，受**噪声**影响很大
- K近邻方法需要**慎重选择度量并预处理数据**，否则可能被误导
 - 例如，借助身高体重进行分类，身高波动范围不大，而体重差距巨大
 - （回顾第二章：数据集成）已知：小明(160,60000)；小王(160,59000)；小李(170, 60000)。小明与谁的体型更相似？



K近邻方法实例

69

□ K近邻思想的应用实例：推荐系统的UCF、ICF模型



UCF: 基于K个相似用户对物品的评分

- 用户A、B购买过物品d，且与C相似，可用他们对d的平均喜爱程度作为C对d的喜爱程度

ICF: 基于用户对K个相似物品的评分

- C购买过a,b，若物品d与a,b相似，可用C对他们的平均喜爱程度作为对物品d的喜爱程度




- Sarwar, Badrul, et al. Item-based collaborative filtering recommendation algorithms. WWW 2001.
➤ Amazon recommendations: Item-to-item collaborative filtering. IEEE Internet computing, 2003



K近邻方法实例

70

- K近邻思想的应用实例：图神经网络中的近邻
 - 基本思想：将K个邻居节点的信息传播到当前节点
 - 距离度量：基于注意力机制计算(GAT模型)



- Hamilton, Will, Zhitao Ying, and Jure Leskovec. "Inductive representation learning on large graphs." NeurIPS 2017



KNN的实例

71

□ Transformer

- Google Brain 2017的提出的一篇工作
- 针对RNN的弱点进行重新设计，解决了RNN效率问题和传递中的缺陷
- **Original paper:** Vaswani et al. *Attention Is All You Need*. In *NIPS*, 2017.

Attention Is All You Need

Ashish Vaswani*
Google Brain
avaswani@google.com

Noam Shazeer*
Google Brain
noam@google.com

Niki Parmar*
Google Research
nikip@google.com


Jakob Uszkoreit*
Google Research
usz@google.com

Llion Jones*
Google Research
llion@google.com

Aidan N. Gomez* †
University of Toronto
aidan@cs.toronto.edu

Lukasz Kaiser*
Google Brain
lukasz.kaiser@google.com

Illia Polosukhin* ‡
illia.polosukhin@gmail.com





分类与预测

72

- 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

73

□ 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


74

□ 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

75

□ 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

76

□ 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

77

□ 分类——支持向量机 (Support Vector Machine)






分类：支持向量机

78

□ 分类——支持向量机 (Support Vector Machine)

一个可行解






分类：支持向量机

79

□ 分类——支持向量机 (Support Vector Machine)

另一个可行解






分类：支持向量机

80

□ 分类——支持向量机 (Support Vector Machine)

其他可行解





分类：支持向量机


81

□ 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

82

□ 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


83

□ 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


84

□ 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

两个边界之间的距离 $d(x)$

支持向量





分类：支持向量机

85

□ 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


86

□ 支持向量机学习算法

□ 优化任务转化

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

优化目标：平方和系数都是为了求导方便



等价

$$\begin{aligned} \underset{w,b}{\operatorname{argmin}} \quad & L(w,b) = \frac{1}{2} \|w\|^2 \\ \text{s.t.} \quad & y_i(w^T \cdot x_i + b) \geq 1, \quad i = 1, 2, \dots, m \end{aligned}$$

- (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

87


□ 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：

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

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



SVM总结

88



□ 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


89

□ 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

90

- 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

91

- 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