

北京市大数据人才培训示范基地

## 第三讲：分类



欧高炎，北京大学博士、博士后  
数据酷客创始人，博雅大数据学院院长

# "机器学习十讲"直播安排

BIBDR  
北京大数据研究院

博雅大数据学院  
BOYA BIG DATA COLLEGE


数据酷客  
COOK DATA

时间	主题	介绍
5/14	机器学习介绍	机器会学习吗？
5/21	回归	回归初心，方得始终
5/28	分类	分门别类，各得其所
6/4	模型提升	三个臭皮匠，顶个诸葛亮
6/11	聚类	物以类聚，人以群分
6/18	降维	取其精华，去其糟粕
6/23	最优化	摸着石头过河，蒙着眼睛爬山
7/2	维度灾难	来自维数的诅咒
7/9	深度学习	深层次学习的艺术
7/16	强化学习	让机器像人类一样学习



## 第二讲作业完成情况

- 144 人完成 10 道题，124 人合格



- “666”准则：
  - 参加本系列直播 6 次以上（观看回放不计入）
  - 6 次考核合格
  - 60 分以上为合格

1. 数学知识回顾：点到平面距离、梯度下降法、最大似然估计
2. 感知机 ( Perceptron )
3. 支持向量机 ( Support Vector Machines )
4. 逻辑回归 ( Logistic Regression )
5. 分类模型评估与Sklearn分类模块
6. 实践案例：使用感知机、逻辑回归和支持向量机进行中文新闻分类

- 直线方程： $w_1x_1 + w_2x_2 + w_0 = 0$


- 点到直线距离

$$d = \frac{|w_1x'_1 + w_2x'_2 + w_0|}{\sqrt{w_1^2 + w_2^2}}$$

- 欧式空间超平面： $w_1x_1 + w_2x_2 + \dots + w_dx_d + w_0 = 0$

- 点到超平面距离：


$$d = \frac{|w_1x'_1 + w_2x'_2 + \dots + w_dx'_d + w_0|}{\sqrt{w_1^2 + w_2^2 + \dots + w_d^2}} = \frac{|\mathbf{w}^\top \mathbf{x}' + w_0|}{\|\mathbf{w}\|_2}$$



- 求解无约束最优化问题的经典方法，机器学习和深度学习中应用最广泛的模型求解算法
- 如果实值函数  $g(\mathbf{w})$  在点  $\mathbf{a}$  处可微且有定义，那么函数  $g(\mathbf{w})$  在点  $\mathbf{a}$  处沿着梯度相反的方向 $-\nabla g(\mathbf{a})$ 下降最快
- 优化问题： $\min_{\mathbf{w}} g(\mathbf{w})$
- 假设初始值为  $\mathbf{w}^{(0)}$ ，梯度下降法用以下迭代公式更新参数：  
$$\mathbf{w}^{(t+1)} \leftarrow \mathbf{w}^{(t)} - \eta_t \nabla g(\mathbf{w}^{(t)})$$
- 其中  $\eta_t$  是学习率，取值范围 $(0,1)$



如何走到山谷？  
策略：沿着斜坡向下走




- 机器学习中，优化目标和梯度具有特定结构：

$$L(\mathbf{w}) = \sum_{i=1}^n l(y_i, f(x_i; \mathbf{w})) \quad \nabla L(\mathbf{w}) = \sum_{i=1}^n \nabla l(y_i, f(x_i; \mathbf{w})) = \sum_{i=1}^n \nabla L_i(\mathbf{w})$$

- 更新参数只用一个样本的梯度，即随机梯度下降法：

$$\mathbf{w}^{(t+1)} \leftarrow \mathbf{w}^{(t)} - \eta_t \nabla L_i(\mathbf{w}^{(t)})$$

- 收敛充分条件  $\sum_{t=1}^{\infty} \eta_t = \infty, \sum_{t=1}^{\infty} \eta_t^2 < \infty$
- 需要随着迭代次数的增加降低学习率



- “似然”：likelihood 可能性
- 最大似然法，一种求解概率模型参数的方法
- 最早是遗传学家以及统计学家罗纳德·费雪在1912年至1922年间开始使用。




罗纳德·费雪(1890-1962)

- 假设有  $n$  个从概率模型  $p_\theta(x)$  独立生成的样本  $\{x_i\}_{i=1}^n$
- 似然函数  $L(\theta) = \prod_{i=1}^n p_\theta(x)$
- 通过最大化  $L(\theta)$  求解模型参数的方法叫做最大似然法

$$L(\theta) = \prod \theta^m (1 - \theta)^n$$

$$\text{NLL}(\theta) = -m \log \theta - n \log(1 - \theta)$$

$$\frac{d \text{NLL}(\theta)}{d\theta} = -\frac{m}{\theta} + \frac{n}{1 - \theta} = 0, \text{ 可得 } \theta = \frac{m}{m+n}$$



# 什么是分类？

- 另一种典型的有监督学习问题
- 标签（模型预测值） $y$  为离散值
- 实际应用举例

- 新闻主题分类：科技、教育、社会、体育？
- 疾病诊断：根据病人肺部影像图片，诊断是否患 COVID-19 肺炎
- 市场营销：根据顾客历史购买记录和行为偏好，预测用户是否喜欢新产品
- 信用评估：根据客户历史信贷记录，预测贷款是否会违约




# 如何做分类？


- 线性回归:  $f(\mathbf{x}) = \mathbf{w}^T \mathbf{x}$ ,  $y \in (-\infty, +\infty)$
- 二分类中， $y \in \{-1, 1\}$ ，用回归的方法做分类，在回归结果上添加映射函数  $H(f)$ ：

$$H(f) = \begin{cases} +1, & f > 0 \\ -1, & f \leq 0 \end{cases}$$

- $H$  的其他选择：
  - $H(f) = \tanh(f)$
  - $H(f) = \sigma(f) = \frac{1}{1+e^{-f}}$



- 线性可分训练集  $D = \{\mathbf{x}_i, y_i\}_{i=1}^n, y \in \{-1, 1\}$
- 感知机：
  - 找到一条直线，将两类数据分开即可
- 支持向量机：
  - 找到一条直线，不仅将两类数据正确分类，还使得数据离直线尽量远
- 逻辑回归：
  - 找到一条直线使得观察到训练集的“可能性”最大



- 假设训练集的特征部分记为  $n \times (d + 1)$  矩阵  $\mathbf{X}$ ，其中最后一列取值全为 1
- 标签部分记为  $\mathbf{y} = (y_1, y_2, \dots, y_n)^T$ ，参数记为  $\mathbf{w} = (w_1, w_2, \dots, w_d, w_0)^T$

$$\hat{\mathbf{y}} = \mathbf{X}\mathbf{w}$$

$$\begin{bmatrix} x_{11} & x_{12} & \dots & x_{1d} & 1 \\ x_{21} & x_{22} & \dots & x_{2d} & 1 \\ \dots & \dots & \dots & \dots & 1 \\ x_{i1} & x_{i2} & \dots & x_{id} & 1 \\ \dots & \dots & \dots & \dots & \dots \\ x_{n1} & x_{n2} & \dots & x_{nd} & 1 \end{bmatrix}$$

$$\begin{bmatrix} w_1 \\ w_2 \\ \dots \\ w_d \\ w_0 \end{bmatrix}$$

$$\begin{bmatrix} \hat{y}_1 \\ \hat{y}_2 \\ \dots \\ \hat{y}_i \\ \dots \\ \hat{y}_n \end{bmatrix}$$

$$\begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_i \\ \dots \\ y_n \end{bmatrix}$$

 $\mathbf{X}$  $\mathbf{w}$  $\hat{\mathbf{y}}$  $\mathbf{y}$

1. 数学知识回顾：点到平面距离、梯度下降法、最大似然估计
2. 感知机 ( Perceptron )
3. 支持向量机 ( Support Vector Machines )
4. 逻辑回归 ( Logistic Regression )
5. 分类模型评估与Sklearn分类模块
6. 实践案例：使用感知机、逻辑回归和支持向量机进行中文新闻分类


- $f(\mathbf{x}) = \mathbf{w}^T \mathbf{x}$ ,  $\mathbf{w} = (w_1, w_2, \dots, w_d, w_0)^T$ 为系数，模型为

$$y = H(f(\mathbf{x})) = \begin{cases} +1, & \mathbf{w}^T \mathbf{x} > 0 \\ -1, & \mathbf{w}^T \mathbf{x} \leq 0 \end{cases}$$

- 决策超平面为： $\mathbf{w}^T \mathbf{x} = 0$
- 线性可分训练集  $D = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\}$ , 点 $(\mathbf{x}_i, y_i)$ 到决策超平面的距离为

$$d_i = \frac{|\mathbf{w}^T \mathbf{x}_i|}{\|\mathbf{w}\|_2} = \frac{y_i \mathbf{w}^T \mathbf{x}_i}{\|\mathbf{w}\|_2} \rightarrow y_i \mathbf{w}^T \mathbf{x}_i \quad \text{不妨令} \|\mathbf{w}\|_2 = 1$$

- 优化目标：误分类样本离超平面距离之和最小



- 目标函数 :  $L(\mathbf{w}) = -\sum_{i \in M} y_i \mathbf{w}^T \mathbf{x}_i$ ,  $M$  为误分类样本

集合  $\{j | y_j \mathbf{w}^T \mathbf{x}_j < 0\}$

- $L(\mathbf{w}) = \sum_{i=1}^n L(y_i, f(\mathbf{x}_i))$


- 梯度 :  $\nabla L(\mathbf{w}) = -\sum_{i \in M} y_i \mathbf{x}_i$

- 梯度下降法 (GD) :


$$\mathbf{w}^{(t+1)} \leftarrow \mathbf{w}^{(t)} + \eta_t \sum_{i \in M} y_i \mathbf{x}_i$$

- 随机梯度下降(SGD) :

$$\mathbf{w}^{(t+1)} \leftarrow \mathbf{w}^{(t)} + \eta_t y_i \mathbf{x}_i$$



- 输入：训练数据  $\mathbf{X}, \mathbf{y}$ ，学习率  $\eta$ ，迭代步数  $T$
- 1 初始化参数  $\mathbf{w}^{(0)}$
- 2 for  $t = 1, \dots, T$ 
  - 2.1 找出误分类样本集合  $M$ ；
  - 2.2 从  $M$  中随机采样一个样本  $i$
  - 2.3 更新参数  $\mathbf{w}^{(t+1)} \leftarrow \mathbf{w}^{(t)} + \eta_t y_i \mathbf{x}_i$
- 输出：  $\mathbf{w}$



1. 数学知识回顾：点到平面距离、梯度下降法、最大似然估计
2. 感知机 ( Perceptron )
3. 支持向量机 ( Support Vector Machines )
4. 逻辑回归 ( Logistic Regression )
5. 分类模型评估与Sklearn分类模块
6. 实践案例：使用感知机、逻辑回归和支持向量机进行中文新闻分类

- 线性可分训练集  $D = \{(x_1, y_1), \dots, (x_n, y_n)\}$ , 点  $(x_i, y_i)$  到决策超平面的

$$d_i = \frac{y_i \mathbf{w}^T \mathbf{x}_i}{\|\mathbf{w}\|_2}$$


- 间隔：训练集中离超平面最小的距离  $\min_i \frac{y_i \mathbf{w}^T \mathbf{x}_i}{\|\mathbf{w}\|_2}$

- 间隔最大化：

$$\max_{\mathbf{w}} \min_i \frac{y_i \mathbf{w}^T \mathbf{x}_i}{\|\mathbf{w}\|_2} \Leftrightarrow \max_{\mathbf{w}} \frac{1}{\|\mathbf{w}\|_2} \min_i y_i \mathbf{w}^T \mathbf{x}_i$$



- 不妨令  $\min_i y_i \mathbf{w}^T \mathbf{x}_i = 1$ , 则上述目标等价于

$$\max_{\mathbf{w}} \frac{1}{\|\mathbf{w}\|_2} \Leftrightarrow \min_{\mathbf{w}} \frac{1}{2} \|\mathbf{w}\|_2^2$$



- 假设  $\min_i y_i \mathbf{w}^T \mathbf{x}_i = 1$ ，则对于训练集任意样本需满足  $y_i \mathbf{w}^T \mathbf{x}_i \geq 1$
- 对于不满足上述条件样本的损失函数定义为  $1 - y_i \mathbf{w}^T \mathbf{x}_i$
- 则样本损失为合页损失 ( hinge loss ) :

$$L(y_i, f(\mathbf{x}_i)) = \max(0, 1 - y_i \mathbf{w}^T \mathbf{x}_i)$$



- 目标函数  $L(\mathbf{w}) = \frac{\lambda}{2} \|\mathbf{w}\|_2^2 + \sum_{i=1}^n \max(0, 1 - y_i \mathbf{w}^\top \mathbf{x}_i)$ ，其中  $\lambda$  超参数
- 记不满足约束的样本集为  $M = \{i \mid y_i \mathbf{w}^\top \mathbf{x}_i < 1\}$ ，则梯度为


$$\nabla L(\mathbf{w}) = \lambda \mathbf{w} - \sum_{i \in M} y_i \mathbf{x}_i$$

- 梯度下降法：

$$\mathbf{w}^{(t+1)} \leftarrow \mathbf{w}^{(t)} - \eta_t \left( \lambda \mathbf{w}^{(t)} - \sum_{i \in M} y_i \mathbf{x}_i \right)$$


- 随机梯度下降：

$$\mathbf{w}^{(t+1)} \leftarrow \mathbf{w}^{(t)} - \eta_t (\lambda \mathbf{w}^{(t)} - I(i \in M) y_i \mathbf{x}_i)$$



映射trick !

将数据点从2维空间映射到3维空间  
中，使得数据线性可分



1. 数学知识回顾：点到平面距离、梯度下降法、最大似然估计
2. 感知机 ( Perceptron )
3. 支持向量机 ( Support Vector Machines )
4. 逻辑回归 ( Logistic Regression )
5. 分类模型评估与Sklearn分类模块
6. 实践案例：使用感知机、逻辑回归和支持向量机进行中文新闻分类

- $f(\mathbf{x}) = \mathbf{w}^T \mathbf{x}$ ,  $\mathbf{w} = (w_1, w_2, \dots, w_d, w_0)^T$ 为系数

离决策面越远，概率越高


- 训练集  $D = \{\mathbf{x}_i, y_i\}_{i=1}^n$ ,  $y \in \{-1, 1\}$ , 概率解释：

$$p(y = 1 | \mathbf{x}) = \frac{1}{1 + e^{-\mathbf{w}^T \mathbf{x}}}$$

$$p(y = -1 | \mathbf{x}) = 1 - p(y = 1 | \mathbf{x}) = \frac{1}{1 + e^{\mathbf{w}^T \mathbf{x}}}$$

- 考虑到  $y \in \{-1, 1\}$ , 则样本  $(\mathbf{x}_i, y_i)$  概率为：

$$p(y_i | \mathbf{x}_i) = \frac{1}{1 + e^{-y_i \mathbf{w}^T \mathbf{x}_i}}$$




- 似然函数为  $L(\mathbf{w}) = \prod_{i=1}^n p(y_i | \mathbf{x}_i) = \prod_{i=1}^n \frac{1}{1 + e^{-y_i \mathbf{w}^\top \mathbf{x}_i}}$
- 便于计算，取对数，将连乘转换成求和，负对数似然函数为：
- $NLL(\mathbf{w}) = \sum_{i=1}^n \ln(1 + e^{-y_i \mathbf{w}^\top \mathbf{x}_i})$
- 梯度为  $\nabla NLL(\mathbf{w}) = -\sum_{i=1}^n \frac{y_i \mathbf{x}_i}{1 + e^{y_i \mathbf{w}^\top \mathbf{x}_i}}$
- 梯度下降法：


$$\mathbf{w}^{(t+1)} \leftarrow \mathbf{w}^{(t)} + \eta_t \sum_{i=1}^n \frac{y_i \mathbf{x}_i}{1 + e^{y_i \mathbf{w}^\top \mathbf{x}_i}}$$

- 随机梯度下降法：

$$\mathbf{w}^{(t+1)} \leftarrow \mathbf{w}^{(t)} + \eta_t \frac{y_i \mathbf{x}_i}{1 + e^{y_i \mathbf{w}^\top \mathbf{x}_i}}$$



- 理想的损失函数不能被高效地优化：0-1损失
- 感知机： $L(y, f(x)) = \max(0, -yf(x))$
- 支持向量机： $L(y, f(x)) = \max(0, 1 - yf(x))$
- 逻辑回归： $L(y, f(x)) = \ln(1 + \exp(-yf(x)))$



1. 数学知识回顾：点到平面距离、梯度下降法、最大似然估计
2. 感知机 ( Perceptron )
3. 支持向量机 ( Support Vector Machines )
4. 逻辑回归 ( Logistic Regression )
5. **分类模型评估与 Sklearn 分类模块**
6. 实践案例：使用感知机、逻辑回归和支持向量机进行中文新闻分类

混淆矩阵 (Confusion Matrix)		预测标签	
		1 ( 正例 )	0 ( 负例 )
真实标签	1 ( 正例 )	TP ( 真正样本数量 )	FN ( 假负样本数量 )
	0 ( 负例 )	FP ( 假正样本数量 )	TN ( 真负样本数量 )

$$\text{正确率}(\textit{accuracy}) = \frac{TP + TN}{TN + FN + FP + TP}$$

$$\text{召回率}(\textit{recall}) = \frac{TP}{TP + FN}$$

$$\text{精确率}(\textit{precision}) = \frac{TP}{TP + FP}$$

$$F_1 = \frac{2 \times \text{精确率} \times \text{召回率}}{\text{精确率} + \text{召回率}}$$

实现工具 : sklearn.metrics 模块实现了常见的模型评价指标函数 , 直接调用即可

类	说明
linear_model.SGDClassifier	梯度下降法实现感知机、LR、SVM等
linear_model.LogisticRegression	逻辑回归
neighbors.KNeighborsClassifier	K近邻
tree.DecisionTreeClassifier	决策树
naive_bayes.BernoulliNB	Bernoulli 贝叶斯
naive_bayes.GaussianNB	Gaussian 贝叶斯
naive_bayes.MultinomialNB	多项式贝叶斯
svm.LinearSVC	线性支持向量分类器
svm.SVC	支持向量分类器

方法	说明
fit(X, y)	训练模型
predict(X)	返回X中样本的预测类标签
predict_log_proba(X)	返回X中样本的对数预测类别概率
predict_proba(X)	返回X中样本的预测类别概率
score(X, y)	对X进行预测得到预测标签，再与真实标签y作比对，返回正确率


1. 数学知识回顾：点到平面距离、梯度下降法、最大似然估计
2. 感知机 ( Perceptron )
3. 支持向量机 ( Support Vector Machines )
4. 逻辑回归 ( Logistic Regression )
5. 分类模型评估与 Sklearn 分类模块
6. 实践案例：使用感知机、逻辑回归和支持向量机进行中文新闻分类

- 数据酷客“数据科学导引”课程 分类模型章节：

[http://cookdata.cn/course/course\\_introduction/1/](http://cookdata.cn/course/course_introduction/1/)

- 数据酷客“机器学习实践”课程 分类章节：

[http://cookdata.cn/course/course\\_introduction/39/](http://cookdata.cn/course/course_introduction/39/)



数据科学导引

5602人 163人



机器学习实践  
998人 61人

## 4章 分类模型

分类是另一种典型的有监督学习问题。本章介绍分类问题和五种经典的分类模型：逻辑回归、K近邻、决策树、朴素贝叶斯和支持向量机。

- 100% 4.1 分类问题概述
- 100% 4.2 逻辑回归
- 100% 4.3 K近邻
- 6% 4.4 决策树
- 5% 4.5 朴素贝叶斯
- 100% 4.6 支持向量机



## 4章 分类模型

介绍主流的分类模型的实现方法，包括逻辑回归、K近邻、决策树、朴素贝叶斯和支持向量机等。

- 0% 4.1 分类问题概述和Scikit-learn分类模块介绍
- 0% 4.2 逻辑回归
- 0% 4.3 K近邻
- 0% 4.4 决策树
- 0% 4.5 朴素贝叶斯
- 66% 4.6 支持向量机
- 0% 4.7 案例：根据多种特征预测学生的学业表现



基于中文新闻数据集，利用三种分类模型建立新闻自动分类器。

1. 使用 Python 和梯度下降法感知机、逻辑回归和支持向量机
2. 借助 Sklearn SGDClassifier类建立文本分类模型
3. 使用混淆矩阵、正确率、精度、召回率等指标进行分类模型评估

案例地址：[http://cookdata.cn/note/view\\_static\\_note/83d69a6c88ff3eec2e5867da890b1957/](http://cookdata.cn/note/view_static_note/83d69a6c88ff3eec2e5867da890b1957/)





— 数据酷客 —



数据科学人工智能

- 介绍了三种用回归办法解决分类问题的模型
- 感知机：
  - 关注误分类样本，将训练集样本分对即可
  - 是支持向量机、神经网络的基本模型
  - 只能应用于线性可分数据集
- 逻辑回归：
  - 使用 Logistic 函数赋予样本概率解释
  - 使用最大似然法求解，是一种线性分类模型
  - 为防止过度拟合，可在优化目标添加正则项
- 支持向量机：
  - 可以使用核技巧将低维数据转换到高维运算，保持低维的计算量
  - 如何选择核函数是一大困难



1. 逻辑回归和支持向量机分别如何处理多分类问题？
2. 如果训练集线性不可分（更常见的场景），应该怎么办？
3. 请尝试实现一个带  $l_2$  正则项的逻辑回归模型。
4. 除了本次课介绍的分类模型，还有哪些分类问题？你能写出他们的优化目标函数吗？



— 数据酷客 —



数据科学人工智能



加入数据酷客交流群