

第二章 贝叶斯决策理论

2010. 09. 27

基于最小风险的贝叶斯决策

□ 定义

- 状态空间 Ω : 由 c 个可能的状态 (c 类) 组成

$$\Omega = \{\omega_1, \omega_2, \dots, \omega_c\}$$

- 决策空间 \mathcal{A} : 由所有可能采取的决策组成

$$\mathcal{A} = \{\alpha_1, \alpha_2, \dots, \alpha_k\}$$

- 损失函数 $\lambda(\alpha_i, \omega_j)$, $i=1, \dots, k, j=1, \dots, c$: 表示对真实状态为 ω_j 的样本, 采取决策 α_i 时所造成的损失。

基于最小风险的贝叶斯决策

损失 决策	自然状态					
	ω_1	ω_2	...	ω_j	...	ω_c
α_1	$\lambda(\alpha_1, \omega_1)$	$\lambda(\alpha_1, \omega_2)$...	$\lambda(\alpha_1, \omega_j)$...	$\lambda(\alpha_1, \omega_c)$
α_2	$\lambda(\alpha_2, \omega_1)$	$\lambda(\alpha_2, \omega_2)$...	$\lambda(\alpha_2, \omega_j)$...	$\lambda(\alpha_2, \omega_c)$
⋮	⋮	⋮	...	⋮	⋮	⋮
α_i	$\lambda(\alpha_i, \omega_1)$	$\lambda(\alpha_i, \omega_2)$...	$\lambda(\alpha_i, \omega_j)$...	$\lambda(\alpha_i, \omega_c)$
⋮	⋮	⋮	...	⋮	⋮	⋮
α_k	$\lambda(\alpha_k, \omega_1)$	$\lambda(\alpha_k, \omega_2)$...	$\lambda(\alpha_k, \omega_j)$...	$\lambda(\alpha_k, \omega_c)$

决策表

基于最小风险的贝叶斯决策

- 条件期望损失 (条件风险): 对于特定的观察样本 \mathbf{x} (特征向量), 决策 α_i 造成的损失对 \mathbf{x} 实际所属类别的各种可能的平均:

$$\begin{aligned} R(\alpha_i | \mathbf{x}) &= E[\lambda(\alpha_i, \omega_j)] \\ &= \sum_{j=1}^c \lambda(\alpha_i, \omega_j) P(\omega_j | \mathbf{x}) \end{aligned}$$

- 期望风险: 对所有 \mathbf{x} 取值所作的决策 $\alpha(\mathbf{x})$ 所带来的平均风险, 即条件风险对 \mathbf{x} 的数学期望。

$$R(\alpha) = E[R(\alpha(\mathbf{x}) | \mathbf{x})] = \int R(\alpha(\mathbf{x}) | \mathbf{x}) p(\mathbf{x}) d\mathbf{x}$$

基于最小风险的贝叶斯决策

- 目标: 最小化决策所带来损失的平均值— (平均) 风险

□ 决策规则

$$\text{Decide } \alpha_k, \text{ if } R(\alpha_k | \mathbf{x}) = \min_{j=1, \dots, a} R(\alpha_j | \mathbf{x})$$

□ 最小风险决策的计算步骤

- 计算后验概率 \rightarrow 计算每个决策的条件风险 \rightarrow 依据最小条件风险决策

基于最小风险的贝叶斯决策

□ 两类别问题

- 行为 α_1 : deciding ω_1 ;
- 行为 α_2 : deciding ω_2 ;
- 损失 $\lambda_{ij} = \lambda(\alpha_i, \omega_j)$, $i, j = 1, 2$.

■ 条件风险

$$\begin{aligned} R(\alpha_1 | \mathbf{x}) &= \lambda_{11} P(\omega_1 | \mathbf{x}) + \lambda_{12} P(\omega_2 | \mathbf{x}) \\ R(\alpha_2 | \mathbf{x}) &= \lambda_{21} P(\omega_1 | \mathbf{x}) + \lambda_{22} P(\omega_2 | \mathbf{x}) \end{aligned}$$

基于最小风险的贝叶斯决策

□ 两类别问题

■ 决策规则

$$\text{Decide } \begin{cases} \omega_1, & \text{if } (\lambda_{21} - \lambda_{11})P(\omega_1 | \mathbf{x}) > (\lambda_{12} - \lambda_{22})P(\omega_2 | \mathbf{x}) \\ \omega_2, & \text{otherwise} \end{cases}$$

$$\text{Decide } \begin{cases} \omega_1, & \text{if } \frac{P(\mathbf{x} | \omega_1)}{P(\mathbf{x} | \omega_2)} > \frac{(\lambda_{12} - \lambda_{22}) P(\omega_2)}{(\lambda_{21} - \lambda_{11}) P(\omega_1)} \\ \omega_2, & \text{otherwise} \end{cases}$$

基于最小风险的贝叶斯决策

□ 例：两类细胞识别问题：正常类和异常类

■ 根据已有知识和经验，两类的先验概率：

正常 (ω_1) : $P(\omega_1) = 0.9$

异常 (ω_2) : $P(\omega_2) = 0.1$

对某一样本观察值 \mathbf{x} ，通过计算或查表得到：

$p(\mathbf{x}|\omega_1)=0.2, p(\mathbf{x}|\omega_2)=0.4$

$\lambda_{11}=0, \lambda_{12}=6, \lambda_{21}=1, \lambda_{22}=0$

■ 依据最小风险决策如何对细胞 \mathbf{x} 进行分类？

基于最小风险的贝叶斯决策

□ 解：

$$P(\omega_1 | \mathbf{x}) = \frac{0.9 \times 0.2}{0.9 \times 0.2 + 0.1 \times 0.4} = 0.818,$$

$$P(\omega_2 | \mathbf{x}) = \frac{0.4 \times 0.1}{0.2 \times 0.9 + 0.4 \times 0.1} = 0.182;$$

$$R(\alpha_1 | \mathbf{x}) = \sum_{j=1}^2 \lambda_{1j} P(\omega_j | \mathbf{x}) = \lambda_{12} P(\omega_2 | \mathbf{x}) = 1.092,$$

$$R(\alpha_2 | \mathbf{x}) = \sum_{j=1}^2 \lambda_{2j} P(\omega_j | \mathbf{x}) = \lambda_{21} P(\omega_1 | \mathbf{x}) = 0.818;$$

$\therefore R(\alpha_1 | \mathbf{x}) > R(\alpha_2 | \mathbf{x}), \therefore \text{Decide } \alpha_2, \mathbf{x} \in \omega_2.$

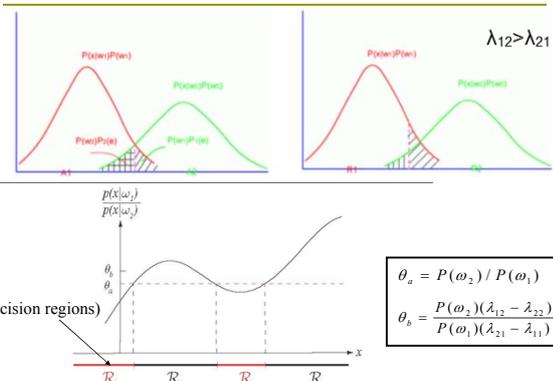
两种决策方法之间的关系

$$\lambda(\alpha_i, \omega_j) = \begin{cases} 0, & i = j \\ 1, & i \neq j \end{cases}, \quad i, j = 1, \dots, c.$$

$$\begin{aligned} R(\alpha_i | \mathbf{x}) &= \sum_{j=1}^c \lambda(\alpha_i, \omega_j) P(\omega_j | \mathbf{x}) \\ &= \sum_{j=1, j \neq i}^c P(\omega_j | \mathbf{x}) = 1 - P(\omega_i | \mathbf{x}) \end{aligned}$$

$$\min_{\alpha} R(\alpha_i | \mathbf{x}) \Leftrightarrow \max_{\alpha} P(\omega_i | \mathbf{x})$$

两种决策方法之间的关系



Neyman-Pearson 决策

□ 两类错误率

■ 令 R 是整个特征空间, R_1 是类别 ω_1 的决策域, R_2 是类别 ω_2 的决策域: $R_1 + R_2 = R$.

$$\begin{aligned} P(\text{error}) &= \int_{R_1} P(\omega_2, \mathbf{x}) d\mathbf{x} + \int_{R_2} P(\omega_1, \mathbf{x}) d\mathbf{x} \\ &= \int_{R_1} p(\mathbf{x} | \omega_2) P(\omega_2) d\mathbf{x} + \int_{R_2} p(\mathbf{x} | \omega_1) P(\omega_1) d\mathbf{x} \\ &= P(\omega_2) \int_{R_1} p(\mathbf{x} | \omega_2) d\mathbf{x} + P(\omega_1) \int_{R_2} p(\mathbf{x} | \omega_1) d\mathbf{x} \\ &= P(\omega_2) P_2(\text{error}) + P(\omega_1) P_1(\text{error}) \end{aligned}$$

两类错误率

13

Neyman-Pearson 决策

□ **决策目标:** 在 $P_2(error)=\varepsilon_0$ 条件下, 求 $P_1(error)$ 极小值。

- 根据Lagrange乘法法

$$\gamma = P_1(error) + \lambda(P_2(error) - \varepsilon_0),$$

其中 λ 是Lagrange乘子, 目标是求 γ 的极小值。

注意: $P_1(error) = \int_{R_2} p(\mathbf{x} | \omega_1) d\mathbf{x} = 1 - \int_{R_1} p(\mathbf{x} | \omega_1) d\mathbf{x};$
 $P_2(error) = \int_{R_1} p(\mathbf{x} | \omega_2) d\mathbf{x} = 1 - \int_{R_2} p(\mathbf{x} | \omega_2) d\mathbf{x} = \varepsilon_0.$

14

Neyman-Pearson 决策

□ **决策目标:** 极小化 γ

$$\gamma = (1 - \lambda\varepsilon_0) + \int_{R_1} [\lambda p(\mathbf{x} | \omega_2) - p(\mathbf{x} | \omega_1)] d\mathbf{x};$$

或者

$$\gamma = (1 - \varepsilon_0)\lambda + \int_{R_2} [p(\mathbf{x} | \omega_1) - \lambda p(\mathbf{x} | \omega_2)] d\mathbf{x};$$

$$\frac{\partial \gamma}{\partial \lambda} = 0 \Rightarrow \int_{R_1} p(\mathbf{x} | \omega_2) d\mathbf{x} = \varepsilon_0,$$

$$\frac{\partial \gamma}{\partial \mathbf{t}} = 0 \Rightarrow \lambda^* = \frac{p(\mathbf{t}^* | \omega_1)}{p(\mathbf{t}^* | \omega_2)}.$$

15

Neyman-Pearson 决策

□ **决策准则**

if $\lambda p(\mathbf{x} | \omega_2) < p(\mathbf{x} | \omega_1)$, then $\mathbf{x} \in \begin{cases} \omega_1 \\ \omega_2 \end{cases}$

or

$$l(\mathbf{x}) = \frac{p(\mathbf{x} | \omega_1)}{p(\mathbf{x} | \omega_2)} > \lambda, \text{ then } \mathbf{x} \in \begin{cases} \omega_1 \\ \omega_2 \end{cases}$$

→ N-P决策规则归结为寻找阈值 λ , 使得

$$\int_{R_1} p(\mathbf{x} | \omega_2) d\mathbf{x} = \varepsilon_0.$$

16

Neyman-Pearson 决策

□ **例:** 一个两类问题中, 模式均为二维正态分布, 其均值矢量和协方差阵分别为:

$$\mu_1 = (-1, 0)^T, \mu_2 = (1, 0)^T, \Sigma_1 = \Sigma_2 = I.$$

设 $\varepsilon_0 = 0.09$, 求Neyman-Pearson的决策阈值。

- 解:

$$p(\mathbf{x} | \omega_1) = \frac{1}{2\pi} \exp\left[-\frac{1}{2}(\mathbf{x} - \mu_1)^T(\mathbf{x} - \mu_1)\right] = \frac{1}{2\pi} \exp\left[-\frac{1}{2}((x_1 + 1)^2 + x_2^2)\right];$$

$$p(\mathbf{x} | \omega_2) = \frac{1}{2\pi} \exp\left[-\frac{1}{2}(\mathbf{x} - \mu_2)^T(\mathbf{x} - \mu_2)\right] = \frac{1}{2\pi} \exp\left[-\frac{1}{2}((x_1 - 1)^2 + x_2^2)\right];$$

$$\therefore \frac{p(\mathbf{x} | \omega_1)}{p(\mathbf{x} | \omega_2)} = \exp(-2x_1).$$

17

Neyman-Pearson 决策

□ **解:** 判决准则

if $\exp(-2x_1) > \lambda$, i.e. $x_1 < -\frac{1}{2} \ln \lambda$, then $\mathbf{x} \in \begin{cases} \omega_1 \\ \omega_2 \end{cases};$

∴ 对于不同的 λ , 决策边界是平行于 x_2 的不同直线。(如图)

18

Neyman-Pearson 决策

□ **解:** 通过计算 $P_2(error)=\varepsilon_0$ 求解 λ :

$$P_2(error) = \int_{R_1} p(\mathbf{x} | \omega_2) d\mathbf{x}$$

$$= \int_{-\infty}^{-\frac{1}{2} \ln \lambda} \int_{-\infty}^{\infty} \frac{1}{2\pi} \exp\left[-\frac{(x_1 - 1)^2 + x_2^2}{2}\right] dx_2 dx_1$$

$$= \int_{-\infty}^{-\frac{1}{2} \ln \lambda} \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{(x_1 - 1)^2}{2}\right] dx_1.$$

λ	4	2	1	1/2	1/4
ε_0	0.046	0.089	0.0159	0.258	0.378

λ 与 ε_0 的关系表

其他决策方法（自学）

最大最小决策

- 基本思想：类先验概率未知，考查先验概率变化对错误率的影响，找出使最小风险贝叶斯决策的风险最大的先验概率，以这种最坏情况设计分类器。

序贯分类方法

- 基本思想：除考虑分类造成的损失外，还考虑特征获取所造成的代价。先用一部分特征分类，然后逐步加入新特征以减少分类损失，同时衡量总的损失，以求得最优的效益。

分类器设计

分类器设计

判别函数：是模式（或特征向量） \mathbf{x} 的函数，用于表述决策规则

- 对于 c 类别问题，相应于每一类别定义一个函数，构成一组判别函数 $g_i(\mathbf{x}), i = 1, 2, \dots, c$ ，使得

$$g_j(\mathbf{x}) > g_i(\mathbf{x}) \Rightarrow \mathbf{x} \in \omega_j, j = 1, \dots, c, j \neq i;$$

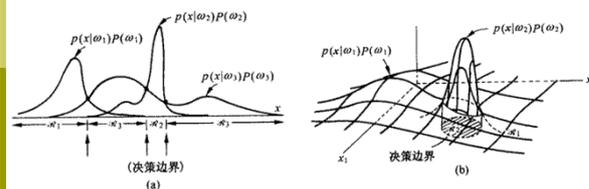
- 最小错误率Bayes决策的判别函数

- $g_i(\mathbf{x}) = P(\omega_i | \mathbf{x})$
- $g_i(\mathbf{x}) = p(\mathbf{x} | \omega_i)P(\omega_i)$
- $g_i(\mathbf{x}) = \ln p(\mathbf{x} | \omega_i) + \ln P(\omega_i)$

分类器设计

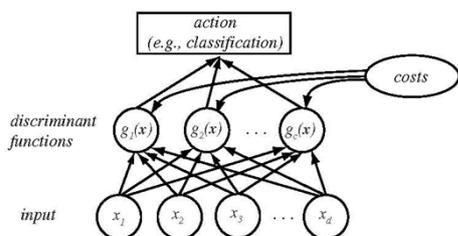
决策面方程：相邻的两个决策域在决策面上的判别函数值相等，即

$$g_i(\mathbf{x}) = g_j(\mathbf{x}).$$



分类器设计

分类器：计算 c 个判别函数并选取与最大判别函数值相对应的类别的网络或机器。



分类器设计

两类别的最小错误率Bayes决策

- 判决函数：

$$g(\mathbf{x}) = g_1(\mathbf{x}) - g_2(\mathbf{x}),$$

- 相应的决策规则

$$\text{if } g(\mathbf{x}) > 0, \text{ then decide } \mathbf{x} \in \begin{cases} \omega_1 \\ \omega_2 \end{cases}.$$

- $g(\mathbf{x}) = P(\omega_1 | \mathbf{x}) - P(\omega_2 | \mathbf{x})$
- $g(\mathbf{x}) = p(\mathbf{x} | \omega_1)P(\omega_1) - p(\mathbf{x} | \omega_2)P(\omega_2)$
- $g(\mathbf{x}) = \ln \frac{p(\mathbf{x} | \omega_1)}{p(\mathbf{x} | \omega_2)} + \ln \frac{P(\omega_1)}{P(\omega_2)}$

分类器设计

25

- 两类别的最小错误率Bayes决策
 - 决策面方程

$$g(\mathbf{x}) = 0.$$
- 分类器

正态分布的最小错误率贝叶斯决策

单变量的正态分布

27

A bell-shaped distribution defined by the probability density function

$$p(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

If the random variable X follows a normal distribution, then

- The probability that X will fall into the interval (a, b) is given by $\int_a^b p(x)dx$
- Expected, or mean, value of X is $E[X] = \int_{-\infty}^{\infty} xp(x)dx = \mu$
- Variance of X is $Var(x) = E[(x-\mu)^2] = \int_{-\infty}^{\infty} (x-\mu)^2 p(x)dx = \sigma^2$
- Standard deviation of X, σ^2 , is $\sigma_x = \sigma$

单变量的正态分布

28

- $p(x)$ 完全由 μ 与 σ^2 确定，常记作 $N(\mu, \sigma^2)$ 。
- 正态分布的熵(entropy)在所有的已知均值及方差的分布中最大。
- $p(x)$ 关于均值对称，最大值位于 $x=\mu$ 处，

$$p(\mu) = \frac{1}{\sqrt{2\pi}\sigma}.$$

多元正态分布

29

- 概率密度函数

$$p(\mathbf{x}) = \frac{1}{(2\pi)^{d/2} |\Sigma|^{1/2}} \exp\left(-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu})^T \Sigma^{-1}(\mathbf{x}-\boldsymbol{\mu})\right),$$

其中:

- $\mathbf{x} = [x_1, x_2, \dots, x_d]^T$ 是 d 维列向量 (T 表示向量的转置);
- $\boldsymbol{\mu} = [\mu_1, \mu_2, \dots, \mu_d]^T$ 是 d 维均值向量;
- Σ 是 $d \times d$ 协方差矩阵;
- Σ^{-1} 是 Σ 的逆矩阵, $|\Sigma|$ 是 Σ 的行列式。

多元正态分布

30

- 均值 $\boldsymbol{\mu}$ 和协方差矩阵 Σ

$$\boldsymbol{\mu} = E[\mathbf{x}] = \int \mathbf{x}p(\mathbf{x})d\mathbf{x};$$

$$\Sigma = E[(\mathbf{x}-\boldsymbol{\mu})(\mathbf{x}-\boldsymbol{\mu})^T] = \int (\mathbf{x}-\boldsymbol{\mu})(\mathbf{x}-\boldsymbol{\mu})^T p(\mathbf{x})d\mathbf{x};$$
- $\mu_i = E[x_i] = \int x_i p(x_i) dx_i$
- $\sigma_{ij}^2 = E[(x_i - \mu_i)(x_j - \mu_j)^T] = \iint (x_i - \mu_i)(x_j - \mu_j)^T p(x_i, x_j) dx_i dx_j.$
- $$\Sigma = \begin{bmatrix} E[(x_1 - \mu_1)^2] & E[(x_1 - \mu_1)(x_2 - \mu_2)] \\ E[(x_2 - \mu_2)(x_1 - \mu_1)] & E[(x_2 - \mu_2)^2] \end{bmatrix} = \begin{bmatrix} \sigma_1^2 & \sigma_{12}^2 \\ \sigma_{21}^2 & \sigma_2^2 \end{bmatrix}.$$