

# 第二章 统计决策方法

苏智勇

可视计算研究组

南京理工大学

[suzhiyong@njust.edu.cn](mailto:suzhiyong@njust.edu.cn)

<https://zhiyongsu.github.io>

# 概率统计复习

## 一、概率

– 频率:  $f_n(A) = \frac{n_A}{n} = \frac{A\text{发生次数}}{\text{总次数}}$ , 表示事件 $A$ 发生的频数/频率

– 概率: 表示事件 $A$ 出现的可能性大小,  $P(\cdot)$ 满足如下条件

‣ 非负性:  $P(A) \geq 0$

‣ 规范性/正则性:  $P(\Omega) = 1$

‣ 可列可加性: 若 $A_1, A_2, \dots, A_n$ 互不相容, 则 $P\left(\bigcup_{i=1}^{\infty} A_i\right) = \sum_{i=1}^{\infty} P(A_i)$

# 概率统计复习

## 一、概率

### – 概率的性质

$$\triangleright P(\bar{A}) = 1 - P(A)$$

$$\triangleright P(A \cup B) = P(A) + P(B) - P(AB)$$

$$\triangleright P\left(\bigcup_{i=1}^n A_i\right) = \sum_{i=1}^n P(A_i) - \sum_{1 \leq i < j \leq n} P(A_i A_j) + \sum_{1 \leq i < j < k \leq n} P(A_i A_j A_k) + \cdots + (-1)^{n-1} P(A_1 A_2 \cdots A_n)$$

# 概率统计复习

## 二、条件概率


对于事件 $A$ 和 $B$ ，若 $P(A) > 0$ 时，则称 $P(B | A) = \frac{P(AB)}{P(A)}$ 为在 $A$ 出现的条件下， $B$ 出现的条件概率。

### - 乘法公式

$$\checkmark P(AB) = P(A) \cdot P(B | A) = P(B) \cdot P(A | B)$$

$$\checkmark P(ABC) = P(A)P(B | A)P(C | AB)$$

$$\checkmark P(A_1A_2 \cdots A_n) = P(A_1)P(A_2 | A_1)P(A_3 | A_1A_2) \cdots P(A_n | A_1 \cdots A_{n-1})$$



# 概率统计复习

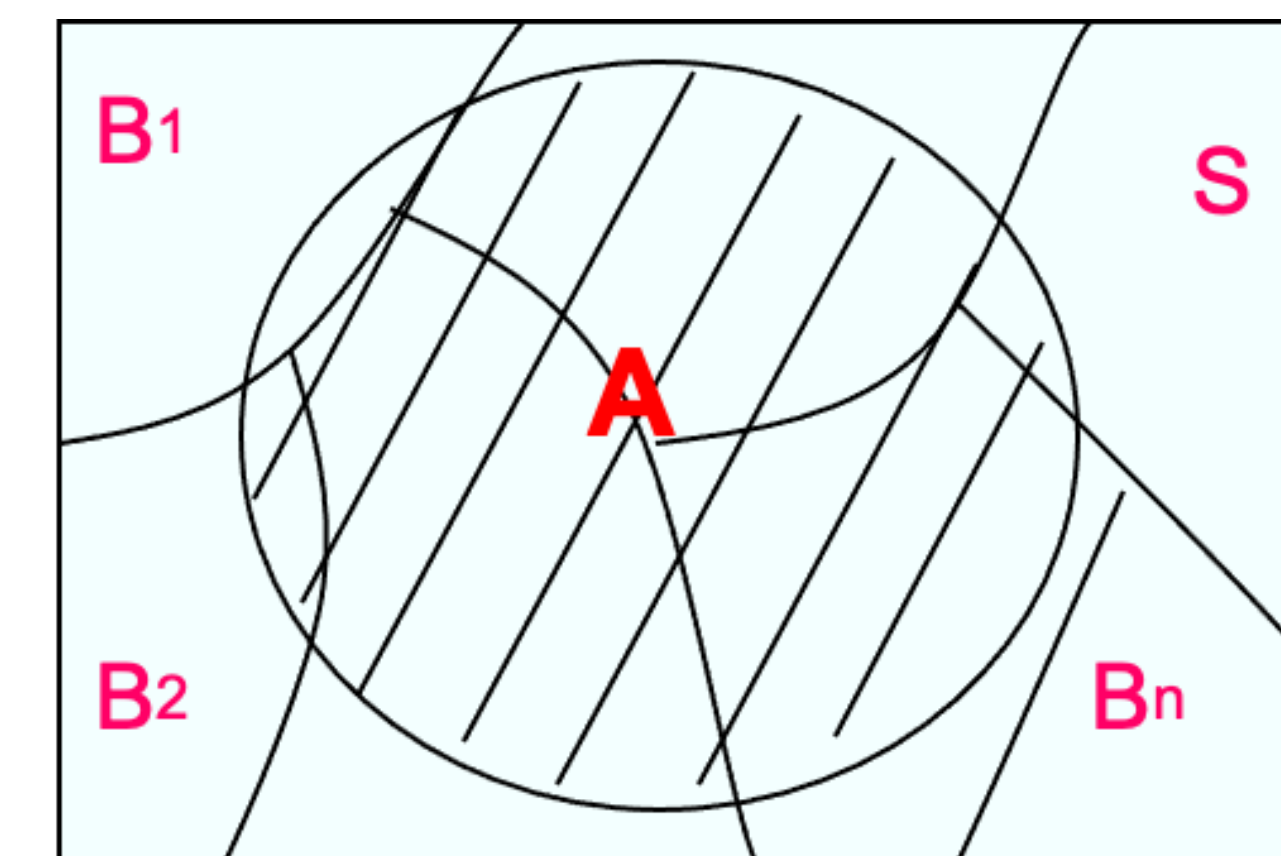

## 二、条件概率

### - 全概率公式


设事件 $B_1, B_2, \dots, B_n$ 为样本空间 $S$ 的一个划分, 且 $P(B_i) > 0$ , 则:

$$P(A) = \sum_{j=1}^n P(AB_j) = \sum_{j=1}^n P(B_j) \cdot P(A|B_j)$$

- 属于**先验概率**:  $A$ 为“结果”,  $B_j$ 为导致 $A$ 发生的诸多“原因”之一, 全概率公式可视为“由因求果”问题中的“因”出现的概率。
- 直观理解**: 这件事还没有发生, 根据以往的经验 and 数据推断出这件事会发生的概率 (例如抛硬币)。



# 概率统计复习



## 二、条件概率

### - 贝叶斯公式

设事件 $B_1, B_2, \dots, B_n$ 为样本空间 $S$ 的一个划分, 且 $P(A) > 0, P(B_i) > 0$ , 则:

$$P(B_i | A) = \frac{P(AB_i)}{P(A)} = \frac{P(B_i)P(A | B_i)}{P(A)} = \frac{P(B_i)P(A | B_i)}{\sum_{j=1}^n P(B_j)P(A | B_j)}$$

- ▶ 属于**后验概率**: 在得到“结果” $A$ 的信息后重新修正的概率, 是“执果寻因”问题中的“果”。
- ▶ **类概率密度** $P(A | B_i)$ : 在类 $B_i$ 条件下的概率密度, 即类 $B_i$ 模式 $A$ 的概率密度分布。
- ▶ **直观理解**: 事件 $A$ 已经发生, 但是导致 $A$ 发生的原因可能有多种 ( $B_j$ ), 计算 $A$ 发生的原因是由某个因素引起的概率。



# 概率统计复习

## 二、条件概率

### – 先验概率 $P(B_i)$

- ▶ 以**全事件**（一般是统计获得）为背景下，事件 $B_i$ 发生的概率， $P(B_i) = P(B_i | \Omega)$
- ▶ 根据以往经验和分析得到的概率，称为先验概率（没有实验前的概率），如**全概率公式**

### – 后验概率 $P(B_i | A)$

- ▶ 以**新事件** $A$ 为背景下，事件 $B_i$ 发生的概率， $P(B_i | A)$
- ▶ 新事件一般是实验，如实验 $A$ ，此时的事件背景从全事件变成了 $A$ ，该事件 $A$ 可能对 $B_i$ 的概率有影响，从 $P(B_i | \Omega)$ 变为 $P(B_i | A)$ ，称为后验概率，即试验(事件 $A$ 发生)后的概率

# 概率统计复习

## 三、随机变量

– 定义：若随机变量 $X$ 的取值为有限个或可数个，则称 $X$ 为**离散型随机变量**

– 性质：

$$\triangleright P(X = x_k) = p_k, \quad k = 1, 2, \dots$$

$$\triangleright p_k \geq 0, \quad \sum_{k=1}^{+\infty} p_k = 1$$


$X$	$x_1$	$x_2$	...	$x_k$	...
$P$	$p_1$	$p_2$	...	$p_k$	...



# 概率统计复习

## 四、概率分布函数

- 定义：随机变随机变量 $X$ , 对任意实数 $x$ , 称函数 $F(x) = P(X \leq x)$ 为 $X$ 的概率分布函数, 简称分布函数。
- 几何意义:



# 概率统计复习

## 五、概率密度函数

- 定义：对于随机变量 $X$ 的分布函数 $F(x)$ ，若存在非负的函数 $f(x)$ ，使对于任意实数 $x$ 有： $F(x) = \int_{-\infty}^x f(t)dt$ ，则称 $X$ 为连续型随机变量，其中 $f(x)$ 称为 $X$ 的概率密度函数，简称概率密度。

# 概率统计复习

## 五、概率密度函数

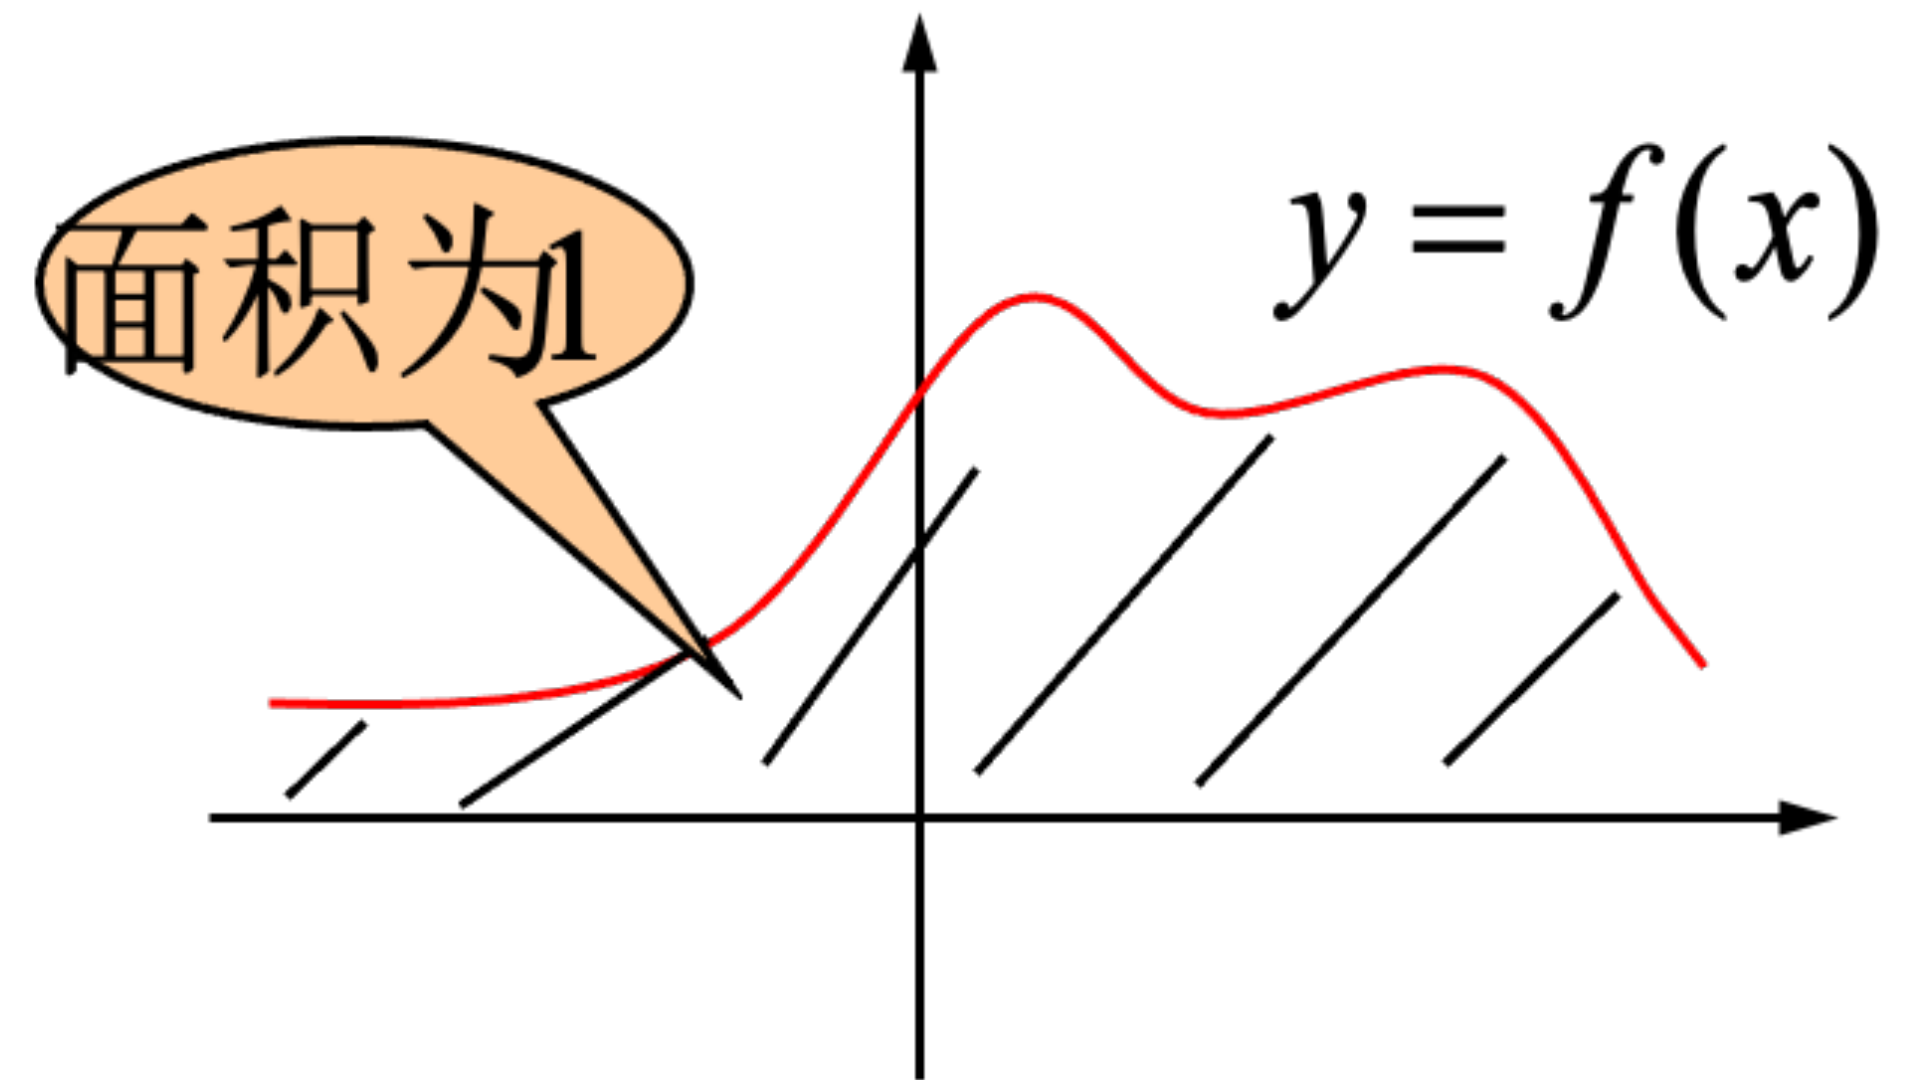
### - 性质

▸  $f(x) \geq 0$

▸  $\int_{-\infty}^{+\infty} f(x)dx = 1$

▸  $P(X \in D) = \int_D f(x)dx$ , 任意  $D \subset R$

▸ 在  $f(x)$  连续点  $x$ ,  $F'(x) = f(x)$



# 概率统计复习


## 六、二元随机变量

- 定义：设 $E$ 是一个随机试验，样本空间

$S = \{e\}$ ；设 $X = X(e)$ 和 $Y = Y(e)$ 是定义

在 $S$ 上的随机变量，由它们构成的向量

$(X, Y)$ 称为二维随机向量或二元随机变量。




# 概率统计复习

## 七、联合分布函数

- 定义：设 $(X, Y)$ 是二元随机变量，对于任意实数 $x, y$ ，二元函数

$$F(x, y) = P(X \leq x, Y \leq y)$$

称为二元随机变量 $(X, Y)$ 的联合分布函数





# 概率统计复习

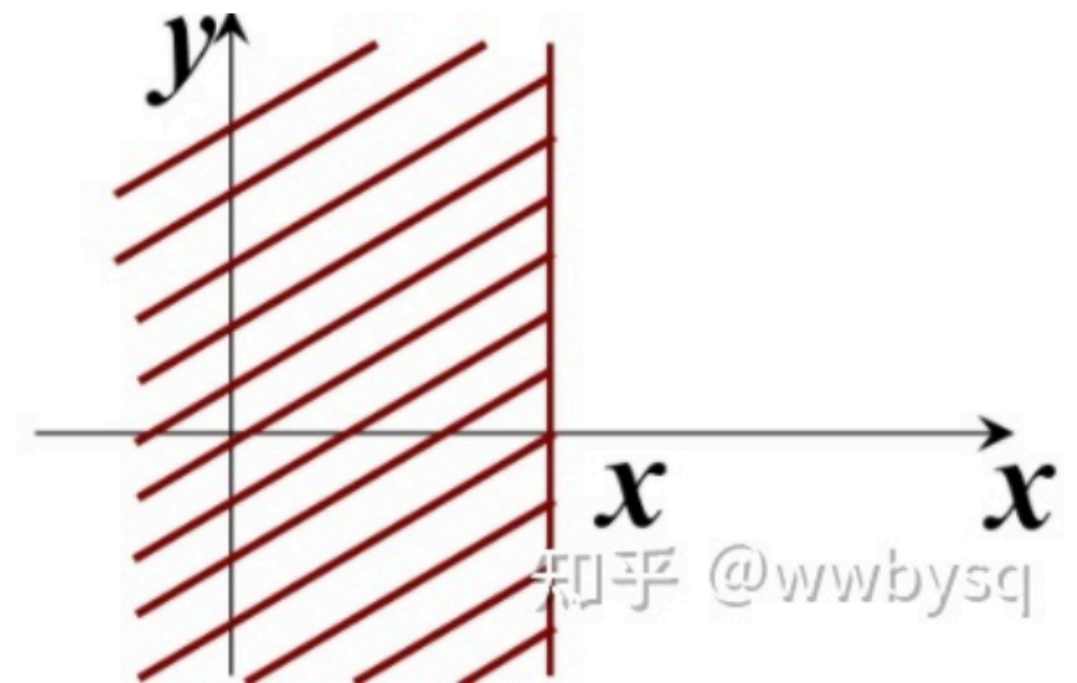
## 八、边际/边缘分布函数

- 定义:  $X$ 和 $Y$ 也有它们自己的分布函数, 分别记为  $F_X(x)$ ,  $F_Y(y)$ 并称他们为边际/边缘分布函数


$$F_X(x) = P(X \leq x) = F(x, +\infty)$$

$$F_Y(y) = P(Y \leq y) = F(+\infty, y)$$

$$\begin{aligned} F_X(x) &= P(X \leq x) \\ &= P(X \leq x, Y < +\infty) \\ &= F(x, +\infty) \end{aligned}$$



$$\begin{aligned} F_Y(y) &= P(Y \leq y) \\ &= P(X < +\infty, Y \leq y) \\ &= F(+\infty, y) \end{aligned}$$





# 概率统计复习

## 九、条件分布函数

- 定义：若 $P(Y = y) > 0$ ，则在 $Y = y$ 条件下， $X$ 的条件分布函数为

$$F_{X|Y}(x | y) = P(X \leq x | Y = y) = \frac{P(X \leq x, Y = y)}{P(Y = y)}$$

# 概率统计复习

## 十、联合概率密度函数

– 定义：对于二元随机变量 $(X, Y)$ 的分布函数 $F(x, y)$ ，如果存在非负函数 $f(x, y)$ ，使对于任意 $x, y$ ，有

$$F(x, y) = \int_{-\infty}^x \int_{-\infty}^y f(u, v) du dv$$

则称 $(X, Y)$ 为二元连续型随机变量，并称 $f(x, y)$ 为二元随机变量 $(X, Y)$ 的联合概率密度函数。

# 概率统计复习

## 十一、数字特征

期望 (数学期望, 均值)

$$E(X) = \begin{cases} \sum_i x_i p_i, & \text{若 } X \text{ 是离散型} \\ \int_{-\infty}^{\infty} x f(x) dx, & \text{若 } X \text{ 是连续型} \end{cases}$$

$$E(g(X, Y)) = \begin{cases} \sum_i g(x_i, y_j) p_{ij}, & \text{若 } (X, Y) \text{ 是离散型} \\ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y) f(x, y) dx dy, & \text{若 } (X, Y) \text{ 是连续型} \end{cases}$$

特别地, 若  $(X, Y)$  是连续型, 则

$$E(g(X)) = \begin{cases} \sum_i g(x_i) p_i, & \text{若 } X \text{ 是离散型} \\ \int_{-\infty}^{\infty} g(x) f(x) dx, & \text{若 } X \text{ 是连续型} \end{cases}$$

$$E(X) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x f(x, y) dx dy$$

$$E(Y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} y f(x, y) dx dy$$

# 概率统计复习

## 十一、数字特征

方差：
$$D(X) = Var(X) = E\{[X - E(X)]^2\} = E(X^2) - [E(X)]^2$$
$$\Rightarrow E(X^2) = Var(X) + [E(X)]^2$$

标准差：
$$\sigma(X) = \sqrt{Var(X)}$$

协方差：
$$Cov(X, Y) = E\{[X - E(X)][Y - E(Y)]\} = E(XY) - E(X)E(Y)$$
$$\Rightarrow E(XY) = Cov(X, Y) + E(X)E(Y)$$

# 主要内容

2.1 引言

2.2 最小错误率贝叶斯决策

2.3 最小风险贝叶斯决策

2.4 Neyman-Pearson决策

2.5 正态分布时的统计决策

2.6 错误率

# 2.1 引言

- 贝叶斯定理有什么用

根据有限的历史数据**预测**未来事情发生的**概率**，帮助我们更好地决策。



正向概率



逆概率



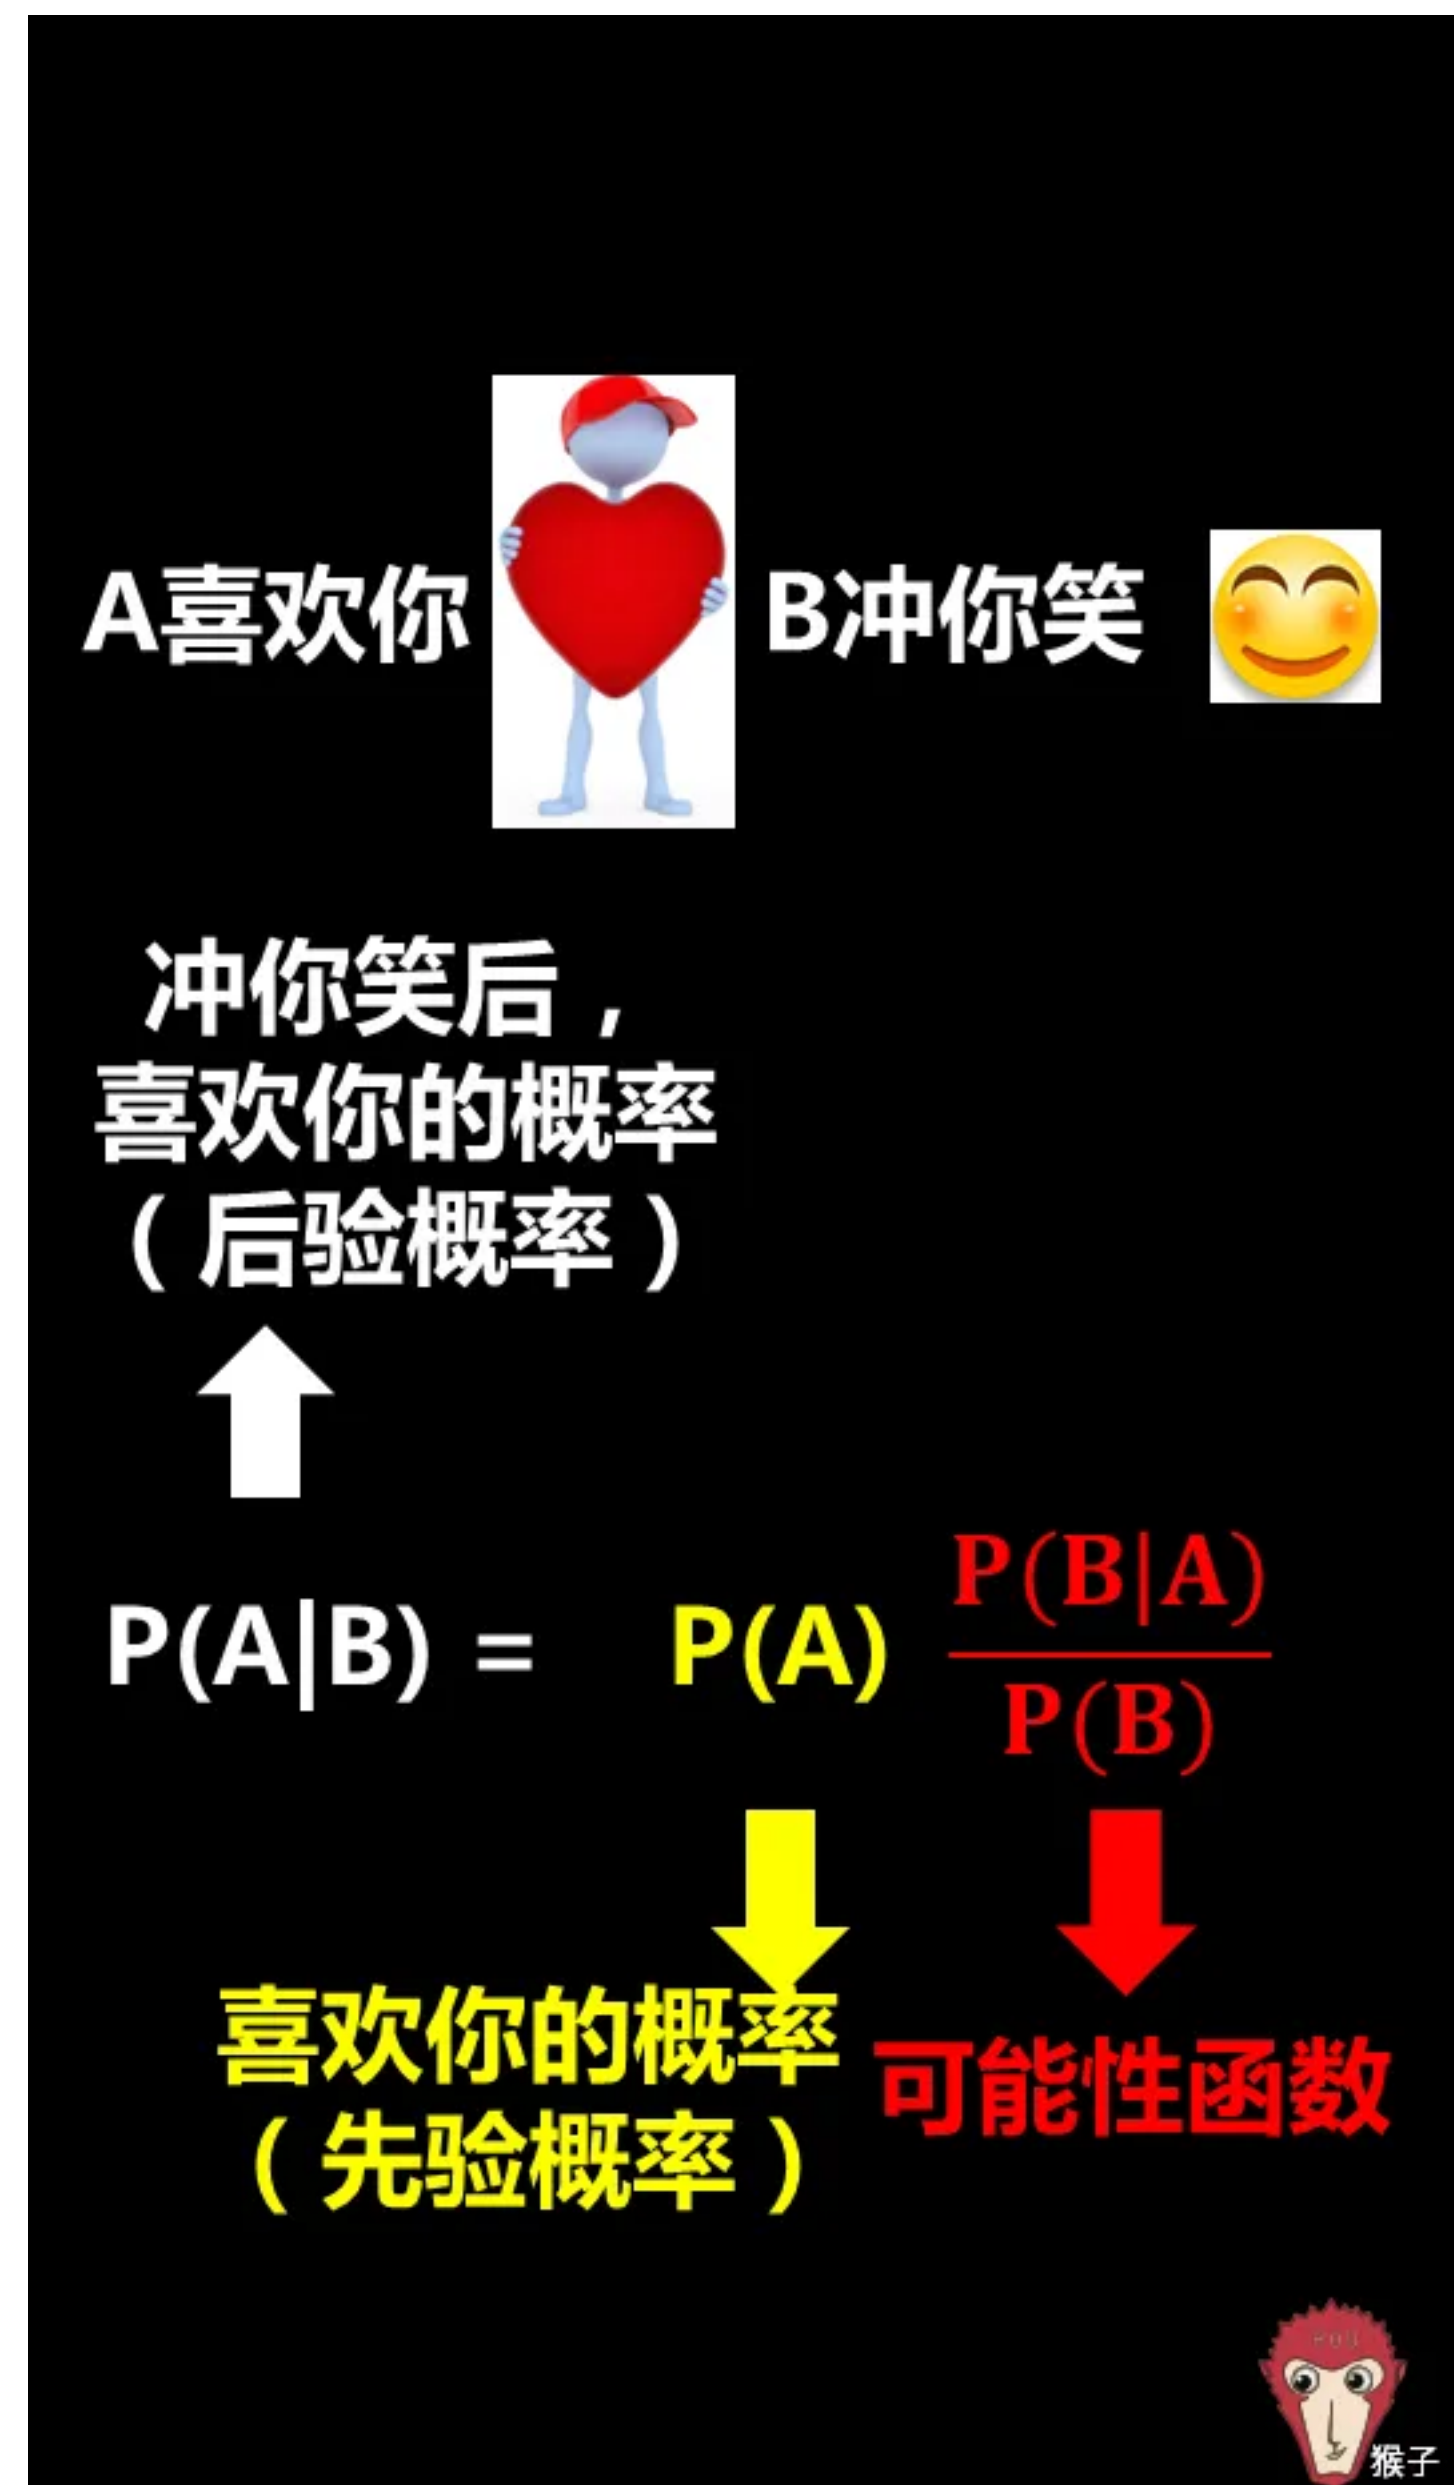
# 2.1 引言

- 贝叶斯定理怎么用

- 思路：在主观判断的基础上，先估计一个值（先验概率），然后根据观察的新信息不断修正(可能性函数)。

例：我的朋友小鹿说，他的女神每次看到他的时候都冲他笑，他现在想知道女神是不是喜欢他呢？

- 问题：女神是否喜欢你，记为A事件
- 已知：女神经常冲你笑，记为B事件
- 求解：P(A|B)，表示女神经常冲你笑这个事件(B)发生后，女神喜欢你（A）的概率




# 2.1 引言

- 先验概率  $P(A)$

- 在不知道B事件的前提下，我们对A事件概率的一个主观判断。
- 假设 $P(A)=50\%$ ，也就是不喜欢你，可能不喜欢你的概率都是一半

- 可能性函数  $P(B|A)/P(B)$

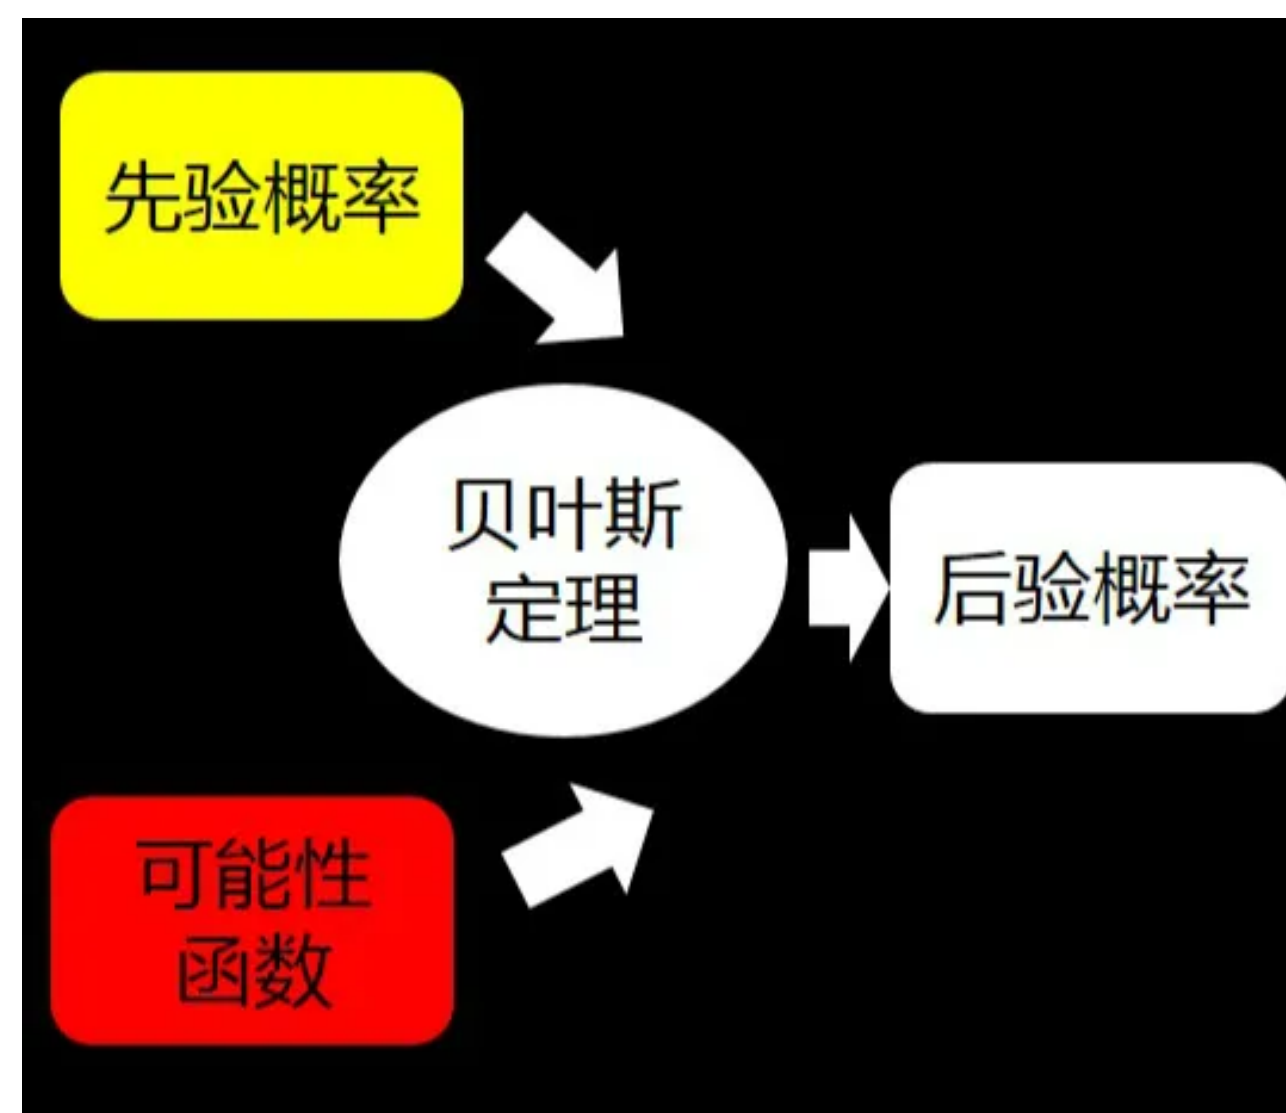
- 调整因子，新信息B带来的调整，作用是将先验概率（之前的主观判断）调整到更接近真实概率
- $P(B|A)/P(B)=1.5$ ：走访调研女神的闺蜜，发现女神平日比较高冷，很少对人笑，也就是对你有好感的可能性比较大（可能性函数 $>1$ ）





# 2.1 引言

- 后验概率  $P(A|B)$

- 在B事件发生之后，我们对A事件概率的重新评估。  
这个例子里就是在女神冲你笑后，对女神喜欢你的概率重新预测
- $P(A|B) = P(A) * P(B|A) / P(B) = 50\% * 1.5 = 75\%$



A喜欢你  B冲你笑 


冲你笑后，  
喜欢你的概率  
(后验概率)  
75%

↑

$P(A|B) = P(A) \frac{P(B|A)}{P(B)}$

喜欢你的概率  
(先验概率)  
50%

可能性函数  
1.5





# 2.1 引言

给一个硬币  $x$ ，没有任何信息，猜是5角还是1角。

- 设：  $P(\omega_1)$ 为1角的概率，  $P(\omega_2)$ 为5角的概率；  $P(\omega_i)$ 为先验概率 (priori probability)， 没有对样本进行任何观测情况下的概率。

- **错误率**： 在所有可能出现的样本上类别决策错误的概率

$$P(\text{error}) = 1 - P(\omega_1) = P(\omega_2) \quad (\text{如果决策 } x \in \omega_1)$$

- **决策规则**（最小错误率准则）：

$$x \begin{cases} \in \omega_1 & P(\omega_1) \geq P(\omega_2) \\ \in \omega_2 & P(\omega_1) < P(\omega_2) \end{cases}$$

# 2.1 引言

给一个硬币，已知重量  $x$ ，猜是5角还是1角。

- 设：  $P(\omega_i | x)$  为已知硬币重量为  $x$  的情况下硬币属于各类的概率，即后验概率 (posterior probability)。
- 根据贝叶斯公式求解  $P(\omega_i | x)$ ：

$$P(\omega_i | x) = \frac{P(\omega_i, x)}{P(x)} = \frac{P(x | \omega_i)P(\omega_i)}{P(x)}$$

- 决策规则：

$$x \begin{cases} \in \omega_1 & P(\omega_1 | x) \geq P(\omega_2 | x) \\ \in \omega_2 & P(\omega_1 | x) < P(\omega_2 | x) \end{cases}$$

- 错误率：

$$P(\text{error} | x) = 1 - P(\omega_1 | x) = P(\omega_2 | x) \quad (\text{如果决策 } x \in \omega_1)$$

# 2.2 最小错误率贝叶斯决策

- 定义

最小错误率贝叶斯决策从最小错误率出发，利用概率论中的贝叶斯公式，得出使**错误率最小**的分类决策。

$$\min P(\text{error}) = \min \int P(\text{error} | x)P(x)dx \Rightarrow \min P(\text{error} | x) \quad \forall x$$



# 2.2 最小错误率贝叶斯决策

- 二分类最小错误率贝叶斯决策

$$P(\omega_i | x) = \frac{P(\omega_i, x)}{P(x)} = \frac{P(x | \omega_i)P(\omega_i)}{P(x)}$$

以二分类为例，对应的**最小错误率贝叶斯决策**如下：

如果 $P(\omega_1 | x) > P(\omega_2 | x)$ ，则 $x \in \omega_1$ ；反之， $x \in \omega_2$

简记作：

如果 $P(\omega_1 | x) \leq P(\omega_2 | x)$ ，则  $x \begin{cases} \in \omega_1 \\ \in \omega_2 \end{cases}$

等价于：

若似然比  $l(x) = \frac{p(x | \omega_1)}{p(x | \omega_2)} \leq \lambda = \frac{p(\omega_2)}{p(\omega_1)}$ ，则  $x \begin{cases} \in \omega_1 \\ \in \omega_2 \end{cases}$

## 2.2 最小错误率贝叶斯决策

癌细胞识别问题： $\omega_1$ 正常细胞， $\omega_2$ 癌细胞。某地区，经大量统计获先验概率  $P(\omega_1)$ ,  $P(\omega_2)$ 。若给定该地区某人细胞  $x$ ，判断该细胞种类。假定特征  $x$  表示细胞核总的光密度，维数为1。

### - 利用先验概率判断


如果  $P(\omega_1) > P(\omega_2)$ ,  $x \in \omega_1$ ; 反之,  $x \in \omega_2$ 。

- ▶ 无意义分类器决策：先验概率  $P(\omega_i)$  只能提供整体上两类细胞出现比例的估计，不能用于对个体的判断。

# 2.2 最小错误率贝叶斯决策

- 先计算后验概率 $P(\omega_1 | x)$ ,  $P(\omega_2 | x)$ , 然后再判断类别
  - ▶ 已知: 先验概率 $P(\omega_1)$ ,  $P(\omega_2)$
  - ▶ 计算类条件概率密度 $P(x | \omega_i)$ : 细胞 $\omega_i$ 光密度值的概率密度, 可以根据之前收集的细胞图像数据计算获得

$$P(\omega_i | x) = \frac{P(\omega_i, x)}{P(x)} = \frac{P(x | \omega_i)P(\omega_i)}{P(x)}$$



# 2.2 最小错误率贝叶斯决策



- 先计算后验概率 $P(\omega_1 | x)$ ,  $P(\omega_2 | x)$ , 然后再判断类别

▶ 计算后验概率 $P(\omega_1 | x)$ ,  $P(\omega_2 | x)$

$$P(\omega_i | x) = \frac{P(x|\omega_i)}{P(x)} = \frac{P(x|\omega_i)P(\omega_i)}{\sum_{j=1}^2 P(x|\omega_j)P(\omega_j)}$$

▶ 决策规则：选择后验概率大的一类

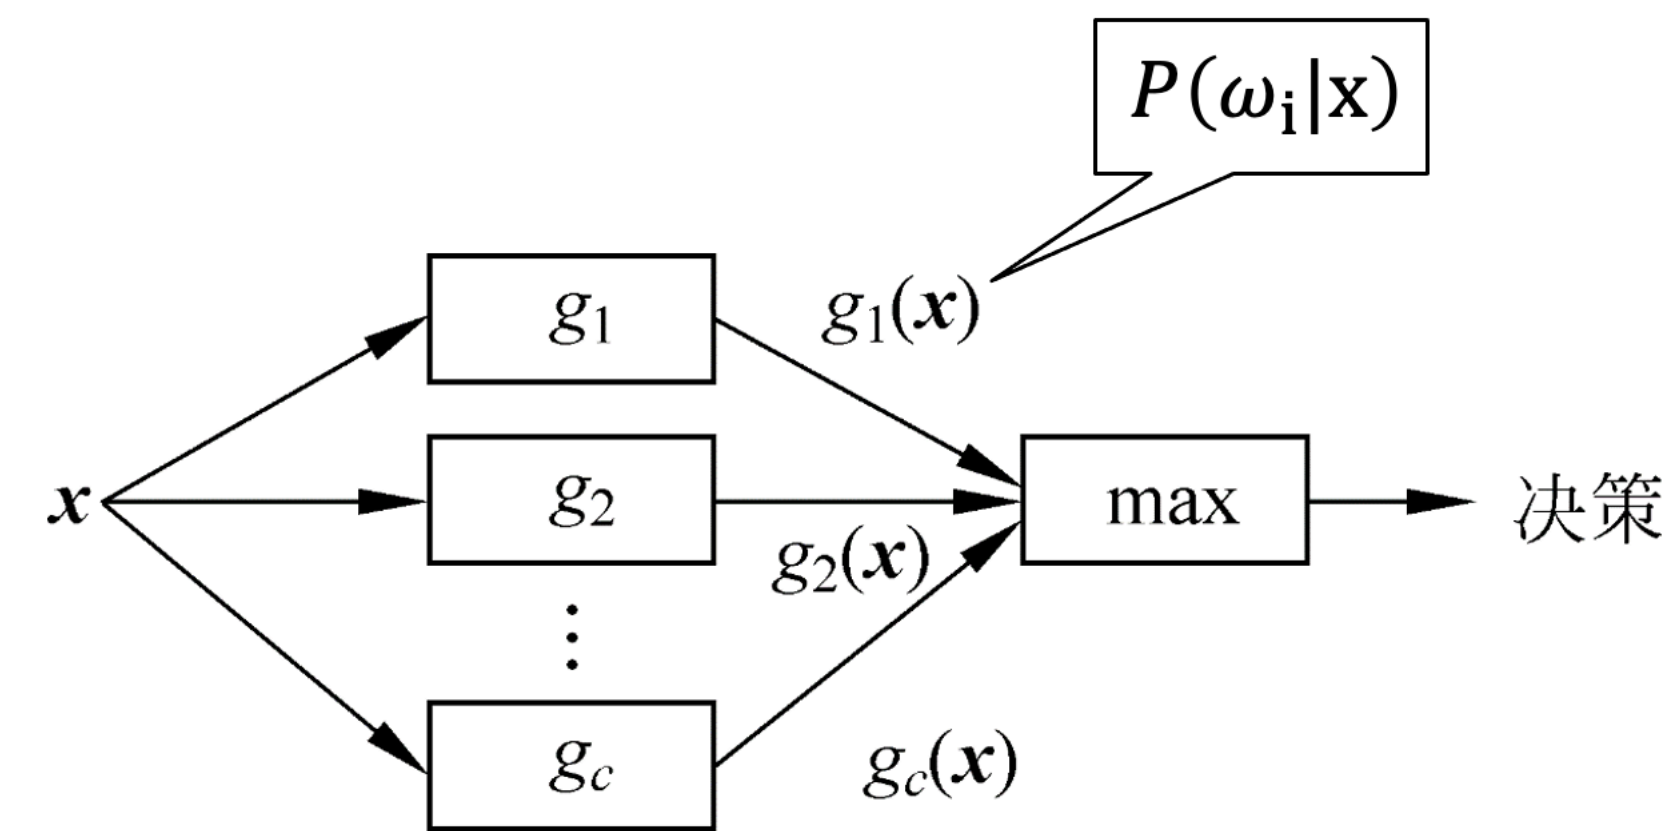
$$\begin{cases} P(\omega_1 | x) > P(\omega_2 | x), & x \in \omega_1 \\ P(\omega_1 | x) < P(\omega_2 | x), & x \in \omega_2 \end{cases}$$



# 2.2 最小错误率贝叶斯决策

- 多分类最小错误率贝叶斯决策

设类别数为  $c$ ，则对应的**最小错误率贝叶斯决策**如下：



$$P(\omega_i | x) = \max_{j=1, \dots, c} P(\omega_j | x) \Rightarrow x \in \omega_i$$

由于其贝叶斯公式分母相同，只需要比较分子，因此，可以等价于：

$$P(x | \omega_i)P(\omega_i) = \max_{j=1, \dots, c} P(x | \omega_j)P(\omega_j) \Rightarrow x \in \omega_i$$



# 2.3 最小风险贝叶斯决策

- 决策原则

考虑各种错误决策造成**损失**不同时的一种最优决策。

- 风险 / 期望损失

$$R(\alpha_i | x) = \sum_{j=1}^c \lambda(\alpha_i, \omega_j) P(\omega_j | x), \quad i = 1, \dots, k$$

- $\lambda(\alpha_i, \omega_j)$ : 损失函数, 对状态为 $\omega_j$ 的向量  $x$  采取策略  $\alpha_i$  所带来的损失; 由具体应用确定
- $x$ : 样本,  $d$  维特征向量
- $\omega_j$ : 状态, 共有  $c$  个可能的状态, 构成状态空间
- $\alpha_i$ : 决策, 共有  $k$  个决策, 组成决策空间



# 2.3 最小风险贝叶斯决策

- 最小风险

$$R(\alpha_i | x) = \begin{cases} \lambda(\alpha_1, \omega_2) \cdot P(\omega_2 | x) & (\text{如果决策 } x \in \omega_1) \\ \lambda(\alpha_2, \omega_1) \cdot P(\omega_1 | x) & (\text{如果决策 } x \in \omega_2) \end{cases} \quad \min R(\alpha) = \min \int R(\alpha(x) | x) P(x) dx$$

- 最小风险贝叶斯决策

- 考虑各种错误造成**损失**不同时的一种最优决策:

$$\alpha = \operatorname{argmin}_{i=1, \dots, k} R(\alpha_i | x)$$

- 决策表不同会导致不同的决策结果，因此，需要人为合理地确定决策表

# 2.4 Neyman-Pearson决策

- 两类错误率及评价指标

- 两类：阳性 (positive)、阴性 (negative)

决策 \ 状态	阳性	阴性
阳性	真阳性 (TP)	假阳性 (FP)
阴性	假阴性 (FN)	真阴性 (TN)

- 第一类错误率 (Type-I error rate): 假阳性/误报/虚警率  $\alpha = FP/(FP+TN)$

- 假阳性样本占总阴性样本的比例

- 第二类错误率 (Type-II error rate): 假阴性/漏报率  $\beta = FN/(FN+TP)$

- 假阴性样本占总阳性样本的比例

# 2.4 Neyman-Pearson决策

决策 \ 状态	阳性	阴性
阳性	真阳性 (TP)	假阳性 (FP)
阴性	假阴性 (FN)	真阴性 (TN)

- 两类错误率及评价指标

- 灵敏度 (sensitivity):  $S_n = TP / (TP + FN) = 1 - \beta$

- ▶ 在真正的阳性样本中有多少比例能被正确检测出来, 或没有被误判

- 特异度 (specificity):  $S_p = TN / (TN + FP) = 1 - \alpha$

- ▶ 在真正的阴性样本中有多少比例能被正确检测出来, 或没有被误判

# 2.4 Neyman-Pearson决策

- 其他常用评价指标

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

- 召回率 (recall): 
$$\text{Rec} = \frac{TP}{TP + FN}$$

- 精确率 (precision): 
$$\text{Pre} = \frac{TP}{TP + FP}$$

- F度量 (F-measure): 
$$F = \frac{2\text{Rec} \cdot \text{Pre}}{\text{Rec} + \text{Pre}}$$

决策 \ 状态	阳性	阴性
阳性	真阳性 (TP)	假阳性 (FP)
阴性	假阴性 (FN)	真阴性 (TN)

# 2.4 Neyman-Pearson决策


- **Neyman-Pearson决策**

- **决策的引入**：保证某一类错误率不变的前提下，最小化另一类错误率。假设 $R_1$ ,  $R_2$ 分别为第一、二两类的决策域， $\omega_1$ 类为阴性， $\omega_2$ 类为阳性， $t$ 为分界面，第一类错误率和第二类错误率分别表示为：

$$P_1(e) = \int_{R_2} p(x | \omega_1) dx, \quad P_2(e) = \int_{R_1} p(x | \omega_2) dx$$

那么决策可以转化为如下**约束最优化问题**：

$$\begin{aligned} & \min P_1(e) \\ & \text{s.t. } P_2(e) - \varepsilon_0 = 0 \end{aligned}$$






# 2.4 Neyman-Pearson决策

- **Neyman-Pearson决策**

- 转化：利用拉格朗日乘子法，将上述约束优化问题转化为无约束优化问题（拉格朗日函数），其中  $\lambda$  是拉格朗日乘子

$$\min \gamma = P_1(e) + \lambda (P_2(e) - \varepsilon_0)$$

$$\begin{aligned} \gamma(x, \lambda) &= \int_{R_2} p(x | \omega_1) dx + \lambda \left[ \int_{R_1} p(x | \omega_2) dx - \varepsilon_0 \right] \\ &= (1 - \lambda \varepsilon_0) + \int_{R_1} \left[ \lambda p(x | \omega_2) - p(x | \omega_1) \right] dx \end{aligned}$$



# 2.4 Neyman-Pearson决策

- **Neyman-Pearson决策**

优化目标：求解使 $\gamma(x, \lambda)$ 最小的决策边界  $x = t$ ，分别对  $\lambda$  和  $x$  分别求导


$$\frac{\partial \gamma}{\partial x} = \lambda p(x | \omega_2) - p(x | \omega_1), \quad \frac{\partial \gamma}{\partial \lambda} = \int_{R_1} p(x | \omega_2) dx - \varepsilon_0$$

在 $\gamma$ 的极值处这两个导数都应该为0，因此，在决策边界上应满足：

$$\lambda = \frac{p(x | \omega_1)}{p(x | \omega_2)}, \quad \int_{R_1} p(x | \omega_2) dx = \varepsilon_0$$

要使 $\gamma(x, \lambda)$ 最小，应选择 $R_1$ 使积分项内全为负值，因此， $R_1$ 应使得下式成立的  $x$  组成的区域：

$$\lambda p(x | \omega_2) - p(x | \omega_1) < 0$$




# 2.4 Neyman-Pearson决策

- **Neyman-Pearson决策**

- **决策规则:**

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



利用**数值方法**，基于似然比 $l(x)$ 和似然比密度函数 $P(l|\omega_2)$ 求解 $\lambda$ ：

$$P_2(e) = 1 - \int_0^\lambda p(l|\omega_2) dl = \varepsilon_0$$

- $p(l|\omega_2) \geq 0$ ,  $P_2(e)$ 是 $\lambda$ 的单调函数
- 采用试探法寻找一个合适的 $\lambda$ 值，满足 $P_2(e) = \varepsilon_0$ 且 $P_1(e)$ 尽可能小

# 2.4 Neyman-Pearson决策

- 三种决策规则的比较

- 本质：采用不同的**决策阈值**，可以达到不同的错误率。

决策名称	含义
最小错误率决策	先验概率比 $P(w_2)/P(w_1)$ 作阈值，达到总的 <b>错误率最小</b> ，即两类错误率加权之和最小
最小风险决策	阈值中考虑了对两类错误率不同的 <b>惩罚</b> ，实现 <b>风险最小</b>
Neyman-Pearson决策	通过调整阈值，使一类的错误率为指定数值，而另一类的错误率求最小



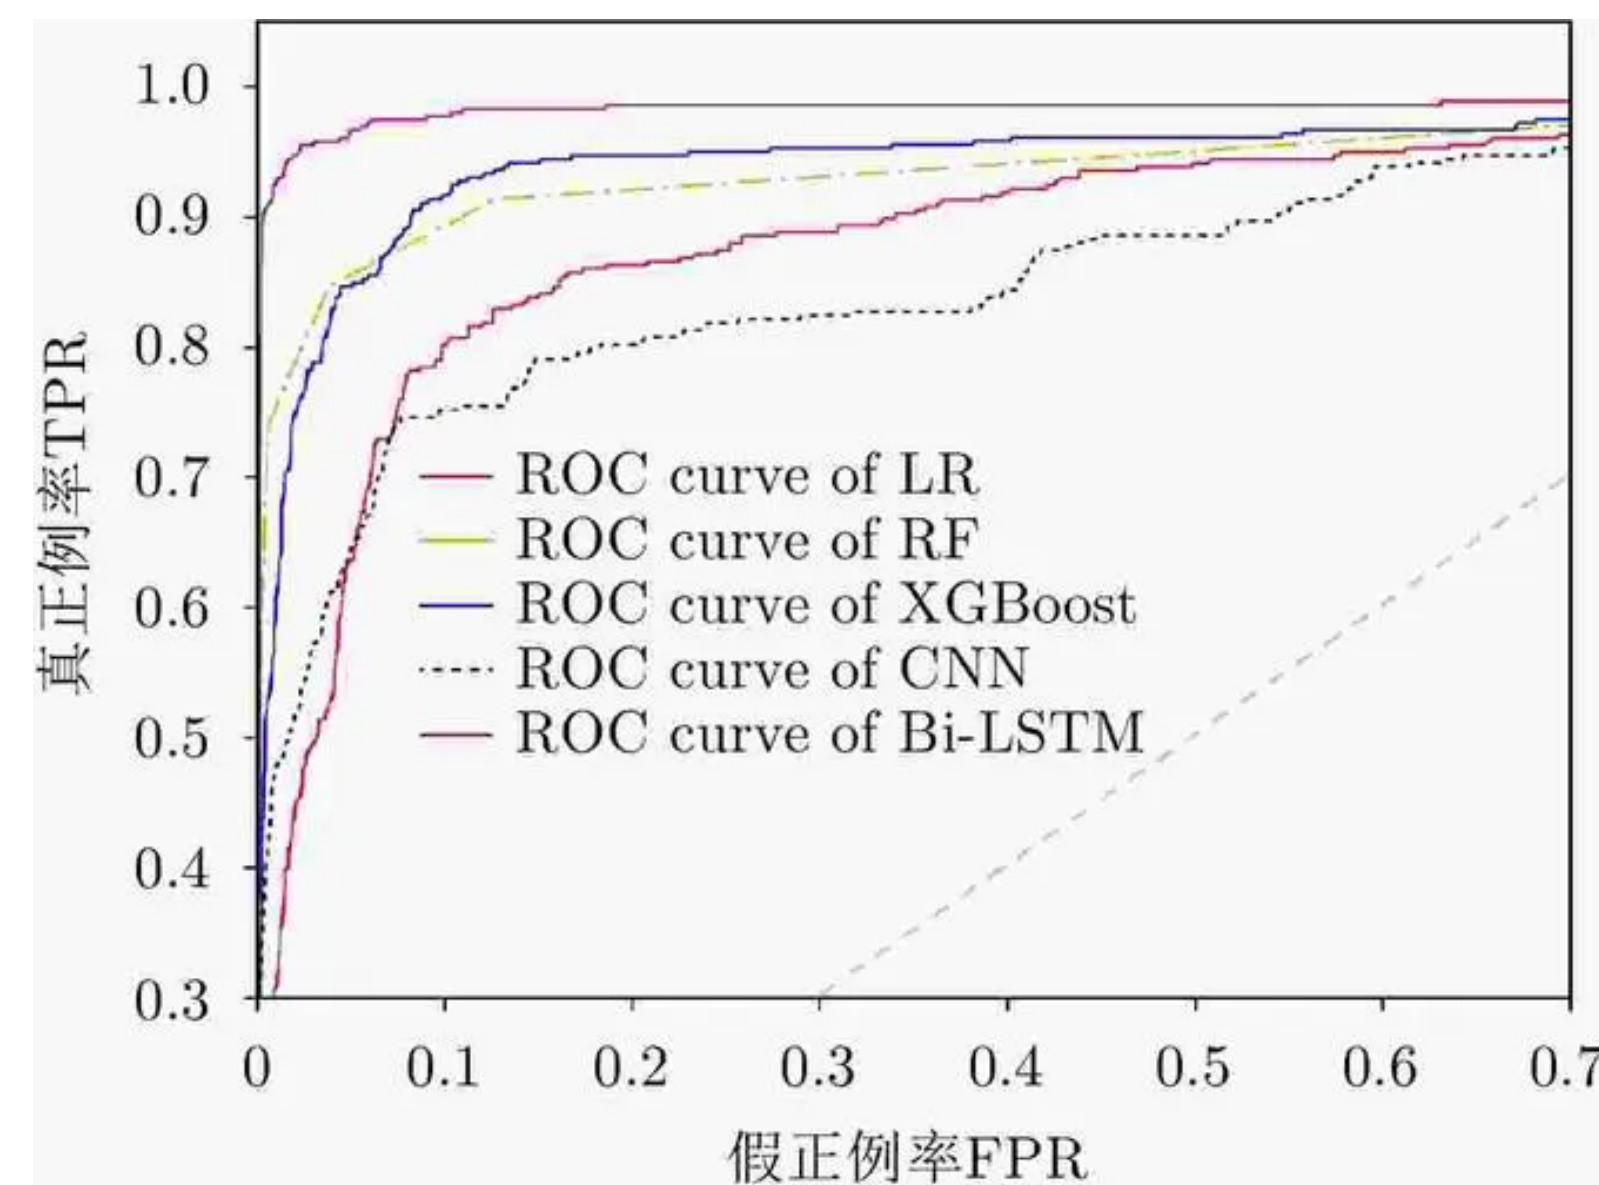


# 2.4 Neyman-Pearson决策

- **ROC曲线**

- ROC (Receiver Operating Characteristic) 曲线

- ▶ 用于阈值选择和模型比较

- AUC (Area Under ROC curves) 曲线下面积






## 2.5 正态分布时的贝叶斯决策

# 2.5.1 正态分布及其性质回顾

- 单变量正态分布  $N(\mu, \sigma^2)$

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


$$\mu = E\{x\} = \int_{-\infty}^{\infty} xp(x)dx, \quad \sigma^2 = \int_{-\infty}^{\infty} (x - \mu)^2 p(x)dx$$



- 多元正态分布  $N(\mu, \Sigma)$



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

$$\mu = E\{x\}, \quad \Sigma = E\left\{ (x - \mu)(x - \mu)^T \right\}$$



# 2.5.1 正态分布及其性质回顾

- 多元正态分布由均值 $\mu$ 和协方差 $\Sigma$ 完全确定
- 等密度点形成超椭球面
- 不相关性等价于独立性
  - 若分量 $x_i$ 和分量 $x_j$ 不相关  $\rightarrow x_i$ 和 $x_j$ 相互独立
  - 若协方差矩阵 $\Sigma$ 为对角阵  $\rightarrow$  各分量相互独立



# 2.5.1 正态分布及其性质回顾

- 多元正态分布的边缘分布是正态分布  $p(x_i) \sim N(\mu_i, \sigma_{ii}^2)$
- 多元正态分布的条件分布是正态分布
- 多元正态随机向量的线性变换仍为多元正态分布

$$\begin{cases} p(x) \sim N(\mu, \Sigma) \\ y = Ax \end{cases} \Rightarrow p(y) \sim N(A\mu, A\Sigma A^T)$$

- 多元正态随机向量的线性组合为一维正态随机变量

# 2.5.2 正态分布下的贝叶斯决策

$$P(\omega_i | x) = \frac{P(\omega_i, x)}{P(x)} = \frac{P(x | \omega_i)P(\omega_i)}{P(x)}$$

- 判别函数

- 概率密度函数  $p(x | \omega_i) \sim N(\mu_i, \Sigma_i)$

$$p(x | \omega_i) = \frac{1}{(2\pi)^{d/2} |\Sigma_i|^{1/2}} \exp \left\{ -\frac{1}{2} (x - \mu_i)^T \Sigma_i^{-1} (x - \mu_i) \right\}$$

- 判别函数：只关注分子，取对数形式

$$g_i(x) = \ln(p(x | \omega_i) p(\omega_i)) = -\frac{1}{2} (x - \mu_i)^T \Sigma_i^{-1} (x - \mu_i) + \ln \frac{1}{(2\pi)^{d/2} |\Sigma_i|^{1/2}} + \ln p(\omega_i)$$

- 决策面方程

$$g_i(x) = g_j(x) \implies -\frac{1}{2} \left[ (x - \mu_i)^T \Sigma_i^{-1} (x - \mu_i) - (x - \mu_j)^T \Sigma_j^{-1} (x - \mu_j) \right] - \frac{1}{2} \ln \frac{|\Sigma_i|}{|\Sigma_j|} + \ln \frac{p(\omega_i)}{p(\omega_j)} = 0$$



# 特殊情况下的正态分布的贝叶斯决策

- 各类协方差矩阵相等、且各特征独立、方差 $\sigma^2$ 相等:  $\Sigma_i = \sigma^2 \mathbf{I}$

- 各类先验概率不相等  $p(\omega_i) \neq p(\omega_j)$ , 则有

$$g_i(x) \triangleq -\frac{1}{2\sigma^2} (x - \mu_i)^T (x - \mu_i) + \ln p(\omega_i) = -\frac{1}{2\sigma^2} \|x - \mu_i\|^2 + \ln p(\omega_i)$$

$$g_i(x) = \frac{\mu_i^T}{\sigma^2} x - \frac{1}{2\sigma^2} \mu_i^T \mu_i + \ln p(\omega_i)$$

- 球状分布 (各类样本落入以 $\mu_i$ 为中心的同样大小的超球体内), 分类只取决于样本到各类中心的距离

# 特殊情况下的正态分布的贝叶斯决策


- 各类协方差矩阵相等、且各特征独立、方差 $\sigma^2$ 相等:  $\Sigma_i = \sigma^2 \mathbf{I}$

- 各类先验概率相等  $p(\omega_i) = p(\omega_j), i, j = 1, 2, \dots, c$ , 则有

$$g_i(x) \triangleq -\frac{1}{2\sigma^2} (x - \mu_i)^T (x - \mu_i) = -\frac{1}{2\sigma^2} \|x - \mu_i\|^2$$

- 决策面与先验概率相等时的决策面平行, 只是向先验概率小的方向偏移

- 先验概率大的一类要占据更大的决策空间



# 特殊情况下的正态分布的贝叶斯决策

- 各类协方差矩阵都相等  $\Sigma_i = \Sigma$

- 各类样本集中于以该类均值  $\mu_i$  为中心的同样大小和形状的超椭球内

$$g_i(x) \triangleq \ln \left( p(x | \omega_i) p(\omega_i) \right) = -\frac{1}{2} \underbrace{(x - \mu_i)^T \Sigma^{-1} (x - \mu_i)} + \ln p(\omega_i)$$

Mahalanobis 距离 (马氏距离的平方), 记为  $\gamma^2$

- 若各类的先验概率相等, 决策面通过  $\mu_i$  和  $\mu_j$  连线中点

- 若各类的先验概率不相等, 决策面向先验概率小的均值点偏移

# 2.6 错误率

- 错误率反映了分类问题固有复杂性的程度
- 在分类器设计出来后, 通常是以错误率大小来衡量其性能优劣
- 通常是以错误率大小作为比较方案的标准

$$P(e) = P(\omega_1) \int P(x | \omega_1) dx + P(\omega_2) \int P(x | \omega_2) dx = P(\omega_1)P_1(e) + P(\omega_2)P_2(e)$$

- 实际中, 按理论公式计算错误率很困难