

粒子物理与核物理实验中的 数据分析

陈少敏
清华大学

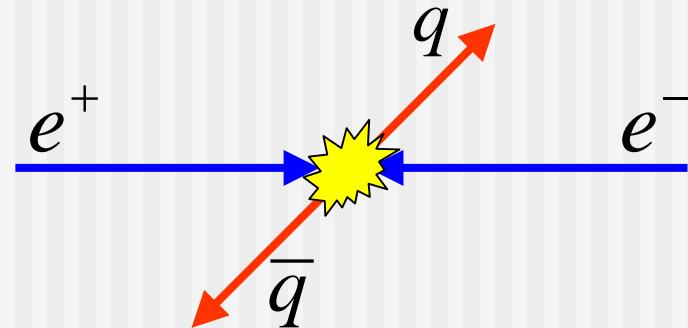
第一讲：基本概念

http://hep.tsinghua.edu.cn/~chensm/lectures/lecture_1.ppt

本次讲座的要点

- 概率
- 随机变量与函数
- 期待值
- 误差传递

实验的目的是什么？



观察某一过程
的 n 个事例

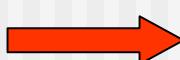
实验测量出每个事例的特征量(能动量，末态粒子数...)。
理论预言出上述各特征量的分布，而且可能还会包含某些如相互作用耦合常数等自由参数。

收集数据
统计分析



估计参数值与相应的误差
围，检验在何种程度上理
与实验数据相符。

问题：如何评价这种检验？



使用概率来量化结论！

随机事例

在一定的实验条件下，现象**A**可能发生，也可能不发生，并且只有发生或不发生这样两种可能性，这是偶然现象中一种比较简单的形态，我们把发生了现象**A**的事例称为**随机事例A**，简称事例**A**。

随机事例之间的相互关系

A与B之并事例 $A \cup B$

指事例A与B中至少有一个出现的事例

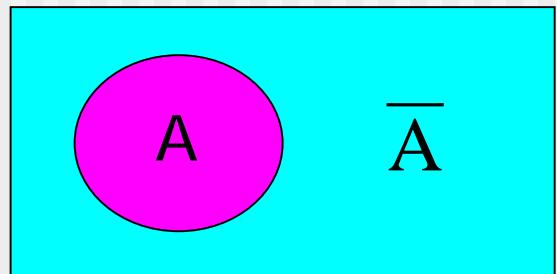
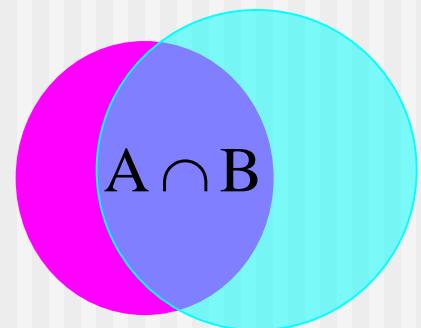
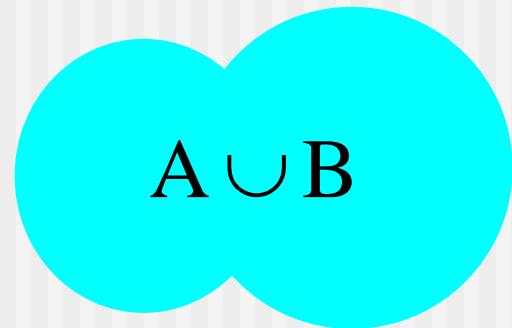
如果A与B互斥，则 $A \cup B = A + B$

A与B之积(交)事例 $A \cap B$

指事例A与B中同时出现的事例

A之逆事例 \bar{A}

指事例A不出现的事例



概率的定义

柯尔莫哥洛夫公理：考虑一全集 **S** 具有子集 **A, B, ...**

$$A \subset S, P(A) \geq 0$$

$$P(S) = 1$$

$$A \cap B = \emptyset \Rightarrow P(A \cup B) = P(A) + P(B)$$

从该公理可以导出下列概率公式

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

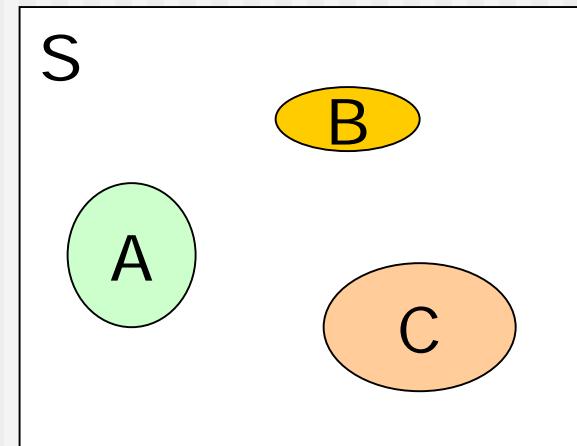
$$P(A \cup \bar{A}) = 1$$

$$A \subset B \Rightarrow P(A) \leq P(B)$$

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$



P(A) 称为事例 **A** 的概率



条件概率

假设**B**出现的概率不为零，在给定**B**的情况下出现**A**的条件概率定义为

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

如果 $P(A \cap B) = P(A)P(B)$ 则表明**A与B相互独立**。

如果**A与B相互独立**，则有

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



结果与**B无关**

注意：与不相交的子集定义不同 $A \cap B$

概率的含义

➤ 相对频率

假设A, B, ...是一可**重复**实验的结果，则概率就是

$$P(A) = \lim_{n \rightarrow \infty} \frac{\text{结果为 } A}{n \text{ 次实验}}$$

➤ 主观概率

如果A, B, ...是**假设**(是真或是假的各种陈述)，那么概率

$$P(A) = \text{对A为真的信心程度}$$

✓ 两种解释皆与柯尔莫哥洛夫公理相符。

✓ 概率的频率解释在数据分析中用起来比较自然，但是...

频率概率中的问题

- 实际问题中，统计量总是有限的。 $P(A)$ 完全取决于**A**的划分与总统计量的大小。

概率大小会出现波动。



需要解决好
•**A**的定义
•适当的误差

- 该定义不适用于某些特殊情况

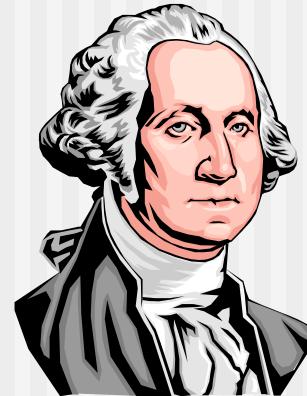
例如：我们可以说“明天有雨”。但是，如果我们根据概率频率定义说“明天可能有雨”，却是一个毫无科学意义的预报。

主观概率中的问题

- 主观性：在对同一随机现象的描述中，我的P(理论)与你的P(理论)可能不同



理论家甲
之理论A



理论家乙
之理论B

- 使用主观概率的原因

- 出于绝望 ✓
- 出于无知 ✗
- 出于懒惰 ?

主观概率的一些特点

主观概率有一些吸引人的地方，例如对于不可重复现象的处理中，显得比较自然

- 系统误差(重复实验时仍保持不变);
- 在该事例出现的粒子是正电子;
- 自然界是超对称的;
- 明天将下雨(将来事件的不确定性);
- 公元1500年元月一日北京下雨(过去事件的不确定性)。

结论中包含了主观上对事件为真的信念!

频率论者与主观概率

$P(938.27195 < \text{质子质量} < 938.27211 \text{MeV})$ 是什么？

当以质量来判断一实际为质子的粒子类别时

- 频率论者：质子或非质子（不知道是哪个）
- 主观主义者（贝叶斯论者）：68%是质子（对知识的陈述）

对主观概率而言，意味着

质子质量的不确定性与从100只球中有68只白球的球筐里能拿出白球的不确定性一样。

频率论者与主观概率(续)

如果大多数贝叶斯论者说

- 巴西赢得2006年世界杯冠军的概率为68%
- 质子质量在 $938.27195\text{--}938.27211\text{MeV}$ 内的概率为68%
- 希拉里·克林顿2009年入主白宫的概率为68%

那么上述论断的68%就应该理解为结果为真的概率。

能否在频率定义中将质子质量在 $938.27195\text{--}938.27211\text{MeV}$ 内理解成：在整个宇宙中，自然界给出了各种不同的质子质量，而它们中有68%在 938.27195 与 938.27211MeV 之间？

没问题...只不过这是对信心程度的一种表达。

贝叶斯定理

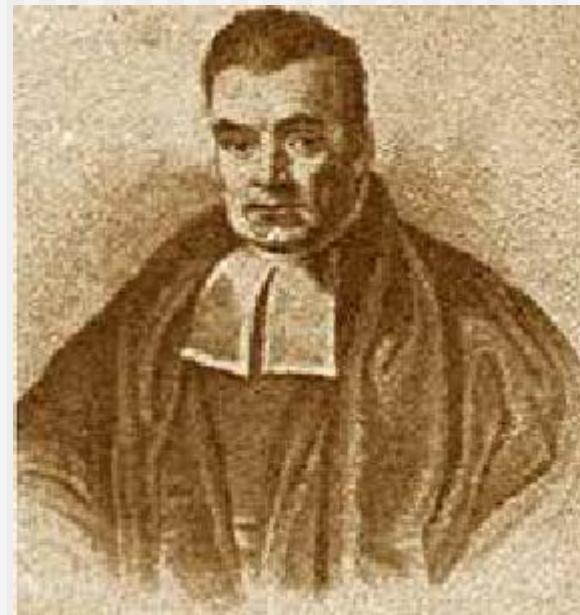
根据条件概率的定义

$$P(A | B) = \frac{P(A \cap B)}{P(B)} \quad \text{与} \quad P(B | A) = \frac{P(B \cap A)}{P(A)}$$

而 $P(A \cap B) = P(B \cap A)$, 故

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

贝叶斯定理由 **Reverend Thomas Bayes (1702-1761)** 首先提出。



贝叶斯理论与主观概率

贝叶斯理论通常用于主观概率问题

$$P(\text{理论} | \text{实验}) = \frac{P(\text{实验} | \text{理论})}{P(\text{实验})} P(\text{理论})$$

通过实验结果改进基于某一理论的信念(后验性的)

- 如果实验证明 $P(\text{实验} | \text{理论})=0$ ，则表明理论不能接受。
- 大的 $P(\text{实验} | \text{理论})$ 会增加对理论的信任度。
- 通过实验结果可以改进 $P(\text{理论})$ 。
- 改进的 $P(\text{理论})$ 可应用于对重复实验结果的预测。
- $P(\text{实验} | \text{理论})$ 对先验理论的依赖将最终消失。

全概率事例

考虑在样本空间**S**中有一子集**B**。将样本空间分为互斥的子集**A_i**，使得

$$\cup_i A_i = \sum_i A_i = S$$

因此，

$$B = B \cap S = B \cap (\cup_i A_i) = \cup_i (B \cap A_i)$$

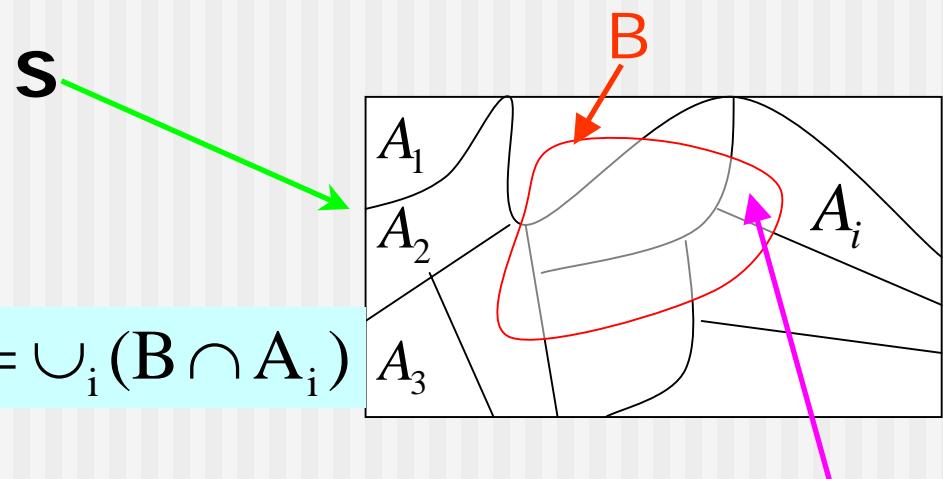
表示成概率的形式为

$$P(B) = P(\cup_i (B \cap A_i)) = \sum_i P(B \cap A_i)$$

$$B \cap A_i$$

得到全概率事例公式

$$P(B) = \sum_i P(B | A_i) P(A_i)$$



贝叶斯定理

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

例子：如何利用贝叶斯定理

假设对任意一个人而言，感染上**AIDS**的概率为

$$P(AIDS) = 0.001 \quad \text{验前概率,即任何检验之前}$$

$$P(\text{no AIDS}) = 0.999$$

考虑任何一次**AIDS**检查的结果只有阴性(-)或阳性(+)两种

$$P(+ | AIDS) = 0.98 \quad \text{AIDS感染患者阳性的概率}$$

$$P(- | AIDS) = 0.02 \quad \text{AIDS感染患者阴性的概率}$$

$$P(+ | \text{no AIDS}) = 0.03 \quad \text{AIDS未感染者阳性的概率}$$

$$P(- | \text{no AIDS}) = 0.97 \quad \text{AIDS未感染者阴性的概率}$$

如果你的检查结果为阳性(+)，而你却觉得自己无明显感染渠道。那么你是否应担心自己真的感染上了**AIDS**？

例子：如何利用贝叶斯定理(续)

利用贝叶斯定理，阳性结果条件下是**AIDS**患者的概率为

$$\begin{aligned} P(AIDS|+) &= \frac{P(+|AIDS)P(AIDS)}{P(+|AIDS)P(AIDS) + P(+|no\ AIDS)P(no\ AIDS)} \\ &= \frac{0.98 \times 0.001}{0.98 \times 0.001 + 0.03 \times 0.999} \quad \text{AIDS患者阳性} \\ &= 0.032 \quad \text{所有为阳性结果的人} \\ & \quad \quad \quad (\text{验后概率}) \end{aligned}$$

也就是说，你可能没什么问题！

从你的观点上看：对自己染上**AIDS**结果的可信度为**3.2%**。

从医生角度上看：象你这样的人有**3.2%**感染上了**AIDS**。

随机变量与概率密度函数

假设实验结果为 x (记作样本空间中元素)

$$P(\text{观测到 } x \text{ 在 } [x, x + dx] \text{ 范围内}) = f(x)dx$$

那么概率密度函数 **p.d.f.** 定义为 $f(x)$ ，它满足

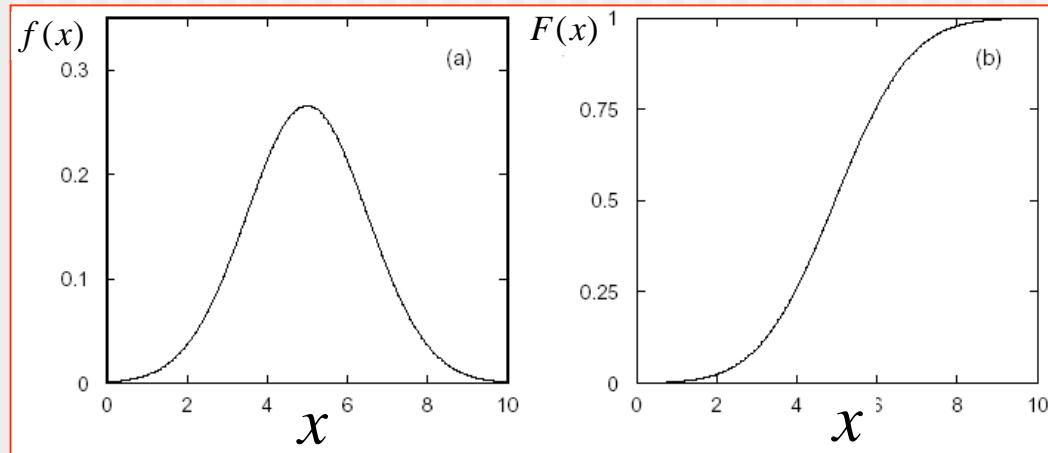
$$\int_{-\infty}^{+\infty} f(x)dx = 1$$

定义累积分布函数为

$$F(x) = \int_{-\infty}^x f(x')dx'$$

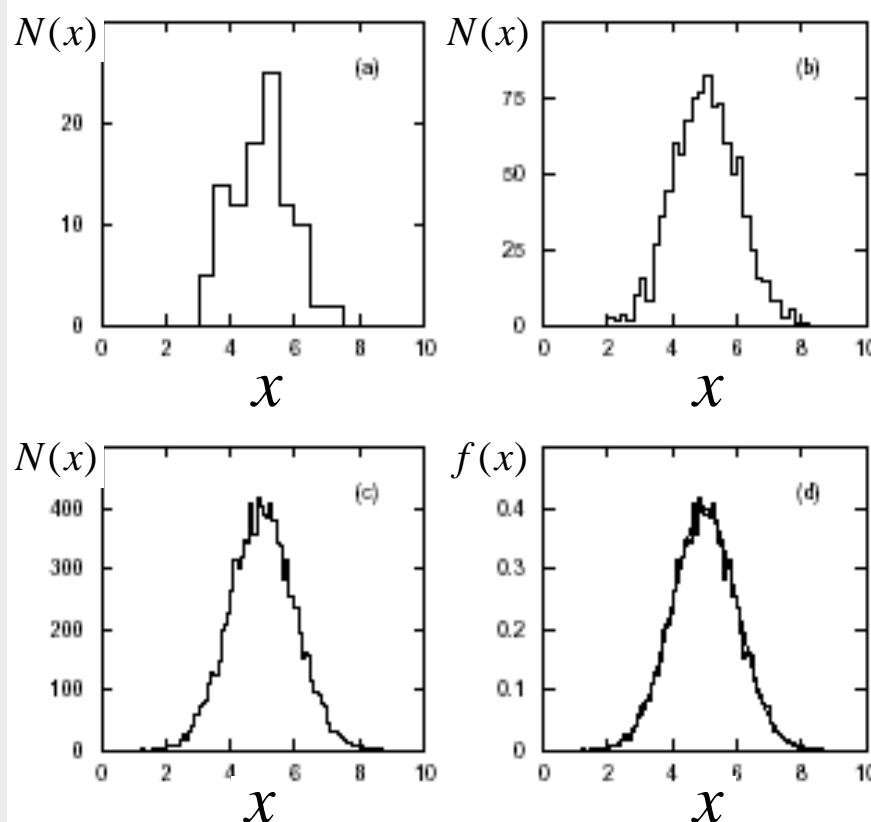
对于离散型随机变量

$$f_i = P(x_i), \quad \sum_{i=1}^n f_i = 1, \quad F(x) = \sum_{x_i \leq x} P(x_i)$$



直方图与概率密度函数

概率密度函数 **p.d.f.** 就是拥有无穷大样本，区间宽度为零，而且归一化到单位面积的**直方图**。



$$f(x) = \frac{N(x)}{n\Delta x}$$

$N(x)$ = 每个区间的事例数(频数)

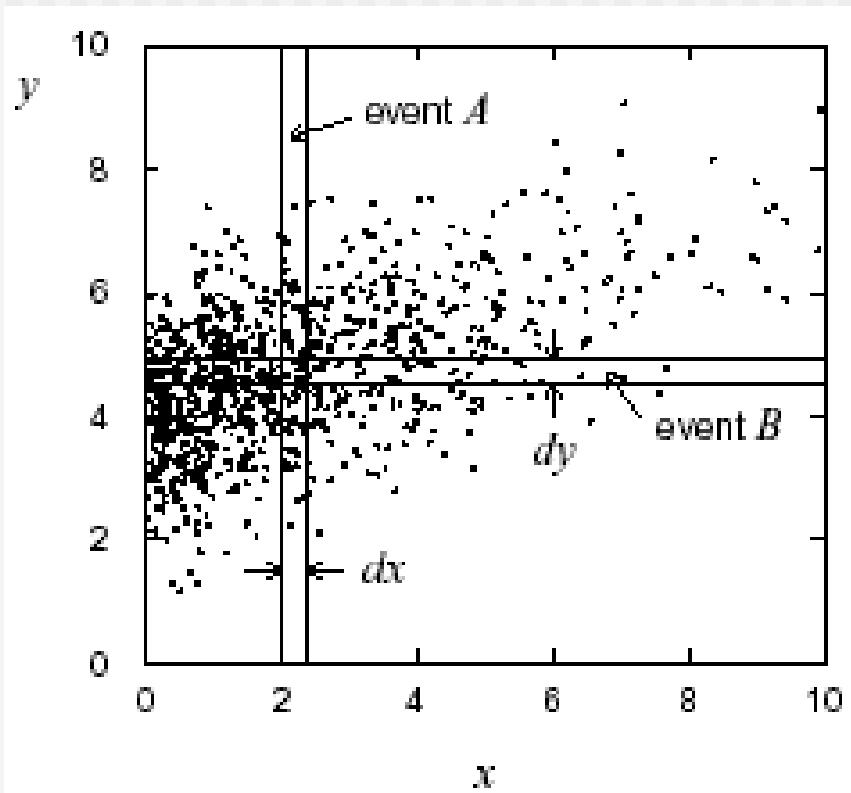
n = 添入直方图的总事例数

Δx = 区间的宽度

直方图在统计分析中非常重要，应准确理解它的含义。

多变量情形

如果观测量大于一个，例如 x 与 y



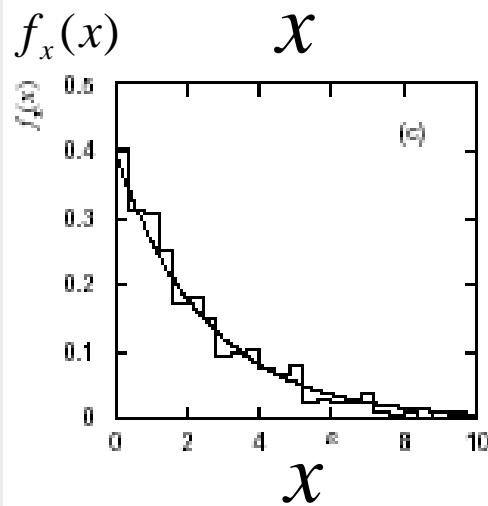
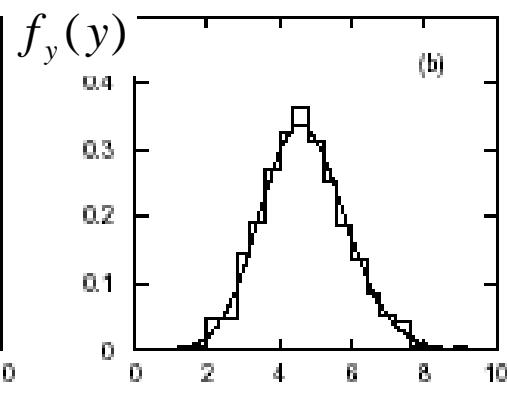
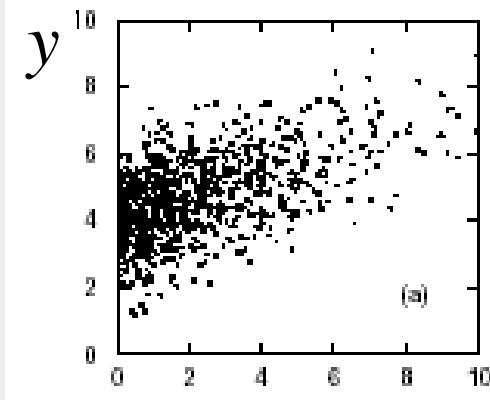
$$P(A \cap B) = f(x, y)dxdy$$

$f(x, y)$ = 联合的 p.d.f.

$$\iint f(x, y)dxdy = 1$$

投影分布

将联合概率密度函数 p.d.f. 投影到 x, y 轴(如图所示)



$$f_x(x) = \int f(x, y) dy$$

$$f_y(y) = \int f(x, y) dx$$

定义 $f_x(x), f_y(y)$ = 投影的 p.d.f .

条件概率密度函数

利用条件概率的定义，可得到

$$P(B | A) = \frac{P(A \cap B)}{P(A)} = \frac{\int f(x, y) dx dy}{\int f_x(x) dx}$$

定义条件概率的密度函数 **p.d.f.** 为

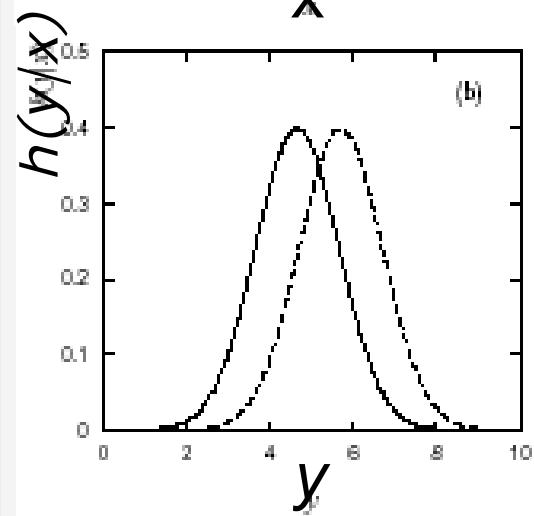
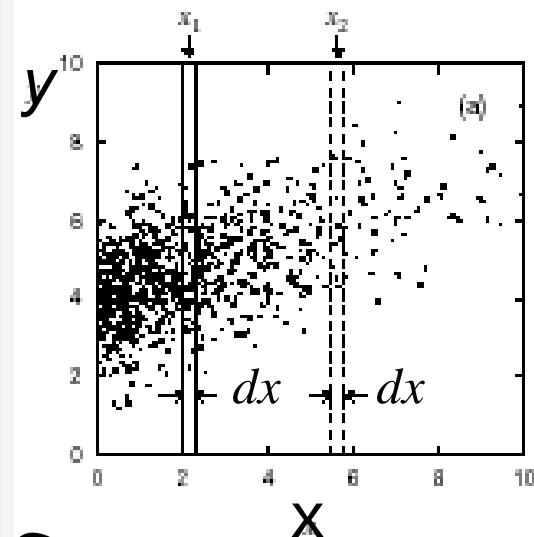
$$h(y | x) = \frac{f(x, y)}{f_x(x)}, \quad g(x | y) = \frac{f(x, y)}{f_y(y)}$$

则贝叶斯定理可写为

$$g(x | y) = \frac{h(y | x) f_x(x)}{f_y(y)}$$

若 x, y 相互独立，则

$$f(x, y) = f_x(x) f_y(y)$$

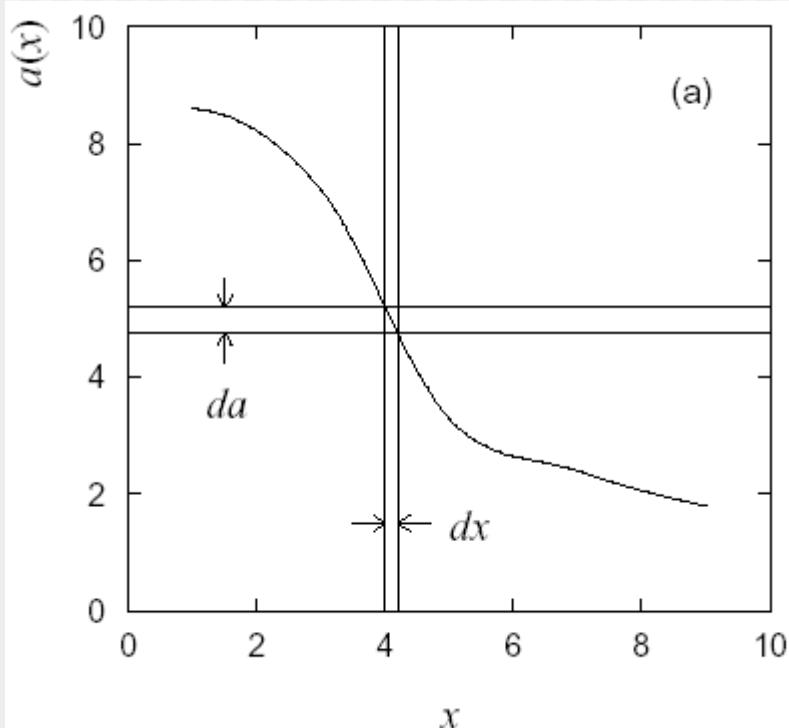


随机变量的函数*

随机变量的函数自身也是一个随机变量。

例如：
 θ 与 $\cos \theta$

假设 x 服从 p.d.f. $f(x)$, 对于函数 $a(x)$, 其 p.d.f. $g(a)$ 为何?



$$g(a)da = \int_{dS} f(x)dx$$

$dS = a$ 在 $[a, a + da]$ 内的 x 空间范围

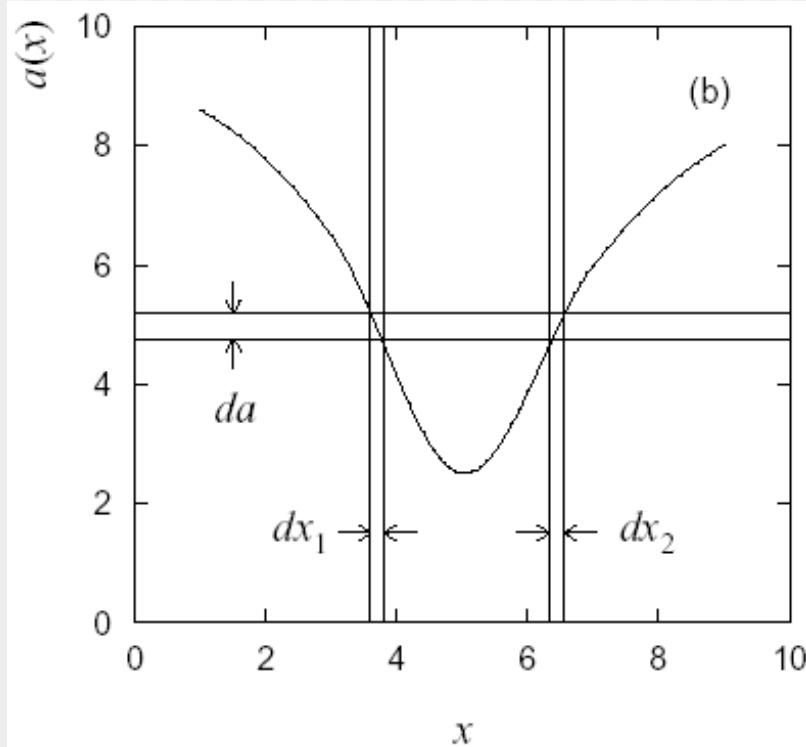
$$g(a)da = \left| \int_{x(a)}^{x(a+da)} f(x')dx' \right|$$

$$= \int_{x(a)}^{x(a)+\left|\frac{dx}{da}\right|da} f(x')dx'$$

$$\Rightarrow g(a) = f(x(a)) \left| \frac{dx}{da} \right|$$

函数的逆不唯一情况 *

假如 $a(x)$ 的逆不唯一，则函数的 p.d.f. 应将 dS 中对应于 da 的所有 dx 的区间包括进来



例如: $a = x^2$, $x = \pm\sqrt{a}$, $dx = \pm\frac{da}{2\sqrt{a}}$

$$g(a)da = \int_{dS} f(x)dx$$
$$dS = \left[\sqrt{a}, \sqrt{a} + \frac{da}{2\sqrt{a}} \right] \cup \left[-\sqrt{a} - \frac{da}{2\sqrt{a}}, -\sqrt{a} \right]$$
$$g(a) = \frac{f(\sqrt{a})}{2\sqrt{a}} + \frac{f(-\sqrt{a})}{2\sqrt{a}}$$

多个随机变量的函数*

考虑随机矢量 $\vec{x} = (x_1, \dots, x_n)$ 与函数 $a(\vec{x})$ 对应的 p.d.f.

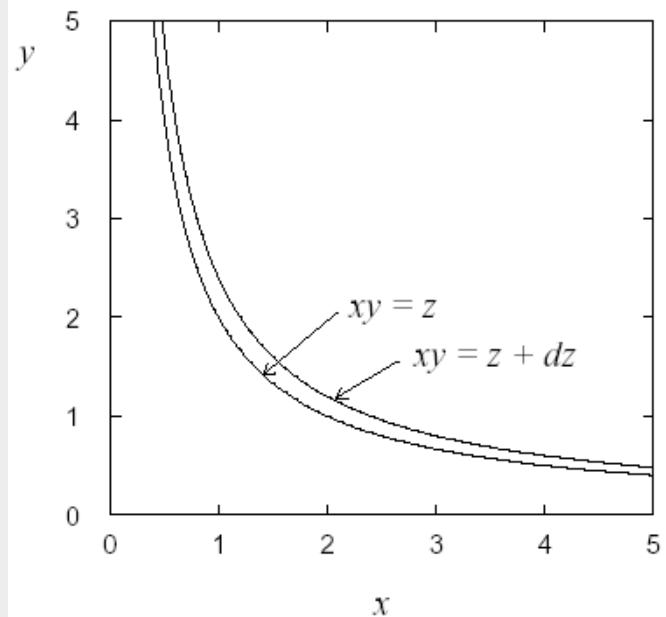
$$g(a')da' = \int \cdots \int_{dS} f(x_1, \dots, x_n) dx_1 \dots dx_n$$

dS = 在 $a(\vec{x}) = a'$ 与 $a(\vec{x}) = a' + da'$ 定义的曲面 \vec{x} 空间范围

例如随机变量 $x, y > 0$ 服从联合的
p.d.f. $f(x, y)$, 考虑函数 $z = xy$,
其 $g(z)$ 应是何种形式

$$\begin{aligned} g(z)dz &= \int \cdots \int_{dS} f(x, y) dxdy \\ &= \int_0^\infty dx \int_{z/x}^{(z+dz)/x} f(x, y) dy \end{aligned}$$

$$g(z) = \int_0^\infty f\left(x, \frac{z}{x}\right) \frac{dx}{x} = \int_0^\infty f\left(\frac{z}{y}, y\right) \frac{dy}{y}$$



多个随机变量的函数(续) *

考虑具有联合的 **p.d.f.** 的随机矢量 $\vec{x} = (x_1, \dots, x_n)$ ，构造 n 个线性独立的函数： $\vec{y}(\vec{x}) = (y_1(\vec{x}), \dots, y_n(\vec{x}))$ ，而且其逆函数 $x_1(\vec{y}), \dots, x_n(\vec{y})$ 存在。那么 \vec{y} 的联合 **p.d.f.** 为

$$g(\vec{y}) = |J| f(\vec{x})$$

这里 J 是雅可比行列式

$$J = \begin{vmatrix} \frac{\partial x_1}{\partial y_1} & \frac{\partial x_1}{\partial y_2} & \dots & \frac{\partial x_1}{\partial y_n} \\ \frac{\partial x_2}{\partial y_1} & \frac{\partial x_2}{\partial y_2} & \dots & \frac{\partial x_2}{\partial y_n} \\ \vdots & & & \vdots \\ & \dots & & \frac{\partial x_n}{\partial y_n} \end{vmatrix} \quad \rightarrow$$

任意一个函数 $g_i(y_i)$ 均可通过对函数 $g(\vec{y})$ 积分掉其它不用的变量而得到。

期待值

考虑具有 **p.d.f.** $f(x)$ 的随机变量 x ，定义**期待(平均)值**为

$$E[x] = \int x f(x) dx \quad \text{通常记为: } E[x] = \mu$$

注意: 它不是 x 的函数, 而是 $f(x)$ 的一个参数。

对**离散型**变量, 有 $E[x] = \sum_{i=1}^n x_i P(x_i)$

对具有 **p.d.f.** $g(y)$ 的函数 $y(x)$, 有

$$E[y] = \int yg(y) dy = \int y(x) f(x) dx$$

方差定义为

$$V[x] = E[(x - E[x])^2] = E[x^2] - \mu^2 \quad \text{通常记为: } V[x] = \sigma^2$$

标准偏差: $\sigma \equiv \sqrt{\sigma^2}$

协方差与相关系数

定义协方差 $\text{cov}[x, y]$ (也可用矩阵表示 V_{xy}) 为

$$\text{cov}[x, y] = E[(x - \mu_x)(y - \mu_y)] = E[xy] - \mu_x \mu_y$$

相关系数定义为

$$\rho_{xy} = \frac{\text{cov}[x, y]}{\sigma_x \sigma_y},$$

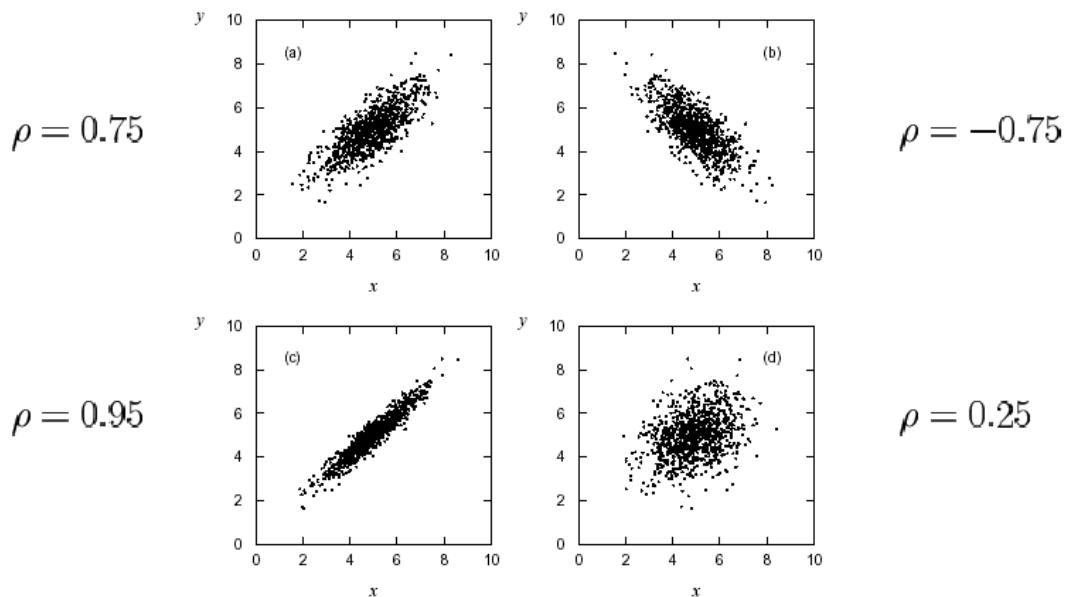
$$-1 \leq \rho_{xy} \leq 1$$

如果 x, y 独立, 即

$$f(x, y) = f_x(x)f_y(y)$$

则

$$\text{cov}[x, y] = 0$$



误差传递

假设 $\vec{x} = (x_1, \dots, x_n)$ 服从某一联合 **p.d.f.** $f(\vec{x})$ ， 我们也许并不全部知道该函数形式，但假设我们有协方差

$$V_{ij} = \text{cov}[x_i, x_j]$$

和平均值 $\vec{\mu} = E[\vec{x}]$

现考虑一函数 $y(\vec{x})$ ， 方差 $V[y] = E[y^2] - (E[y])^2$ 是什么？
将 $y(\vec{x})$ 在 $\vec{\mu}$ 附近按泰勒展开到第一级

$$y(\vec{x}) \approx y(\vec{\mu}) + \sum_{i=1}^n \left[\frac{\partial y}{\partial x_i} \right]_{\vec{x}=\vec{\mu}} (x_i - \mu_i)$$

然后，计算 $E[y]$ 与 $E[y^2]$...

误差传递(续一)

由于 $E[x_i - \mu_i] = 0$ 所以

$$E[y(\vec{x})] \approx y(\vec{\mu})$$

$$E[y^2(\vec{x})] \approx y^2(\vec{\mu}) + 2y(\vec{\mu}) \cdot \sum_{i=1}^n \left[\frac{\partial y}{\partial x_i} \right]_{\vec{x}=\vec{\mu}} E[x_i - \mu_i]$$

$$+ E \left[\left(\sum_{i=1}^n \left[\frac{\partial y}{\partial x_i} \right]_{\vec{x}=\vec{\mu}} (x_i - \mu_i) \right) \left(\sum_{j=1}^n \left[\frac{\partial y}{\partial x_j} \right]_{\vec{x}=\vec{\mu}} (x_j - \mu_j) \right) \right]$$

$$= y^2(\vec{\mu}) + \sum_{i,j=1}^n \left[\frac{\partial y}{\partial x_i} \frac{\partial y}{\partial x_j} \right]_{\vec{x}=\vec{\mu}} V_{ij}$$

误差传递(续二)

两项合起来给出 $y(\vec{x})$ 的方差

$$\sigma_y^2 \approx \sum_{i,j=1}^n \left[\frac{\partial y}{\partial x_i} \frac{\partial y}{\partial x_j} \right]_{\vec{x}=\vec{\mu}} V_{ij}$$

如果 x_i 之间是无关的, 则 $V_{ij} = \sigma_i^2 \delta_{ij}$, 那么上式变为

$$\sigma_y^2 \approx \sum_{i=1}^n \left[\frac{\partial y}{\partial x_i} \right]_{\vec{x}=\vec{\mu}}^2 \sigma_i^2$$

类似地, 对于 m 组函数

$$\vec{y}(\vec{x}) = (y_1(\vec{x}), \dots, y_m(\vec{x}))$$

误差传递(续三)

$$U_{kl} = \text{cov}[y_k, y_l] \approx \sum_{i,j=1}^n \left[\frac{\partial y_k}{\partial x_i} \frac{\partial y_l}{\partial x_j} \right]_{\vec{x}=\vec{\mu}} V_{ij}$$

或者记为矩阵形式

$$U = A V A^T, \quad A_{ij} = \left[\frac{\partial y_i}{\partial x_j} \right]_{\vec{x}=\vec{\mu}}$$

注意：上式只对 $\vec{y}(\vec{x})$ 为线性时是精确的，近似程度在函数非线性变化比 σ_i 要大时遭到很大的破坏。另外，上式并不需要知道 x_i 的 **p.d.f.** 具体形式，例如，它可以不是高斯的。

误差传递的一些特殊情况

$$y = x_1 + x_2$$

$$\sigma_y^2 = \sigma_1^2 + \sigma_2^2 + 2\text{cov}[x_1, x_2]$$

$$y = x_1 x_2$$

$$\frac{\sigma_y^2}{y^2} = \frac{\sigma_1^2}{x_1^2} + \frac{\sigma_2^2}{x_2^2} + 2 \frac{\text{cov}[x_1, x_2]}{x_1 x_2}$$

注意在相关的情况下，最终的误差会有很大的改变，例如当

$$y = x_1 - x_2, \mu_1 = \mu_2 = 10, \sigma_1 = \sigma_2 = 1$$

$$\begin{cases} \rho = 0: & E[y] = \mu_1 - \mu_2 = 0, V[y] = 1^2 + 1^2 = 2, \sigma_y = 1.4 \\ \rho = 1: & E[y] = \mu_1 - \mu_2 = 0, V[y] = 1^2 + 1^2 - 2 = 0, \sigma_y = 0 \end{cases}$$

这种特征有时候是有益的：将公共的或难以估计的误差，通过适当的数学处理将它们消掉，达到减小误差的目的。

小结

1. 概率

- a) 定义：柯尔莫哥洛夫公理 + 条件概率
- b) 解释：频率或信心程度
- c) 贝叶斯定理

2. 随机变量

- a) 概率密度函数 p.d.f.
- b) 累积分布函数
- c) 联合，投影与条件的 p.d.f.

3. 随机变量函数

- a) 函数自身也是随机变量
- b) 几种方法找出 p.d.f.

4. 误差传递

函数方差的计算方法是基于一阶泰勒展开，只对线性方程精确。

习题

习题1.1:一束光子束流含有 10^{-4} 的电子.当它们通过一双层的探测器会给出无击中,单层击中或双层击中的信号.对于可能是电子和光子的概率为

$$P(0 | e) = 0.001 \quad P(0 | \gamma) = 0.99899$$

$$P(1 | e) = 0.01 \quad P(1 | \gamma) = 0.001$$

$$P(2 | e) = 0.989 \quad P(2 | \gamma) = 10^{-5}$$

- (a)求在只观测到一层击中的情况下,是光子的概率;
- (b)求在观测到两层都击中的情况下,是电子的概率.

习题(续)

习题1.2:证明对于一个随机变量 x 和常数 α 与 β 有下式

$$E[\alpha x + \beta] = \alpha E[x] + \beta$$

$$V[\alpha x + \beta] = \alpha^2 V[x]$$

习题1.3:对于两个变量 x 与 y 的情况

(a) 证明变量 $\alpha x + y$ 存在

$$\begin{aligned} V[\alpha x + y] &= \alpha^2 V[x] + V[y] + 2\alpha \text{cov}[x, y] \\ &= \alpha^2 V[x] + V[y] + 2\alpha \rho \sigma_x \sigma_y \end{aligned}$$

这里 α 是任意常数,

(b) 利用结果(a), 证明相关系数总是在 $[-1, 1]$ 之间.(利用变量 $V[\alpha x + y]$ 总是大于或等于零并考虑 $\alpha = \pm \sigma_y / \sigma_x$)