

《贝叶斯分析》勘误表 (2019.12)

(适用于第一版第三次印刷)

第一章

P_9 , -2 至 -1 行中: $\begin{cases} \text{误:} & \text{在考虑统计推断时, 除了利用样本信息外,} \\ \text{正:} & \text{在考虑统计推断时, 除了利用抽样信息外,} \end{cases}$

P_{10} , 第 10 行中: $\begin{cases} \text{误:} & \text{先验分布 } \pi(\theta) \text{ 是在抽取样本 } X \text{ 之前对参数 } \theta \text{ 可能取值的认识.} \\ \text{正:} & \text{先验分布 } \pi(\theta) \text{ 是在抽取样本 } X \text{ 之前对参数 } \theta \text{ 的认识.} \end{cases}$

第二章

P_{33} , -3 至 -2 行中: $\begin{cases} \text{误:} & \text{是人们根据经验对事件发生机会的个人信念的强弱.} \\ \text{正:} & \text{是人们根据经验对事件发生机会的个人信念.} \end{cases}$

P_{35} , 第 12 行中: $\begin{cases} \text{误:} & \text{(3) 绘制直方图, 纵坐标为主观概率或频率与区间长之比;} \\ \text{正:} & \text{(3) 绘制直方图, 纵坐标为主观概率或频率与小小区间长之比;} \end{cases}$

P_{35} , -8 至 -7 行中: $\begin{cases} \text{误:} & \text{记录了 102 个周的销售量, 每周销售最多 35 kg, 最少 5 kg, 数据见表 2.2.1.} \\ \text{正:} & \text{记录了 102 个周的销售量, 每周销售最多 35 kg, 数据见表 2.2.1.} \end{cases}$

P_{40} , -12 行中: $\begin{cases} \text{误:} & \hat{\mu} = \sum_{i=1}^8 x_i p_i = 2.198 \\ \text{正:} & \hat{\mu} = \sum_{i=1}^8 x_i p_i = 2.199, \end{cases}$

P_{40} , -9 行表 2.2.2 中: $\begin{cases} \text{误:} & 2 \\ \text{正:} & 2.00 \\ & \text{注: 将表 2.2.2 左侧栏目第二行中的数字 2 改为 2.00, 以便与同侧栏目中} \\ & \text{其他各行一样保留小数点后 2 位} \end{cases}$

P_{41} , 第 1 行中: $\begin{cases} \text{误:} & \hat{\sigma}^2 = \sum_{i=1}^8 x_i^2 p_i - \hat{\mu}^2 = 4.838 - 2.198^2 = 0.0824^2, \\ \text{正:} & \hat{\sigma}^2 = \sum_{i=1}^8 x_i^2 p_i - \hat{\mu}^2 = 4.843 - 2.199^2 = 0.086^2, \end{cases}$

P_{53} , 第 7-8 行中: $\begin{cases} \text{误:} & \text{设 } \mathbf{X} = (X_1, \dots, X_n) \text{ 是从自总体 } f(x|\theta) \text{ 中抽取的简单样本.} \\ \text{正:} & \text{设 } \mathbf{X} = (X_1, \dots, X_n) \text{ 是从自总体 } f(x|\theta) \text{ 中抽取的简单样本.} \\ & \text{注: 将 } \theta \text{ 改为黑体的 } \theta \end{cases}$

P_{53} , 第 8-9 行中: $\begin{cases} \text{误:} & \text{Jeffreys 用费希尔信息阵行列式的平方根作为 } \theta \text{ 的无信息先验,} \\ \text{正:} & \text{Jeffreys 用费希尔信息阵行列式的平方根作为 } \theta \text{ 的无信息先验,} \\ & \text{注: 将 } \theta \text{ 改为黑体的 } \theta \end{cases}$

P_{63} , -2 至 -1 行中: $\begin{cases} \text{误:} & \text{仍想使用贝叶斯方法的情况, 故引入了无信息先验分布.} \\ \text{正:} & \text{仍想使用贝叶斯方法, 引入了无信息先验分布.} \end{cases}$

P_{66} , 第 6 行中: $\begin{cases} \text{误:} & I_{\pi(\theta)}(\theta, \mathbf{x}^{(k)}) = \int_{\Theta} \pi(\theta) \ln \frac{f_k(\theta)}{\pi(\theta)} d\theta \\ \text{正:} & I_{\pi(\theta)}(\theta, \mathbf{x}^{(k)}) = \int_{\Theta} \pi(\theta) \ln \frac{f_k(\theta)}{\pi(\theta)} d\theta \end{cases}$

P_{77} , -3 至 -2 行 (题 7) 中: $\begin{cases} \text{误:} & \text{如 } \theta_1, \dots, \theta_n \text{ 是来自伽玛分布 } \Gamma(r, \lambda) \text{ 的样本,} \\ \text{正:} & \text{如 } \theta_1, \dots, \theta_n \text{ 是相互独立来自伽玛分布 } \Gamma(r, \lambda) \text{ 的样本,} \end{cases}$

P_{77} , -1 行 (题 8) 中: $\begin{cases} \text{误:} & \text{在上题中, 设 } n = 3, x_1 = 3, x_2 = 0, x_3 = 5, \text{ 找出 } ML-II \text{ 先验.} \\ \text{正:} & \text{在上题中, 设 } n = 3, x_1 = 3, x_2 = 0, x_3 = 5, r = 4, \text{ 找出 } ML-II \text{ 先验.} \end{cases}$

P_{78} , 第 2 行 (题 9) 中: $\begin{cases} \text{误:} & \hat{\lambda} = \frac{S^2 - \bar{x}}{\bar{x}} \quad (0 < \bar{x} < S^2). \\ \text{正:} & \hat{\lambda} = \frac{\bar{x}}{S^2 - \bar{x}} \quad (0 < \bar{x} < S^2). \\ & \text{注: 将 } \hat{\lambda} \text{ 表达式的分子和分母颠倒一下} \end{cases}$

第三章

P_{82} , 第 7 行中: $\begin{cases} \text{误:} & \pi(\theta|x) \propto l(\theta|x)\pi(\theta). \\ \text{正:} & \pi(\theta|x) \propto l(\theta|x)\pi(\theta) \propto \{l(\theta|x) \text{ 之核}\} \cdot \{\pi(\theta) \text{ 之核}\}. \end{cases}$

P_{82} , 第 9-11 行中:

$\begin{cases} \text{误:} & \text{将式 (3.1.2) 右边添加一个与 } \theta \text{ 无关 (但可与 } x \text{ 有关) 的正则化常数因子 } c(x), \text{ 使得} \\ & \int_{\Theta} c(x)l(\theta|x)\pi(\theta)d\theta = 1, \text{ 则 } \pi(\theta|x) = c(x)l(\theta|x)\pi(\theta) \text{ 就是 } \theta \text{ 的后验概率密度函数.} \\ \text{正:} & \text{将 (3.1.2) 式右边添加一个与 } \theta \text{ 无关 (但可与 } x \text{ 有关) 的正则化常数因子 } c(x), \text{ 使得} \\ & \pi(\theta|x) = c(x) \cdot \{l(\theta|x) \text{ 之核}\} \cdot \{\pi(\theta) \text{ 之核}\} \\ & \text{就是 } \theta \text{ 的后验概率密度函数.} \end{cases}$

P_{90} , 第 6-7 行中:

$\begin{cases} \text{误:} & \pi(\theta|\mathbf{x}) = \frac{\Gamma(n+k/2)}{\Gamma(x_1+1/2)\cdots\Gamma(x_k+1/2)} \theta_1^{x_1-1/2} \cdots \theta_k^{x_k-1/2}, \\ & \text{这是一个狄利克雷 (Dirichlet) 分布 } D(x_1 + 1/2, \dots, x_k + 1/2). \\ \text{正:} & \pi(\theta|\mathbf{x}) = \frac{\Gamma(n+k/2)}{\Gamma(x_1+1/2)\cdots\Gamma(x_k+1/2)} \theta_1^{x_1-1/2} \cdots \theta_k^{x_k-1/2}, \\ & \text{其中 } \theta_i \geq 0, i = 1, \dots, k, \sum_{i=1}^k \theta_i = 1. \text{ 这是一个狄利克雷 (Dirichlet) 分布} \\ & D(x_1 + 1/2, \dots, x_k + 1/2). \end{cases}$

P_{94} , 第 4 行中: $\begin{cases} \text{误:} & \mathbf{3.} \mu \text{ 和 } \sigma^2 \text{ 皆未知的情形} \\ \text{正:} & \mathbf{3.} \text{ 当 } \theta \text{ 和 } \sigma^2 \text{ 皆未知的情形} \end{cases}$

P_{99} , -3 行中: $\begin{cases} \text{误:} & \text{用使后验密度 } \pi(\theta|x) \text{ 达到最大时 } \theta \text{ 的值作为 } \theta \text{ 的估计量,} \\ \text{正:} & \text{用使后验密度 } \pi(\theta|\mathbf{x}) \text{ 达到最大时 } \theta \text{ 的值作为 } \theta \text{ 的估计量,} \\ & \text{注: 将 } x \text{ 改为黑体的 } \mathbf{x} \end{cases}$

P_{100} , 第 4 行 (注 3.4.1) 中: $\begin{cases} \text{误:} & \text{一般场合下, 这三种估计是不同的, 但当后验密度对称时,} \\ \text{正:} & \text{一般场合下, 这三种估计是不同的, 但当后验密度为单峰对称时,} \end{cases}$

P_{100} , 第 11 行中: $\begin{cases} \text{误:} & \text{由于后验分布 } N(\mu_n(\mathbf{x}), \eta_n^2) \text{ 为对称分布,} \\ \text{正:} & \text{由于后验分布 } N(\mu_n(\mathbf{x}), \eta_n^2) \text{ 为单峰对称分布,} \end{cases}$

P_{108} , -7 行 (定义 3.5.1) 中: $\begin{cases} \text{误:} & \text{设参数 } \theta \text{ 的后验分布为 } \pi(\theta|\bar{x}), \\ \text{正:} & \text{设参数 } \theta \text{ 的后验分布为 } \pi(\theta|x), \end{cases}$

P_{112} , -11 行中: $\begin{cases} \text{误:} & \text{则 } 2(t + \beta)\theta^{-1} \sim \chi_{2(r+\alpha)}^2, \\ \text{正:} & \text{则 } 2(t + \beta)\theta^{-1}|t \sim \chi_{2(r+\alpha)}^2, \end{cases}$

P_{113} , 第 12 行中: $\begin{cases} \text{误:} & \text{等尾可信区间在实际中常被用, 其计算方便, 但不是最好的,} \\ \text{正:} & \text{等尾可信区间在实际中常被用, 其计算方便, 但不一定是最好的,} \end{cases}$

P_{115} , 第 2 行中: $\begin{cases} \text{误:} & \text{取先验 } \pi(\theta) \equiv 1 \ (\theta \in \mathbb{R}), \\ \text{正:} & \text{取先验 } \pi(\theta) \equiv 1 \ (\theta > 0), \end{cases}$

P_{115} , 第 6 行中: $\begin{cases} \text{误:} & \pi(\theta|\mathbf{x}) = \frac{\prod_{i=1}^n [1 + (x_i - \theta)^2]^{-1}}{\int_0^\infty \prod_{i=1}^n [1 + (x_i - \theta)^2]^{-1} d\theta}. \\ \text{正:} & \pi(\theta|\mathbf{x}) = \frac{\prod_{i=1}^n [1 + (x_i - \theta)^2]^{-1}}{\int_0^\infty \prod_{i=1}^n [1 + (x_i - \theta)^2]^{-1} d\theta}, \quad \theta > 0. \end{cases}$

P_{117} , -10 行中: $\begin{cases} \text{误:} & \text{其中 } \Theta_0 \text{ 和 } \Theta_1 \text{ 是参数空间 } \Theta \text{ 的两个真子集,} \\ \text{正:} & \text{其中 } \Theta_0 \text{ 和 } \Theta_1 \text{ 是参数空间 } \Theta \text{ 的两个非空真子集,} \end{cases}$

P_{117} , -9 行中: $\begin{cases} \text{误:} & (2) \text{ 选择检验统计 } T(\mathbf{X}), \\ \text{正:} & (2) \text{ 选择检验统计量 } T(\mathbf{X}), \end{cases}$

$$P_{119}, \text{第 11 行中: } \begin{cases} \text{误:} & H_0 : \Theta_0 = \{\theta_0\} \longleftrightarrow H_1 : \Theta_1 = \{\theta_1\}. \\ \text{正:} & H_0 : \theta \in \Theta_0 = \{\theta_0\} \longleftrightarrow H_1 : \theta \in \Theta_1 = \{\theta_1\}. \end{cases}$$

$$P_{121}, \text{-8 行中: } \begin{cases} \text{误:} & \text{在这一情形下说仅仅由数据来决定上述比值就是合理的了.} \\ \text{正:} & \text{在这一情形下才可以说仅仅由数据来决定上述比值是合理的了.} \end{cases}$$

$$P_{126}, \text{-1 行中: } \begin{cases} \text{误:} & \text{设在 } (-\infty, 1/2) \cup (1/2, \infty) \text{ 上的密度 } g_1(\theta) \text{ 为 } (0,1) \text{ 上的均匀分布 } U(0,1). \\ \text{正:} & \text{设在 } (0, 1/2) \cup (1/2, 1) \text{ 上的密度 } g_1(\theta) \text{ 为 } (0,1) \text{ 上的均匀分布密度函数.} \end{cases}$$

$$P_{127}, \text{-4 行中: } \begin{cases} \text{误:} & \text{其中 } \Theta_1 \cup \Theta_2 \cup \dots \cup \Theta_k = \Theta, \text{ 每个 } \Theta_i \text{ 为 } \Theta \text{ 的真子集.} \\ \text{正:} & \text{其中 } \Theta_1 \cup \Theta_2 \cup \dots \cup \Theta_k = \Theta, \text{ 每个 } \Theta_i \text{ 为 } \Theta \text{ 的非空真子集.} \end{cases}$$

$$P_{129}, \text{-5 行中: } \begin{cases} \text{误:} & f(\theta|x) = P(X = x|\theta) = \binom{n}{x} \theta^x (1-\theta)^{n-x} \quad (x = 0, 1, \dots, n). \\ \text{正:} & f(x|\theta) = P(X = x|\theta) = \binom{n}{x} \theta^x (1-\theta)^{n-x} \quad (x = 0, 1, \dots, n). \end{cases}$$

$$P_{130}, \text{第 11 行中: } \begin{cases} \text{误:} & p(5|3) = 0.02128. \\ \text{正:} & p(5|3) = 0.01282. \end{cases}$$

P_{136} , 第 7-8 行 (习题 21) 中:

$$\begin{cases} \text{误:} & \text{求 } \theta \text{ 的广义极大似然估计和后验均值估计, 以及它们各自的后验方差.} \\ \text{正:} & \text{求 } \theta \text{ 的后验众数估计和后验期望估计, 以及它们的后验均方误差或后验方差.} \end{cases}$$

$$P_{136}, \text{第 13 行中: } \begin{cases} \text{误:} & \text{设 } \mathbf{X} = (X_1, \dots, X_r) \text{ 服从多项分布 } M(r, \boldsymbol{\theta}), \\ \text{正:} & \text{设 } \mathbf{X} = (X_1, \dots, X_r) \text{ 服从多项分布 } M(N, \boldsymbol{\theta}), \end{cases}$$

P_{137} , -3 至 -1 行 (题 38) 中:

$$\begin{cases} \text{误:} & \text{求检验问题} \\ & H_0 : 0 \leq \theta \leq 15 \leftrightarrow H_1 : \theta > 15 \\ & \text{的每个假设的后验概率、后验概率比和贝叶斯因子, 并对此检验作出结论.} \\ \text{正:} & \text{求多重检验问题} \\ & H_1 : 0 < \theta \leq 15, H_2 : 15 < \theta \leq 30, H_3 : \theta > 30. \end{cases}$$

P_{137} 最后一行后增加 2 个习题, 即题 39 和题 40:

39. 中超联赛中某足球队在当年已进行过的 12 场比赛中获胜了 5 场, 设 θ 表示此球队在一场比赛中获胜的概率, 假定 θ 的先验为 $(0,1)$ 区间上的无信息先验 $U(0,1)$, 对此足球队在当年剩下的 8 场比赛获胜的次数作出预测.

40. (续例 3.7.2) 若两架天平称重的方差相同, 皆为 0.25. 设第一架天平称一颗钻石 10 次, 重量分别为 9.45, 10.62, 9.40, 10.12, 9.85, 10.92, 10.93, 9.85, 9.81, 10.28 (单位: 克). 令 θ 表示钻石的真实重量, 根据这颗钻石的历史资料可假定 $\theta \sim N(10, 1)$, 试求用第二架天平称此颗钻石重量 Z 的预测值和可信系数为 95% 的预测区间.

第四章

P_{140} , -3 行中: $\begin{cases} \text{误:} & \text{我们将证明: 由式 (4.2.1) 定义的后验风险最小准则下} \\ \text{正:} & \text{我们将证明: 由式 (4.2.2) 定义的后验风险最小准则下} \end{cases}$

P_{141} , 第 1 行中: $\begin{cases} \text{误:} & \text{定理 4.2.1 设存在非随机化决策函数 } \delta_{\pi}(x), \\ \text{正:} & \text{定理 4.2.1 设存在决策函数 } \delta_{\pi}(x), \end{cases}$

P_{141} , 第 4 行中: $\begin{cases} \text{误:} & \text{证 设 } \delta(x) \text{ 为任一非随机化决策函数,} \\ \text{正:} & \text{证 设 } \delta(x) \text{ 为任一决策函数,} \end{cases}$

P_{142} , -10 至 -9 行中: $\begin{cases} \text{误:} & \text{若先验分布 } \pi(\theta) \text{ 为 } N(\mu, \tau^2), \text{ 求平方损失下 } \theta \text{ 的贝叶斯估计.} \\ \text{正:} & \text{若先验分布 } \pi(\theta) \text{ 为 } N(\mu, \tau^2), \mu \text{ 和 } \tau^2 \text{ 已知, 求平方损失下 } \theta \\ & \text{的贝叶斯估计.} \end{cases}$

P_{142} , -4 行中: $\begin{cases} \text{误:} & \text{例 4.3.2 设 } X \sim P(\theta), \text{ 即} \\ \text{正:} & \text{例 4.3.2 设 } X \sim \text{泊松分布 } P(\theta), \text{ 即} \end{cases}$

P_{151} , 第 1 行中: $\begin{cases} \text{误:} & \text{由例 3.3.1 已知 } \pi(\theta|\mathbf{x}) \text{ 为 } N(\mu_n(\bar{x}), \eta_n^2), \text{ 其中} \\ \text{正:} & \text{由例 3.3.1 已知 } \pi(\theta|\bar{x}) \text{ 为 } N(\mu_n(\bar{x}), \eta_n^2), \text{ 其中} \end{cases}$

P_{151} , 第 5 行和第 9 行中: $\begin{cases} \text{误:} & P(\Theta_1|\mathbf{x}) = \\ \text{正:} & P(\Theta_1|\bar{x}) = \end{cases}$

P_{151} , 第 2, 5, 7, 9, 11, 13 行中 (共 7 处), 将 “ $\mu_n(\mathbf{x})$ ” 改为 “ $\mu_n(\bar{x})$ ”

P_{152} , -3 至 -1 行中: $\begin{cases} \text{误:} & L(\theta, a_2) = \begin{cases} 90 - \theta, & \theta < 90, \\ 0, & 90 \leq \theta \leq 110, \\ \theta - 110, & (\theta > 110), \end{cases} \\ \text{正:} & L(\theta, a_2) = \begin{cases} 90 - \theta, & \theta < 90, \\ 0, & 90 \leq \theta \leq 110, \\ \theta - 110, & \theta > 110, \end{cases} \\ & \text{注: 将最后一行中的括号去掉} \end{cases}$

P_{154} , 第 4 行中: $\begin{cases} \text{误:} & = m_1[d_2(\mathbf{x}) - d_1(\mathbf{x})] + m_2P(\theta \notin C(\mathbf{x})). \\ \text{正:} & = m_1[d_2(\mathbf{x}) - d_1(\mathbf{x})] + m_2P(\theta \notin C(\mathbf{x})|\mathbf{x}). \end{cases}$

P_{160} , -1 行中: $\begin{cases} \text{误:} & \{N(\theta, \sigma^2) : \sigma^2 \text{ 已知, } -\infty < \theta < \infty\}, \\ \text{正:} & \{N(a, \sigma^2) : \sigma^2 \text{ 已知, } -\infty < a < \infty\}, \\ & \text{注: 此处及以下 } P_{161} \text{ 中几处所列勘误, 皆是将 } \theta \text{ 改为 } a \end{cases}$

$$P_{161}, \text{第 2 行中: } \begin{cases} \text{误:} & Y_i \text{ iid} \sim \{N(\theta + c, \sigma^2) : \sigma^2 \text{ 已知}, -\infty < \theta < \infty, -\infty < c < \infty\}. \\ \text{正:} & Y_i \text{ iid} \sim \{N(a + c, \sigma^2) : \sigma^2 \text{ 已知}, -\infty < a < \infty, -\infty < c < \infty\}. \end{cases}$$

$$P_{161}, \text{第 4-5 行中: } \begin{cases} \text{误:} & \theta \rightarrow \eta \text{ (即 } \eta = \theta + c) \\ \text{正:} & a \rightarrow \eta \text{ (即 } \eta = a + c) \end{cases}$$

$$P_{161}, \text{第 7-8 行中: } \begin{cases} \text{误:} & \theta \rightarrow \eta, \text{ 引进行动空间 } \mathcal{D} \text{ 上的变换 } d \rightarrow d^*, \text{ 使得 } L(d^*, \eta) = L(d, \theta). \\ \text{正:} & a \rightarrow \eta, \text{ 引进行动空间 } \mathcal{D} \text{ 上的变换 } d \rightarrow d^*, \text{ 使得 } L(d^*, \eta) = L(d, a). \end{cases}$$

$$P_{161}, \text{第 9-10 行中: } \begin{cases} \text{误:} & \text{诱导参数空间上的变换 } \eta = \theta + c, \\ \text{正:} & \text{诱导参数空间上的变换 } \eta = a + c, \end{cases}$$

$$P_{161}, \text{第 10-11 行中: } \begin{cases} \text{误:} & \text{则对平方损失函数 } L(\theta, d) = (\theta - d)^2 \text{ 条件 } L(d, \theta) = L(d^*, \eta) \text{ 成立.} \\ \text{正:} & \text{则对平方损失函数 } L(a, d) = (a - d)^2 \text{ 条件 } L(d, a) = L(d^*, \eta) \text{ 成立.} \end{cases}$$

$$P_{172}, \text{第 11 行中: } \begin{cases} \text{误:} & \mu^\pi(x) = E^{\pi(\theta|x)}[\theta] = \lambda(x)\mu_0^\pi(x) + (1 - \lambda(x))\mu^q(x). \\ \text{正:} & \mu^\pi(x) = E^{\pi(\theta|x)}[\theta] = \lambda(x)\mu^{\pi_0}(x) + (1 - \lambda(x))\mu^q(x). \end{cases}$$

$$P_{181}, \text{第 6-7 行中: } \begin{cases} \text{误:} & \text{假如未知参数 } \theta \text{ 的先验分布为指数分布 } \text{Exp}\{\theta\}. \\ \text{正:} & \text{假如未知参数 } \theta \text{ 的先验分布为指数分布 } \text{Exp}\{\lambda\}. \end{cases}$$

$$P_{182}, \text{第 4 行中: } \begin{cases} \text{误:} & \text{易知 } E(X|\theta) = r\theta, D(X|\theta) = r\theta(1 - \theta). \\ \text{正:} & \text{易知 } E(X|\theta) = r\theta, D(X|\theta) = r\theta(1 + \theta). \end{cases}$$

$$P_{186}, \text{第 1-2 行中: } \begin{cases} \text{误:} & \text{设先验分布如 10(2) 题所述, 在平方损失函数 } L(\theta, d) = (\theta - d)^2 \text{ 下,} \\ & \text{求 } \theta \text{ 的贝叶斯估计和 Minimax 估计.} \\ \text{正:} & \text{设先验分布和损失函数如 10(1) 题所述, 证明 } \theta \text{ 的贝叶斯估计也是} \\ & \text{Minimax 估计.} \end{cases}$$

第五章

$$P_{189}, \text{-3 行中: } \begin{cases} \text{误:} & = e^{-nh(\hat{\theta})}(2\pi)^{k/2}n^{k/2}|\Delta_h(\hat{\theta})|^{-1/2}\{q(\hat{\theta}) + O(n^{-1})\}. \\ \text{正:} & = e^{-nh(\hat{\theta})}(2\pi)^{k/2}n^{-k/2}|\Delta_h(\hat{\theta})|^{-1/2}\{q(\hat{\theta}) + O(n^{-1})\}. \end{cases}$$

$$P_{193}, \text{-8 行中: } \begin{cases} \text{误:} & \text{统计蒙特卡洛抽样方法也是一个可选的计算方法.} \\ \text{正:} & \text{蒙特卡洛抽样方法也是一个可选的计算方法.} \end{cases}$$

$$P_{195}, \text{-7 至 -6 行中: } \begin{cases} \text{误:} & \text{其中 } \theta \text{ 服从双指数先验分布, 即密度为 } \frac{1}{2}e^{-|\theta|/2}, \\ \text{正:} & \text{其中 } \theta \text{ 服从双指数先验分布, 即密度为 } \frac{1}{4}e^{-|\theta|/2}, \end{cases}$$

$$P_{212}, -4 \text{ 行中: } \begin{cases} \text{误:} & \frac{250!}{x_1! \cdots x_5!} p_1^{x_1} p_2^{x_2} p_3^{x_3} p_4^{x_4} p_5^{x_5}. \\ \text{正:} & \pi(\beta|\mathbf{x}) \propto l(\mathbf{p}(\beta)|\mathbf{x}) \cdot \pi(\beta) \propto \left(\frac{1}{3}\right)^{x_1} \left(\frac{1-\beta}{3}\right)^{x_2} \left(\frac{1-2\beta}{3}\right)^{x_3} \left(\frac{2\beta}{3}\right)^{x_4} \left(\frac{\beta}{3}\right)^{x_5}. \end{cases}$$

$$P_{216}, \text{ 第 12 行中: } \begin{cases} \text{误:} & \text{当状态空间为多维时, 不整体更新 } X_n, \\ \text{正:} & \text{当状态空间为多维时, 不整体更新 } \mathbf{X}_n, \\ & \text{注: 将 } X_n \text{ 改为黑体的 } \mathbf{X}_n \end{cases}$$

$$P_{216}, -10 \text{ 至 } -9 \text{ 行中: } \begin{cases} \text{误:} & f(x_i|\mathbf{x}_{-i}) = f(x)/\int f(x_1, \cdots, x_k) dx_i \text{ 表示 } X_i \text{ 对其他分量的条件密度.} \\ \text{正:} & f(x_i|\mathbf{x}_{-i}) = f(\mathbf{x})/\int f(x_1, \cdots, x_k) dx_i \text{ 表示 } X_i \text{ 对其他分量的条件密度.} \\ & \text{注: 将 } f(x) \text{ 中的 } x \text{ 改为黑体 } \mathbf{x} \end{cases}$$

$$P_{221}, \text{ 第 1 行中: } \begin{cases} \text{误:} & \text{对 } t = 1, \cdots, T: \\ \text{正:} & \text{在 } t = 0 \text{ 时, 将 } (\beta_0, \beta_1) \text{ 赋初始值 } (\beta_0^{(0)}, \beta_1^{(0)}), \text{ 对 } t = 1, 2, \cdots, T \text{ 重复下列步骤:} \end{cases}$$

$$P_{221}, \text{ 第 11 行中: } \begin{cases} \text{误:} & \text{(h) 令 } \beta^{(t)} = \beta. \\ \text{正:} & \text{(h) 令 } \beta^{(t)} = \beta. \\ & \text{(i) 增加 } t, \text{ 返回到 (a).} \\ & \text{注: 即在 } P_{221} \text{ 第 11 行后增加如上的一行} \end{cases}$$

$$P_{222}, -7 \text{ 行中: } \begin{cases} \text{误:} & \text{(a) 从 } f(X_j|x_{-j}) \text{ 中产生候选点 } X_j^*(t). \\ \text{正:} & \text{(a) 从 } f(x_j|\mathbf{x}_{-j}) \text{ 中产生候选点 } X_j^*(t). \\ & \text{注: 将 } X_j|x_{-j} \text{ 中的 } X_j \text{ 改为小写的 } x_j, \text{ 同时将其中 } x_{-j} \text{ 改为黑体的 } \mathbf{x}_{-j}. \end{cases}$$

$$P_{224}, \text{ 第 7 行中: } \begin{cases} \text{误:} & \text{Gibbs 算法如下:} \\ \text{正:} & \text{Gibbs 算法如下: 在 } t = 0 \text{ 时初始化 } \mathbf{X}(0), \text{ 对 } t = 1, 2, \cdots, T \text{ 重复下列步骤:} \end{cases}$$

$$P_{224}, \text{ 第 12 行中: } \begin{cases} \text{误:} & \text{(5) 令 } \mathbf{X}(t) = (X_1^*(t), X_2^*(t)). \\ \text{正:} & \text{(5) 令 } \mathbf{X}(t) = (X_1^*(t), X_2^*(t)). \\ & \text{(6) 增加 } t, \text{ 返回到 (1).} \\ & \text{注: 即在 } P_{224} \text{ 第 12 行后增加如上的一行} \end{cases}$$

$$P_{225}, \text{ 第 10 行中: } \begin{cases} \text{误:} & \text{取先验分布为} \\ \text{正:} & \text{令 } \mu \text{ 和 } \sigma^2 \text{ 的先验分布独立, 分别为} \end{cases}$$

$$P_{225}, -9 \text{ 行中: } \begin{cases} \text{误:} & \text{对 } t = 1, \cdots, T, \\ \text{正:} & \text{在 } t = 0 \text{ 时, 将 } (\mu, \sigma) \text{ 赋初值 } (\mu^{(0)}, \sigma^{(0)}), \text{ 对 } t = 1, 2, \cdots, T \text{ 重复下列步骤:} \end{cases}$$

$$P_{225}, -2 \text{ 行中: } \begin{cases} \text{误:} & \text{(7) 令 } \sigma^2 = 1/\tau \text{ 以及 } \sigma^{(t)} = \sigma. \\ \text{正:} & \text{(7) 令 } \sigma^2 = 1/\tau \text{ 以及 } \sigma^{(t)} = \sigma. \\ & \text{(8) 增加 } t, \text{ 返回到 (1).} \\ & \text{注: 即在 } P_{225} -2 \text{ 行后增加如上的一行} \end{cases}$$

P_{235} , -7 至 -6 行中: $\begin{cases} \text{误:} & \text{可以访问 } \text{http://www.mrc-bsu.cam.ac.uk/bugs/} \text{ 查看详细介绍.} \\ \text{正:} & \text{可以访问 } \text{http://www.mrc-bsu.cam.ac.uk/software/bugs/} \text{ 查看详细介绍.} \end{cases}$

第七章

$$P_{270}, -6 \text{ 行中: } \begin{cases} \text{误:} & P(M_k|\mathbf{x}_n) = \left[\sum_{j=1}^r \frac{P(M_j)}{P(M_k)} BF_{jk} \right]^{-1} \\ \text{正:} & P(M_k|\mathbf{x}_n) = \left[\sum_{j=1}^r \frac{P(M_j)}{P(M_k)} \cdot \frac{1}{BF_{kj}} \right]^{-1} \end{cases}$$

将 P_{271} , 8-15 行 (表 7.2.1) 中

表 7.2.1 Jeffreys 对贝叶斯因子 BF_{kj} 的值所表示的模型支持强度解释

贝叶斯因子	解释
$B_{kj} < 1$	否定模型 M_k
$1 < B_{kj} < 3$	对模型 M_k 的支持证据微乎其微
$3 < B_{kj} < 10$	较强的证据支持 M_k
$10 < B_{kj} < 30$	强烈的证据支持 M_k
$30 < B_{kj} < 100$	非常强烈的证据支持 M_k
$100 < B_{kj}$	肯定支持 M_k

改为

表 7.2.1 Jeffreys 对贝叶斯因子 BF_{kj} 的值所表示的模型支持强度解释

贝叶斯因子	解释
$B_{kj} < 1$	否定模型 M_k
$1 \leq B_{kj} < 3$	对模型 M_k 的支持证据微乎其微
$3 \leq B_{kj} < 10$	较强的证据支持 M_k
$10 \leq B_{kj} < 30$	强烈的证据支持 M_k
$30 \leq B_{kj} < 100$	非常强烈的证据支持 M_k
$100 \leq B_{kj}$	肯定支持 M_k

注: 表 7.2.1 中修改是将表中第一栏第 3-7 行中左侧的不等号 “<” 改为 小于等于号 “≤”

$$P_{276}, -6 \text{ 行中: } \begin{cases} \text{误:} & FBF_{kj}^b = \frac{\int \pi_k(\boldsymbol{\theta}_k) f_k(\mathbf{x}|\boldsymbol{\theta}_k) d\boldsymbol{\theta}_k}{\int \pi_j(\boldsymbol{\theta}_j) f_j(\mathbf{x}|\boldsymbol{\theta}_j) d\boldsymbol{\theta}_j} \cdot \frac{\int \pi_j(\boldsymbol{\theta}_j) [f_j(\mathbf{x}|\boldsymbol{\theta}_j)]^b d\boldsymbol{\theta}_j}{\int \pi_k(\boldsymbol{\theta}_k) [f_k(\mathbf{x}|\boldsymbol{\theta}_k)]^b d\boldsymbol{\theta}_k} \\ \text{正:} & FBF_{kj}^b = \frac{\int \pi_k(\boldsymbol{\theta}_k) f_k(\mathbf{x}|\boldsymbol{\theta}_k) d\boldsymbol{\theta}_k}{\int \pi_j(\boldsymbol{\theta}_j) f_j(\mathbf{x}|\boldsymbol{\theta}_j) d\boldsymbol{\theta}_j} \cdot \frac{\int \pi_j(\boldsymbol{\theta}_j) [f_j(\mathbf{x}|\boldsymbol{\theta}_j)]^b d\boldsymbol{\theta}_j}{\int \pi_k(\boldsymbol{\theta}_k) [f_k(\mathbf{x}|\boldsymbol{\theta}_k)]^b d\boldsymbol{\theta}_k} \end{cases}$$

$$P_{276}, -5 \text{ 行中: } \left\{ \begin{array}{l} \text{误:} \\ \text{正:} \end{array} \right. \left\{ \begin{array}{l} = B_{kj} \cdot \frac{\int \pi_j(\boldsymbol{\theta}_j)[f_j(\mathbf{x}|\boldsymbol{\theta}_j)]^b d\boldsymbol{\theta}_j}{\int \pi_k(\boldsymbol{\theta}_k)[f_k(\mathbf{x}|\boldsymbol{\theta}_k)]^b d\boldsymbol{\theta}_k}, \\ = BF_{kj} \cdot \frac{\int \pi_j(\boldsymbol{\theta}_j)[f_j(\mathbf{x}|\boldsymbol{\theta}_j)]^b d\boldsymbol{\theta}_j}{\int \pi_k(\boldsymbol{\theta}_k)[f_k(\mathbf{x}|\boldsymbol{\theta}_k)]^b d\boldsymbol{\theta}_k}, \end{array} \right.$$

第八章

$$P_{296}, \text{第 2-3 行中: } \left\{ \begin{array}{l} \text{误:} \\ \text{正:} \end{array} \right. \left\{ \begin{array}{l} \text{概率密度函数的核估计方法有多种,} \\ \text{概率密度函数的估计方法有多种,} \end{array} \right.$$

$$P_{298}, -14 \text{ 行中: } \left\{ \begin{array}{l} \text{误:} \\ \text{正:} \end{array} \right. \left\{ \begin{array}{l} f_n(x) = \frac{1}{nh_n} \sum_{i=1}^n K\left(\frac{x - \mathbf{X}_i}{h_n}\right) \\ f_n(x) = \frac{1}{nh_n} \sum_{i=1}^n K\left(\frac{x - X_i}{h_n}\right) \\ \text{注: 将 } K(\cdot) \text{ 中的 } \mathbf{X}_i \text{ 改为非黑体的 } X_i \end{array} \right.$$

$$P_{300}, -2 \text{ 行中: } \left\{ \begin{array}{l} \text{误:} \\ \text{正:} \end{array} \right. \left\{ \begin{array}{l} (1) E[|f_n(x) - f(x)|^2] \rightarrow 0 (n \rightarrow \infty); \\ (1) E|f_n(x) - f(x)|^2 \rightarrow 0 (n \rightarrow \infty); \end{array} \right.$$