

第三章 正态分布的贝叶斯推断

Wang Shujia

Contents

1	一元正态模型 (单参数)	2
1.1	方差已知	2
1.2	方差未知	3
2	一元正态模型 (多参数: 均值与方差都未知)	5
2.1	无信息先验	6
2.2	共轭先验	9
3	多元正态模型	11
3.1	多元正态分布及 Wishart 分布	11
3.2	多元正态模型 (协方差阵 Σ 已知)	12
3.3	多元正态模型 (协方差阵 Σ 未知)	12

1 一元正态模型（单参数）

1.1 方差已知

正态分布的定义

定义 1. 正态分布 $X \sim N(\mu, \sigma^2)$ 的 pdf 为

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

- 方差的倒数 $\tau = 1/\sigma^2$ 称为精度 (precision)
- 贝叶斯统计常用精度而不用方差。
- 在 WinBUGS 中，正态分布记为 $X \sim N(\mu, \tau)$
- 本节分别讨论 Location(μ) 和 scale (σ) 的贝叶斯估计

正态-正态模型（方差已知）

假设观察值 $\mathbf{x} = (x_1, \dots, x_n)'$ 来自正态总体 $N(\mu, \sigma^2)$, σ^2 已知。

如果先验分布也是正态: $\mu \sim N(\mu_0, \sigma_0^2)$,

则后验分布为

$$\mu|\mathbf{x} \sim N\left(\frac{\mu_0\tau_0 + n\bar{x}\tau}{\tau_0 + n\tau}, \frac{1}{\tau_0 + n\tau}\right)$$

记为 $\mu|\mathbf{x} \sim N(\mu_n, \sigma_n^2)$, 其中 $\tau = 1/\sigma^2$ 为总体分布（一个样本）的精度, $\tau_0 = 1/\sigma_0^2$ 为先验分布的精度。

贝叶斯收缩

- 参数 μ 的贝叶斯估计: 后验均值

$$\begin{aligned} E(\mu|\mathbf{x}) &= \frac{\mu_0\tau_0 + n\bar{x}\tau}{\tau_0 + n\tau} \\ &= w\mu_0 + (1-w)\bar{x} \end{aligned}$$

- 参数 μ 的贝叶斯估计等于先验均值 μ_0 和样本均值 \bar{x} 的加权平均
 - 相当于由 \bar{x} 向先验均值 μ_0 收缩, 称为贝叶斯收缩 (Bayes Shrinkage)
 - 权重 $w = \tau_0/(\tau_0 + n\tau)$: 先验精度所占的比重
- 当数据 $n \rightarrow \infty$ 时, $w \rightarrow 0$, 此时 $\theta|\mathbf{x} \approx N(\bar{x}, \sigma^2/n)$
- 当数据 $n \approx 0$ 时, $w = 1$, 此时 $\theta|\mathbf{x} \approx N(\mu_0, \sigma_0^2)$

贝叶斯估计的精度

- 后验分布的方差:

$$D(\mu|\mathbf{x}) = \frac{1}{\tau_0 + n\tau} = \frac{\sigma_0^2\sigma^2}{n\sigma_0^2 + \sigma^2}$$

- 后验精度 = $\tau_0 + n\tau$ = 先验精度 ($1/\sigma_0^2$) + 数据精度 (n/σ^2)
- 当先验精度 $\tau_0 \approx 0$, 此时 $\theta|\mathbf{x} \approx N(\bar{x}, \sigma^2/n)$
- 当先验精度 $\tau_0 \approx \infty$, $D(\mu|\mathbf{x}) \rightarrow 0$, 此时 $\theta|\mathbf{x} \approx \mu_0$

预测分布

- 后验分布为: $\mu|\mathbf{y} \sim N(\mu_n, \sigma_n^2)$
- 设 \tilde{y} 是一个未来观察值, 则 $\tilde{y}|\mu \sim N(\mu, \sigma^2)$ 。 \tilde{y} 的后验预测均值和方差为:

$$\begin{aligned} E(\tilde{y}|\mathbf{y}) &= E[E(\tilde{y}|\mu)|\mathbf{y}] = E(\mu|\mathbf{y}) = \mu_n \\ \text{Var}(\tilde{y}|\mathbf{y}) &= \text{Var}[E(\tilde{y}|\mu)|\mathbf{y}] + E[\text{Var}(\tilde{y}|\mu)|\mathbf{y}] \\ &= \text{Var}(\mu|\mathbf{y}) + E(\sigma^2|\mathbf{y}) \\ &= \sigma_n^2 + \sigma^2 \end{aligned}$$

即 \tilde{y} 的后验预测分布为:

$$\tilde{y}|\mathbf{y} \sim N(\mu_n, \sigma_n^2 + \sigma^2)$$

- 简捷推导: $\tilde{y}|\mathbf{y} = (\tilde{y} - \mu)|\mathbf{y} + \mu|\mathbf{y}$
- 不确定性两个来源: 后验分布 + 未来观测值

1.2 方差未知

逆伽玛-正态模型: 共轭先验

假设观察值 $\mathbf{x} = (x_1, \dots, x_n)'$ 来自正态总体 $N(\mu, \sigma^2)$, σ^2 未知, μ 已知。如何确定 σ^2 的共轭先验分布?

似然函数:

$$\begin{aligned} L(\sigma^2|\mathbf{x}) &\propto \sigma^{-n} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right) \\ &= (\sigma^2)^{-n/2} \exp\left(-\frac{T}{2\sigma^2}\right) \end{aligned}$$

其中 T 为充分统计量 $T = \sum (x_i - \mu)^2$
共轭先验的 pdf 应该有如下形式:

$$\pi(\sigma^2) \propto (\sigma^2)^{-(\alpha+1)} \exp\left(-\frac{\beta}{\sigma^2}\right)$$

逆伽玛分布

定义 2 (Inverse-Gamma). 如果 $1/X \sim \text{Gamma}(\alpha, \beta)$, 则称 X 服从逆伽玛分布, 记为 $X \sim \text{IG}(\alpha, \beta)$ 分布, 其 pdf 为:

$$f(x|\alpha, \beta) = \frac{\beta^\alpha}{\Gamma(\alpha)} x^{-(\alpha+1)} \exp(-\beta/x), (\alpha > 0, \beta > 0)$$

- $E(X) = \beta/(\alpha - 1)$, $\alpha > 1$
- $D(X) = \frac{\alpha^2}{(\alpha-1)^2(\alpha-2)}$, $\alpha > 2$
- If $X \sim \text{IG}(\alpha, \beta)$, then $1/X \sim \text{Gamma}(\alpha, \beta)$
- If $X \sim \text{IG}(\nu/2, \nu s^2/2)$, then $\nu s^2/X \sim \chi^2(\nu)$

逆伽玛-正态模型: 后验分布 (基于 IG)

事实 1 (方差的后验分布). 假设观察值 $\mathbf{x} = (x_1, \dots, x_n)'$ 来自总体 $N(\mu, \sigma^2)$, σ^2 未知, μ 已知。

假设先验: $\sigma^2 \sim \text{IG}(\nu_0/2, \nu_0 \sigma_0^2/2)$,

则后验分布为:

$$\sigma^2|\mathbf{x} \sim \text{IG}((\nu_0 + n)/2, (\nu_0 \sigma_0^2 + T)/2)$$

其中 $T = \sum_{i=1}^n (x_i - \mu)^2$

- 为共轭先验
- 后验分布也可以用 χ^2 分布表示

χ^2 分布

定义 3 (χ^2 -分布). 称 $X \sim \chi^2(\nu)$, 如果 $X = \sum_{i=1}^{\nu} X_i^2$, 其中 X_1, X_2, \dots, X_{ν} 为独立同分布的标准正态分布, 其 pdf 为

$$f(x) = \frac{(1/2)^{\nu/2}}{\Gamma(\nu/2)} x^{\nu/2-1} e^{-x/2} (x > 0; \nu > 0)$$

定义 4 ($\text{Inv-}\chi^2$). 称 $X \sim \text{Inv-}\chi^2(\nu)$ if $1/X \sim \chi^2(\nu)$

定义 5 ($\text{Scaled-Inv-}\chi^2$). 称 $X \sim \text{Scaled-Inv-}\chi^2(\nu, s^2)$ if $\nu s^2/X \sim \chi^2(\nu)$

Some Properties

- If $X \sim \chi(\nu)$, then $E(X) = \nu$, $D(X) = 2\nu$
- If $X_i \stackrel{iid}{\sim} N(0, 1)$, $i = 1, 2, \dots, \nu$, then $X = \sum_{i=1}^{\nu} X_i^2 \sim \chi^2(\nu)$
- If $X \sim \text{IG}(\nu/2, 1/2)$, then $X \sim \text{Inv-}\chi^2(\nu)$
- If $X \sim \text{Inv-}\chi^2(\nu)$, then $X \sim \text{Scaled-Inv-}\chi^2(\nu, 1/\nu)$
- If $\sigma^2 \sim \text{IG}(\nu_0/2, \nu_0 \sigma_0^2/2)$, then $\nu_0 \sigma_0^2/\sigma^2 \sim \chi^2(\nu)$,
or $\sigma^2 \sim \text{Scaled-Inv-}\chi^2(\nu_0, \sigma_0^2)$

逆卡方-正态模型：后验分布（基于 χ^2 ）

事实 2 (方差的后验分布). 假设观察值 $\mathbf{x} = (x_1, \dots, x_n)'$ 来自正态总体 $N(\mu, \sigma^2)$, σ^2 未知, μ 已知。

假设先验: $\sigma^2 \sim \text{Scaled-Inv-}\chi^2(\nu_0, \sigma_0^2)$

则后验分布为:

$$\sigma^2 | \mathbf{x} \sim \text{Scaled-Inv-}\chi^2(\nu_0 + n, \nu_0 \sigma_0^2 + T)$$

- 为共轭先验

2 一元正态模型 (多参数: 均值与方差都未知)

多参数模型

- 多参数贝叶斯模型:

1. 似然函数 $L(\boldsymbol{\theta} | \mathbf{y})$: 总体 $Y \sim f(y | \boldsymbol{\theta})$, 其中 $\boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_p)^T$ 为 p 维未知参数向量, y_1, y_2, \dots, y_n 为样本观察值,

$$L(\boldsymbol{\theta} | \mathbf{y}) = \prod_{i=1}^n f(y_i | \boldsymbol{\theta})$$

2. 先验分布: $\boldsymbol{\theta} \sim \pi(\boldsymbol{\theta})$
3. 后验分布: $p(\boldsymbol{\theta} | \mathbf{y}) \propto \pi(\boldsymbol{\theta}) L(\boldsymbol{\theta} | \mathbf{y})$

- Bad news:

- 实际应用中不容易明确多元参数 $\boldsymbol{\theta}$ 的先验分布;
- 计算困难, 因为涉及多重积分。

如果有多余参数

- 现实中有多个未知参数, 但只有一个或少数几个参数是我们感兴趣的
 - $\boldsymbol{\theta} = (\theta_1, \theta_2)^T$, 对 θ_1 感兴趣
 - θ_2 称为**多余参数** (Nuisance parameter)
- 如何对 θ_1 进行贝叶斯推断?
 - 联合后验分布对多余参数平均, 得到 θ_1 的边缘后验分布

$$\begin{aligned} p(\theta_1 | \mathbf{y}) &= \int p(\theta_1, \theta_2 | \mathbf{y}) d\theta_2 \\ &= \int p(\theta_1 | \theta_2, \mathbf{y}) p(\theta_2 | \mathbf{y}) d\theta_2 \end{aligned}$$

- $p(\theta_1 | \mathbf{y})$ 含义: 给定 θ_2 条件下, 对所有可能的 θ_2 进行加权平均, 权重函数为 $p(\theta_2 | \mathbf{y})$
- 一般情形下, 以上积分没有显式解, 需要随机模拟。

正态分布（均值、方差未知）的双参数模型

正态模型 $N(\mu, \sigma^2)$: 均值和方差均未知。

1. 如何给定 (μ, σ^2) 联合先验分布?
 - (a) 无信息先验
 - (b) 共轭先验
2. 如何对参数进行贝叶斯推断?
 - (a) μ 的边缘后验分布 $\mu|\mathbf{y}$?
 - (b) σ^2 的边缘后验分布 $\sigma^2|\mathbf{y}$?
 - (c) 预测分布 $\hat{y}|\mathbf{y}$?

2.1 无信息先验

联合后验分布

设 $Y \sim N(\mu, \sigma^2)$, μ 和 σ^2 未知。 $\mathbf{y} = (y_1, y_2, \dots, y_n)'$, 对 μ 感兴趣, σ^2 为多余参数

- 位置-尺度参数的 Jeffreys 无信息先验:

$$\pi(\mu, \sigma^2) \propto 1/\sigma^2$$

- 联合后验分布:

$$\begin{aligned} p(\mu, \sigma^2|\mathbf{y}) &\propto \pi(\mu, \sigma^2)f(\mathbf{y}|\mu, \sigma^2) \\ &\propto \sigma^{-(n+2)} \exp\left\{-\frac{1}{2\sigma^2}[(n-1)s^2 + n(\bar{y} - \mu)^2]\right\} \end{aligned}$$

其中 s^2 为样本方差 $s^2 = \frac{1}{n-1} \sum (y_i - \bar{y})^2$

- (\bar{y}, s^2) 是充分统计量 (Sufficient statistics)
- Q: μ 和 σ^2 的后验分布是否相互独立?

方差的 σ^2 边缘后验分布

- σ^2 的边缘后验分布:

$$\begin{aligned} p(\sigma^2|\mathbf{y}) &= \int p(\mu, \sigma^2|\mathbf{y})d\mu \\ &\propto (\sigma^2)^{-\frac{n+1}{2}} \exp\left[-\frac{(n-1)s^2}{2\sigma^2}\right] \end{aligned}$$

- 即 $\sigma^2|\mathbf{y} \sim \text{IG}(\frac{n-1}{2}, \frac{n-1}{2}s^2)$,
- 亦即 $\sigma^2|\mathbf{y} \sim \text{Scaled-inv-}\chi^2(n-1, s^2)$,
- 亦即

$$\frac{(n-1)s^2}{\sigma^2} \Big| \mathbf{y} \sim \chi^2(n-1)$$

均值 μ 的边缘后验分布

- μ 的后验条件分布

$$\mu|\sigma^2, \mathbf{y} \sim N(\bar{y}, \frac{\sigma^2}{n})$$

- μ 的边缘后验分布

$$\begin{aligned} p(\mu|\mathbf{y}) &= \int p(\mu|\sigma^2, \mathbf{y})p(\sigma^2|\mathbf{y})d\sigma^2 \\ &\propto \left[1 + \frac{n(\bar{y} - \mu)^2}{(n-1)s^2}\right]^{-n/2} \end{aligned}$$

即 $\mu|\mathbf{y} \sim t_{(n-1)}(\bar{y}, s^2/n)$, 或

$$\frac{\mu - \bar{y}}{s/\sqrt{n}}|\mathbf{y} \sim t(n-1)$$

- 结果等价于频率学派, 但解释不同

一般 t -分布的定义

定义 6. 一个随机变量称为 $T \sim t_\nu(\mu, \sigma^2)$, 如果 $T = \mu + \sigma Z$, 其中 Z 为标准 t -分布, 其 pdf 为

$$f(t|\nu, \mu, \sigma^2) = \frac{\Gamma[(\nu+1)/2]}{(\sigma^2\nu\pi)^{1/2}\Gamma(\nu/2)} \left[1 + \frac{(t-\mu)^2}{\nu\sigma^2}\right]^{-(\nu+1)/2}$$

其中 ν 为自由度, μ 为位置参数, σ 为尺度参数。

$$E(T) = \mu \quad (\nu > 1)$$

$$Var(T) = \frac{\nu\sigma^2}{\nu-2} \quad (\nu > 2)$$

如果 $\mu = 0, \sigma^2 = 1$, 则为标准 t -分布: $T \sim t(\nu)$ 。

预测分布

- 预测分布 $\tilde{y}|\mathbf{y}$:

$$\begin{aligned} p(\tilde{y}|\mathbf{y}) &= \iint f(\tilde{y}|\mu, \sigma^2, \mathbf{y})p(\mu, \sigma^2|\mathbf{y})d\mu d\sigma^2 \\ &= \int \left[\int f(\tilde{y}|\mu, \sigma^2, \mathbf{y})p(\mu|\sigma^2, \mathbf{y})d\mu \right] p(\sigma^2|\mathbf{y})d\sigma^2 \\ &= \int p(\tilde{y}|\sigma^2, \mathbf{y})p(\sigma^2|\mathbf{y})d\sigma^2 \end{aligned}$$

- 需要先求 $\hat{y}|\mathbf{y}, \sigma^2$ 的分布。方差已知时, 先验 $\mu \sim N(\mu_0, \sigma_0^2)$, 预测分布为 $\hat{y}|\mathbf{y}, \sigma^2 \sim N(\mu_n, \sigma_n^2)$, 无信息先验相当于 $\sigma_0^2 \rightarrow \infty$, 此时, 预测分布为: $\hat{y}|\mathbf{y}, \sigma^2 \sim N[\bar{y}, (1 + \frac{1}{n})\sigma^2]$
- 预测分布 $\hat{y}|\mathbf{y}$ (与 $\mu|\mathbf{y}$ 推导类似):

$$\hat{y}|\mathbf{y} \sim t_{n-1}[\bar{y}, (1 + \frac{1}{n})s^2]$$

巴菲特: 投资收益率

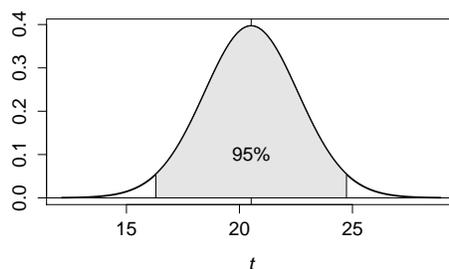
巴菲特从 1965-2012 年投资年回报率的均值为 20.65, 标准差为 14.52。假设年回报率 $y \sim N(\mu, \sigma^2)$, 采用无信息先验。

1. 平均回报率 μ 的分布及估计;
2. 投资风险值 σ^2 的分布及估计;
3. 预测巴菲特 2013 年的投资收益率。

巴菲特: 平均回报率

$$\mu|\mathbf{y} \sim t_{(n-1)}(\bar{y}, s^2/n) = t_{47}(20.52, 4.39), n = 48, \bar{y} = 20.52, s = 14.52$$

- 点估计: $\hat{\mu} = \bar{y} = 20.65$
- 95% 可信区间: [16.77, 26.33]



巴菲特: 方差 (风险)

$$\frac{(n-1)s^2}{\sigma^2} | \mathbf{y} \sim \chi^2(n-1)$$

$$\sigma^2 | \mathbf{y} = \frac{(n-1)s^2}{\chi^2(n-1)} \sim \text{Scaled - inv - } \chi^2(n-1, s^2)$$

用模拟的方法:

1. 抽取 N 个样本: `chisq<-rchisq(N,n-1)`
2. 计算: `V<-(n-1)*s^2/chisq`
3. 计算 95% 区间: `quantile(V,c(0.025,0.975))`
结果: N=100000, 95%CI: [146 331]

巴菲特：预测

预测分布： $\tilde{y}|\mathbf{y} \sim t_{n-1}[\bar{y}, (1 + \frac{1}{n})s^2] = t_{47}(20.65, 215.22)$

点预测： $E(\tilde{y}|\mathbf{y}) = \bar{y} = 20.65$,

预测区间： $[-8.99, 50.033]$

$$\bar{y} - st_{\alpha/2}(n-1)\sqrt{1 + \frac{1}{n}} \leq \tilde{y} \leq \bar{y} + st_{\alpha/2}(n-1)\sqrt{1 + \frac{1}{n}}$$

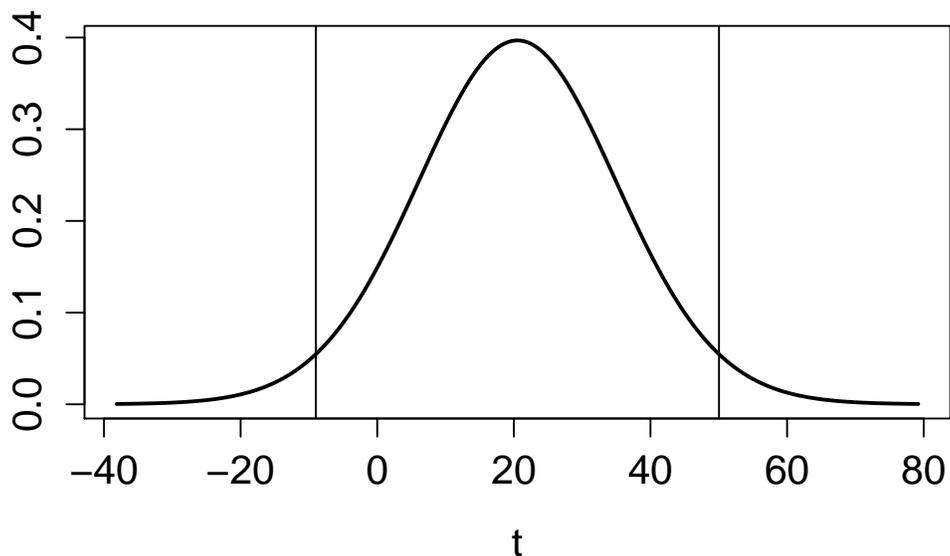
R codes:

```
tcrt<-qt(c(.025,.975),n-1)
```

```
CI<-ybar+s*tcrt*sqrt(1+1/n)
```

巴菲特：预测分布

Predictive Distribution



2.2 共轭先验

联合先验分布

- 模型 $y_1, \dots, y_n \sim N(\mu, \sigma^2)$, μ 和 σ^2 未知。
- 先验分布:

$$\mu|\sigma^2 \sim N(\mu_0, \frac{\sigma^2}{k_0}), \sigma^2 \sim \text{Inv} - \chi^2(\nu_0, \sigma_0^2)$$

联合先验分布

$$\pi(\mu, \sigma^2) \propto \frac{1}{\sigma} \frac{1}{(\sigma^2)^{\nu_0/2+1}} \exp\left(-\frac{1}{2\sigma^2}[\nu_0\sigma_0^2 + k_0(\mu - \mu_0)^2]\right)$$

- 称为: Normal-Inv- χ^2 分布
- μ 与 σ^2 独立吗?

联合后验分布

- 联合后验分布:

$$p(\mu, \sigma^2 | \mathbf{y}) \propto \frac{1}{\sigma} \frac{1}{(\sigma^2)^{\nu_n/2+1}} \exp\left(-\frac{1}{2\sigma^2}[\nu_n\sigma_n^2 + k_n(\mu - \mu_n)^2]\right)$$

其中

$$\begin{aligned}\mu_n &= \frac{k_0}{k_0 + n}\mu_0 + \frac{n}{k_0 + n}\bar{y} \\ k_n &= k_0 + n \\ \nu_n &= \nu_0 + n \\ \nu_n\sigma_n^2 &= \nu_0\sigma_0^2 + (n-1)s^2 + \frac{k_0n}{k_0 + n}(\bar{y} - \mu_0)^2\end{aligned}$$

- 也是 Normal-Inv- χ^2 分布, 所以共轭。

μ 的条件后验

- 条件后验分布: $p(\mu | \sigma^2, \mathbf{y})$

$$\mu | \sigma^2, \mathbf{y} \sim N(\mu_n, \sigma_n^2)$$

其中

$$\mu_n = \frac{\frac{k_0}{\sigma^2}\mu_0 + \frac{n}{\sigma^2}\bar{y}}{\frac{k_0}{\sigma^2} + \frac{n}{\sigma^2}} \quad \sigma_n^2 = \frac{1}{\frac{k_0}{\sigma^2} + \frac{n}{\sigma^2}}$$

- 与方差已知情形结果一致

μ 和 σ^2 的边缘后验

- 方差 σ^2 的后验分布:

$$\sigma^2 | \mathbf{y} \sim \text{Scaled - inv - } \chi^2(\nu_n, \sigma_n^2)$$

- 均值 μ 的边缘后验分布:

$$\mu | \mathbf{y} \sim t_{\nu_n}\left(\mu_n, \frac{\sigma_n^2}{k_n}\right)$$

小结：一元正态（均值、方差未知）的贝叶斯分析

A. 无信息先验： $\pi(\mu, \sigma^2) \propto 1/\sigma^2$

- σ^2 的边缘后验分布 $\sigma^2|\mathbf{y}$?

$$- \sigma^2|\mathbf{y} \sim \text{Inv-Gamma}\left(\frac{n-1}{2}, \frac{n-1}{2}s^2\right) = \text{Scaled-inv-}\chi^2(n-1, s^2)$$

- μ 的边缘后验分布 $\mu|\mathbf{y}$?

$$- \mu|\mathbf{y} \sim t_{n-1}(\bar{y}, s^2/n)$$

- 预测分布 $\tilde{y}|\mathbf{y}$?

$$- \tilde{y}|\mathbf{y} \sim t_{n-1}[\bar{y}, (1 + \frac{1}{n})s^2]$$

小结：一元正态（均值、方差未知）的贝叶斯分析

B. 共轭先验： $\mu|\sigma^2 \sim N(\mu_0, \frac{\sigma^2}{k_0})$, $\sigma^2 \sim \text{Inv-}\chi^2(\nu_0, \sigma_0^2)$

- σ^2 的边缘后验分布：

$$\sigma^2|\mathbf{y} \sim \text{Scaled-inv-}\chi^2(\nu_n, \sigma_n^2)$$

- μ 的条件后验分布：

$$\mu|\sigma^2, \mathbf{y} \sim N\left(\mu_n, \frac{\sigma_n^2}{k_n}\right)$$

- μ 的边缘后验分布：

$$\mu|\mathbf{y} \sim t_{\nu_n}\left(\mu_n, \frac{\sigma_n^2}{k_n}\right)$$

3 多元正态模型

3.1 多元正态分布及 Wishart 分布

多元正态分布的密度函数及似然函数

定义 7. 称 p 维随机向量 $\mathbf{y} \sim N_p(\boldsymbol{\mu}, \Sigma)$, 如果

$$f(\mathbf{y}|\boldsymbol{\mu}, \Sigma) \propto |\Sigma|^{-1/2} \exp\left(-\frac{1}{2}(\mathbf{y} - \boldsymbol{\mu})^T \Sigma^{-1}(\mathbf{y} - \boldsymbol{\mu})\right)$$

设有 n 个样本观察向量 $\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_n$, 则似然函数为

$$\begin{aligned} L(\boldsymbol{\mu}, \Sigma|\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_n) &\propto |\Sigma|^{-1/2} \exp\left(-\frac{1}{2} \sum (\mathbf{y}_i - \boldsymbol{\mu})^T \Sigma^{-1}(\mathbf{y}_i - \boldsymbol{\mu})\right) \\ &= |\Sigma|^{-1/2} \exp\left(-\frac{1}{2} \text{tr}(\Sigma^{-1} \mathbf{S}_0)\right) \end{aligned}$$

其中 $\mathbf{S}_0 = \sum_{i=1}^n (\mathbf{y}_i - \boldsymbol{\mu})(\mathbf{y}_i - \boldsymbol{\mu})^T$

Wishart and Inverse Wishart

定义 8 (Wishart 分布). 称 $p \times p$ 随机矩阵 $\mathbf{X} \sim \text{Wishart}_p(\Sigma, \nu)$, 如果其 pdf 为

$$f(\mathbf{X}) = \frac{|\mathbf{X}|^{\frac{\nu-p-1}{2}}}{2^{\frac{\nu p}{2}} |\Sigma|^{\frac{\nu}{2}} \Gamma_p(\frac{\nu}{2})} \exp\left[-\frac{1}{2} \text{tr}(\Sigma^{-1} \mathbf{X})\right]$$

1. 如果 $\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_n \stackrel{iid}{\sim} N_p(0, \Sigma)$, $\mathbf{X} = \sum_{i=1}^n \mathbf{z}_i \mathbf{z}_i^T \sim \text{Wishart}_p(\Sigma, n)$
2. 一维: $z_1, z_2, \dots, z_n \stackrel{iid}{\sim} N(0, \sigma^2)$, then $X = \sum z_i^2 \sim \sigma^2 \chi_n^2$
3. $E(\mathbf{X}) = \nu \Sigma$, $D(X_{ij}) = \nu(\sigma_{ij}^2 + \sigma_{ii} \sigma_{jj})$

定义 9 (Inverse Wishart). 称 $\mathbf{X} \sim \text{Inv-Wishart}_p(\Lambda, \nu)$, 如果 $\mathbf{X}^{-1} \sim \text{Wishart}_p(\Lambda^{-1}, \nu)$

- $E(\mathbf{X}) = \Lambda/(\nu - p - 1)$, $\text{Mod}(\mathbf{X}) = \Lambda/(\nu + p + 1)$

3.2 多元正态模型 (协差阵 Σ 已知)

多元正态 (协差阵已知): 共轭先验

模型: $\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_n \sim N_p(\boldsymbol{\mu}, \Sigma)$, Σ 已知。

先验: $\boldsymbol{\mu} \sim N_p(\boldsymbol{\mu}_0, \Lambda_0)$ 。

- 后验分布

$$\boldsymbol{\mu} | \mathbf{y} \sim N_p(\boldsymbol{\mu}_n, \Lambda_n)$$

其中

$$\begin{aligned} \boldsymbol{\mu}_n &= \Lambda_n (\Lambda_0^{-1} \boldsymbol{\mu}_0 + n \Sigma^{-1} \bar{\mathbf{y}}) \\ \Lambda_n &= (\Lambda_0^{-1} \boldsymbol{\mu}_0 + n \Sigma^{-1})^{-1} \end{aligned}$$

- 预测分布

$$\tilde{\mathbf{y}} | \mathbf{y} \sim N_p(\boldsymbol{\mu}_n, \Lambda_n + \Sigma)$$

- 与一维情形类似

3.3 多元正态模型 (协差阵 Σ 未知)

多元正态 (协差阵未知, 均值为 $\mathbf{0}$)

设 $\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_n \stackrel{iid}{\sim} N(0, \Sigma)$, 先验分布 $\Sigma \sim \text{Inv-Wishart}_p(\Lambda_0^{-1}, \nu_0)$, 则 Σ 的后验分布为

$$\Sigma | \mathbf{Y} \sim \text{Inv-Wishart}_p(\mathbf{S} + \Lambda_0^{-1}, n + \nu_0)$$

其中 $\mathbf{S} = \sum_{i=1}^n (\mathbf{y}_i - \bar{\mathbf{y}})(\mathbf{y}_i - \bar{\mathbf{y}})'$

多元正态（协差阵与均值均未知）：Jeffreys 无信息先验

无信息先验 (Jeffreys):

$$\pi(\boldsymbol{\mu}, \Sigma) \propto |\Sigma|^{-(p+1)/2}$$

• 后验分布:

$$\begin{aligned}\Sigma|\mathbf{y} &\sim \text{Inv-Wishart}_p(\mathbf{S}, n-1) \\ \boldsymbol{\mu}|\Sigma, \mathbf{y} &\sim \text{N}_p(\bar{\mathbf{y}}, \Sigma/n)\end{aligned}$$

• 边缘后验 $\boldsymbol{\mu}|\mathbf{y}$:

$$\boldsymbol{\mu}|\mathbf{y} \sim t_{n-p}[\bar{\mathbf{y}}, \mathbf{S}/(n(n-p))]$$

多元 t 分布的定义

定义 10 (多元 t 分布). 称 p 维随机向量 $\mathbf{y} \sim t_\nu(\boldsymbol{\mu}, \Sigma)$ 或 $t(\boldsymbol{\mu}, \Sigma, \nu)$, 如果

$$f(\mathbf{y}) \propto \frac{1}{c} |\Sigma|^{-\frac{1}{2}} \left(1 + \frac{1}{\nu} (\mathbf{y} - \boldsymbol{\mu})^T \Sigma^{-1} (\mathbf{y} - \boldsymbol{\mu}) \right)^{-(\nu+p)/2}$$

其中 ν 自由度, $\boldsymbol{\mu}$ 为位置参数, Σ 为尺度参数 (正定矩阵)。

多元正态（协差阵与均值均未知）：共轭先验

先验: Normal-Inv-Wishart 分布

$$\begin{aligned}\Sigma &\sim \text{Inv-Wishart}_p(\Lambda_0^{-1}, \nu_0) \\ \boldsymbol{\mu}|\Sigma &\sim \text{N}_p(\boldsymbol{\mu}_0, \Sigma/k_0)\end{aligned}$$

其中 k_0/n 越小表示先验所占比重越小。

• 后验分布:

$$\begin{aligned}\Sigma|\mathbf{y} &\sim \text{Inv-Wishart}_p(\Lambda_n^{-1}, \nu_n) \\ \boldsymbol{\mu}|\Sigma, \mathbf{y} &\sim \text{N}_p(\boldsymbol{\mu}_n, \Sigma/k_n)\end{aligned}$$

• 边缘后验 $\boldsymbol{\mu}|\mathbf{y}$:

$$\boldsymbol{\mu}|\mathbf{y} \sim t_{\nu_n-p+1} \left(\boldsymbol{\mu}_n, \frac{\Lambda_n}{k_n(\nu_n-p+1)} \right)$$

• 预测分布:

$$\tilde{\mathbf{y}}|\mathbf{y} \sim t_{\nu_n-p+1} \left(\boldsymbol{\mu}_n, \frac{\Lambda_n + k_n + 1}{k_n(\nu_n-p+1)} \right)$$

多元正态（协差阵与均值均未知）：共轭先验

其中

$$\begin{aligned}\boldsymbol{\mu}_n &= \frac{k_0}{k_0+n}\boldsymbol{\mu}_0 + \frac{n}{k_0+n}\bar{\mathbf{y}} \\ k_n &= k_0+n \\ \nu_n &= \nu_0+n \\ \Lambda_n &= \Lambda_0 + \mathbf{S} + \frac{k_0 n}{k_0+n}(\bar{\mathbf{y}} - \boldsymbol{\mu}_0)(\bar{\mathbf{y}} - \boldsymbol{\mu}_0)^T\end{aligned}$$

- 当 $k_0 \rightarrow 0$, $\nu_0 \rightarrow -1$ 及 $|\Sigma_0| \rightarrow 0$, 共轭先验 = 无信息先验

小结：多元正态分布的贝叶斯模型

1. $\boldsymbol{\mu}$ 未知, Σ 已知

- 正态先验: $\boldsymbol{\mu} \sim N_p(\boldsymbol{\mu}_0, \Lambda_0)$
- 后验: $\boldsymbol{\mu}|\mathbf{y} \sim N_p(\boldsymbol{\mu}_n, \Lambda_n)$

2. $\boldsymbol{\mu}, \Sigma$ 均未知

- 无信息先验: $\pi(\boldsymbol{\mu}, \Sigma) \propto |\Sigma|^{(p+1)/2}$
 $\Sigma|\mathbf{y} \sim \text{Inv-Wishart}_p(\mathbf{S}, n-1)$
 $\boldsymbol{\mu}|\Sigma, \mathbf{y} \sim N_p(\bar{\mathbf{y}}, \Sigma/n)$
 $\boldsymbol{\mu}|\mathbf{y} \sim t_{n-p}[\bar{\mathbf{y}}, \mathbf{S}/(n(n-p))]$
- 共轭先验

$$\begin{aligned}\Sigma &\sim \text{Inv-Wishart}_p(\Lambda_0^{-1}, \nu_0), \boldsymbol{\mu}|\Sigma \sim N_p(\boldsymbol{\mu}_0, \Sigma/k_0) \\ \Sigma|\mathbf{y} &\sim \text{Inv-Wishart}_{\nu_n}(\Lambda_n^{-1}); \boldsymbol{\mu}|\Sigma, \mathbf{y} \sim N_p(\boldsymbol{\mu}_n, \Sigma/k_n) \\ \boldsymbol{\mu}|\mathbf{y} &\sim \text{Multivariate}t_{\nu_n-p+1}\left(\boldsymbol{\mu}_n, \frac{\Lambda_n}{k_n(\nu_n-p+1)}\right)\end{aligned}$$

Recap

1. 一元正态模型（单参数）

- 方差已知：正态-正态模型
- 方差未知：逆伽玛-正态模型
- 方差未知：逆卡方-正态模型

2. 一元正态模型（多参数：均值和方差均未知）

- 无信息先验
- 共轭先验

3. 多元正态模型

- 均值 $\boldsymbol{\mu}$ 未知, 协差阵 Σ 已知
- 均值 $\boldsymbol{\mu}$ 和协差阵 Σ 均未知
 - 无信息先验
 - 共轭先验