

§3.3 1次元 Gauss 分布の学習と予測.

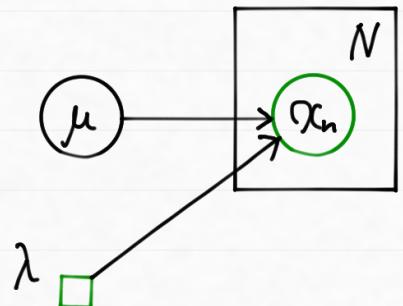
精度パラメータ : $\lambda = \frac{1}{\sigma^2}$ とおく.

3.3.1. 平均が未知の場合

- $\lambda \in \mathbb{R}_{>0}$: fixed. μ を推定したい.

$$x \sim p(x|\mu) = \mathcal{N}(x|\mu, \lambda^{-1}).$$

μ (=未知) は、夫役事前分布は Gauss 分布.



- データ $\mathcal{X} = \{x_1, \dots, x_N\}$: given.

$$p(\mu | \mathcal{X}) \propto p(\mathcal{X} | \mu) p(\mu) \quad (\because \text{Bayes' Th.})$$

$$\begin{aligned} &= \left(\prod_{n=1}^N p(x_n | \mu) \right) p(\mu) \\ &= \left(\prod_{n=1}^N \mathcal{N}(x_n | \mu, \lambda^{-1}) \right) \mathcal{N}(\mu | m, \lambda_\mu^{-1}). \end{aligned}$$

$$\log p(\mu | \mathcal{X}) = \sum_{n=1}^N \log \mathcal{N}(x_n | \mu, \lambda^{-1}) + \log \mathcal{N}(\mu | m, \lambda_\mu^{-1}) + \text{const.}$$

$$= \sum_{n=1}^N \left(\underbrace{\frac{1}{2} \log \lambda - \frac{1}{2} \log 2\pi}_{\text{const.}} - \frac{1}{2} \lambda (x_n - \mu)^2 \right)$$

今日興味あるのは
μの項のみ.

$$+ \underbrace{\frac{1}{2} \log \lambda_\mu - \frac{1}{2} \log 2\pi}_{\text{const.}} - \frac{1}{2} \lambda_\mu (\mu - m)^2 + \text{const.}$$

$$= -\frac{1}{2} \sum_{n=1}^N \underbrace{(\lambda x_n^2 - 2\lambda x_n \mu + \lambda \mu^2)}_{\text{const.}} - \frac{1}{2} \lambda_\mu \mu^2 + \lambda_\mu m \mu - \underbrace{\frac{1}{2} \lambda_\mu m^2}_{\text{const.}} + \text{const.}$$

$$= -\frac{1}{2} \left((N\lambda + \lambda_\mu) \mu^2 - 2 \left(\lambda \sum_{n=1}^N x_n + m \lambda_\mu \right) \mu \right) + \text{const.}$$

$\rightarrow \mu$ は開く上に凸の2次曲線 $f(x)$ で μ の事後分布は Gauss 分布.

$\rightarrow p(\mu | \mathcal{X}) = N(\mu | \hat{m}, \hat{\lambda}_\mu^{-1})$ と書けるとする。

$$\begin{aligned} \log p(\mu | \mathcal{X}) &= \frac{1}{2} \log \hat{\lambda}_\mu - \frac{1}{2} \log 2\pi - \frac{\hat{\lambda}_\mu}{2} (\mu - \hat{m})^2 \\ &= -\frac{1}{2} (\hat{\lambda}_\mu \mu^2 - 2\hat{m}\hat{\lambda}_\mu \mu) + \text{const.} \end{aligned}$$

先に式

$$\log p(\mu | \mathcal{X}) = -\frac{1}{2} \left(\underbrace{((N\lambda + \lambda_\mu)\mu^2 - 2(\lambda \sum_{n=1}^N x_n + m\lambda_\mu)\mu)}_{=\hat{\lambda}_\mu} \right) + \text{const.}$$

$= \hat{m}\hat{\lambda}_\mu$

と比較して、

$$\hat{\lambda}_\mu = N\lambda + \lambda_\mu, \quad \hat{m} = \frac{1}{\hat{\lambda}_\mu} \left(\lambda \sum_{n=1}^N x_n + m\lambda_\mu \right)$$

と求まる。

○ 解釈

・事後分布の精度: $\hat{\lambda}_\mu = N\lambda + \lambda_\mu \xrightarrow{N \rightarrow \infty} \infty$.

$\rightarrow \mu$ に対する精度がデータの観測により上昇していく。

・事後分布の平均: $\hat{m} = \frac{1}{\hat{\lambda}_\mu} \left(\lambda \sum_{n=1}^N x_n + m\lambda_\mu \right)$

$$= \frac{1}{N\lambda + \lambda_\mu} \left(N\lambda \left(\frac{1}{N} \sum_{n=1}^N x_n \right) + \lambda_\mu m \right)$$

\nwarrow データ平均 $\frac{1}{N} \sum x_n$ と m の加重平均

$\rightarrow N \rightarrow \infty$ で “データ平均” の影響が大きくなってしまう。

- 未観測データに対する予測分布.

$$\begin{aligned} p(x_*) &= \int p(x_*|\mu) p(\mu) d\mu \\ &= \int \mathcal{N}(x_*|\mu, \lambda^{-1}) \mathcal{N}(\mu|m, \lambda_\mu^{-1}) d\mu. \end{aligned}$$

これを直接計算するのは面倒. 対数を使う.

- Bayes' Thm. 使う.

$$p(\mu|x_*) = \frac{p(x_*|\mu)p(\mu)}{p(x_*)}$$

この対数をとると

$$\log p(\mu|x_*) = \log p(x_*|\mu) - \log p(x_*) + \log p(\mu).$$

$\hookrightarrow x_*$ は既定の
const. として扱えよ.

$$\therefore \log p(x_*) = \log p(x_*|\mu) - \log p(\mu|x_*) + \text{const.}$$

$$\cdot p(\mu|x_*) \text{ は } \dots$$

x_* : given のときの μ の条件付き分布とみると, 事後分布の計算と同様.

\rightarrow \mathcal{N} あるデータ x を, 1つのデータ x_* をあわせて考へると,

$$p(\mu|x_*) = \mathcal{N}\left(\mu \mid \frac{\lambda x_* + \lambda_\mu m}{\lambda + \lambda_\mu}, (\lambda + \lambda_\mu)^{-1}\right)$$

$$=: m(x_*)$$

$$\log p(\mu|x_*) = -\frac{1}{2}(\lambda + \lambda_\mu)(\mu - m(x_*))^2 + \text{const.}$$

$$= -\frac{1}{2}(\lambda + \lambda_\mu)(m(x_*)^2 - 2\mu m(x_*)) + \text{const.}$$

$$\begin{aligned}
 & \therefore \log p(x_*) \\
 &= -\frac{1}{2} \left(\lambda(x_*^2 - 2\mu x_*) - (\lambda + \lambda_\mu)(m(x_*)^2 - 2\mu m(x_*)) \right) + \text{const.} \\
 &= -\frac{1}{2} \left(\lambda x_*^2 - 2\mu \cancel{\lambda} x_* - \frac{(\lambda x_* + \lambda_\mu m)^2}{\lambda + \lambda_\mu} + 2\mu (\cancel{\lambda x_* + \lambda_\mu m}) \right) + \text{const.} \\
 &= -\frac{1}{2} \left(\lambda x_*^2 - \frac{1}{\lambda + \lambda_\mu} (\lambda^2 x_*^2 + 2\lambda \lambda_\mu m x_* + \lambda_\mu^2 m^2) \right) + \text{const.} \\
 &= -\frac{1}{2} \left(\frac{\lambda \lambda_\mu}{\lambda + \lambda_\mu} x_*^2 - 2m \frac{\lambda \lambda_\mu}{\lambda + \lambda_\mu} x_* \right) + \text{const.} \\
 &\quad \stackrel{=: \lambda_*}{=} \stackrel{=: \mu_* \lambda_*}{=} \nwarrow \text{Gauss分布の対数表示.}
 \end{aligned}$$

$$\therefore p(x_*) = \mathcal{N}(x_* | \mu_*, \lambda_*^{-1}),$$

$$\lambda_* = \frac{\lambda \lambda_\mu}{\lambda + \lambda_\mu}, \quad \mu_* = m.$$

↓
分散を考慮すると、 $\lambda_*^{-1} = \lambda^{-1} + \lambda_\mu^{-1}$ つまり。

$$\begin{aligned}
 (\text{予測分布の不確さ}) &= (\text{観測分布の不確さ}) \\
 &+ (\text{事前分布の不確さ}),
 \end{aligned}$$

・ $p(x_* | \mathcal{X})$ を求めるときは、上の式の m, λ_μ と $\hat{m}, \hat{\lambda}_\mu$ を使う。

・ λ の分布も学習したいときは、ガシマ事前分布をモデルに追加して推論する。

3.3.2 精度が未知の場合.

μ : given, λ : unknown. $\rightarrow \lambda$ を推定.

観測モデル: $p(x|\lambda) = N(x|\mu, \lambda^{-1})$.

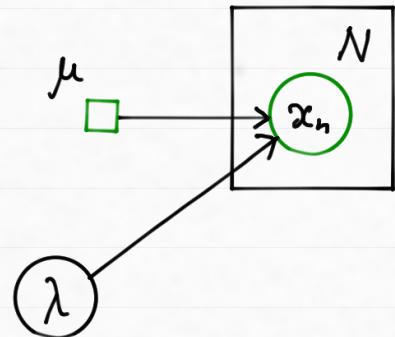
λ の事前分布として, $\lambda \in \mathbb{R}_{>0}$ ためガンマ事前分布を使う:

$$p(\lambda) = \text{Gam}(\lambda|a,b).$$

ガンマ分布は, Gauss分布の精度パラメータに対する共役事前分布.

* パラメータの更新:

$$\begin{aligned} p(\lambda|x) &\stackrel{\text{Bayes' Thm.}}{\sim} p(x|\lambda)p(\lambda) \\ &= \left(\prod_{n=1}^N p(x_n|\lambda) \right) p(\lambda) \\ &= \left(\prod_{n=1}^N N(x_n|\mu, \lambda^{-1}) \right) \text{Gam}(\lambda|a,b). \end{aligned}$$



この対数をとると,

$$\begin{aligned} \log p(\lambda|x) &= \sum_{n=1}^N \log N(x_n|\mu, \lambda^{-1}) + \log \text{Gam}(\lambda|a,b) + \text{const.} \\ &= \sum_{n=1}^N \left(-\frac{1}{2} (\lambda(x_n - \mu)^2 - \log \lambda) \right) + (a-1) \log \lambda - b \lambda + \text{const.} \\ &= \left(\frac{N}{2} + a - 1 \right) \log \lambda - \left(\frac{1}{2} \sum_{n=1}^N (x_n - \mu)^2 + b \right) \lambda + \text{const.} \end{aligned}$$

\rightarrow ガンマ分布のpdfに対数をとったものと形が同じ.

$$\therefore p(\lambda|x) = \text{Gam}(\lambda|\hat{a}, \hat{b}),$$

$$\hat{a} := \frac{N}{2} + a, \quad \hat{b} := \frac{1}{2} \sum_{n=1}^N (x_n - \mu)^2 + b$$

以上より共役事前分布からガシマ分布であることが確認できました。

* 予測分布の計算.

$$p(x_*) = \int p(x_*|\lambda) p(\lambda) d\lambda \quad \text{を計算してもよいが面倒。対数を活用する}$$

$$p(\lambda|x_*) = \frac{p(x_*|\lambda)p(\lambda)}{p(x_*)} \quad (\because \text{Bayes' Thm.}) \quad \begin{matrix} \downarrow & \text{対数とり} \\ & \text{整理} \end{matrix}$$

$$\therefore \log p(x_*) = \log p(x_*|\lambda) - \log p(\lambda|x_*) + \log p(\lambda).$$

・第1項はモデルの式より、

$$\log p(x_*|\lambda) = \log N(x_*|\mu, \lambda^{-1}) = -\frac{1}{2} (\lambda(x_* - \mu)^2 - \log \lambda) + \text{const}$$

・第2項.

$p(\lambda|x_*)$ を、「 x_* : given のときの事後分布」とみれば、先の計算より

$$p(\lambda|x_*) = \text{Gam}(\lambda|\frac{1}{2}+a, b(x_*)), \quad b(x_*) := \frac{1}{2}(x_* - \mu)^2 + b.$$

$$\therefore \log p(\lambda|x_*)$$

ほんの少しだけ複雑になります。
lambdaに影響する const. でありますので計算では取り除く。

$$= \left(\frac{1}{2} + a - 1 \right) \log \lambda - \left(\frac{1}{2}(x_* - \mu)^2 + b \right) \lambda + \log C_G(a, b(x_*))$$

$$= \left(\frac{1}{2} + a - 1 \right) \log \lambda - \left(\frac{1}{2}(x_* - \mu)^2 + b \right) \lambda + \left(\frac{1}{2} + a \right) \log \left(\frac{1}{2}(x_* - \mu)^2 + b \right) + \text{const}$$

・第3項は事前分布の式より $\log p(\lambda) = (a-1) \log \lambda - b \lambda + \text{const.}$

$$\begin{aligned}
\therefore \log p(x_*) &= \log p(x_* | \lambda) - \log p(\lambda | x_*) + \log p(\lambda) \\
&= -\frac{1}{2} \left(\lambda (x_* - \mu)^2 - \log \lambda \right) - \left(\frac{1}{2} + a - 1 \right) \log \lambda + \left(\frac{1}{2} (x_* - \mu)^2 + b \right) \lambda \\
&\quad - \left(\frac{1}{2} + a \right) \log \left(\frac{1}{2} (x_* - \mu)^2 + b \right) + (a-1) \log \lambda - b \lambda + \text{const.} \\
&= -\frac{2a+1}{2} \log \left(b \left(1 + \frac{1}{2b} (x_* - \mu)^2 \right) \right) + \text{const.} \\
&= -\frac{2a+1}{2} \log \left(1 + \frac{1}{2b} (x_* - \mu)^2 \right) + \text{const.}
\end{aligned}$$

→ 実は、これは Student の t 分布の pdf の対数をとったものと同一形.

Def. (Student の t 分布) $\mu_s \in \mathbb{R}, \lambda_s, \nu_s \in \mathbb{R}_{>0}$.

$$\text{pdf. : } St(x | \mu_s, \lambda_s, \nu_s) = \frac{\Gamma(\frac{\nu_s+1}{2})}{\Gamma(\frac{\nu_s}{2})} \left(\frac{\lambda_s}{\pi \nu_s} \right)^{\frac{1}{2}} \left(1 + \frac{\lambda_s}{\nu_s} (x - \mu_s)^2 \right)^{-\frac{\nu_s+1}{2}}$$

$(x \in \mathbb{R}) \quad \square$

- $\log St(x | \mu_s, \lambda_s, \nu_s) = -\frac{\nu_s+1}{2} \log \left(1 + \frac{\lambda_s}{\nu_s} (x - \mu_s)^2 \right) + \text{const.}$

- 以上より, $p(x_*) = St(x_* | \mu_s, \lambda_s, \nu_s)$,

$$\mu_s = \mu, \lambda_s = \frac{a}{b}, \nu_s = 2a.$$

Cf. Student の t 分布の正規化項, 平均, 分散の計算.

- 正規化項 $\frac{\Gamma(\frac{\nu_s+1}{2})}{\Gamma(\frac{\nu_s}{2})} \left(\frac{\lambda_s}{\pi \nu_s} \right)^{\frac{1}{2}}$ は正しいと確認する.

$$I = \int_{-\infty}^{\infty} \left(1 + \frac{\lambda_s}{\nu_s} (x - \mu_s)^2 \right)^{-\frac{\nu_s+1}{2}} dx = \frac{\Gamma(\frac{\nu_s}{2})}{\Gamma(\frac{\nu_s+1}{2})} \left(\frac{\pi \nu_s}{\lambda_s} \right)^{\frac{1}{2}}$$

を示せばよい.

$$\text{また}, \sqrt{\frac{\lambda_s}{\nu_s}} (x - \mu_s) = t \text{ とおくと}, I = \sqrt{\frac{\nu_s}{\lambda_s}} \int_{-\infty}^{\infty} (1 + t^2)^{-\frac{\nu_s+1}{2}} dt.$$

被積分函数は七の偶函数なので、

$$I = 2 \sqrt{\frac{\nu_s}{\lambda_s}} \int_0^\infty (1+t^2)^{-\frac{\nu_s+1}{2}} dt.$$

$$u = (1+t^2)^{-1} \text{ とおくと, } t = \sqrt{\frac{1-u}{u}},$$

$$du = -(1+t^2)^{-2} \cdot 2t dt = -2u^2 \sqrt{\frac{1-u}{u}} dt.$$

$$\therefore dt = -\frac{1}{2} u^{-\frac{3}{2}} (1-u)^{-\frac{1}{2}} du.$$

積分範囲は $0 \rightarrow \infty$ が $1 \rightarrow 0$ (=反転) である。

$$\therefore I = \sqrt{\frac{\nu_s}{\lambda_s}} \int_0^1 u^{\frac{\nu_s+1}{2}} \cdot u^{-\frac{3}{2}} (1-u)^{-\frac{1}{2}} du$$

$$= \sqrt{\frac{\nu_s}{\lambda_s}} \int_0^1 u^{\frac{\nu_s}{2}-1} (1-u)^{\frac{1}{2}-1} du$$

$$= \sqrt{\frac{\nu_s}{\lambda_s}} B\left(\frac{\nu_s}{2}, \frac{1}{2}\right)$$

$$= \sqrt{\frac{\nu_s}{\lambda_s}} \frac{\Gamma\left(\frac{\nu_s}{2}\right) \Gamma\left(\frac{1}{2}\right)}{\Gamma\left(\frac{\nu_s+1}{2}\right)}$$

$$= \frac{\Gamma\left(\frac{\nu_s}{2}\right)}{\Gamma\left(\frac{\nu_s+1}{2}\right)} \left(\frac{\pi \nu_s}{\lambda_s}\right)^{\frac{1}{2}}$$

ベータ函数の定義

ベータ函数の性質

$$B(a,b) = \frac{\Gamma(a)\Gamma(b)}{\Gamma(a+b)}.$$

$$\Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}.$$

□

• 平均の計算

$$C_t(\mu_s, \lambda_s, \nu_s) := \frac{\Gamma\left(\frac{\nu_s+1}{2}\right)}{\Gamma\left(\frac{\nu_s}{2}\right)} \left(\frac{\lambda_s}{\pi \nu_s}\right)^{\frac{1}{2}} \text{ とおく。}$$

$$\mathbb{E}[X] = C_t(\mu_s, \lambda_s, \nu_s) \int_{-\infty}^{\infty} x \left(1 + \frac{\lambda_s}{\nu_s} (x - \mu_s)^2\right)^{-\frac{\nu_s+1}{2}} dx$$

$$\begin{aligned}
&= C_t(\mu_s, \lambda_s, \nu_s) \int_{-\infty}^{\infty} (x - \mu_s) \left(1 + \frac{\lambda_s}{\nu_s} (x - \mu_s)^2 \right)^{-\frac{\nu_s+1}{2}} dx \\
&\quad + \mu_s \int_{-\infty}^{\infty} C_t(\mu_s, \lambda_s, \nu_s) \left(1 + \frac{\lambda_s}{\nu_s} (x - \mu_s)^2 \right)^{-\frac{\nu_s+1}{2}} dx. \\
&= \mu_s + C_t(\mu_s, \lambda_s, \nu_s) \int_{-\infty}^{\infty} (x - \mu_s) \left(1 + \frac{\lambda_s}{\nu_s} (x - \mu_s)^2 \right)^{-\frac{\nu_s+1}{2}} dx. \\
&\quad \int_{-\infty}^{\infty} (x - \mu_s) \left(1 + \frac{\lambda_s}{\nu_s} (x - \mu_s)^2 \right)^{-\frac{\nu_s+1}{2}} dx \downarrow \sqrt{\frac{\lambda_s}{\nu_s}} (x - \mu_s) = t \text{ となる} \\
&= \frac{\nu_s}{\lambda_s} \int_{-\infty}^{\infty} t \left(1 + t^2 \right)^{-\frac{\nu_s+1}{2}} dt \\
&= \frac{\nu_s}{\lambda_s} \left(\int_0^{\infty} t \left(1 + t^2 \right)^{-\frac{\nu_s+1}{2}} dt + \int_{-\infty}^0 t \left(1 + t^2 \right)^{-\frac{\nu_s+1}{2}} dt \right) \downarrow 1+t^2 = u \\
&= \frac{\nu_s}{2\lambda_s} \left(\int_1^{\infty} u^{-\frac{\nu_s+1}{2}} du + \int_{\infty}^1 u^{-\frac{\nu_s+1}{2}} du \right).
\end{aligned}$$

$\therefore t = \sqrt{\frac{\lambda_s}{\nu_s}} (x - \mu_s)$, $\nu_s \neq 1$ のとき,

$$\begin{aligned}
\int_1^{\infty} u^{-\frac{\nu_s+1}{2}} du &= \lim_{a \rightarrow \infty} \int_1^a u^{-\frac{\nu_s+1}{2}} du \\
&= \lim_{a \rightarrow \infty} \left[-\frac{2}{\nu_s - 1} u^{-\frac{\nu_s-1}{2}} \right]_1^a \\
&= \lim_{a \rightarrow \infty} \frac{2}{\nu_s - 1} \left(1 - a^{-\frac{\nu_s-1}{2}} \right) \\
&= \begin{cases} \frac{2}{\nu_s - 1} & (\nu_s > 1) \\ -\infty & (0 < \nu_s < 1) \end{cases}.
\end{aligned}$$

$\nu_s = 1$ のとき,

$$\int_1^\infty u^{-\frac{\nu_s+1}{2}} du = \int_1^\infty u^{-1} du = \lim_{a \rightarrow \infty} [\log u]_1^a = \infty.$$

同様に,

$$\int_\infty^1 u^{-\frac{\nu_s+1}{2}} du = \begin{cases} -\frac{2}{\nu_s-1} & (\nu_s > 1) \\ -\infty & (\nu_s = 1) \\ \infty & (0 < \nu_s < 1) \end{cases}$$

以上より,

$$\int_1^\infty u^{-\frac{\nu_s+1}{2}} du + \int_\infty^1 u^{-\frac{\nu_s+1}{2}} du = \begin{cases} 0 & (\nu_s > 1) \\ \text{indeterminate} & (0 < \nu_s \leq 1) \end{cases}$$

$$\therefore \mathbb{E}[X] = \begin{cases} \mu_s & (\nu_s > 1) \\ \text{undefined} & (0 < \nu_s \leq 1) \end{cases}$$

• 分散の計算.

$\mathbb{E}[X]$ は $\nu_s > 1$ のとき存在するが、 $\nu_s > 1$ の範囲で考える。

$V[X]$

$$= \mathbb{E}[(X-\mu_s)^2]$$

$$= C_t(\mu_s, \lambda_s, \nu_s) \int_{-\infty}^\infty (x-\mu_s)^2 \left(1 + \frac{\lambda_s}{\nu_s} (x-\mu_s)^2\right)^{-\frac{\nu_s+1}{2}} dx.$$

$$\begin{aligned}
 & \int_{-\infty}^{\infty} (x - \mu_s)^2 \left(1 + \frac{\lambda_s}{\nu_s} (x - \mu_s)^2 \right)^{-\frac{\nu_s+1}{2}} dx \\
 &= \left(\frac{\nu_s}{\lambda_s} \right)^{\frac{3}{2}} \int_{-\infty}^{\infty} t^2 (1+t^2)^{-\frac{\nu_s+1}{2}} dt \\
 &= \left(\frac{\nu_s}{\lambda_s} \right)^{\frac{3}{2}} \cdot 2 \int_0^{\infty} t^2 (1+t^2)^{-\frac{\nu_s+1}{2}} dt \\
 &\because t^2, (1+t^2)^{-1} \text{ は偶函数}, t \rightarrow \infty \text{ で } u \rightarrow 0.
 \end{aligned}$$

$$dt = -\frac{1}{2tu^2} du \quad t^2, t = \sqrt{\frac{1-u}{u}}.$$

$$\begin{aligned}
 & \therefore \int_0^{\infty} t^2 (1+t^2)^{-\frac{\nu_s+1}{2}} dt \\
 &= \int_1^0 \sqrt{\frac{1-u}{u}} \cdot u^{\frac{\nu_s+1}{2}} \left(-\frac{1}{2u^2} \right) du \\
 &= \frac{1}{2} \int_0^1 u^{\frac{\nu_s-2}{2}-1} (1-u)^{\frac{3}{2}-1} du
 \end{aligned}$$

$$= \begin{cases} \frac{1}{2} B\left(\frac{\nu_s-2}{2}, \frac{3}{2}\right) & (\nu_s > 2) \\ \text{undefined} & (1 < \nu_s \leq 2) \end{cases}$$

Γ -函数 $B(x,y)$ の定義域は

$x > 0, y > 0$.

この範囲で t の値は収束します。

したがって, $\nu_s > 2$ の範囲で,

$$\begin{aligned}
 & \int_{-\infty}^{\infty} (x - \mu_s)^2 \left(1 + \frac{\lambda_s}{\nu_s} (x - \mu_s)^2 \right)^{-\frac{\nu_s+1}{2}} dx \\
 &= \left(\frac{\nu_s}{\lambda_s} \right)^{\frac{3}{2}} B\left(\frac{\nu_s-2}{2}, \frac{3}{2}\right) \\
 &= \left(\frac{\nu_s}{\lambda_s} \right)^{\frac{3}{2}} \frac{\Gamma\left(\frac{\nu_s-2}{2}\right) \Gamma\left(\frac{3}{2}\right)}{\Gamma\left(\frac{\nu_s+1}{2}\right)}
 \end{aligned}$$

このとき、

$$\begin{aligned} \mathbb{V}[X] &= C_t(\mu_s, \lambda_s, \nu_s) \left(\frac{\nu_s}{\lambda_s} \right)^{\frac{3}{2}} \frac{\Gamma\left(\frac{\nu_s-2}{2}\right) \Gamma\left(\frac{3}{2}\right)}{\Gamma\left(\frac{\nu_s+1}{2}\right)} \\ &= \frac{\Gamma\left(\frac{\nu_s+1}{2}\right)}{\Gamma\left(\frac{\nu_s}{2}\right)} \left(\frac{\lambda_s}{\pi \nu_s} \right)^{\frac{1}{2}} \left(\frac{\nu_s}{\lambda_s} \right)^{\frac{3}{2}} \frac{\Gamma\left(\frac{\nu_s-2}{2}\right) \Gamma\left(\frac{3}{2}\right)}{\Gamma\left(\frac{\nu_s+1}{2}\right)} \\ &= \frac{\nu_s \Gamma\left(\frac{\nu_s-2}{2}\right) \Gamma\left(\frac{3}{2}\right)}{\Gamma\left(\frac{\nu_s}{2}\right) \sqrt{\pi}} \lambda_s^{-1} \quad \downarrow P(x+1) = xP(x) \\ &= \frac{\nu_s \Gamma\left(\frac{\nu_s-2}{2}\right)^{\frac{1}{2}} \Gamma\left(\frac{1}{2}\right)}{\frac{\nu_s-2}{2} \Gamma\left(\frac{\nu_s-2}{2}\right) \sqrt{\pi}} \lambda_s^{-1} \quad \downarrow P\left(\frac{1}{2}\right) = \sqrt{\pi} \\ &= \frac{\nu_s}{\nu_s-2} \lambda_s^{-1}. \end{aligned}$$

$$\therefore \mathbb{V}[X] = \begin{cases} \frac{\nu_s}{\nu_s-2} \lambda_s^{-1} & (\nu_s > 2) \\ \text{undefined} & (0 < \nu_s \leq 2) \end{cases}.$$

3.3.3 平均・精度が未知の場合.

観測モデル $p(x|\mu, \lambda) = \mathcal{N}(x|\mu, \lambda^{-1})$.

夫役事前分布は Gauss-カシマ分布 :

$$\begin{aligned} p(\mu, \lambda) &= NG(\mu, \lambda | m, \beta, a, b) \\ &:= \mathcal{N}(\mu | m, (\beta\lambda)^{-1}) \text{Gam}(\lambda | a, b). \end{aligned}$$

→ 今 $\mathcal{X} = \{x_1, \dots, x_N\}$ 観測後の $\hat{m}, \hat{\beta}, \hat{a}, \hat{b}$ を求めよ.

- 平均 μ (セント).

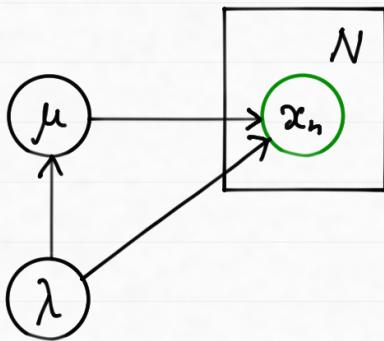
$$\left. \begin{aligned} p(\mu) &= \mathcal{N}(\mu | m, \lambda_\mu^{-1}) \text{ とする} \\ p(\mu | \mathcal{X}) &= \mathcal{N}(\mu | \hat{m}, \hat{\lambda}_\mu^{-1}) \\ \hat{\lambda}_\mu &= N\lambda + \lambda_\mu, \quad \hat{m} = \frac{\lambda \sum_{n=1}^N x_n + \lambda_\mu m}{\hat{\lambda}_\mu} \end{aligned} \right\} \text{でまとめ.}$$

$$p(\mu | \lambda) = \mathcal{N}(\mu | m, (\beta\lambda)^{-1}) \text{ とする}.$$

$$p(\mu | \lambda, \mathcal{X}) = \mathcal{N}(\mu | \hat{m}, (\hat{\beta}\lambda)^{-1}),$$

$$\hat{\beta} = N + \beta, \quad \hat{m} = \frac{1}{\hat{\beta}} \left(\sum_{n=1}^N x_n + \beta m \right)$$

とする.



・精度入力について.

$$p(\lambda) = \text{Gam}(\lambda | a, b). \quad p(\lambda | x) を求めよ.$$

x と μ と λ の同時分布は、

$$\begin{aligned} p(x, \mu, \lambda) &= p(\mu | \lambda, x) p(\lambda, x) \\ &= p(\mu | \lambda, x) p(\lambda | x) p(x). \end{aligned}$$

よって、

$$p(\lambda | x) = \frac{p(x, \mu, \lambda)}{p(\mu | \lambda, x) p(x)} \propto \frac{p(x, \mu, \lambda)}{p(\mu | \lambda, x)}.$$

$\rightarrow p(\mu | \lambda, x)$ は既に求めた！ $p(x, \mu, \lambda)$ も

$$\begin{aligned} p(x, \mu, \lambda) &= p(x | \mu, \lambda) p(\mu, \lambda) \\ &= \left(\prod_{n=1}^N \mathcal{N}(x_n | \mu, \bar{\lambda}') \right) \mathcal{N}(\mu | m, (\beta \lambda)^{-1}) \text{Gam}(\lambda | a, b) \end{aligned}$$

が求めまる。

$$\therefore \log p(\lambda | x)$$

$$\begin{aligned} &= \sum_{n=1}^N \log \mathcal{N}(x_n | \mu, \bar{\lambda}') + \log \mathcal{N}(\mu | m, (\beta \lambda)^{-1}) + \log \text{Gam}(\lambda | a, b) \\ &\quad - \log \mathcal{N}(\mu | \hat{m}, (\hat{\beta} \lambda)^{-1}) + \text{const.} \end{aligned}$$

$$\begin{aligned} &= \sum_{n=1}^N \left(-\frac{1}{2} (\lambda (x_n - \mu)^2 - \log \lambda) \right) - \frac{1}{2} (\beta \lambda (\mu - m)^2 - \log \beta \lambda) \\ &\quad + (a-1) \log \lambda - b \lambda + \frac{1}{2} (\hat{\beta} \lambda (\mu - \hat{m})^2 - \log \hat{\beta} \lambda) + \text{const.} \end{aligned}$$

$$\begin{aligned}
&= \sum_{n=1}^N \left(-\frac{1}{2} (\lambda(x_n - \mu)^2 - \log \lambda) \right) - \frac{1}{2} (\beta \lambda (\mu - m)^2 - \log \beta \lambda) \\
&\quad + (a-1) \log \lambda - b \lambda + \frac{1}{2} (\hat{\beta} \lambda (\mu - \hat{m})^2 - \log \hat{\beta} \lambda) + \text{const.} \\
&= \left(\frac{N}{2} + a - 1 \right) \log \lambda - \frac{1}{2} \lambda \sum_{n=1}^N (x_n - \mu)^2 - \frac{1}{2} \beta \lambda (\mu - m)^2 \\
&\quad + \frac{1}{2} (\log \beta + \log \lambda) - b \lambda + \frac{1}{2} \hat{\beta} \lambda (\mu - \hat{m})^2 - \frac{1}{2} (\log \hat{\beta} + \log \lambda) + \text{const} \\
&= \left(\frac{N}{2} + a - 1 \right) \log \lambda - \frac{\lambda}{2} \left(\sum_{n=1}^N x_n^2 - 2 \mu \sum_{n=1}^N x_n + N \mu^2 \right) \quad \begin{matrix} \text{const.} \\ \cancel{2\mu \sum_{n=1}^N x_n} \end{matrix} \quad \begin{matrix} \hat{m} \in \hat{\beta} \Sigma \\ \text{fit } \lambda \text{ 33.} \end{matrix} \\
&\quad - \frac{\lambda}{2} (\beta \mu^2 - 2 \beta \mu m + \beta m^2) - b \lambda + \frac{\lambda}{2} (\hat{\beta} \mu^2 - 2 \hat{\beta} \mu \hat{m} + \hat{\beta} \hat{m}^2) + \text{const.} \\
&= \left(\frac{N}{2} + a - 1 \right) \log \lambda - \left(\frac{1}{2} \left(\sum_{n=1}^N x_n^2 + \beta m^2 - \hat{\beta} \hat{m}^2 \right) + b \right) \lambda + \text{const.}
\end{aligned}$$

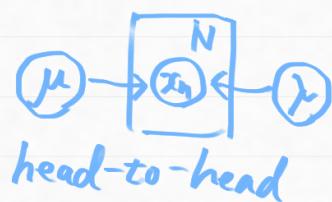
$$\therefore p(\lambda | \mathcal{X}) = \text{Gam}(\lambda | \hat{a}, \hat{b}),$$

$$\hat{a} = \frac{N}{2} + a, \quad \hat{b} = \frac{1}{2} \left(\sum_{n=1}^N x_n^2 + \beta m^2 - \hat{\beta} \hat{m}^2 \right) + b.$$

以上で、

$$\begin{aligned}
p(\mu, \lambda | \mathcal{X}) &= p(\mu | \lambda, \mathcal{X}) p(\lambda | \mathcal{X}) \\
&= \mathcal{N}(\mu | \hat{m}, (\hat{\beta} \lambda)^{-1}) \text{Gam}(\lambda | \hat{a}, \hat{b}) \\
&= \mathcal{N}(\mu, \lambda | \hat{m}, \hat{\beta}, \hat{a}, \hat{b}).
\end{aligned}$$

- $p(\mu, \lambda) = p(\mu)p(\lambda)$ (独立な prior) を使うことで“3点”。
 つまり観測後は μ, λ が独立にならないため、
 $p(\mu, \lambda | \mathcal{X})$ が二つのパラメータの同時分布になる。
 → Gauss-Gaussian 分布でやる方が簡単。



- 予測分布の計算.

$$p(x_*) = \iint p(x_* | \mu, \lambda) p(\mu, \lambda) d\mu d\lambda.$$

→ 直接計算をしないで計算.

Bayes' Thm. より

$$\log p(x_*) = \log p(x_* | \mu, \lambda) - \log p(\mu, \lambda | x_*) + \log p(\mu, \lambda).$$

$$\begin{aligned} \log p(x_* | \mu, \lambda) &= \log \mathcal{N}(x_* | \mu, \lambda^{-1}) \\ &= -\frac{1}{2} (\lambda(x_* - \mu)^2 - \log \lambda) + \text{const.} \end{aligned}$$

$$\log p(\mu, \lambda | x_*) = \log p(\mu | \lambda, \{x_*\}) + \log p(\lambda | \{x_*\})$$

$$= \log \mathcal{N}(\mu | \frac{1}{1+\beta}(x_* + \beta m), ((1+\beta)\lambda)^{-1}) \\ \quad \stackrel{=: m(x_*)}{=} \quad$$

$$+ \log \text{Gam}(\lambda | \frac{1}{2} + a, \frac{1}{2}(x_*^2 + \beta m^2 - (1+\beta)(\frac{1}{1+\beta}(x_* + \beta m))^2) + b)$$

$$= \log \mathcal{N}(\mu | m(x_*), ((1+\beta)\lambda)^{-1})$$

$$+ \log \text{Gam}(\lambda | \frac{1}{2} + a, \frac{\beta}{2(1+\beta)}(x_* - m)^2 + b) \\ \quad \stackrel{=: b(x_*)}{=} \quad$$

$$= \log \mathcal{N}(\mu | m(x_*), ((1+\beta)\lambda)^{-1}) + \log \text{Gam}(\lambda | \frac{1}{2} + a, b(x_*))$$

$$= -\frac{1}{2} ((1+\beta)\lambda(\mu - m(x_*))^2 - \log(1+\beta)\lambda)$$

$$+ (\frac{1}{2} + a - 1) \log \lambda - b(x_*) \lambda + (\frac{1}{2} + a) \log b(x_*) + \text{const.}$$

$$\log p(\mu, \lambda) = \log N(\mu | m, (\beta\lambda)^{-1}) + \log \text{Gam}(\lambda | a, b)$$

$$= -\frac{1}{2}(\beta\lambda(\mu-m)^2 - \log \beta\lambda) + (a-1)\log \lambda - b\lambda + \text{const.}$$

$$\therefore \log p(x_*) = \log p(x_* | \mu, \lambda) - \log p(\mu, \lambda | x_*) + \log p(\mu, \lambda).$$

$$= -\frac{1}{2}(\lambda(x_*-\mu)^2 - \log \lambda) + \frac{1}{2}((1+\beta)\lambda(\mu-m(x_*))^2 - \log(1+\beta)\lambda)$$

$$- (\frac{1}{2}+a-1)(\log \lambda + b(x_*)\lambda - (\frac{1}{2}+a)\log b(x_*))$$

$$- \frac{1}{2}(\beta\lambda(\mu-m)^2 - \log \beta\lambda) + (a-1)\log \lambda - b\lambda + \text{const.}$$

$$= -\frac{\lambda}{2}(x_*-\mu)^2 + \frac{\lambda}{2}(1+\beta)(\mu^2 - 2\mu m(x_*) + m(x_*)^2)$$

$$- \frac{1}{2}(\log(1+\beta) + \log \lambda) + b(x_*)\lambda - (\frac{1}{2}+a)\log b(x_*)$$

$$- \frac{\lambda}{2}\beta(\mu^2 - 2\mu m + m^2) + \frac{1}{2}(\log \beta + \log \lambda) - b\lambda + \text{const.}$$

$$= -\frac{\lambda}{2}(x_*-\mu)^2 + \frac{\lambda}{2}(1+\beta)(\mu^2 - 2\mu m(x_*) + m(x_*)^2)$$

$$+ b(x_*)\lambda - (\frac{1}{2}+a)\log b(x_*) - \frac{\lambda}{2}\beta(\mu^2 - 2\mu m + m^2) - b\lambda + \text{const.}$$

$$= -\frac{\lambda}{2}(x_*-\mu)^2 + \frac{\lambda}{2}(\mu^2 + \beta\mu^2 - 2\mu(x_* + \beta m) + (1+\beta)m(x_*)^2)$$

$$+ b(x_*)\lambda - (\frac{1}{2}+a)\log b(x_*) - \frac{\lambda}{2}\beta(\mu^2 - 2\mu m + m^2) - b\lambda + \text{const.}$$

$$= -\frac{\lambda}{2}(x_*-\mu)^2 + \frac{\lambda}{2}((x_*-\mu)^2 - x_*^2 + (1+\beta)m(x_*)^2)$$

$$+ b(x_*)\lambda - (\frac{1}{2}+a)\log b(x_*) - \frac{\lambda}{2}\beta m^2 - b\lambda + \text{const.}$$

$$= -\frac{\lambda}{2}(x_*^2 - (1+\beta)m(x_*)^2 + \beta m^2) + b(x_*)\lambda - b\lambda$$

$$- (\frac{1}{2}+a)\log b(x_*) + \text{const.}$$

$$\begin{aligned}
&= -\frac{\lambda}{2} \left(x_*^2 - \frac{x_*^2 + 2\beta_m x_* - \beta_m^2}{1+\beta} + \beta_m^2 \right) \\
&\quad + \frac{\lambda}{2} \frac{\beta}{1+\beta} (x_*^2 - 2m x_* + m^2) + b\lambda - b\lambda \\
&\quad - \left(\frac{1}{2} + \alpha \right) \log b(x_*) + \text{const.} \\
&= \frac{\lambda}{2(1+\beta)} \left(-((1+\beta)x_*^2 + x_*^2 + 2\beta_m x_* - \beta_m^2) - (1+\beta)\beta_m^2 \right. \\
&\quad \left. + \beta x_*^2 - 2\beta_m x_* + \beta_m^2 \right) \\
&\quad - \left(\frac{1}{2} + \alpha \right) \log b(x_*) + \text{const.} \\
&= -\left(\frac{1}{2} + \alpha \right) \log b(x_*) + \text{const.} \\
&= -\frac{2\alpha + 1}{2} \log \left(b \left(1 + \frac{\beta}{2b(1+\beta)} (x_* - m)^2 \right) \right) + \text{const} \\
&= -\frac{2\alpha + 1}{2} \log \left(1 + \frac{\beta}{2b(1+\beta)} (x_* - m)^2 \right) + \text{const.}
\end{aligned}$$

Задача Student о т. б. ф.

$$p(x_*) = St(x_* | \mu_s, \lambda_s, \nu_s),$$

$$\mu_s = m, \lambda_s = \frac{\beta \alpha}{(1+\beta)b}, \nu_s = 2\alpha.$$