


Modelos Gaussianas




Mike Wiper

Departamento de Estadística
Universidad Carlos III de Madrid

Grado en Estadística y Empresa

Objetivo



Mostrar como implementar la inferencia bayesiana cuando los datos son normales o Gaussianos.

La verosimilitud Gaussiana

Supongamos que observamos datos y_1, \dots, y_n de una distribución Gaussiana: Normal (μ, σ^2) . Luego, la función de verosimilitud es:

$$\begin{aligned} f(\text{datos}|\mu, \sigma^2) &= \prod_{i=1}^n f(y_i|\mu, \sigma^2) \\ &= \prod_{i=1}^n \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{1}{2\sigma^2}(y_i - \mu)^2\right) \\ &= (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mu)^2\right) \\ &= (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \bar{y} + \bar{y} - \mu)^2\right) \end{aligned}$$

La verosimilitud Gaussiana

Ahora, resolvemos el cuadrado y tenemos:

$$\begin{aligned}f(\text{datos}|\mu, \sigma^2) &= (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} \left[\sum_{i=1}^n (y_i - \bar{y})^2 + 2 \sum_{i=1}^n (y_i - \bar{y})(\bar{y} - \mu) + \right. \right. \\ &\quad \left. \left. \sum_{i=1}^n (\bar{y} - \mu)^2 \right] \right) \\ &= (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} \left[\sum_{i=1}^n (y_i - \bar{y})^2 + n(\bar{y} - \mu)^2 \right] \right) \\ &= (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} \left[(n-1)s^2 + n(\bar{y} - \mu)^2 \right] \right)\end{aligned}$$

donde la cuasi-varianza, $s^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2$.

Estimación máximo-verosimil

Es fácil ver que el EMV de μ es $\hat{\mu} = \bar{y}$ (tanto si σ^2 es conocido como desconocido).

Cuando μ es desconocido, el EMV de σ^2 es la varianza muestral:

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2.$$

El EMV de σ^2 cuando μ es desconocido es sesgado. Un estimador insesgado es la cuasi-varianza.

Estimación por intervalos

Se tiene que $\bar{Y}|\mu, \sigma^2 \sim \text{Normal}\left(\mu, \frac{\sigma^2}{n}\right)$.

En el caso de que σ^2 sea desconocido, recordamos que $\sum_{i=1}^n (Y_i - \bar{Y})^2 \sim \chi_{n-1}^2$ y luego, el intervalo para μ es:

$$\bar{y} \pm t_{n-1} \left(1 - \frac{\alpha}{2}\right) \frac{s}{\sqrt{n}},$$

dónde $t_a(p)$ es el p -cuantíl de la distribución t de Student con a grados de libertad.

▶ ST


Cuando μ es desconocido, un intervalo para σ^2 es:

$$\left(\frac{(n-1)s^2}{\chi_{n-1}^2 \left(1 - \frac{\alpha}{2}\right)}, \frac{(n-1)s^2}{\chi_{n-1}^2 \left(\frac{\alpha}{2}\right)} \right),$$

dónde $\chi_a^2(p)$ es el p -cuantíl de una distribución ji-cuadrado con a grados de libertad.

Ejemplo

Famosos datos utilizados para demostrar empíricamente la teoría de la relatividad.



$$n = 64, \quad \bar{y} = -0,015 \quad s^2 = 0,042$$

Intervalos de 95 % de confianza para μ, σ^2 son $(-0,066, 0,036)$ y $(0,0310, 0,062)$ respectivamente.

Inferencia bayesiana

¿Existe una distribución a priori conjugada (para μ y/o σ^2) en el caso de datos Gaussianos?

Miramos la función de verosimilitud otra vez:

$$l(\mu, \sigma^2 | \text{datos}) \propto \sigma^{-n} \exp\left(-\frac{1}{2\sigma^2} [(n-1)s^2 + n(\bar{y} - \mu)^2]\right).$$

En términos de μ , ¿parece como una distribución conocida?

Inferencia bayesiana

¿Existe una distribución a priori conjugada (para μ y/o σ^2) en el caso de datos Gaussianos?

Miramos la función de verosimilitud otra vez:

$$l(\mu, \sigma^2 | \text{datos}) \propto \sigma^{-n} \exp\left(-\frac{1}{2\sigma^2} [(n-1)s^2 + n(\bar{y} - \mu)^2]\right).$$

En términos de μ , ¿parece como una distribución conocida?

En términos de σ^2 , ¿parece como una distribución conocida?

Reescribiendo la verosimilitud

Sea $\phi = 1/\sigma^2$ la precisión del modelo. Luego, escribimos la verosimilitud en términos de ϕ :

$$l(\mu, \phi | \text{datos}) \propto \phi^{\frac{n}{2}} \exp\left(-\frac{\phi}{2} [(n-1)s^2 + n(\bar{y} - \mu)^2]\right).$$

Ahora, en términos de ϕ , ¿parece como una distribución conocida?

Una distribución a priori conjugada: la distribución normal-gamma

Consideramos la situación donde tanto μ como ϕ son desconocidos. Una distribución a priori natural es suponer que:

$$\begin{aligned}\phi &\sim \text{Gamma}\left(\frac{a}{2}, \frac{b}{2}\right) \\ \mu|\phi &\sim \text{Normal}\left(m, \frac{1}{c\phi}\right)\end{aligned}$$

Esta distribución se llama la distribución normal-gamma con parámetros m, c, a, b .

Propiedades de la distribución normal-gamma

La distribución conjunta de μ, ϕ es:

$$f(\mu, \phi) = \sqrt{\frac{c}{2\pi}} \frac{\left(\frac{b}{2}\right)^{\frac{a}{2}}}{\Gamma\left(\frac{a}{2}\right)} \phi^{\frac{a+1}{2}-1} \exp\left(-\frac{\phi}{2} [b + c(\mu - m)^2]\right)$$

La distribución marginal de μ es:

$$\begin{aligned} f(\mu) &= \int_0^{\infty} f(\mu, \phi) d\phi \\ &= \sqrt{\frac{c}{2\pi}} \frac{\left(\frac{b}{2}\right)^{\frac{a}{2}}}{\Gamma\left(\frac{a}{2}\right)} \int_0^{\infty} \phi^{\frac{a+1}{2}-1} \exp\left(-\frac{\phi}{2} [b + c(\mu - m)^2]\right) d\phi \\ &= \sqrt{\frac{c}{2\pi}} \frac{\left(\frac{b}{2}\right)^{\frac{a}{2}}}{\Gamma\left(\frac{a}{2}\right)} \frac{\Gamma\left(\frac{a+1}{2}\right)}{\left(\frac{1}{2} [b + c(\mu - m)^2]\right)^{\frac{a+1}{2}}} \end{aligned}$$

Propiedades de la distribución normal-gamma

$$\begin{aligned} f(\mu) &= \sqrt{\frac{c}{b\pi}} \frac{\Gamma\left(\frac{a+1}{2}\right)}{\Gamma\left(\frac{a}{2}\right)} \left(1 + \frac{c}{b} (\mu - m)^2\right)^{-\frac{a+1}{2}} \\ &= \sqrt{\frac{ac}{b}} \frac{\Gamma\left(\frac{a+1}{2}\right)}{\sqrt{a\pi}\Gamma\left(\frac{a}{2}\right)} \left(1 + \frac{1}{a} \left(\frac{\mu - m}{\sqrt{b/(ac)}}\right)^2\right)^{-\frac{a+1}{2}} \end{aligned}$$

La distribución marginal de μ es una distribución t de Student, escalada y no centrada:

$$\frac{\mu - m}{\sqrt{b/(ac)}} \sim t_a.$$

La distribución a posteriori

Se puede demostrar que dada la muestra, y_1, \dots, y_n , la distribución a posteriori es también normal gamma con parámetros m^* , c^* , a^* , b^* donde:

$$\begin{aligned}c^* &= c + n \\m^* &= \frac{cm + n\bar{y}}{c + n} \\a^* &= a + n \\b^* &= b + (n - 1)s^2 + \frac{cn}{c + n}(m - \bar{y})^2\end{aligned}$$

► Demostración

Ejemplo

Usamos una distribución a priori normal-gamma con $m = 0$, $c = 1$, $a = b = 1$.
Luego,

$$E[\mu|\text{datos}] = -0,014 \quad E[\sigma^2|\text{datos}] = 0,058$$

y intervalos de 95 % de credibilidad para μ , σ^2 son $(-0,073, 0,044)$ y $(0,041, 0,082)$ respectivamente

Predicción

Supongamos que queremos predecir un nuevo dato: $Y|\mu, \phi \sim \text{Normal}\left(\mu, \frac{1}{\phi}\right)$.


Luego, tenemos $Y = \mu + \epsilon$ donde $\mu|\phi, \text{datos} \sim \text{Normal}\left(m^*, \frac{1}{c^*\phi}\right)$,

$\epsilon|\phi \sim \text{Normal}\left(0, \frac{1}{\phi}\right)$, $\phi|\text{datos} \sim \text{Gamma}\left(\frac{a^*}{2}, \frac{b^*}{2}\right)$.

Luego, $Y|\phi, \text{datos} \sim \text{Normal}\left(m^*, \frac{1}{c^{**}\phi}\right)$ donde $c^{**} = \frac{c^*}{c^*+1}$ y la distribución conjunta de Y, ϕ es normal gamma.

Entonces, la distribución marginal de Y es otra t de Student trasladada y escalada.

Ejemplo



La distribución predictiva se ajusta bastante bien a los datos.

Una distribución a priori “no-informativa”

Dejando $c, m, a, b \rightarrow 0$ proporciona la distribución a priori impropia:

$$f(\mu, \phi) \propto \frac{1}{\phi}.$$

En este caso, la distribución a posteriori es

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

que es una distribución normal-gamma:

$$\mu | \phi, \text{datos} \sim \text{Normal}\left(\bar{y}, \frac{1}{n\phi}\right)$$

$$\phi | \text{datos} \sim \text{Gamma}\left(\frac{n-1}{2}, \frac{(n-1)s^2}{2}\right)$$

Estimación de μ

Claramente, la media a posteriori de μ es $E[\mu|\text{datos}] = \bar{y} = \hat{\mu}$.

Además, recordando la fórmula para la distribución marginal de μ , tenemos:

$$\frac{\mu - \bar{y}}{s/\sqrt{n}} \sim t_{n-1}$$

y luego, un intervalo bayesiano de credibilidad para μ coincide con el intervalo frecuentista.

Estimación de ϕ y σ^2

La media a posteriori de ϕ es $E[\phi|\text{datos}] = \frac{1}{s^2}$, correspondiendo al inverso del estimador insesgado frecuentista de σ^2 .

No obstante, la media a posteriori de σ^2 es

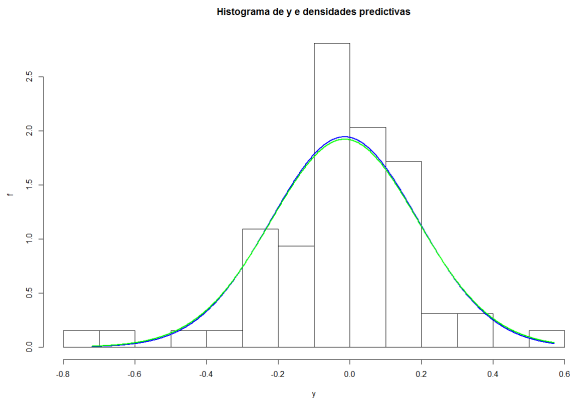
$$E[\sigma^2|\text{datos}] = E\left[\frac{1}{\phi}|\text{datos}\right] = \frac{n-1}{n-3}s^2$$

que es distinto al EMV.


El intervalo de credibilidad para σ^2 sí coincide con el intervalo frecuentista.

Predicción y ejemplo

En el caso de la predicción frecuentista, lo normal sería utilizar estimadores "plug-in" de μ, σ^2 , y luego, la distribución predictiva, frecuentista sería Normal (\bar{y}, s^2) . La distribución predictiva bayesiana es una t de Student y muestra alguna diferencia con la predicción frecuentista.



Apéndice: la distribución t de Student



Una variable continua, Y tiene una distribución t de Student con $\nu > 0$ grados de libertad si:

$$f(y) = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{2\pi\nu}\Gamma\left(\frac{\nu}{2}\right)} \left(1 + \frac{y^2}{\nu}\right)^{-\frac{\nu+1}{2}} \quad \forall y \in \mathbb{R}.$$

Se tiene $E[Y] = 0$ para $\nu > 1$ y $V[Y] = \frac{\nu}{\nu-2}$ para $\nu > 2$.

Resumen y siguiente sesión

$$\hat{\nu} \approx \frac{(g_1 + g_2)^2}{g_1^2/(n_1 - 1) + g_2^2/(n_2 - 1)} \quad \text{where } g_i = s_i^2/n_i.$$

En esta sección hemos comparado la inferencia frecuentista y la inferencia bayesiana para una población normal.

En la siguiente sesión estudiamos problemas de dos muestras y introduciremos como usar el método Monte Carlo para implementar la inferencia bayesiana en uno de ellos, que es difícil de resolver con métodos básicos frecuentistas.

Apéndice: demostración de la distribución a posteriori

Por el teorema de Bayes:

$$\begin{aligned}f(\mu, \phi | \text{datos}) &\propto f(\text{datos} | \mu, \phi) f(\mu, \phi) \\&\propto \phi^{\frac{n}{2}} \exp\left(-\frac{\phi}{2} [(n-1)s^2 + n(\mu - \bar{y})^2]\right) \times \\&\quad \sqrt{\frac{c}{2\pi}} \frac{\left(\frac{b}{2}\right)^{\frac{a}{2}}}{\Gamma\left(\frac{a}{2}\right)} \phi^{\frac{a+1}{2}-1} \exp\left(-\frac{\phi}{2} [b + c(\mu - m)^2]\right) \\&\propto \phi^{\frac{a+n+1}{2}-1} \exp\left(-\frac{\phi}{2} [b + (n-1)s^2 + c(\mu - m)^2 + n(\bar{y} - \mu)^2]\right) \\&\propto \phi^{\frac{a+n+1}{2}-1} \exp\left(-\frac{\phi}{2} [b + (n-1)s^2 + (c+n)\mu^2 -\right. \\&\quad \left. 2\mu(cm + n\bar{y}) + cm^2 + n\bar{y}^2]\right)\end{aligned}$$

$$\begin{aligned}
f(\mu, \phi | \text{datos}) &\propto \phi^{\frac{a+n+1}{2}-1} \exp \left(-\frac{\phi}{2} \left[b + (n-1)s^2 + (c+n) \left(\mu - \frac{cm + n\bar{y}}{c+n} \right)^2 \right. \right. \\
&\quad \left. \left. + cm^2 + n\bar{y}^2 - \frac{(cm + n\bar{y})^2}{c+n} \right] \right) \\
&\propto \phi^{\frac{a+n+1}{2}-1} \exp \left(-\frac{\phi}{2} \left[b + (n-1)s^2 + \frac{cn}{c+n} (m - \bar{y})^2 + \right. \right. \\
&\quad \left. \left. \left(\mu - \frac{cm + n\bar{y}}{c+n} \right)^2 \right] \right) \\
&\propto \phi^{\frac{a^*+1}{2}-1} \exp \left(-\frac{\phi}{2} \left[b^* + c^* (\mu - m^*)^2 \right] \right)
\end{aligned}$$

que es el núcleo de la distribución normal-gamma con parámetros a^* , b^* , c^* , m^* . 😊