

# MLE for 1D Gaussian PDF

假設我們有一組純量  $x_i, i=1 \cdots n$ ，如果這些點的分佈會趨近一個中間值，同時左右接近對稱，則我們可用一維高斯密度函數  $g(x_i; \mu, \sigma^2)$  來描述產生這些點的機率密度函數 (PDF, probability density function)：

$$g(x; \mu, \sigma^2) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right]$$

其中  $\mu$  代表此密度函數的中心點， $\sigma^2$  則約略代表此密度函數的寬窄，這些參數決定了此密度函數的特性。

我們的目標，是要求得 PDF 的最佳參數  $[\mu, \sigma^2]$  以描述所觀察到的資料點。在上述一維高斯密度函數的假設下，當  $x = x_i$  時，其機率密度為  $g(x_i; \mu, \sigma^2)$ ，若我們假設  $x_i, i=1 \sim n$  之間為互相獨立的事件，則發生  $X = \{x_1, x_2 \cdots x_n\}$  的機率密度為

$$p(X; \mu, \sigma^2) = \prod_{i=1}^n g(x_i; \mu, \sigma^2)$$

由於  $X$  是已經發生之事件，因此我們希望找出  $[\mu, \sigma^2]$  值，使得  $p(X; \mu, \sigma^2)$  能有最大值，此種估測 PDF 參數的方法，即稱為**最佳似然率估測法** (MLE, maximum likelihood estimation)。(注意： $p(X; \mu, \sigma^2)$  不是機率，而是機率密度，有時候又稱為 likelihood 或似然率。)

欲求得  $p(X; \mu, \sigma^2)$  的最大值，我們通常將之轉化為求下列  $J(\mu, \sigma^2)$  的最大值

$$\begin{aligned} J(\mu, \sigma^2) &= \ln p(X; \mu, \sigma^2) \\ &= \ln \left[ \prod_{i=1}^n g(x_i; \mu, \sigma^2) \right] \\ &= \sum_{i=1}^n \ln g(x_i; \mu, \sigma^2) \\ &= \sum_{i=1}^n \left[ -\frac{1}{2} \ln(2\pi) - \ln \sigma - \frac{1}{2} \left( \frac{x_i - \mu}{\sigma} \right)^2 \right] \\ &= -\frac{n}{2} \ln(2\pi) - n \ln \sigma - \frac{1}{2} \sum_{i=1}^n \left( \frac{x_i - \mu}{\sigma} \right)^2 \end{aligned}$$

欲求最佳的  $\mu$  及  $\sigma$  值，直接求  $J(\mu, \sigma^2)$  對  $\mu$  及  $\sigma$  的微分，並令其為零：

$$\frac{\partial J(\mu, \sigma^2)}{\partial \mu} = \sum_{i=1}^n \left( \frac{x_i - \mu}{\sigma} \right) = 0 \Rightarrow \hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i$$

$$\frac{\partial J(\mu, \sigma^2)}{\partial \sigma} = -\frac{n}{\sigma} - \sum_{i=1}^n \left( \frac{x_i - \mu}{\sigma} \right) \left( -\frac{x_i - \mu}{\sigma^2} \right) = 0 \Rightarrow \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{\mu})^2$$

上述所得到的  $\hat{\mu}$  及  $\hat{\sigma}^2$  值，即是使用 MLE 原則所得到的最佳參數值。