

Cap. 6 : Estimación de parámetros

Alexandre Blondin Massé

Departamento de Informática y Matemática
Université du Québec à Chicoutimi

19 de junio del 2015

Modelado de sistemas aleatorios
Ingeniería de sistemas, producción y ambiental

Tabla de contenidos

1. Introducción
2. Máxima verosimilitud
3. Media de una población normal
 - Varianza conocida
 - Varianza desconocida
4. Varianza de una población normal
5. Medias de dos poblaciones normales
 - Varianzas conocidas
 - Varianzas desconocidas

- ▶ En este capítulo, se considera una **muestra** de n variables aleatorias

$$(X_1, X_2, \dots, X_n)$$

que siguen una **distribución conocida**;

- ▶ Sin embargo, los **parámetros** de la distribución son **desconocidos**;
- ▶ **Ejemplo:** Una muestra de una **distribución de Poisson** cuya **media** λ es desconocida (**1 parámetro**);
- ▶ **Otro ejemplo:** Una muestra de una **distribución normal** cuyas **media** μ y **varianza** σ^2 son desconocidas (**2 parámetros**).

Estudiamos **2 tipos** de estimadores de un parámetro θ :
puntual y **por intervalo**.

- ▶ **Puntual**. Se asigna una **cantidad exacta** a θ ;
- ▶ **Por intervalo**. Se da
 1. un **intervalo** $[a, b]$ en el que pensamos que se encuentra el parámetro θ et
 2. un **nivel de confianza** que θ esté en $[a, b]$.

Definición

Cualquiera estadística que se utiliza para **estimar** el valor de un **parámetro desconocido** θ se llama **estimador**. El valor del **estimador** se llama **estimación**.

- ▶ Por ejemplo, un estimador de la **media de una población normal** es la **media muestral**

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n}.$$

- ▶ Si tenemos una muestra de tamaño $n = 3$ de tal manera que $X_1 = 2$, $X_2 = 3$ et $X_3 = 4$, entonces el valor $\bar{X} = 3$ es una **estimación** de la media de la población.

Tabla de contenidos

1. Introducción
2. Máxima verosimilitud
3. Media de una población normal
 - Varianza conocida
 - Varianza desconocida
4. Varianza de una población normal
5. Medias de dos poblaciones normales
 - Varianzas conocidas
 - Varianzas desconocidas

Ejemplo (1/2)

- ▶ Suponemos que una muestra X_1, X_2, \dots, X_n tiene una distribución **conjunta exponencial** de **media desconocida** θ .
- ▶ Entonces

$$f_{X_i}(x) = \lambda e^{-\lambda x} = \frac{1}{\theta} e^{-x/\theta}, \quad \text{para } i = 1, 2, \dots, n,$$

porque $\lambda = 1/\theta$.

- ▶ **Nota:** si X y Y son dos variables **aleatorias independientes** de densidades f_X y f_Y , entonces sus **densidades individuales** son

$$f(x, y) = f_X(x)f_Y(y).$$

Ejemplo (2/2)

- ▶ Si los X_i son independientes, la **densidad conjunta** es

$$f(x_1, x_2, \dots, x_n)$$

Ejemplo (2/2)

- ▶ Si los X_i son independientes, la **densidad conjunta** es

$$f(x_1, x_2, \dots, x_n) = f_{X_1}(x_1) \cdot f_{X_2}(x_2) \cdots f_{X_n}(x_n)$$

Ejemplo (2/2)

- ▶ Si los X_i son independientes, la **densidad conjunta** es

$$\begin{aligned}f(x_1, x_2, \dots, x_n) &= f_{X_1}(x_1) \cdot f_{X_2}(x_2) \cdots f_{X_n}(x_n) \\ &= \frac{1}{\theta} e^{-x_1/\theta} \cdot \frac{1}{\theta} e^{-x_2/\theta} \cdots \frac{1}{\theta} e^{-x_n/\theta}\end{aligned}$$

Ejemplo (2/2)

- Si los X_i son independientes, la **densidad conjunta** es

$$\begin{aligned}f(x_1, x_2, \dots, x_n) &= f_{X_1}(x_1) \cdot f_{X_2}(x_2) \cdots f_{X_n}(x_n) \\&= \frac{1}{\theta} e^{-x_1/\theta} \cdot \frac{1}{\theta} e^{-x_2/\theta} \cdots \frac{1}{\theta} e^{-x_n/\theta} \\&= \frac{1}{\theta} \exp(-x_1/\theta) \cdot \frac{1}{\theta} \exp(-x_2/\theta) \cdots \frac{1}{\theta} \exp(-x_n/\theta)\end{aligned}$$

Ejemplo (2/2)

- Si los X_i son independientes, la **densidad conjunta** es

$$\begin{aligned}f(x_1, x_2, \dots, x_n) &= f_{X_1}(x_1) \cdot f_{X_2}(x_2) \cdots f_{X_n}(x_n) \\&= \frac{1}{\theta} e^{-x_1/\theta} \cdot \frac{1}{\theta} e^{-x_2/\theta} \cdots \frac{1}{\theta} e^{-x_n/\theta} \\&= \frac{1}{\theta} \exp(-x_1/\theta) \cdot \frac{1}{\theta} \exp(-x_2/\theta) \cdots \frac{1}{\theta} \exp(-x_n/\theta) \\&= \frac{1}{\theta^n} \exp\left(-\frac{x_1 + x_2 + \cdots + x_n}{\theta}\right)\end{aligned}$$

Ejemplo (2/2)

- ▶ Si los X_i son independientes, la **densidad conjunta** es

$$\begin{aligned}f(x_1, x_2, \dots, x_n) &= f_{X_1}(x_1) \cdot f_{X_2}(x_2) \cdots f_{X_n}(x_n) \\&= \frac{1}{\theta} e^{-x_1/\theta} \cdot \frac{1}{\theta} e^{-x_2/\theta} \cdots \frac{1}{\theta} e^{-x_n/\theta} \\&= \frac{1}{\theta} \exp(-x_1/\theta) \cdot \frac{1}{\theta} \exp(-x_2/\theta) \cdots \frac{1}{\theta} \exp(-x_n/\theta) \\&= \frac{1}{\theta^n} \exp\left(-\frac{x_1 + x_2 + \cdots + x_n}{\theta}\right)\end{aligned}$$

- ▶ **Propósito:** estimar el parámetro θ a partir de los valores x_1, x_2, \dots, x_n utilizando la **densidad conjunta**.

La densidad conjunta $f(x_1, x_2, \dots, x_n)$ se puede ver como una función del **parámetro desconocido** θ

Definición

La **función de verosimilitud** del parámetro θ para una densidad conjunta $f(x_1, x_2, \dots, x_n)$ es

$$L(\theta) = f(x_1, x_2, \dots, x_n).$$

El **estimador de máxima verosimilitud (EMV)**, denotado por $\hat{\theta}$, es el valor de θ que **maximiza** $L(\theta)$.

Nota: No es siempre **único**.

Distribución de Bernoulli (1/3)

- ▶ Hacemos n experimentos **independientes** de Bernoulli, con probabilidad de **éxito** p ;
- ▶ ¿Cuál es el **EMV** para el **parámetro** p si tenemos una muestra X_1, X_2, \dots, X_n ?
- ▶ Es razonable suponer que la **proporción** de los variables X_i que son iguales a 1 en comparación con los que son iguales a 0 tienda hacia n ;
- ▶ En otras palabras, esperamos obtener

$$\hat{p} = \frac{\sum_{i=1}^n X_i}{n}.$$

- ▶ Primero, tenemos

$$P(X_i = 1) = p$$

$$P(X_i = 0) = 1 - p$$

$$P(X_i = x) = \mathbf{p^x(1 - p)^{1-x}}, \text{ para } x = 0, 1.$$

- ▶ Primero, tenemos

$$P(X_i = 1) = p$$

$$P(X_i = 0) = 1 - p$$

$$P(X_i = x) = \mathbf{p^x(1 - p)^{1-x}}, \text{ para } x = 0, 1.$$

- ▶ Consecuamente, la **función de verosimilitud** es

$$L(p)$$

- ▶ Primero, tenemos

$$P(X_i = 1) = p$$

$$P(X_i = 0) = 1 - p$$

$$P(X_i = x) = \mathbf{p^x(1 - p)^{1-x}}, \text{ para } x = 0, 1.$$

- ▶ Consecuamente, la **función de verosimilitud** es

$$L(p) = p^{x_1}(1 - p)^{1-x_1} \cdot p^{x_2}(1 - p)^{1-x_2} \cdots p^{x_n}(1 - p)^{1-x_n}$$

- ▶ Primero, tenemos

$$P(X_i = 1) = p$$

$$P(X_i = 0) = 1 - p$$

$$P(X_i = x) = \mathbf{p^x(1 - p)^{1-x}}, \text{ para } x = 0, 1.$$

- ▶ Consecuamente, la **función de verosimilitud** es

$$\begin{aligned} L(p) &= p^{x_1}(1-p)^{1-x_1} \cdot p^{x_2}(1-p)^{1-x_2} \cdots p^{x_n}(1-p)^{1-x_n} \\ &= p^{x_1+x_2+\dots+x_n}(1-p)^{n-(x_1+x_2+\dots+x_n)} \end{aligned}$$

- ▶ Primero, tenemos

$$P(X_i = 1) = p$$

$$P(X_i = 0) = 1 - p$$

$$P(X_i = x) = \mathbf{p^x(1 - p)^{1-x}}, \text{ para } x = 0, 1.$$

- ▶ Consecuamente, la **función de verosimilitud** es

$$\begin{aligned} L(p) &= p^{x_1}(1-p)^{1-x_1} \cdot p^{x_2}(1-p)^{1-x_2} \cdots p^{x_n}(1-p)^{1-x_n} \\ &= p^{x_1+x_2+\dots+x_n}(1-p)^{n-(x_1+x_2+\dots+x_n)} \\ &= p^{\sum_{i=1}^n x_i}(1-p)^{n-\sum_{i=1}^n x_i}. \end{aligned}$$

- ▶ ¿Cuál es el valor de p que **maximiza** $L(p)$?

- ▶ Para calcular el **máximo** de una función que contiene **productos**, es más fácil utilizar **logaritmo**:

$$\ln L(p) = \ln \left(p^{\sum_{i=1}^n x_i} (1-p)^{n-\sum_{i=1}^n x_i} \right)$$

- ▶ Para calcular el **máximo** de una función que contiene **productos**, es más fácil utilizar **logaritmo**:

$$\begin{aligned}\ln L(p) &= \ln \left(p^{\sum_{i=1}^n x_i} (1-p)^{n-\sum_{i=1}^n x_i} \right) \\ &= \sum_{i=1}^n x_i \ln(p) + \left(n - \sum_{i=1}^n x_i \right) \ln(1-p)\end{aligned}$$

- ▶ Para calcular el **máximo** de una función que contiene **productos**, es más fácil utilizar **logaritmo**:

$$\begin{aligned}\ln L(p) &= \ln \left(p^{\sum_{i=1}^n x_i} (1-p)^{n-\sum_{i=1}^n x_i} \right) \\ &= \sum_{i=1}^n x_i \ln(p) + \left(n - \sum_{i=1}^n x_i \right) \ln(1-p)\end{aligned}$$

- ▶ Luego, derivamos

$$\frac{d}{dp} \ln L(p) = \frac{\sum_{i=1}^n x_i}{p} - \frac{n - \sum_{i=1}^n x_i}{1-p}$$

- ▶ Para calcular el **máximo** de una función que contiene **productos**, es más fácil utilizar **logaritmo**:

$$\begin{aligned}\ln L(p) &= \ln \left(p^{\sum_{i=1}^n x_i} (1-p)^{n-\sum_{i=1}^n x_i} \right) \\ &= \sum_{i=1}^n x_i \ln(p) + \left(n - \sum_{i=1}^n x_i \right) \ln(1-p)\end{aligned}$$

- ▶ Luego, derivamos

$$\frac{d}{dp} \ln L(p) = \frac{\sum_{i=1}^n x_i}{p} - \frac{n - \sum_{i=1}^n x_i}{1-p}$$

- ▶ La derivada es **nula** si

$$p = \frac{\sum_{i=1}^n x_i}{n}.$$

- ▶ Se producen **microchips RAM** en una fábrica.
- ▶ Cada microchip es **aceptable** con probabilidad p , de manera **independiente**.
- ▶ Suponemos que en una muestra de **1000 microchips**, **921** son aceptables y **79 son defectuosos**.
- ▶ ¿Cuál es el **EMV** para p ?

- ▶ Se producen **microchips RAM** en una fábrica.
- ▶ Cada microchip es **aceptable** con probabilidad p , de manera **independiente**.
- ▶ Suponemos que en una muestra de **1000 microchips**, **921** son aceptables y **79 son defectuosos**.
- ▶ ¿Cuál es el **EMV** para p ?
- ▶ Sea

$$X_i = \begin{cases} 1, & \text{si el microchip } i \text{ es aceptable;} \\ 0, & \text{si no es aceptable.} \end{cases}$$

- ▶ Se producen **microchips RAM** en una fábrica.
- ▶ Cada microchip es **aceptable** con probabilidad p , de manera **independiente**.
- ▶ Suponemos que en una muestra de **1000 microchips**, **921** son aceptables y **79 son defectuosos**.
- ▶ ¿Cuál es el **EMV** para p ?
- ▶ Sea

$$X_i = \begin{cases} 1, & \text{si el microchip } i \text{ es aceptable;} \\ 0, & \text{si no es aceptable.} \end{cases}$$

- ▶ Entonces

$$\hat{p} = \sum_{i=1}^n x_i / 1\ 000 = 921 / 1000 = \mathbf{0,921}.$$

Distribución de Poisson (1/3)

- ▶ Sean X_1, X_2, \dots, X_n variables aleatorias **independientes** de **Poisson** de parámetro **desconocido** λ ;
- ▶ ¿Cuál es el **EMV** para λ ?
- ▶ Como λ es la **media**, esperamos que

$$\hat{\lambda} = \frac{\sum_{i=1}^n X_i}{n}.$$

- ▶ La **función de probabilidad de Poisson** es

$$f(x) = \frac{e^{-\lambda} \lambda^x}{x!}.$$

- ▶ La **función de verosimilitud** del parámetro λ para una muestra de tamaño n es

$$L(\lambda) = \frac{e^{-\lambda} \lambda^{x_1}}{x_1!} \cdot \frac{e^{-\lambda} \lambda^{x_2}}{x_2!} \cdots \frac{e^{-\lambda} \lambda^{x_n}}{x_n!}$$

- ▶ La **función de probabilidad de Poisson** es

$$f(x) = \frac{e^{-\lambda} \lambda^x}{x!}.$$

- ▶ La **función de verosimilitud** del parámetro λ para una muestra de tamaño n es

$$\begin{aligned} L(\lambda) &= \frac{e^{-\lambda} \lambda^{x_1}}{x_1!} \cdot \frac{e^{-\lambda} \lambda^{x_2}}{x_2!} \cdots \frac{e^{-\lambda} \lambda^{x_n}}{x_n!} \\ &= \frac{e^{-n\lambda} \lambda^{\sum_{i=1}^n x_i}}{x_1! x_2! \cdots x_n!} \end{aligned}$$

- ▶ ¿Cuál es el **EMV** $\hat{\lambda}$?

- ▶ Se calcula otra vez el **logaritmo**:

$$\ln L(\lambda) = -n\lambda + \sum_{i=1}^n x_i \ln(\lambda) - \ln(x_1!x_2! \cdots x_n!).$$

- ▶ Se calcula otra vez el **logaritmo**:

$$\ln L(\lambda) = -n\lambda + \sum_{i=1}^n x_i \ln(\lambda) - \ln(x_1!x_2! \cdots x_n!).$$

- ▶ Luego, **derivamos**

$$\frac{d}{d\lambda} \ln L(\lambda) = -n + \frac{\sum_{i=1}^n x_i}{\lambda}.$$

- ▶ Se calcula otra vez el **logaritmo**:

$$\ln L(\lambda) = -n\lambda + \sum_{i=1}^n x_i \ln(\lambda) - \ln(x_1!x_2! \cdots x_n!).$$

- ▶ Luego, **derivamos**

$$\frac{d}{d\lambda} \ln L(\lambda) = -n + \frac{\sum_{i=1}^n x_i}{\lambda}.$$

- ▶ La derivada es **nula** cuando

$$\lambda = \frac{\sum_{i=1}^n x_i}{n}.$$

- ▶ Los números de **accidentes** en una ciudad dada durante **10 días** elegidos al azar son

4, 0, 6, 5, 2, 1, 2, 0, 4, 3.

- ▶ Utilicen estos datos para **estimar la proporción** de días del año que no tienen más de **2 accidentes**.

Aplicación (2/2)

- ▶ Es razonable suponer que el número de accidentes sigue una **distribución de Poisson**.

Aplicación (2/2)

- ▶ Es razonable suponer que el número de accidentes sigue una **distribución de Poisson**.
- ▶ También, tenemos

$$\bar{X} = \frac{1}{10} \sum_{i=1}^{10} X_i = 2,7.$$

Aplicación (2/2)

- ▶ Es razonable suponer que el número de accidentes sigue una **distribución de Poisson**.
- ▶ También, tenemos

$$\bar{X} = \frac{1}{10} \sum_{i=1}^{10} X_i = 2,7.$$

- ▶ Entonces $\hat{\lambda} = 2,7$.

Aplicación (2/2)

- ▶ Es razonable suponer que el número de accidentes sigue una **distribución de Poisson**.
- ▶ También, tenemos

$$\bar{X} = \frac{1}{10} \sum_{i=1}^{10} X_i = 2,7.$$

- ▶ Entonces $\hat{\lambda} = 2,7$.
- ▶ Ahora, sea X el número de accidentes en un día dado;

Aplicación (2/2)

- ▶ Es razonable suponer que el número de accidentes sigue una **distribución de Poisson**.
- ▶ También, tenemos

$$\bar{X} = \frac{1}{10} \sum_{i=1}^{10} X_i = 2,7.$$

- ▶ Entonces $\hat{\lambda} = 2,7$.
- ▶ Ahora, sea X el número de accidentes en un día dado;
- ▶ Entonces la estimación buscada es

$$P(X \leq 2)$$

Aplicación (2/2)

- ▶ Es razonable suponer que el número de accidentes sigue una **distribución de Poisson**.
- ▶ También, tenemos

$$\bar{X} = \frac{1}{10} \sum_{i=1}^{10} X_i = 2,7.$$

- ▶ Entonces $\hat{\lambda} = 2,7$.
- ▶ Ahora, sea X el número de accidentes en un día dado;
- ▶ Entonces la estimación buscada es

$$P(X \leq 2) = P(X = 0) + P(X = 1) + P(X = 2)$$

Aplicación (2/2)

- ▶ Es razonable suponer que el número de accidentes sigue una **distribución de Poisson**.
- ▶ También, tenemos

$$\bar{X} = \frac{1}{10} \sum_{i=1}^{10} X_i = 2,7.$$

- ▶ Entonces $\hat{\lambda} = 2,7$.
- ▶ Ahora, sea X el número de accidentes en un día dado;
- ▶ Entonces la estimación buscada es

$$\begin{aligned} P(X \leq 2) &= P(X = 0) + P(X = 1) + P(X = 2) \\ &= e^{-2,7} \left(1 + 2,7 + \frac{(2,7)^2}{2} \right) \end{aligned}$$

Aplicación (2/2)

- ▶ Es razonable suponer que el número de accidentes sigue una **distribución de Poisson**.
- ▶ También, tenemos

$$\bar{X} = \frac{1}{10} \sum_{i=1}^{10} X_i = 2,7.$$

- ▶ Entonces $\hat{\lambda} = 2,7$.
- ▶ Ahora, sea X el número de accidentes en un día dado;
- ▶ Entonces la estimación buscada es

$$\begin{aligned} P(X \leq 2) &= P(X = 0) + P(X = 1) + P(X = 2) \\ &= e^{-2,7} \left(1 + 2,7 + \frac{(2,7)^2}{2} \right) \\ &\approx \mathbf{0,4936}. \end{aligned}$$

Distribución normal (1/3)

- ▶ Sean X_1, X_2, \dots, X_n variables **normales** de media **desconocida** μ y de desviación estándar **desconocida** σ ;
- ▶ ¿Cuál es el **EMV** para μ y σ ?

Distribución normal (1/3)

- ▶ Sean X_1, X_2, \dots, X_n variables **normales** de media **desconocida** μ y de desviación estándar **desconocida** σ ;
- ▶ ¿Cuál es el **EMV** para μ y σ ?
- ▶ Vamos a ver que

$$\begin{aligned}\hat{\mu} &= \bar{X} \\ \hat{\sigma} &= S\sqrt{\frac{n-1}{n}},\end{aligned}$$

- ▶ En otras palabras, son la **media muestral** y la **desviación estándar muestral no corregida**.

- ▶ La **función de densidad** de una distribución normal es

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

- ▶ La **función de densidad** de una distribución normal es

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

- ▶ Entonces, la **función de verosimilitud** de los parámetros μ y σ para una muestra de tamaño n es

$$L(\mu, \sigma) = \left(\frac{1}{2\pi} \right)^{n/2} \frac{1}{\sigma^n} \exp \left[\frac{-\sum_{i=1}^n (x_i - \mu)^2}{2\sigma^2} \right].$$

- ▶ La **función de densidad** de una distribución normal es

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

- ▶ Entonces, la **función de verosimilitud** de los parámetros μ y σ para una muestra de tamaño n es

$$L(\mu, \sigma) = \left(\frac{1}{2\pi} \right)^{n/2} \frac{1}{\sigma^n} \exp \left[\frac{-\sum_{i=1}^n (x_i - \mu)^2}{2\sigma^2} \right].$$

- ▶ Buscamos los valores μ y σ que **maximizan** L .

- ▶ El **logaritmo** de verosimilitud es

$$\ln(L(\mu, \sigma)) = -\frac{n}{2} \ln(2\pi) - n \ln \sigma - \frac{\sum_{i=1}^n (x_i - \mu)^2}{2\sigma^2}.$$

- ▶ El **logaritmo** de verosimilitud es

$$\ln(L(\mu, \sigma)) = -\frac{n}{2} \ln(2\pi) - n \ln \sigma - \frac{\sum_{i=1}^n (x_i - \mu)^2}{2\sigma^2}.$$

- ▶ Derivando **respecto a μ** y a σ , obtenemos

$$\frac{\partial}{\partial \mu} \ln(L(\mu, \sigma)) = \frac{\sum_{i=1}^n (x_i - \mu)}{\sigma^2}$$

$$\frac{\partial}{\partial \sigma} \ln(L(\mu, \sigma)) = -\frac{n}{\sigma} + \frac{\sum_{i=1}^n (x_i - \mu)^2}{\sigma^3}.$$

Distribución normal (3/3)

- ▶ El **logaritmo** de verosimilitud es

$$\ln(L(\mu, \sigma)) = -\frac{n}{2} \ln(2\pi) - n \ln \sigma - \frac{\sum_{i=1}^n (x_i - \mu)^2}{2\sigma^2}.$$

- ▶ Derivando **respecto a μ** y a σ , obtenemos

$$\frac{\partial}{\partial \mu} \ln(L(\mu, \sigma)) = \frac{\sum_{i=1}^n (x_i - \mu)}{\sigma^2}$$

$$\frac{\partial}{\partial \sigma} \ln(L(\mu, \sigma)) = -\frac{n}{\sigma} + \frac{\sum_{i=1}^n (x_i - \mu)^2}{\sigma^3}.$$

- ▶ Entonces

$$\hat{\mu} = \sum_{i=1}^n x_i/n \quad \text{y} \quad \hat{\sigma} = \sqrt{\sum_{i=1}^n (x_i - \hat{\mu})^2/n}.$$

Distribución uniforme

- ▶ Suponemos que X_1, X_2, \dots, X_n siguen una distribución uniforme en el intervalo $[0, \theta]$, donde θ es desconocido;

Distribución uniforme

- ▶ Suponemos que X_1, X_2, \dots, X_n siguen una distribución uniforme en el intervalo $[0, \theta]$, donde θ es desconocido;
- ▶ Entonces la función de verosimilitud es

$$L(\theta) = \begin{cases} 1/\theta^n, & \text{si } 0 < x_i < \theta \text{ para } i = 1, 2, \dots, n; \\ 0, & \text{de otra manera.} \end{cases}$$

Distribución uniforme

- ▶ Suponemos que X_1, X_2, \dots, X_n siguen una distribución uniforme en el intervalo $[0, \theta]$, donde θ es desconocido;
- ▶ Entonces la función de verosimilitud es

$$L(\theta) = \begin{cases} 1/\theta^n, & \text{si } 0 < x_i < \theta \text{ para } i = 1, 2, \dots, n; \\ 0, & \text{de otra manera.} \end{cases}$$

- ▶ El máximo se llega cuando θ es pequeño.

Distribución uniforme

- ▶ Suponemos que X_1, X_2, \dots, X_n siguen una distribución uniforme en el intervalo $[0, \theta]$, donde θ es desconocido;
- ▶ Entonces la función de verosimilitud es

$$L(\theta) = \begin{cases} 1/\theta^n, & \text{si } 0 < x_i < \theta \text{ para } i = 1, 2, \dots, n; \\ 0, & \text{de otra manera.} \end{cases}$$

- ▶ El máximo se llega cuando θ es pequeño.
- ▶ Pero $\theta \geq x_1, x_2, \dots, x_n$, de tal manera que

$$\hat{\theta} = \text{máx}\{x_1, x_2, \dots, x_n\}.$$

Distribución uniforme

- ▶ Suponemos que X_1, X_2, \dots, X_n siguen una distribución uniforme en el intervalo $[0, \theta]$, donde θ es desconocido;
- ▶ Entonces la función de verosimilitud es

$$L(\theta) = \begin{cases} 1/\theta^n, & \text{si } 0 < x_i < \theta \text{ para } i = 1, 2, \dots, n; \\ 0, & \text{de otra manera.} \end{cases}$$

- ▶ El máximo se llega cuando θ es pequeño.
- ▶ Pero $\theta \geq x_1, x_2, \dots, x_n$, de tal manera que

$$\hat{\theta} = \text{máx}\{x_1, x_2, \dots, x_n\}.$$

- ▶ La media de la distribución es

$$\frac{\text{máx}\{X_1, X_2, \dots, X_n\}}{2} \neq \bar{X}.$$

Tabla de contenidos

1. Introducción
2. Máxima verosimilitud
3. Media de una población normal
 - Varianza conocida
 - Varianza desconocida
4. Varianza de una población normal
5. Medias de dos poblaciones normales
 - Varianzas conocidas
 - Varianzas desconocidas

- ▶ Sea X_1, X_2, \dots, X_n una muestra de una **población normal** de **media** μ y de **varianza** σ^2 ;
- ▶ Sabemos que \bar{X} es el **EMV** para μ ;
- ▶ No esperamos que \bar{X} sea **exactamente igual** a μ , pero que esté **cerca**;
- ▶ Consecuamente, en lugar de dar una **estimación puntual**, se prefiere de vez en cuando dar un **intervalo** donde se encuentra μ con un **nivel de confianza**.

Tabla de contenidos

1. Introducción
2. Máxima verosimilitud
3. Media de una población normal
 - Varianza conocida
 - Varianza desconocida
4. Varianza de una población normal
5. Medias de dos poblaciones normales
 - Varianzas conocidas
 - Varianzas desconocidas

Intervalo de confianza (1/3)

- ▶ Deseamos estimar la **media** μ de una población **normal** asumiendo que **conocemos** σ ;
- ▶ Sabemos que la variable aleatoria \bar{X} sigue una distribución **normal** con **media** μ y **varianza** σ^2/n ;
- ▶ Buscamos un **intervalo** que contiene μ con probabilidad **0,95**;
- ▶ Leyendo la **tabla normal**, obtenemos

$$P\left(-1,96 < \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} < 1,96\right) = 0,95.$$

- ▶ **Hallando** μ en la mitad de las desigualdades, obtenemos

$$P\left(\bar{X} - 1,96\frac{\sigma}{\sqrt{n}} < \mu < \bar{X} + 1,96\frac{\sigma}{\sqrt{n}}\right) = 0,95.$$

- ▶ Si \bar{x} es el vector de los **datos** en la muestra, entonces decimos que

$$\left(\bar{x} - 1,96\frac{\sigma}{\sqrt{n}}, \quad \bar{x} + 1,96\frac{\sigma}{\sqrt{n}}\right)$$

es un **intervalo de confianza (bilateral)** del parámetro μ à **95 %**;

En general:

Definición

Sea X_1, X_2, \dots, X_n una muestra aleatoria de una población normal de **media desconocida** μ y de **desviación estándar conocida** σ . Sea $\alpha \in [0, 1]$ un número real y z_α el número que satisface $P(Z > z_\alpha) = \alpha$, donde Z es una variable aleatoria normal estándar.

Entonces

$$\left(\bar{x} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \quad \bar{x} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right)$$

es un **intervalo de confianza (bilateral)** de nivel $1 - \alpha$ para la **media** μ .

Ejemplo (1/2)

- ▶ Suponemos que una información se transmite por un señal con un cierto **ruido**.
- ▶ Más precisamente, cuando el valor μ se transmite a partir de **un punto** A , vuelve $\mu + N$ al punto B , donde N es una variable normal de **media** 0 y de **varianza** 4 .
- ▶ Para reducir los errores, se envía el mismo valor **9 veces**.
- ▶ Suponemos que los valores son

5; 8,5; 12; 15; 7; 9; 7,5; 6,5; 10,5.

- ▶ Calculamos un intervalo de confianza de (a) **95%** y (b) **99%** para la media μ .

Ejemplo (2/2)

- ▶ Obtenemos $\bar{x} = 81/9 = \mathbf{9}$.

Ejemplo (2/2)

- ▶ Obtenemos $\bar{x} = 81/9 = \mathbf{9}$.
- ▶ Consecuamente, el interval de confianza es

$$\left(9 - 1,96\frac{\sigma}{3}, \quad 9 + 1,96\frac{\sigma}{3}\right) \approx (7,69; 10,31).$$

Ejemplo (2/2)

- ▶ Obtenemos $\bar{x} = 81/9 = 9$.
- ▶ Consecuamente, el intervalo de confianza es

$$\left(9 - 1,96\frac{\sigma}{3}, \quad 9 + 1,96\frac{\sigma}{3}\right) \approx (7,69; 10,31).$$

- ▶ Entonces, estamos **95 %** seguros que el valor esta entre **7,69** y **10,31**.

Ejemplo (2/2)

- ▶ Obtenemos $\bar{x} = 81/9 = 9$.
- ▶ Consecuamente, el intervalo de confianza es

$$\left(9 - 1,96\frac{\sigma}{3}, \quad 9 + 1,96\frac{\sigma}{3}\right) \approx (7,69; 10,31).$$

- ▶ Entonces, estamos **95 %** seguros que el valor esta entre **7,69** y **10,31**.
- ▶ Ahora, como $z_{0,01/2} = z_{0,005} \approx 2,575$, hay que

$$\left(9 - 2,575\frac{\sigma}{3}, \quad 9 + 2,575\frac{\sigma}{3}\right) \approx (7,283; 10,717).$$

Ejemplo (2/2)

- ▶ Obtenemos $\bar{x} = 81/9 = 9$.
- ▶ Consecuamente, el interval de confianza es

$$\left(9 - 1,96\frac{\sigma}{3}, \quad 9 + 1,96\frac{\sigma}{3}\right) \approx (7,69; 10,31).$$

- ▶ Entonces, estamos **95 %** seguros que el valor esta entre **7,69** y **10,31**.
- ▶ Ahora, como $z_{0,01/2} = z_{0,005} \approx 2,575$, hay que

$$\left(9 - 2,575\frac{\sigma}{3}, \quad 9 + 2,575\frac{\sigma}{3}\right) \approx (7,283; 10,717).$$


- ▶ Entonces, estamos **99 %** seguros que el valor esta entre **7,283** y **10,717**.

- ▶ De vez en cuando, deseamos saber si la media μ **no es mayor** que un valor dado con un **nivel de confianza**;
- ▶ En este caso, el intervalo es de la forma


$$\left(\bar{x} - z_{\alpha} \frac{\sigma}{\sqrt{n}}, +\infty \right) \quad \text{ou} \quad \left(-\infty, \bar{x} + z_{\alpha} \frac{\sigma}{\sqrt{n}} \right)$$

y decimos que el intervalo es **unilateral** y que su **nivel de confianza** es $1 - \alpha$.

Bilateral :



Unilateral :



Tamaño de una muestra (1/2)

- ▶ De vez en cuando, el problema se **invierte**;
- ▶ Por ejemplo, se puede preguntar que **tamaño de muestra** hay que utilizar para que el **error** sea con un **nivel de confianza dado**;
- ▶ Por ejemplo, el **peso promedio** de salmones **varia** cada año, pero la **desviación estándar** es siempre 0,3.
- ▶ Deseamos conocer la media con **confianza 95 %** y **error** menor que $\pm 0,1$.
- ▶ ¿Cuál **valor de n** tenemos que utilizar?

Tamaño de una muestra (1/2)

- ▶ Buscamos un intervalo de confianza a 95 %.

Tamaño de una muestra (1/2)

- ▶ Buscamos un intervalo de confianza a 95 %.
- ▶ Sea n el tamaño de la muestra. Entonces

$$\mu \in \left(\bar{x} - 1,96 \frac{\sigma}{\sqrt{n}}, \quad \bar{x} + 1,96 \frac{\sigma}{\sqrt{n}} \right).$$

Tamaño de una muestra (1/2)

- ▶ Buscamos un intervalo de confianza a 95 %.
- ▶ Sea n el tamaño de la muestra. Entonces

$$\mu \in \left(\bar{x} - 1,96 \frac{\sigma}{\sqrt{n}}, \quad \bar{x} + 1,96 \frac{\sigma}{\sqrt{n}} \right).$$

- ▶ Hay que

$$1,96 \frac{\sigma}{\sqrt{n}} \leq 0,1,$$

es decir que $\sqrt{n} \geq 5,88$ y entonces $n \geq 34,57$.

Tamaño de una muestra (1/2)

- ▶ Buscamos un intervalo de confianza a 95 %.
- ▶ Sea n el tamaño de la muestra. Entonces

$$\mu \in \left(\bar{x} - 1,96 \frac{\sigma}{\sqrt{n}}, \quad \bar{x} + 1,96 \frac{\sigma}{\sqrt{n}} \right).$$

- ▶ Hay que

$$1,96 \frac{\sigma}{\sqrt{n}} \leq 0,1,$$

es decir que $\sqrt{n} \geq 5,88$ y entonces $n \geq 34,57$.

- ▶ Así, una muestra de **35 o más** es suficiente.

Tabla de contenidos

1. Introducción
2. Máxima verosimilitud
3. Media de una población normal
 - Varianza conocida
 - Varianza desconocida
4. Varianza de una población normal
5. Medias de dos poblaciones normales
 - Varianzas conocidas
 - Varianzas desconocidas

Media y varianza desconocidas (1/2)

- ▶ Sea una muestra X_1, X_2, \dots, X_n de una población normal de **media desconocida** μ y de **varianza desconocida** σ^2 ;
- ▶ Aquí **no tenemos** el hecho que $\sqrt{n}(\bar{X} - \mu)/\sigma$ es una variable normal estándar;
- ▶ Sin embargo, sabemos que

$$\sqrt{n} \frac{\bar{X} - \mu}{S}$$

sigue una **distribución de Student** con $n - 1$ grados de libertad;

Media y varianza desconocidas (2/2)

- ▶ Consecuamente, para cualquier número $\alpha \in (0, 1/2)$, tenemos

$$P\left(-t_{\alpha/2, n-1} < \sqrt{n} \frac{\bar{X} - \mu}{S} < t_{\alpha/2, n-1}\right) = 1 - \alpha.$$

- ▶ Entonces,

$$P\left(\bar{X} - t_{\alpha/2, n-1} \frac{S}{\sqrt{n}} < \mu < \bar{X} + t_{\alpha/2, n-1} \frac{S}{\sqrt{n}}\right) = 1 - \alpha.$$

- ▶ Así que si se obtienen \bar{x} y s , entonces la media es

$$\mu \in \left(\bar{x} - t_{\alpha/2, n-1} \frac{s}{\sqrt{n}}, \quad \bar{x} + t_{\alpha/2, n-1} \frac{s}{\sqrt{n}}\right)$$

con **nivel de confianza** $1 - \alpha$.

- ▶ En el caso donde la **varianza es conocida**, tenemos versiones **unilaterales** para los intervalos.
- ▶ Podemos decir con **confianza** $1 - \alpha$ que

$$\mu \in \left(\bar{x} - \frac{s}{\sqrt{n}} t_{\alpha, n-1}, +\infty \right)$$

- ▶ También,

$$\mu \in \left(-\infty, \bar{x} - \frac{s}{\sqrt{n}} t_{\alpha, n-1} \right)$$

Ejemplo (1/2)

- ▶ Calculamos un intervalo de confianza a **95 %** para estimar el número de latidos del corazón por minuto de **15 personas**:

54, 63, 58, 72, 49, 92, 70, 73, 69, 104, 48, 66, 80, 64, 77.

- ▶ Se calculan la **media** y la **varianza muestrales**:

```
1 >>> X = [54, 63, 58, 72, 49, 92, 70, 73, 69, 104, 48, 66, 80, 64, 77]
2 >>> Xb = sum(X) * 1.0 / len(X)
3 >>> Xc = map(lambda x: x*x, X)
4 >>> print X; print Xb; print Xc
5 [54, 63, 58, 72, 49, 92, 70, 73, 69, 104, 48, 66, 80, 64, 77]
6 69.26666666666667
7 [2916, 3969, 3364, 5184, 2401, 8464, 4900, 5329, 4761, 10816, 2304,
8   4356, 6400, 4096, 5929]
9 >>> S2 = (sum(Xc) - len(X) * Xb**2) * 1.0 / (len(X) - 1)
10 >>> from math import sqrt
11 >>> S = sqrt(S2)
12 >>> print S2; print S
13 230.06666666666667
14 15.16794866638
```

Ejemplo (1/2)

- ▶ Luego calculamos los límites del intervalo de confianza a 95 % :

```
1 >>> from scipy.stats import t
2 >>> t.interval(0.95, len(X) - 1)
3 (-2.1447866879169273, 2.1447866879169273)
4 >>> t.interval(0.95, len(X) - 1, Xb, S/sqrt(len(X)))
5 (60.866936673272512, 77.666396660060826)
```

- ▶ Para obtener un intervalo **unilateral**, se hace así:

```
1 >>> t.interval(0.90, len(X) - 1, Xb, S/sqrt(len(X)))
2 (62.368764111375242, 76.164569221958089)
```

de tal manera que los intervalos son

$$(-\infty, 76,1646) \quad \text{y} \quad (62,3688, +\infty).$$

Tabla de contenidos

1. Introducción
2. Máxima verosimilitud
3. Media de una población normal
 - Varianza conocida
 - Varianza desconocida
4. Varianza de una población normal
5. Medias de dos poblaciones normales
 - Varianzas conocidas
 - Varianzas desconocidas

Intervalo de confianza para la varianza

- ▶ Sea una muestra X_1, X_2, \dots, X_n de una población normal de **media desconocida** μ y de **varianza desconocida** σ^2 ;
- ▶ Es también posible estimar la **varianza** σ^2 utilizando el hecho que

$$(n-1) \frac{S^2}{\sigma^2} \sim \chi_{n-1}^2.$$

- ▶ Entonces

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

con **confianza** $1 - \alpha$.

Ejemplo (1/2)

- ▶ Suponemos que una empresa produce **tuercas**;
- ▶ La desviación estándar debe ser **muy pequeña** para su espesor;
- ▶ Sea una muestra de **10 tuercas** con espesores:

123, 124, 126, 120, 130, 133, 125, 128, 124, 126.

- ▶ Deseamos calcular un intervalo confianza a **90%** para la desviación estándar.

Ejemplo (1/2)

- ▶ Suponemos que una empresa produce **tuercas**;
- ▶ La desviación estándar debe ser **muy pequeña** para su espesor;
- ▶ Sea una muestra de **10 tuercas** con espesores:

123, 124, 126, 120, 130, 133, 125, 128, 124, 126.

- ▶ Deseamos calcular un intervalo confianza a **90%** para la desviación estándar.
- ▶ La varianza muestral es **$S^2 \approx 1,366 \times 10^{-5}$** ;

Ejemplo (2/2)

- ▶ Tenemos $\chi_{0,05,9}^2 \approx 16,917$ y $\chi_{0,95,9}^2 \approx 3,334$:

```
1 >>> from scipy.stats import chi2
2 >>> chi2.ppf(0.05,9)
3 3.3251128430668162
4 >>> chi2.ppf(0.95,9)
5 16.918977604620448
```

Ejemplo (2/2)

- ▶ Tenemos $\chi_{0,05,9}^2 \approx 16,917$ y $\chi_{0,95,9}^2 \approx 3,334$:

```
1 >>> from scipy.stats import chi2
2 >>> chi2.ppf(0.05,9)
3 3.3251128430668162
4 >>> chi2.ppf(0.95,9)
5 16.918977604620448
```

- ▶ También

```
1 >>> 9 * 1.366 * 10**(-5) / chi2.ppf(0.95,9)
2 7.2663965206991e-06
3 >>> 9 * 1.366 * 10**(-5) / chi2.ppf(0.05,9)
4 3.6973181303107313e-05
```

Ejemplo (2/2)

- ▶ Tenemos $\chi_{0,05,9}^2 \approx 16,917$ y $\chi_{0,95,9}^2 \approx 3,334$:

```
1 >>> from scipy.stats import chi2
2 >>> chi2.ppf(0.05,9)
3 3.3251128430668162
4 >>> chi2.ppf(0.95,9)
5 16.918977604620448
```

- ▶ También

```
1 >>> 9 * 1.366 * 10**(-5) / chi2.ppf(0.95,9)
2 7.2663965206991e-06
3 >>> 9 * 1.366 * 10**(-5) / chi2.ppf(0.05,9)
4 3.6973181303107313e-05
```

- ▶ Un intervalo de confianza a 90% para σ^2 es
($7,266 \times 10^{-6}$, $36,973 \times 10^{-6}$)

Ejemplo (2/2)

- ▶ Tenemos $\chi_{0,05,9}^2 \approx 16,917$ y $\chi_{0,95,9}^2 \approx 3,334$:

```
1 >>> from scipy.stats import chi2
2 >>> chi2.ppf(0.05,9)
3 3.3251128430668162
4 >>> chi2.ppf(0.95,9)
5 16.918977604620448
```

- ▶ También

```
1 >>> 9 * 1.366 * 10**(-5) / chi2.ppf(0.95,9)
2 7.2663965206991e-06
3 >>> 9 * 1.366 * 10**(-5) / chi2.ppf(0.05,9)
4 3.6973181303107313e-05
```

- ▶ Un intervalo de confianza a **90%** para σ^2 es
 $(7,266 \times 10^{-6}, 36,973 \times 10^{-6})$
- ▶ Finalmente, un intervalo de confianza para σ es
 $(2,696 \times 10^{-3}, 6,072 \times 10^{-3})$.

Tabla de contenidos

1. Introducción
2. Máxima verosimilitud
3. Media de una población normal
 - Varianza conocida
 - Varianza desconocida
4. Varianza de una población normal
5. Medias de dos poblaciones normales
 - Varianzas conocidas
 - Varianzas desconocidas

- ▶ A hora se consideran **dos poblaciones normales** de **medias** μ_1 y μ_2 y de **varianzas** σ_1^2 y σ_2^2 ;
- ▶ Eligimos dos muestras $(X_i)_{1 \leq i \leq n}$ et $(Y_i)_{1 \leq i \leq m}$
- ▶ Deseamos estimar $\mu_1 - \mu_2$;
- ▶ Como antes, hay dos casos donde
 - ▶ Las varianzas σ_1^2 y σ_2^2 son conocidas;
 - ▶ Las varianzas σ_1^2 y σ_2^2 son desconocidas y $\sigma_1 = \sigma_2$.

- ▶ Primero, es fácil verificar que el **EMV** de $\mu_1 - \mu_2$ es $\bar{X} - \bar{Y}$;
- ▶ También, sabemos que

$$\begin{aligned}\bar{X} &\sim \mathcal{N}(\mu_1, \sigma_1^2/n) \\ \bar{Y} &\sim \mathcal{N}(\mu_2, \sigma_2^2/m),\end{aligned}$$

- ▶ Entonces

$$\bar{X} - \bar{Y} \sim \mathcal{N}\left(\mu_1 - \mu_2, \frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}\right).$$

- ▶ Cuando σ_1 y σ_2 son **conocidas**, se utiliza la **distribución normal** para estimar $\mu_1 - \mu_2$.

Tabla de contenidos

1. Introducción
2. Máxima verosimilitud
3. Media de una población normal
 - Varianza conocida
 - Varianza desconocida
4. Varianza de una población normal
5. Medias de dos poblaciones normales
 - Varianzas conocidas
 - Varianzas desconocidas

- ▶ Si las varianzas σ_1^2 y σ_2^2 son **conocidas**, entonces

$$\mu_1 - \mu_2 \in \left(\bar{x} - \bar{y} - z_{\alpha/2} \sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}} < \mu_1 - \mu_2 < \bar{x} - \bar{y} + z_{\alpha/2} \sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}} \right)$$

con **nivel de confianza** $1 - \alpha$;

- ▶ Se obtienen fórmulas similares para intervalos **unilaterales**.
- ▶ La distribución es mas **compleja** cuando las varianzas son **desconocidas**.

Tabla de contenidos

1. Introducción
2. Máxima verosimilitud
3. Media de una población normal
 - Varianza conocida
 - Varianza desconocida
4. Varianza de una población normal
5. Medias de dos poblaciones normales
 - Varianzas conocidas
 - Varianzas desconocidas

- ▶ En el caso donde σ_1^2 y σ_2^2 son **desconocidas**, es natural estimarlas con S_1 y S_2 ;
- ▶ Hay que conocer la distribución de

$$\frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{\sqrt{S_1^2/n + S_2^2/m}}.$$

- ▶ Desafortunadamente, esta distribución **depende de σ_1 y σ_2** ;
- ▶ Sin embargo, en el caso **special** donde $\sigma_1 = \sigma_2$, es posible dar una **estimación por intervalo**.

- ▶ Se puede demostrar que

$$\frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{\sqrt{S_p^2(1/n + 1/m)}}$$

sigue una **distribución de Student** de $n + m - 2$ **grados de libertad**, donde S_p^2 satisface

$$S_p^2 = \frac{(n-1)S_1^2 + (m-1)S_2^2}{n+m-2}.$$

- ▶ Consecuamente,

$$\mu_1 - \mu_2 \in \left(\bar{x} - \bar{y} - t_{\alpha/2, n+m-2} s_p \sqrt{1/n + 1/m}, \quad \bar{x} - \bar{y} + t_{\alpha/2, n+m-2} s_p \sqrt{1/n + 1/m} \right)$$

con **nivel de confianza** $1 - \alpha$.