

Estadísticos muestrales (media, vza.)

Antonio Sala Piqueras

Dept. Ing. Sistemas y Automática (DISA)
Universitat Politècnica de València (UPV)

Video-presentación disponible en:

<http://personales.upv.es/asala/YT/V/muest.html>



UNIVERSITAT
POLITÀCNICA
DE VALÈNCIA

Presentación

Motivación:

En una aplicación suele ser necesario indicar alrededor de qué valores se sitúa una variable aleatoria, y cómo de “dispersas” están sus muestras. Con un “modelo”, se calculan con sumas o integrales... ¿qué se hace con datos experimentales? Se estiman a partir de funciones (estadísticos) del conjunto de muestras.

Objetivos:

Comprender la relación de media, varianza y desviación típica de una variable aleatoria con sus estimados muestrales.

Contenidos:

Preliminares. Moda, media y varianza. Estadísticos muestrales. Ley de grandes números y resultados relacionados. Conclusiones.



Esperanza, Media y Varianza de una variable aleatoria

Sean una variable aleatoria $x \in \Omega \subset \mathbb{R}$, con una cierta función de densidad $f(x)$, o una variable discreta con un conjunto de probabilidades puntuales $p(x_1), p(x_2), \dots$.

- **Esperanza matemática** de $g : \Omega \mapsto \mathbb{R}$:

$$E(g(\cdot)) = \int_{\Omega} g(x) f(x) dx$$

$$\text{Discreto: } \mu := \sum_{x \in \Omega} g(x) p(x)$$

- **Media:** $\mu := E(x) = \int_{\Omega} x \cdot f(x) dx$

$$\text{Discr.: } \mu := \sum_{x \in \Omega} p(x) x$$

- **Varianza:**

$$\sigma^2 := E((x - \mu)^2) = \int_{\Omega} (x - \mu)^2 f(x) dx \quad \text{Discr.: } \sigma^2 = \sum_{x \in \Omega} p(x) \cdot (x - \mu)^2$$

Desviación típica: raíz cuadrada de varianza.



Media, Varianza y estadísticos muestrales

Si **no** se dispone de un **modelo** –*fórmula explícita de $f(x)$* –, puede obtenerse información **experimental** de una variable aleatoria x a base de **muestreo** (repetido).

A partir de muestras de datos $\xi^T := (x(1), x(2), x(3), x(4), \dots, x(N))$, de N repeticiones independientes con la misma distribución de probabilidad:

- **Media** muestral: $\mu_N := \frac{1}{N} \sum_{i=1}^N x(i)$.
- **Varianza** muestral: $\sigma_N^2 := \frac{1}{N-1} \sum_{i=1}^N (x(i) - E_N(x))^2$. Con media muestral cero (vbles. incrementales), resulta $\sigma_N^2 = \frac{1}{N-1} \xi^T \xi_x$.
- **Valor esperado** muestral: $E_N(g(x)) := \frac{1}{N} \sum_{i=1}^N g(x(i))$

En general, un “estadístico muestral” es una función $T(\xi) = T(x(1), \dots, x(N))$ que devuelve “números” que estiman algún parámetro de la distribución de probabilidad que ha generado la muestra ξ .



Exactitud según número de muestras N

Los **estadísticos muestrales** (media, varianza, ...) son ellos mismos **variables aleatorias**: si se repite el experimento se obtienen resultados diferentes.
 ¿Cómo se “parecen” a los **valores ideales** $\int \dots f(x) dx$ de media μ ,
 varianza σ^2 o esperanza matemática $E(g(x))$?

[1] **Ley de los grandes números:** muestras infinitas

“las integrales teóricas se pueden *aproximar promediando muchas muestras*”

$$\lim_{N \rightarrow \infty} E_N(x) = E(x), \quad \lim_{N \rightarrow \infty} E_N((\Delta x)^2) = \sigma^2, \quad \lim_{N \rightarrow \infty} E_N(g(x)) = E(g(x))$$

*Pero en la vida real, N nunca es infinito; a veces es bastante “pequeño” ...

[2] **Leyes de muestras finitas genéricas** (o “casi”):

Cotas de Chebyshev, Chernoff, Hoeffding, Bernstein.

$$P(|\mu_N - \mu| \leq \epsilon) \geq \alpha(N, \sigma, \epsilon)$$

[3] **Leyes de muestras finitas adaptadas a distribuciones de probabilidad**

concretas: p.ej. intervalos de confianza y tests estadísticos en distribución normal.

Conclusiones

- En variables aleatorias numéricas, se pueden definir media y varianza.
- A partir de múltiples muestras **independientes**, se estiman con operaciones sobre secuencias de datos.
 - Tomando muchas muestras, los valores muestrales convergen a los parámetros ideales de la distribución subyacente (ley grandes números).
 - Existen fórmulas que calculan número de muestras N necesario dada exactitud deseada ϵ y confianza estadística α —equivalentemente, probabilidad de equivocarse $(1-\alpha)$ —.
- Aplicaciones:
 - **validar modelos:** ¿Está, de verdad, la media de lo que está generando estos datos entre 7 y 8?
 - **identificación:** ajuste por mínimos cuadrados da $K = 3 \text{ N/m}$ de cte. de muelle; usados 300 datos con ruido. Si el muelle fuera realmente lineal, ¿Es la *'probabilidad de que me esté equivocando en más de 0.3 N/m'* menor del 5%?.