

Estadística I

Profesor de teoría:

Andrés M. Alonso

Despacho 10.1.32


E. Mail: andres.alonso@uc3m.es

Web: www.est.uc3m.es/amalonso

Web docente: <http://www.est.uc3m.es/amalonso/esp/docencia.html>

Profesores de práctica:

- Concepción Molina (Grupo 30)
- Javier Reques (Grupo 31)
- Natalia Fojo (Grupo 32)



Estadística I

Temario de la asignatura

- Análisis de datos univariantes.
- Análisis de datos bivariantes.
- Probabilidad.
- Variables aleatorias multidimensionales.
- Distribuciones muestrales.
- Estimación puntual.
- Estimación por intervalos.
- Contrastes de hipótesis.



Estadística I

Bibliografía básica

Newbold, P., Carlson, W.L. y Thorne, B. (2008) *Estadística para Administración y Economía*, Editorial Prentice Hall, Madrid.

Peña, D. (2001) *Fundamentos de Estadística*, Alianza Editorial, Madrid.

Peña, D. y Romo, J. (1997) *Introducción a la Estadística para las Ciencias Sociales*, Editorial McGraw Hill, Madrid.



Estadística I

Bibliografía complementaria

Levin, R.I. y Rubin, D.S. (2004) *Estadística para Administración y Economía*, Editorial Prentice Hall, Madrid.

Newbold, P. (2001) *Estadística para los Negocios y la Economía*, Editorial Prentice Hall, Madrid.

Martín Pliego, F.J. (2004) *Introducción a la Estadística Económica y Empresarial*, Thomson Editores, Madrid.

Moore, D.S. (1998) *Estadística Aplicada Básica*, Editorial Antoni Bosch, Barcelona.



Tema 1: Análisis de datos univariantes

1. Introducción

2. Representaciones y gráficos

- Tablas de frecuencias
- Diagrama de barras, Diagrama de sectores, Histograma, y Diagrama de caja

3. Resumen numérico

- Medidas de localización
- Medidas de dispersión
- Medidas de forma

Lecturas recomendadas:

- Capítulos 1 al 3 del libro de Newbold, Carlson, y Thorne (2008).
- Capítulos 1 y 2 del libro de Peña (2001).
- Capítulos 1 al 5 del libro de Peña y Romo (1997).



Objetivos del tema

Después de estudiar este tema, se podrá:

- Explicar las siguientes definiciones básicas:
 - ◆ Población frente a Muestra
 - ◆ Parámetro frente Estadístico
 - ◆ Estadística Descriptiva frente a Estadística Inferencial
- Describir un muestreo aleatorio



Objetivos del tema

Después de estudiar este tema, se podrá:

- Identificar tipos de datos y niveles de medidas.
- Crear e interpretar gráficos para describir variables categóricas:
 - Distribución de frecuencias, frecuencias absolutas y relativas, diagrama de barras, diagrama de tartas.
- Crear e interpretar gráficos para describir variables numéricas:
 - Distribución de frecuencias, frecuencias absolutas y relativas, frecuencias acumuladas absolutas y relativas, histograma, diagrama de cajas.



Objetivos del tema

Después de estudiar este tema, se podrá:


- Calcular e interpretar la **media, mediana, y moda** de un conjunto de datos.
- Calcular el **rango, varianza, desviación estándar, y coeficiente de variación** e interpretar dichos valores.

Definiciones básicas

- Una **población** es la colección **completa** de **todos** los elementos de interés que se investigan.
 - N representa el tamaño de la población
- Una **muestra** es un subconjunto observado de la población
 - n representa el tamaño muestral
- Un **parámetro** es una característica específica de una población (fija)
- Un **estadístico** es una característica específica de una muestra (puede variar entre diferentes muestras)


Población frente a muestra

Población



Valores calculados usando todos los elementos de la población se llaman **parámetros**

Muestra



Valores calculados usando los elementos de la muestra se llaman **estadísticos**



Ejemplos de poblaciones

- Nombres de **todos** los votantes de la Unión Europea
- Ingresos de **todas** las familias que viven en Getafe
- Índice anual de las acciones en la bolsa de Londres
- Nota media de **todos** los estudiantes de la universidad

Muestreo aleatorio

El **muestreo aleatorio simple** es un procedimiento en el que

- Cada miembro de la población se elige al azar,
- Cada miembro de la población tiene la misma posibilidad de ser elegido,
- Cada posible muestra de n elementos tiene la misma probabilidad de ser elegida

La muestra resultante se denomina *muestra aleatoria simple*

Dos ramas de la estadística:


■ Estadística Descriptiva

- Recoger, resumir y procesar los datos para transformar dichos datos en *información*

■ Inferencia Estadística

- Proporciona las bases para predicciones y estimaciones para convertir la *información* en *conocimiento*.

Tipos de variables o datos



Ejemplos:

- Estado Civil
- ¿Es mayor de edad?
- Color de Ojos
(Categorías definidas o grupos)


Ejemplos:

- Número de hijos
- Defectos por hora
(recuento de elementos)

Ejemplos:

- Peso
- Voltaje
(Características Medibles)

Niveles de medida



Representaciones y gráficos

- Datos *en bruto* en forma de listas no son fáciles de usar para tomar decisiones
- Se necesita algún tipo de organización:
 - Tablas
 - Gráficos
- El tipo de gráfico depende de la variable que se va a resumir

Representaciones y gráficos

Técnicas que se presentan en este tema

Variables Categóricas

- Distribución Frecuencias
- Diagrama de Barras
- Diagrama de Tarta

Variables Numéricas

- Distribución Frecuencias
- Histograma
- Diagrama de Caja

Tablas y gráficos para variables categóricas




Tabla de frecuencias

Resumir datos por categorías

Ejemplo: Pacientes de un Hospital según Servicio



Indice Clase <i>i = 1, ..., k</i>	Servicio Hospital Clase <i>c_i</i>	Número de Pacientes Frecuencia Absoluta <i>n_i = número de observaciones clase c_i</i>	Proporción de Pacientes Frecuencia Relativa <i>f_i = n_i / n</i>
1	Cardiología	1052	0.12
2	Emergencias	2245	0.25
3	<i>UCI</i>	340	0.04
4	Maternidad	552	0.06
5 (=k)	Cirugía	4630	0.53
		$n_1 + n_2 + \dots + n_k = n = 8819$	$f_1 + \dots + f_k = 1.00$

Diagrama de Barras y de Sectores

- Los **Diagramas de Barras** y los **Diagramas de Sectores o Tartas** se usan a menudo para datos cualitativos (categóricos)
- La altura de la barra, o el tamaño de la porción de tarta, muestran la frecuencia o porcentaje de cada categoría


Ejemplo de Diagrama de Barras

Hospital Unidad	Número Pacientes
Cardiac Care	1052
Emergency	2245
Intensive Care	340
Maternity	552
Surgery	4630




Ejemplo de Diagrama de Sectores

Hospital Unidad	Numero Pacientes	% de Total
Cardiac Care	1052	11.93
Emergency	2245	25.46
Intensive Care	340	3.86
Maternity	552	6.26
Surgery	4630	52.50




(Porcentajes se redondean al valor más cercano)

Hospital Patients by Unit



Tablas y gráficos para variables cuantitativas





Distribución de frecuencias

¿Qué es una Distribución de Frecuencias?

- Una distribución de frecuencias es una **tabla**
- que contiene **agrupamientos en clases** (categorías o rangos en donde *caen* los datos)
- y las **frecuencias correspondientes** con las que se presentan los datos en cada clase o categoría



¿Por qué usar tablas de frecuencias?

- Una distribución de frecuencias es una manera de resumir los datos.
- La distribución condensa la lista de datos *en bruto* de una forma más útil que
- permite una interpretación visual rápida de los datos
- y permite la comparación con otros conjuntos de datos

Intervalos y extremos de clase

- Cada clase de agrupamiento tiene, generalmente, la misma anchura.
- Determinar la anchura de cada intervalo por:

$$A = \text{anchura de intervalo} = \frac{\text{Número mayor} - \text{Número menor}}{\text{Número deseado de intervalos}}$$

- Usar al menos 5, pero no más de 15-20 intervalos
- Intervalos **nunca** solapan.
- Se redondea la anchura de los intervalos para obtener los extremos de más fácil manejo

Ejemplo de distribución de frecuencias

Ejemplo: un fabricante de *aislamientos* selecciona al azar 20 días de invierno y recoge las temperaturas máximas diarias:

**24, 35, 17, 21, 24, 37, 26, 46, 58, 30,
32, 13, 12, 38, 41, 43, 44, 27, 53, 27**

Ejemplo de distribución de frecuencias


- Ordenar los datos *en bruto* en orden ascendente :
12, 13, 17, 21, 24, 24, 26, 27, 27, 30, 32, 35, 37, 38, 41, 43, 44, 46, 53, 58.
- Calcular el rango: **$58 - 12 = 46$**
- Seleccionar número de clases: **5** (usualmente entre 5 y 15)
- Calcular anchura de intervalos: **10** (46/5 por lo que se redondea)
- Determinar extremos de intervalos: **10 pero menos que 20, 20 pero menos que 30, . . . , 60 pero menos que 70**
- Contar las observaciones y asignarlas a las clases.

Ejemplo de distribución de frecuencias

Datos ordenados:

12, 13, 17, 21, 24, 24, 26, 27, 27, 30, 32, 35, 37, 38, 41, 43, 44, 46, 53, 58

Intervalos	Frecuencias	Freq. Relativas	Porcentaje
<i>10 y menos que 20</i>	3	.15	15
<i>20 y menos que 30</i>	6	.30	30
<i>30 y menos que 40</i>	5	.25	25
<i>40 y menos que 50</i>	4	.20	20
<i>50 y menos que 60</i>	2	.10	10
Total	20	1.00	100



Histograma


- El gráfico de los datos en una distribución de frecuencias se llama un **histograma**.
- Los **extremos de intervalos** aparecen en el **eje horizontal**.
- El eje vertical representa **frecuencias, frecuencias relativas, ó porcentajes**.
- Se usan barras de alturas adecuadas para representar el número de observaciones dentro de cada clase.

Ejemplo de Histograma

Intervalo	Frecuencia
10 y menos que 20	3
20 y menos que 30	6
30 y menos que 40	5
40 y menos que 50	4
50 y menos que 60	2

(Sin huecos entre barras)

Histogram : Daily High Temperature





¿Cómo agrupar los datos?

- ¿Cuántas clases deben usarse?
 - Si n no es demasiado grande tomar \sqrt{n} , en caso contrario tomar $1+3.22 \ln(n)$
 - A menudo se responde por *prueba y error*, sujeto al juicio del investigador
 - El objetivo es crear una distribución que no sea ni demasiado *dentada* ni demasiado *en bloques*
 - El objetivo es mostrar apropiadamente el patrón de variación de los datos.

¿Cuántos intervalos de clase?

- **Muchos (Intervalos de clase Estrechos)**
 - Puede dar lugar a una distribución dentada con huecos de clases vacías
 - Puede ocultar cómo varía la frecuencia entre las clases
- **Pocos (Intervalos de clase Anchos)**
 - Puede comprimir mucho la variación y originar una distribución en bloque.
 - Puede oscurecer patrones importantes de variación.



Distribución de frecuencias acumuladas


Datos ordenados:

12, 13, 17, 21, 24, 24, 26, 27, 27, 30, 32, 35, 37, 38, 41, 43, 44, 46, 53, 58

Clase	Frecuencia	Porcentaje	Frecuencia Acumulada	Porcentaje Acumulada
10 y menos que 20	3	15	3	15
20 y menos que 30	6	30	9	45
30 y menos que 40	5	25	14	70
40 y menos que 50	4	20	18	90
50 y menos que 60	2	10	20	100
Total	20	100		

Forma de la distribución

- La forma de la distribución se dice que es ***simétrica*** si las observaciones están equilibradas, o distribuidas simétricamente respecto al centro.





Forma de la distribución


- La forma de la distribución se dice que es **asimétrica** si las observaciones **NO** están equilibradas, o distribuidas simétricamente respecto al centro.

Una distribución **asimétrica positiva** (asimétrica a la derecha) tiene una cola que se extiende a la derecha en dirección de los valores positivos.


Una distribución **asimétrica negativa** (asimétrica a la izquierda) tiene una cola que se extiende a la izquierda en dirección de los valores negativos.



Resumen numérico



Medidas de tendencia central



Media aritmética

- La **media aritmética** (media) es la medida más común de tendencia central

- Para una población de N valores:

$$\mu = \frac{\sum_{i=1}^N x_i}{N} = \frac{x_1 + x_2 + \dots + x_N}{N}$$

Valores Población

Tamaño Población

- Para una muestra de n valores:



$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} = \frac{x_1 + x_2 + \dots + x_n}{n}$$

Valores observados

Tamaño muestra



Media aritmética

- Es la medida más común de tendencia central
- Es una medida de fácil cálculo
- Afectada por valores extremos (*outliers*)



Mediana

- En una lista ordenada, la **mediana** es valor central (**50% por encima, 50% por debajo**)



No resulta afectada por valores extremos

Cálculo de la mediana

- La localización de la mediana:



$$\textit{Posición Mediana} = \frac{n+1}{2} \textit{ posición en los datos ordenados}$$

- Si el número de valores es impar, la mediana es la observación central
- Si el número de valores es par, la mediana es la media de las dos observaciones centrales

- Nótese que $\frac{n+1}{2}$ no es el *valor* de la mediana, sólo es la *posición* de la mediana en los datos ordenados

Moda

- Es una medida de tendencia central
- Valor que aparece más en la muestra
- No afectada por valores extremos
- Usada para valores numéricos o categóricos
- Puede no haber una moda
- Puede haber varias modas




Sin Moda

Ejemplo

- Cinco casas en una colina cerca de la playa

Precios Casas:

€2.000.000
500.000
300.000
100.000
100.000



Ejemplo

Precios Casas:

€2.000.000
500.000
300.000
100.000
<u>100.000</u>

Suma 3.000.000


- **Media:** $(€3.000.000/5)$
= **€600.000**
- **Mediana:** valor medio de los datos ordenados
= **€300.000**
- **Moda:** valor más frecuente
= **€100.000**

¿Cual es la mejor medida de centralidad?


- **Media:** se usa generalmente, salvo que existan valores extremos (*outliers*).
- En ese caso se usa la **mediana**, porque no es sensible a valores extremos.
 - *Ejemplo:* Mediana de los precios de inmuebles para una región: es menos sensible a outliers.

Forma de la distribución


- Describe cómo se distribuyen los datos
- Medidas de **forma**
 - Simétrica o asimétrica



Medidas de variación



- Las medidas de variación dan información sobre la **dispersión** o **variabilidad** de los datos.




Mismo centro,
diferente variación

Rango

- Medida más simple de variación
- Diferencia entre la mayor y la menor de las observaciones:

$$\text{Rango} = X_{\text{mayor}} - X_{\text{menor}}$$


Ejemplo:



$$\text{Rango} = 14 - 1 = 13$$

Desventajas del rango

- Ignora el modo en el que se distribuyen los datos



- Muy sensible a *outliers*

1,1,1,1,1,1,1,1,1,1,2,2,2,2,2,2,2,2,3,3,3,3,4,5

$$\text{Rango} = 5 - 1 = 4$$

1,1,1,1,1,1,1,1,1,1,2,2,2,2,2,2,2,2,3,3,3,3,4,120

$$\text{Rango} = 120 - 1 = 119$$

Rango intercuartílico


- Se pueden eliminar algunos problemas de *outliers* usando el **rango intercuartílico**
- Elimina valores muy grandes y muy pequeños calculando el rango de la *parte central* formada por el 50% de los datos

• **Rango Intercuartílico** = 3^{er} cuartil – 1^{er} cuartil

$$\text{IQR} = Q_3 - Q_1$$


Rango intercuartílico

Ejemplo:



Cuartiles

- Cuartiles dividen los datos ordenados en 4 segmentos con igual número de valores por segmento



- Primer cuartil**, Q_1 , es el valor tal que el 25% de las observaciones son menores y el 75% son mayores
- Q_2 es la **mediana** (50% son menores, 50% son mayores)
- Sólo el 25% de las observaciones son mayores que el **tercer cuartil**

Cálculo de los cuartiles


- Calcular un cuartil determinando el valor en la posición adecuada en los datos ordenados:
- Posición primer cuartil : $Q_1 = 0.25(n+1)$
- Posición segundo cuartil: $Q_2 = 0.50(n+1)$
- Posición tercer cuartil: $Q_3 = 0.75(n+1)$

donde n es el número de valores observados

Cálculo de los cuartiles

- *Ejemplo:* Calcular el primer cuartil

Datos Muestrales Ordenados: 11 12 13 16 16 17 18 21 22



Q_1 = está en la posición $0.25(9+1) = 2.5$ de los datos ordenados

Así, se usa el valor intermedio entre los valores 2^o y 3^{ero} :

$$Q_1 = 12.5$$

Varianza poblacional

- Media de las desviaciones al cuadrado de los valores a la media

$$\sigma^2 = \frac{\sum_{i=1}^N (x_i - \mu)^2}{N}$$

donde

μ = media población

N = tamaño población

x_i = i ésimo valor de la variable x

Varianza muestral

- Promedio de las desviaciones al cuadrado de los valores a la media

– **Varianza Muestral:**

$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n - 1}$$

donde \bar{x} = media aritmética

n = tamaño muestral

x_i = i^{esimo} valor de la variable x

Desviación estándar poblacional

- Medida de variación más comúnmente usada
- Muestra la variación alrededor de la media
- Tiene las mismas unidades de medida que los datos originales

$$\sigma = \sqrt{\frac{\sum_{i=1}^N (x_i - \mu)^2}{N}}$$

Desviación estándar muestral


- La medida de variación usada más común
- Muestra la variación respecto a la media
- Tiene las **mismas unidades de medida que los datos originales**

$$s = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}}$$

Medida de variación

Desviación estándar pequeña

Desviación estándar grande



Ejemplo

Datos

Muestrales (x_i): 10 12 14 15 17 18 18 24

$n = 8$ Media = $\bar{x} = 16$

$$\begin{aligned} s &= \sqrt{\frac{(10 - \bar{x})^2 + (12 - \bar{x})^2 + (14 - \bar{x})^2 + \dots + (24 - \bar{x})^2}{n - 1}} \\ &= \sqrt{\frac{(10 - 16)^2 + (12 - 16)^2 + (14 - 16)^2 + \dots + (24 - 16)^2}{7}} \\ &= \sqrt{\frac{126}{7}} = 4.2426 \end{aligned}$$

Medida del *promedio* de la dispersión alrededor de la media


Cálculo de la desviación estándar

- SC = Suma de Cuadrados:


$$SC(x) = \sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n x_i^2 - n\bar{x}^2$$

$$s = \sqrt{\frac{\sum_{i=1}^n x_i^2 - n\bar{x}^2}{n-1}}$$


Comparación de desviaciones estándar



Media = 15.5
s = 3.122



Media = 15.5
s = 0.866



Media = 15.5
s = 4.275



Ventajas de la varianza y de la desviación estándar

- Se usan todos los valores del conjunto de datos en los cálculos.
- A los valores alejados de la media se les asigna un peso extra (porque las desviaciones a la media se elevan al cuadrado)

Coefficiente de variación

- Medida de la **variación relativa**
- Se expresa en porcentaje (%)
- Muestra la **variación relativa respecto a la media**
- Se puede usar para comparar dos o más conjuntos de datos, medidos en diferentes unidades

$$CV = \left(\frac{s}{\bar{x}} \right) \cdot 100\%$$

Comparación de coeficientes de variación

- *Stock A:*

- Precio medio último año = €50
- Desviación estándar = €5

$$CV_A = \left(\frac{s}{\bar{x}} \right) \cdot 100\% = \frac{€5}{€50} \cdot 100\% = 10\%$$

- *Stock B:*

- Precio medio último año = €100
- Desviación estándar = €5

$$CV_B = \left(\frac{s}{\bar{x}} \right) \cdot 100\% = \frac{€5}{€100} \cdot 100\% = 5\%$$

Ambos stocks tienen la misma desviación estándar, pero el stock B es menos variable en relación a su precio