

Bioestadística. Curso 2012-2013  
Grado en Medicina  
Capítulo 1. Estadística descriptiva

Beatriz Pateiro López

Introducción

estadística.

(Del al. Statistik).

1. f. Estudio de los datos cuantitativos de la población, de los recursos naturales e industriales, del tráfico o de cualquier otra manifestación de las sociedades humanas.
2. f. Conjunto de estos datos.
3. f. Rama de la matemática que utiliza grandes conjuntos de datos numéricos para obtener inferencias basadas en el cálculo de probabilidades.

Diccionario de la lengua española. Real Academia Española

Introducción

La estadística es una ciencia con base matemática referente a la recolección, análisis e interpretación de datos, que busca explicar condiciones regulares en fenómenos de tipo aleatorio. Es transversal a una amplia variedad de disciplinas, desde la física hasta las ciencias sociales, desde las ciencias de la salud hasta el control de calidad, y es usada para la toma de decisiones en áreas de negocios e instituciones gubernamentales.

Wikipedia

Introducción

- Se puede definir la Bioestadística como la ciencia que maneja mediante métodos estadísticos la incertidumbre en el campo de la medicina y la salud.
- En medicina, los componentes aleatorios se deben, entre otros aspectos, al desconocimiento o a la imposibilidad de medir algunos determinantes de los estados de salud y enfermedad, así como a la variabilidad en las respuestas de los pacientes.
- La Bioestadística no sólo se centra en medir incertidumbres sino que se preocupa también del control de su impacto.
- Por otra parte el profesional de la medicina no solo se forma para atender al paciente, sino que tiene además una responsabilidad y obligación social con la colectividad. Debe por lo tanto conocer los problemas de salud que afectan a su comunidad, los recursos con que cuenta y sus posibles soluciones.

Introducción



Un ejemplo

- Un cardiólogo, que investiga un nuevo fármaco para rebajar el colesterol, desea conocer el consumo de grasas en varones adultos mayores de 40 años. ¿Cómo debe proceder?

**Población:** Es el universo de individuos al cual se refiere el estudio que se pretende realizar.

**Variable:** Rasgo o característica de los elementos de la población que se pretende analizar.

**Muestra:** Subconjunto de la población cuyos valores de la variable que se pretende analizar son conocidos.

Clasificamos las tareas vinculadas a la Estadística en tres grandes disciplinas:  
**Estadística Descriptiva.** Se ocupa de recoger, clasificar y resumir la información contenida en la muestra.

**Cálculo de Probabilidades.** Es una parte de la matemática teórica que estudia las leyes que rigen los mecanismos aleatorios.

**Inferencia Estadística.** Pretende extraer conclusiones para la población a partir del resultado observado en la muestra.

La Inferencia Estadística tiene un objetivo más ambicioso que el de la mera descripción de la muestra (Estadística Descriptiva). Dado que la muestra se obtiene mediante procedimientos aleatorios, el Cálculo de Probabilidades es una herramienta esencial de la Inferencia Estadística.

### Tipos de Variables

**Variables cualitativas:** No aparecen en forma numérica, sino como categorías o atributos.

- el sexo
- color de ojos
- 
- 

**Variables cuantitativas:** Toman valores numéricos porque son frecuentemente el resultado de una medición.

- el peso (kg.) de una persona
- número de llamadas diarias a un servicio de urgencias
- 
- 

### Tipos de Variables. Variables cuantitativas

Se clasifican a su vez en:

- **Cuantitativas discretas:** Toman un número discreto de valores (en el conjunto de números naturales).
  - el número de hijos de una familia
  - número de cigarrillos fumados por día
  - 
  -
- **Cuantitativas continuas:** Toman valores numéricos dentro de un intervalo real.
  - el peso
  - concentración de un elemento
  - 
  -

### Tipos de Variables. Variables cualitativas

Se clasifican a su vez en:

- **Cualitativas nominales:** Miden características que no toman valores numéricos. A estas características se les llama modalidades.
  - el sexo (hombre o mujer)
  - color de ojos (azul, verde, marrón,...)
  - 
  -
- **Cualitativas ordinales:** Miden características que no toman valores numéricos pero sí presentan entre sus posibles valores una relación de orden.
  - si se desea examinar el resultado de un tratamiento, las modalidades podrían ser: en remisión, mejorado, estable, empeorado
  - El nivel de estudios puede tomar los valores: sin estudios, primaria, secundaria, etc.
  - 
  -

### Ejemplo

En la última hora han acudido al servicio de urgencias de un hospital ocho pacientes, cuyos datos de ingreso se encuentran resumidos en la siguiente tabla. Clasifica las variables recogidas (sexo, peso, estatura, temperatura, número de visitas previas al servicio de urgencias y dolor).

Sexo	Peso (kg.)	Estatura (m.)	Temperatura (°C)	Visitas	Dolor
M	63	1.74	38	0	Leve
M	58	1.63	36.5	2	Intenso
H	84	1.86	37.2	0	Intenso
M	47	1.53	38.3	0	Moderado
M	70	1.75	37.1	1	Intenso
M	57	1.68	36.8	0	Leve
H	87	1.82	38.4	1	Leve
M	55	1.46	36.6	1	Intenso

## Ejemplo

En la última hora han acudido al servicio de urgencias de un hospital ocho pacientes, cuyos datos de ingreso se encuentran resumidos en la siguiente tabla. Clasifica las variables recogidas (sexo, peso, estatura, temperatura, número de visitas previas al servicio de urgencias y dolor).

Sexo	Peso (kg.)	Estatura (m.)	Temperatura (°C)	Visitas	Dolor
M	63	1.74	38	0	Leve
M	58	1.63	36.5	2	Intenso
H	84	1.86	37.2	0	Intenso
M	47	1.53	38.3	0	Moderado
M	70	1.75	37.1	1	Intenso
M	57	1.68	36.8	0	Leve
H	87	1.82	38.4	1	Leve
M	55	1.46	36.6	1	Intenso

¿Cómo resumimos la información contenida en los datos de la variable Dolor?



## Descripción de variables cualitativas y cuantitativas discretas

Las frecuencias se pueden escribir ordenadamente mediante una **tabla de frecuencias**, que adopta esta forma:

$c_i$	$n_i$	$f_i$	$N_i$	$F_i$
$c_1$	$n_1$	$f_1$	$N_1$	$F_1$
$c_2$	$n_2$	$f_2$	$N_2$	$F_2$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$c_m$	$n_m$	$f_m$	$N_m$	$F_m$



## Ejemplo

En la última hora han acudido al servicio de urgencias de un hospital ocho pacientes, cuyos datos de ingreso se encuentran resumidos en la siguiente tabla. Clasifica las variables recogidas (sexo, peso, estatura, temperatura, número de visitas previas al servicio de urgencias y dolor).

Sexo	Peso (kg.)	Estatura (m.)	Temperatura (°C)	Visitas	Dolor
M	63	1.74	38	0	Leve
M	58	1.63	36.5	2	Intenso
H	84	1.86	37.2	0	Intenso
M	47	1.53	38.3	0	Moderado
M	70	1.75	37.1	1	Intenso
M	57	1.68	36.8	0	Leve
H	87	1.82	38.4	1	Leve
M	55	1.46	36.6	1	Intenso

¿Cómo resumimos la información contenida en los datos de la variable Visitas?



## Descripción de variables cualitativas y cuantitativas discretas

Supongamos que los distintos valores que puede tomar la variable son:  $c_1, c_2, \dots, c_m$ .

**Frecuencia absoluta:** Se denota por  $n_i$  y representa el número de veces que ocurre el resultado  $c_i$ .

**Frecuencia relativa:** Se denota por  $f_i$  y representa la proporción de datos en cada una de las clases,

$$f_i = \frac{n_i}{n}$$

**Frecuencia absoluta acumulada.** Es el número de veces que se ha observado el resultado  $c_i$  o valores anteriores. La denotamos por

$$N_i = \sum_{c_j \leq c_i} n_j$$

**Frecuencia relativa acumulada.** Es la frecuencia absoluta acumulada dividida por el tamaño muestral. La denotamos por

$$F_i = \frac{N_i}{n} = \sum_{c_j \leq c_i} f_j$$



## Descripción de variables cualitativas y cuantitativas discretas

Las frecuencias se pueden escribir ordenadamente mediante una **tabla de frecuencias**, que adopta esta forma:

$c_i$	$n_i$	$f_i$	$N_i$	$F_i$
$c_1$	$n_1$	$f_1$	$N_1$	$F_1$
$c_2$	$n_2$	$f_2$	$N_2$	$F_2$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$c_m$	$n_m$	$f_m$	$N_m$	$F_m$

### Propiedades:

Frecuencias absolutas	$0 \leq n_i \leq n$	$\sum_{i=1}^m n_i = n$
Frecuencias relativas	$0 \leq f_i \leq 1$	$\sum_{i=1}^m f_i = 1$
Frecuencias absolutas acumuladas	$0 \leq N_i \leq n$	$N_m = n$
Frecuencias relativas acumuladas	$0 \leq F_i \leq 1$	$F_m = 1$



## Ejemplo

En la última hora han acudido al servicio de urgencias de un hospital ocho pacientes, cuyos datos de ingreso se encuentran resumidos en la siguiente tabla. Clasifica las variables recogidas (sexo, peso, estatura, temperatura, número de visitas previas al servicio de urgencias y dolor).

Sexo	Peso (kg.)	Estatura (m.)	Temperatura (°C)	Visitas	Dolor
M	63	1.74	38	0	Leve
M	58	1.63	36.5	2	Intenso
H	84	1.86	37.2	0	Intenso
M	47	1.53	38.3	0	Moderado
M	70	1.75	37.1	1	Intenso
M	57	1.68	36.8	0	Leve
H	87	1.82	38.4	1	Leve
M	55	1.46	36.6	1	Intenso

¿Cómo resumimos la información contenida en los datos de la variable Peso?



## Descripción de variables cuantitativas continuas

- Para construir las frecuencias es habitual agrupar los valores que puede tomar la variable en intervalos. De este modo contamos el número de veces que la variable cae en cada intervalo
- A cada uno de estos intervalos le llamamos **intervalo de clase** y a su punto medio **marca de clase**
- Por tanto, para la definición de las frecuencias y la construcción de la tabla de frecuencias sustituiremos los valores  $c_i$  por los intervalos de clase y las marcas de clase.

## Descripción de variables cuantitativas continuas

Algunas consideraciones a tener en cuenta:

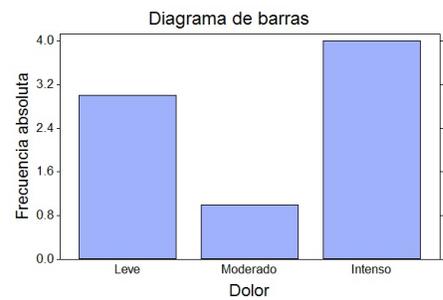
- **Número de intervalos a considerar:**
  - Cuantos menos intervalos tomemos, menos información se recoge.
  - Cuantos más intervalos tomemos, más difícil es manejar las frecuencias.Se suele tomar como número de intervalos el entero más próximo a  $\sqrt{n}$ .
- **Amplitud de cada intervalo:** Lo más común, salvo justificación en su contra, es tomar todos los intervalos de igual longitud.
- **Posición de los intervalos:** Los intervalos deben situarse allí donde se encuentran las observaciones y de forma contigua.

## Representaciones gráficas

La representación gráfica de la información contenida en una tabla estadística es una manera de obtener una información visual clara y evidente de los valores asignados a la variable estadística. Existen multitud de gráficos adecuados a cada situación. Unos se emplean con variables cualitativas y otros con variables cuantitativas.

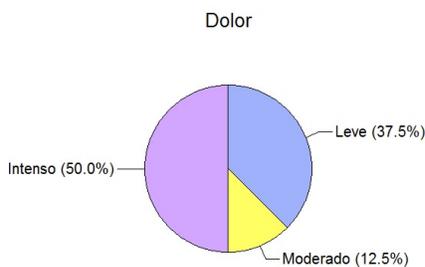
## Representaciones gráficas de variables cualitativas

- **Diagrama de barras:** Representa frecuencias absolutas o relativas



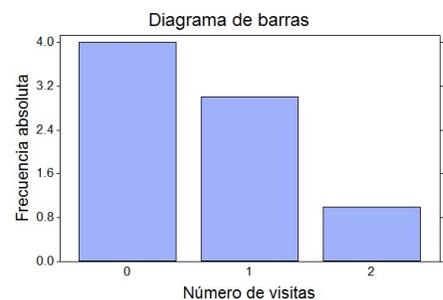
## Representaciones gráficas de variables cualitativas

- **Diagrama de sectores:** Se obtiene dividiendo un círculo en tantos sectores como modalidades tome la variable. La amplitud de cada sector debe ser proporcional a la frecuencia del valor correspondiente.



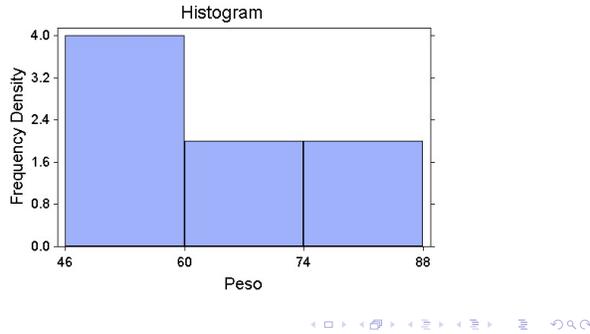
## Representaciones gráficas de variables cuantitativas discretas

- **Diagrama de barras:** Representa frecuencias absolutas o relativas
- **Diagrama de frecuencias acumuladas o diagrama escalonado:** Representa frecuencias acumuladas absolutas o relativas



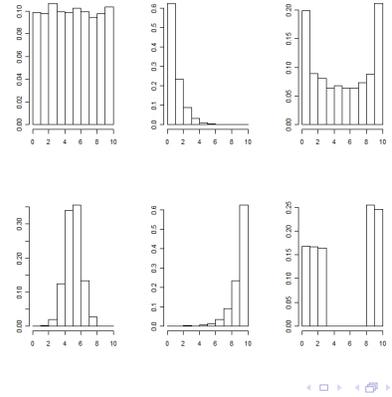
## Representaciones gráficas de variables cuantitativas continuas

- **Histograma:** Es un gráfico para la distribución de una variable cuantitativa continua que representa frecuencias mediante áreas. El histograma se construye colocando en el eje de abscisas los intervalos de clase, como trozos de la recta real, y levantando sobre ellos rectángulos con **área proporcional a la frecuencia**.



## Interpretación del histograma

Una determinada operación de vesícula se puede realizar siguiendo seis técnicas distintas. Para cada técnica, hemos registrado el tiempo de postoperatorio de 100 pacientes sometidos a dicha operación. Los resultados aparecen resumidos en los siguientes histogramas.



## Medidas características: Medidas de posición, de dispersión y de forma

Por **medida** entendemos un número que se calcula sobre la muestra y que refleja cierta cualidad de la misma. Parece claro que el cálculo de estas medidas requiere la posibilidad de efectuar operaciones con los valores que toma la variable. Por este motivo, en lo que resta del tema tratamos sólo con variables cuantitativas.

## Medidas características: Medidas de posición, de dispersión y de forma

Por **medida** entendemos un número que se calcula sobre la muestra y que refleja cierta cualidad de la misma. Parece claro que el cálculo de estas medidas requiere la posibilidad de efectuar operaciones con los valores que toma la variable. Por este motivo, en lo que resta del tema tratamos sólo con variables cuantitativas.

- **Medidas de posición:** son medidas que nos indican la posición que ocupa la muestra
- **Medidas de dispersión:** se utilizan para describir la variabilidad o esparcimiento de los datos de la muestra respecto a la posición central
- **Medidas de forma:** tratan de medir el grado de simetría y apuntamiento en los datos

## Medidas de posición

- Media aritmética
- Mediana
- Moda
- Cuantiles

## Medidas de posición. Media aritmética

Sean  $x_1, x_2, \dots, x_n$  un conjunto de  $n$  observaciones de la variable  $X$ . Se define la media aritmética (o simplemente media) de estos valores como:

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

## Medidas de posición. Mediana

Una vez ordenados los datos de menor a mayor, se define la mediana como el valor de la variable que deja a su izquierda el mismo número de valores que a su derecha. Si hay un número impar de datos, la mediana es el valor central. Si hay un número par de datos, la mediana es la media de los dos valores centrales.

## Medidas de posición. Moda

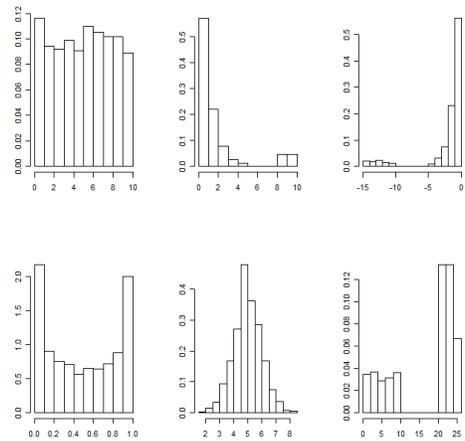
- Es el valor de la variable que se presenta con mayor frecuencia.
- A diferencia de las otras medidas, la moda también se puede calcular para variables cualitativas. Pero, al mismo tiempo, al estar tan vinculada a la frecuencia, no se puede calcular para variables continuas sin agrupación por intervalos de clase. Al intervalo con mayor frecuencia le llamamos **clase modal**.
- Puede ocurrir que haya una única moda, en cuyo caso hablamos de distribución de frecuencias **unimodal**. Si hay más de una moda, diremos que la distribución es **multimodal**.

## Medidas de posición. Cuantiles

- Hemos visto que la mediana divide a los datos en dos partes iguales. Pero también tiene interés estudiar otros parámetros, llamados cuantiles, que dividen los datos de la distribución en partes iguales, es decir en intervalos que comprenden el mismo número de valores.
- Sea  $p \in (0, 1)$ . Se define el cuantil  $p$  como el número que deja a su izquierda una frecuencia relativa  $p$ . Existen distintos métodos para calcular los cuantiles. Una posible forma de calcular el cuantil  $p$  consistiría en ordenar la muestra y tomar como cuantil el menor dato de la muestra (primero de la muestra ordenada) cuya frecuencia relativa acumulada es mayor que  $p$ .
- Algunos órdenes de los cuantiles tienen nombres específicos. Así los **cuartiles** son los cuantiles de orden (0.25, 0.5, 0.75) y se representan por  $Q_1$ ,  $Q_2$ ,  $Q_3$ . Los cuartiles dividen la distribución en cuatro partes. Los **deciles** son los cuantiles de orden (0.1, 0.2, ..., 0.9). Los **percentiles** son los cuantiles de orden  $j/100$  donde  $j=1,2,\dots,99$ .

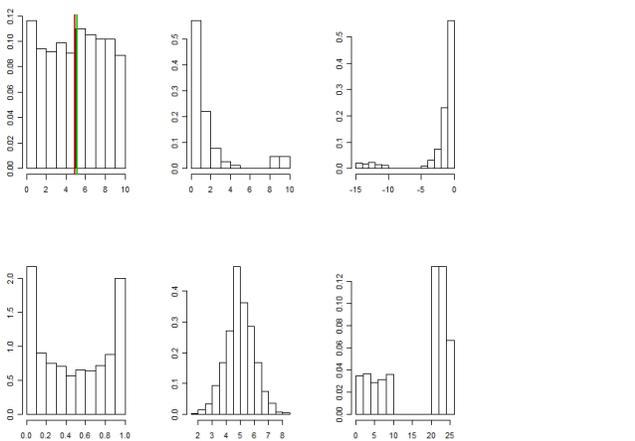
## Medidas de posición.

¿Serías capaz de deducir cuál es aproximadamente la media y mediana de los conjuntos de datos con los siguientes histogramas?



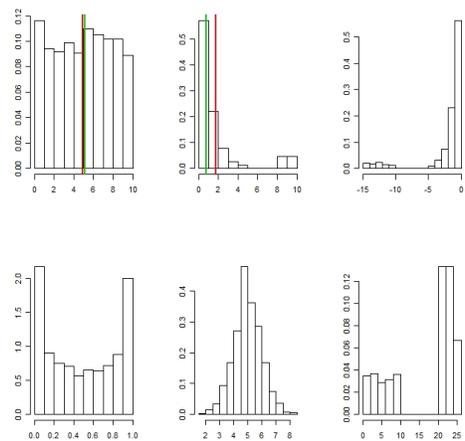
## Medidas de posición.

¿Serías capaz de deducir cuál es aproximadamente la media y mediana de los conjuntos de datos con los siguientes histogramas?



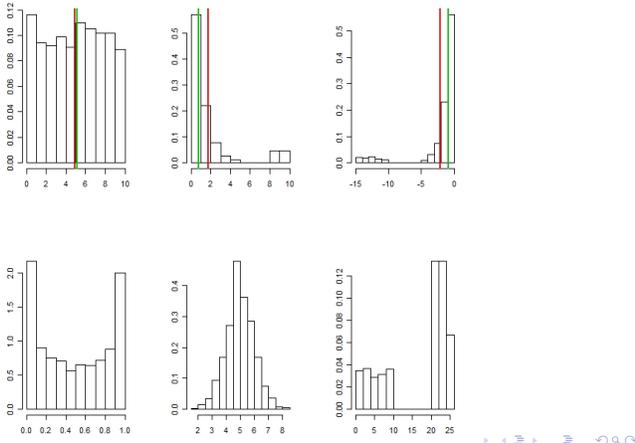
## Medidas de posición.

¿Serías capaz de deducir cuál es aproximadamente la media y mediana de los conjuntos de datos con los siguientes histogramas?



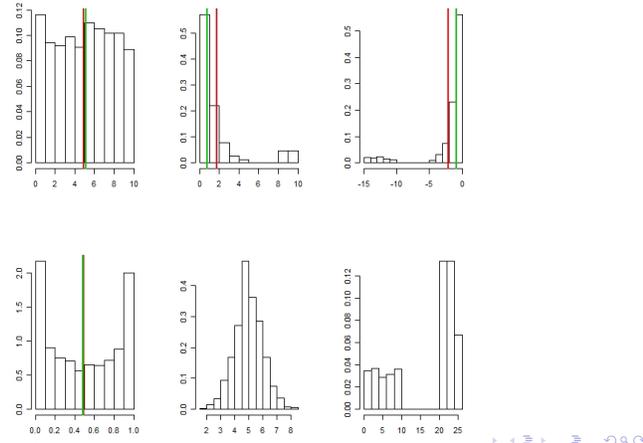
### Medidas de posición.

¿Serías capaz de deducir cuál es aproximadamente la media y mediana de los conjuntos de datos con los siguientes histogramas?



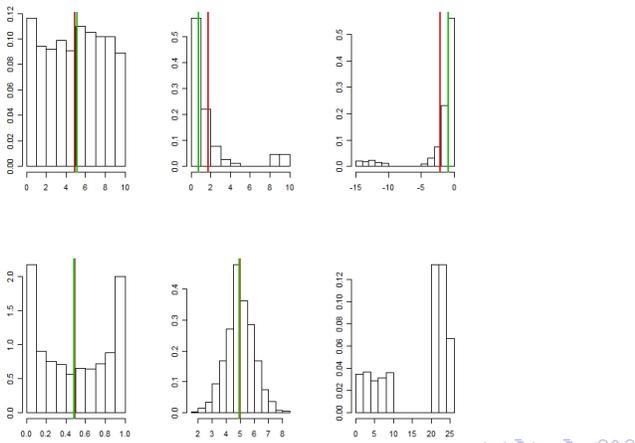
### Medidas de posición.

¿Serías capaz de deducir cuál es aproximadamente la media y mediana de los conjuntos de datos con los siguientes histogramas?



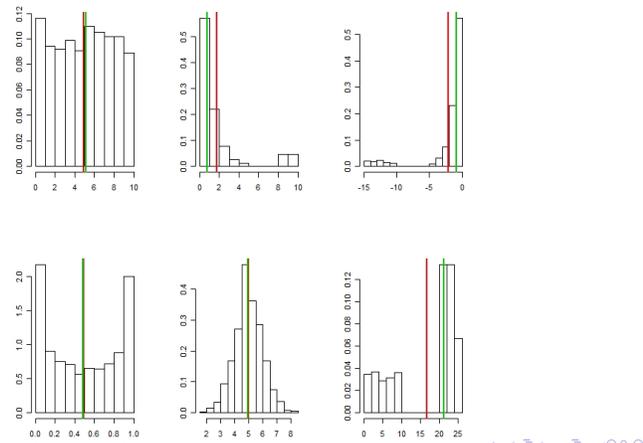
### Medidas de posición.

¿Serías capaz de deducir cuál es aproximadamente la media y mediana de los conjuntos de datos con los siguientes histogramas?



### Medidas de posición.

¿Serías capaz de deducir cuál es aproximadamente la media y mediana de los conjuntos de datos con los siguientes histogramas?



### Medidas de dispersión

- Recorrido o rango
- Recorrido intercuartílico
- Varianza
- Desviación típica
- Coeficiente de variación

### Medidas de dispersión. Recorrido o rango

$$● R = \max x_i - \min x_i.$$

- se define como la diferencia entre el cuartil tercero y el cuartil primero, es decir,  $RI = Q_3 - Q_1$

Sean  $x_1, x_2, \dots, x_n$  un conjunto de  $n$  observaciones de la variable  $X$ . Se define la varianza muestral como:

$$s^2 = \frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n - 1} = \frac{1}{n - 1} \sum_{i=1}^n (x_i - \bar{x})^2$$

Sean  $x_1, x_2, \dots, x_n$  un conjunto de  $n$  observaciones de la variable  $X$ . Se define la desviación típica como:

$$s = \sqrt{\frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n - 1}} = \sqrt{\frac{1}{n - 1} \sum_{i=1}^n (x_i - \bar{x})^2}$$

Hay situaciones en las que tenemos que comparar poblaciones en las que

- las unidades de medida son distintas

Ejemplo:

Peso de hormigas en gramos: ( $s = 2,41$  gramos)

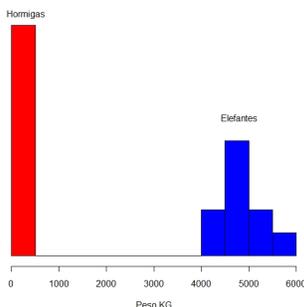
8.180881	10.503650	8.210198	13.096271	9.259044
15.540982	7.854185	12.010111	8.725924	11.712810

Peso de elefantes en kg: ( $s = 320,0495$  kilos)

5100.636	4987.702	5035.441	5321.591	5502.833
4737.402	4537.105	4731.434	4742.981	4444.282

Hay situaciones en las que tenemos que comparar poblaciones en las que

- o que aún teniendo la misma unidad de medida difieren en sus magnitudes.



- Hay situaciones en las que tenemos que comparar poblaciones en las que las unidades de medida son distintas, o que aún teniendo la misma unidad de medida difieren en sus magnitudes. Para estos casos necesitamos una medida de la dispersión en la que no influyan las unidades, sería conveniente tener una medida adimensional.
- Si queremos una medida de dispersión que no dependa de la escala y que, por tanto, permita una comparación de las dispersiones relativas de varias muestras, podemos utilizar el coeficiente de variación, que se define así:

$$CV = \frac{s}{\bar{x}}$$

Por supuesto, para que se pueda definir esta medida es preciso que la media no sea cero.

## Medidas de dispersión. Coeficiente de variación

### Ejemplo:

Peso de hormigas en gramos: ( $CV = 0,229$ )

8.180881	10.503650	8.210198	13.096271	9.259044
15.540982	7.854185	12.010111	8.725924	11.712810

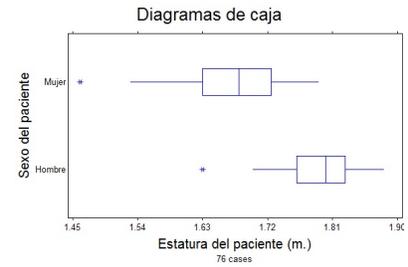
Peso de elefantes en kg: ( $CV = 0,065$ )

5100.636	4987.702	5035.441	5321.591	5502.833
4737.402	4537.105	4731.434	4742.981	4444.282

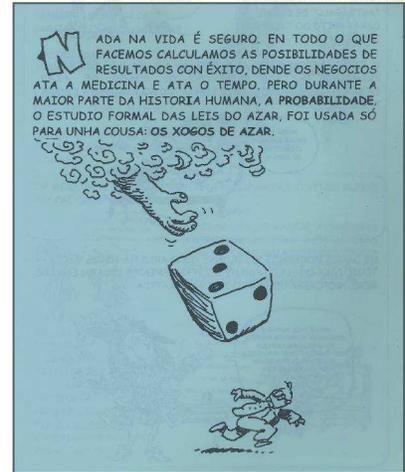
## Diagramas de caja

Los diagramas de caja (boxplots) nos dan información visual sobre como están distribuidos los datos. El diagrama de caja consta de:

- una caja central delimitada por los cuartiles  $Q_1$  y  $Q_3$ .
- Dentro de esa caja se dibuja la línea que representa la mediana (cuartil  $Q_2$ ).
- De los extremos de la caja salen los bigotes que se extienden hasta los puntos  $LI = \max\{\min(x_i), Q_1 - 1,5RI\}$  y  $LS = \min\{\max(x_i), Q_3 + 1,5RI\}$
- Los datos que caen fuera de los bigotes se representan individualmente mediante "\*" (datos atípicos moderados) y "o" (datos atípicos extremos).



## Introducción



A Estatística en caricaturas. Larry Gonick, Woollcott Smith

## Introducción

Vinculada inicialmente a los juegos de azar, la probabilidad aparece siempre que queremos saber si algo va a ocurrir o no:

- ¿Cuál es la probabilidad de que salga un seis en una tirada de dado?

## Introducción

Vinculada inicialmente a los juegos de azar, la probabilidad aparece siempre que queremos saber si algo va a ocurrir o no:

- ¿Cuál es la probabilidad de que salga un seis en una tirada de dado?
- ¿Cuál es la probabilidad de acertar los seis números de la lotería primitiva?

## Introducción

Vinculada inicialmente a los juegos de azar, la probabilidad aparece siempre que queremos saber si algo va a ocurrir o no:

- ¿Cuál es la probabilidad de que salga un seis en una tirada de dado?
- ¿Cuál es la probabilidad de acertar los seis números de la lotería primitiva?
- ¿Cuál es la probabilidad de que me caiga en el examen un tema de los que tengo preparados?

## Introducción

Vinculada inicialmente a los juegos de azar, la probabilidad aparece siempre que queremos saber si algo va a ocurrir o no:

- ¿Cuál es la probabilidad de que salga un seis en una tirada de dado?
- ¿Cuál es la probabilidad de acertar los seis números de la lotería primitiva?
- ¿Cuál es la probabilidad de que me caiga en el examen un tema de los que tengo preparados?
- ¿Cuál es la probabilidad de que un paciente sobreviva a una determinada operación de trasplante?

## Introducción

Vinculada inicialmente a los juegos de azar, la probabilidad aparece siempre que queramos saber si algo va a ocurrir o no:

- ¿Cuál es la probabilidad de que salga un seis en una tirada de dado?
- ¿Cuál es la probabilidad de acertar los seis números de la lotería primitiva?
- ¿Cuál es la probabilidad de que me caiga en el examen un tema de los que tengo preparados?
- ¿Cuál es la probabilidad de que un paciente sobreviva a una determinada operación de trasplante?
- Y si el paciente sobrevive a la operación, ¿cuál es la probabilidad de que su cuerpo rechace el trasplante en menos de un mes?

## Introducción

La mayoría de la gente tiene una noción de lo que significa la probabilidad de que algo ocurra:

## Introducción

La mayoría de la gente tiene una noción de lo que significa la probabilidad de que algo ocurra:

- Las probabilidades son números comprendidos entre 0 y 1 que reflejan las expectativas de que un suceso ocurra.
- Probabilidades próximas a 1 indican que cabe esperar que ocurran los sucesos en cuestión.
- Probabilidades próximas a 0 indican que no cabe esperar que ocurran los sucesos en cuestión.
- Probabilidades próximas a 0.5 indican que es tan verosímil que ocurra el suceso como que no.

## Experimento aleatorio

- Cuando de un experimento podemos averiguar de alguna forma cuál va a ser su resultado **antes** de que se realice, decimos que el experimento es **determinístico**.
- Nosotros queremos estudiar experimentos que no son determinísticos, pero no estamos interesados en todos ellos. Por ejemplo, no podremos estudiar un experimento del que, por no saber, ni siquiera sabemos por anticipado los resultados que puede dar. No realizaremos tareas de adivinación. Por ello definiremos **experimento aleatorio** como aquel que verifique ciertas condiciones que nos permitan un estudio riguroso del mismo.

## Conceptos básicos

- Experimento aleatorio
- Espacio muestral
- Suceso

## Experimento aleatorio

Llamamos **experimento aleatorio** al que satisface los siguientes requisitos:

- Todos sus posibles resultados son conocidos de antemano.
- El resultado particular de cada realización del experimento es imprevisible.
- El experimento se puede repetir indefinidamente en condiciones idénticas.

## Experimento aleatorio

Ejemplos de experimentos aleatorios son:

- $\mathcal{E}_1 = \text{Lanzar una moneda al aire}$
- $\mathcal{E}_2 = \text{Lanzar dos veces una moneda}$
- $\mathcal{E}_3 = \text{Determinar la temperatura corporal}$

## Espacio muestral

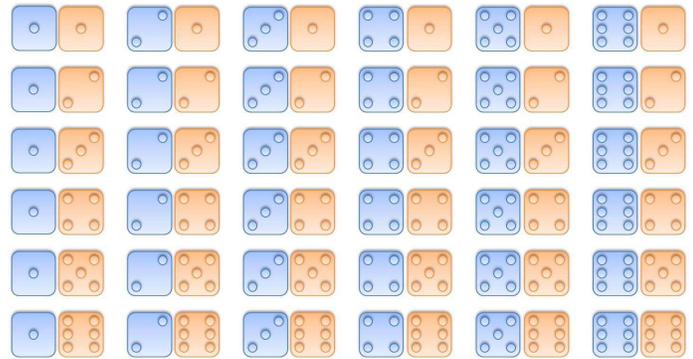
- Llamamos **espacio muestral** al conjunto formado por todos los resultados posibles del experimento aleatorio. Lo denotamos por  $\Omega$ .

### Sucesos elementales

- **Suceso elemental:** Un suceso elemental es cada uno de los posibles resultados  $\omega \in \Omega$  del experimento aleatorio.

### Sucesos elementales

Consideremos ahora el experimento  $\mathcal{E} = \text{Lanzar un par de dados}$ . Este espacio muestral tiene 36 ( $6 \times 6$ ) sucesos elementales.



### Sucesos

- **Suceso:** Cualquier subconjunto del espacio muestral.

### Sucesos

- Decimos que **ha ocurrido** un suceso cuando se ha obtenido alguno de los resultados que lo forman.
- El objetivo de la Teoría de la Probabilidad es estudiar con rigor los sucesos, asignarles probabilidades y efectuar cálculos sobre dichas probabilidades.
- Observamos que los sucesos no son otra cosa que conjuntos y por tanto, serán tratados desde la **Teoría de Conjuntos**.

## Sucesos

- **Suceso seguro:** Es el que siempre ocurre y, por tanto, es el espacio muestral,  $\Omega$ .
- **Suceso imposible:** Es el que nunca ocurre y, por tanto, es el vacío,  $\emptyset$ .
- **Unión:** Ocurre  $A \cup B$  si ocurre al menos uno de los sucesos  $A$  o  $B$ .
- **Intersección:** Ocurre  $A \cap B$  si ocurren los dos sucesos  $A$  y  $B$  a la vez.
- **Complementario:** Ocurre  $A^c$  si y sólo si no ocurre  $A$ .
- **Diferencia de sucesos:** Ocurre  $A \setminus B$  si ocurre  $A$ , pero no ocurre  $B$ . Por tanto,  $A \setminus B = A \cap B^c$ .
- **Sucesos incompatibles:** Dos sucesos  $A$  y  $B$  se dicen incompatibles si no pueden ocurrir a la vez. Dicho de otro modo, que ocurra  $A$  y  $B$  es imposible. Escrito en notación conjuntista, resulta  $A \cap B = \emptyset$ .
- **Suceso contenido en otro:** Diremos que  $A$  está contenido en  $B$ , y lo denotamos por  $A \subset B$ , si siempre que ocurra  $A$  también sucede  $B$ .

## Ejemplo

La intervención quirúrgica de colocación de prótesis de rodilla se realiza mediante anestesia general o epidural. Durante la intervención se realiza una incisión en la rodilla para cortar y extraer parcialmente uno de los huesos (fémur, tibia o peroné) en la zona próxima a la rodilla, y a continuación se sustituye por la prótesis, que puede ser de metal o resina.

Intervención	Posibilidades
Anestesia	General o epidural
Hueso	Fémur, tibia o peroné
Prótesis	Metal o resina

- Indica el espacio muestral de posibles condiciones (anestesia, hueso y prótesis) en las que se realizan las intervenciones de colocación de prótesis.
- Si  $A$  es el suceso consistente en que la intervención se realiza con prótesis de metal, lista los elementos de  $A$ .
- Si  $B$  es el suceso consistente en que la intervención se realiza con anestesia general, lista los elementos de  $B$ .
- ¿Cuáles son los elementos de  $A \cap B$ ?
- Si  $C$  es el suceso consistente en que la intervención se realiza con anestesia epidural, lista los elementos de  $B \cup C$ .
- ¿Cuáles son los elementos de  $B \cap C$ ?
- Si  $D$  es el suceso consistente en que la intervención se realiza con extracción parcial del fémur, y  $E$  es el suceso consistente en que la intervención se realiza con extracción parcial del peroné, lista los elementos de  $C \cap (D \cup E)$ .

## Definición de probabilidad

Una vez definido un experimento aleatorio, se trata de asignar un **peso numérico o probabilidad** a cada suceso que mida su grado de ocurrencia.

## Definición clásica o de Laplace

Cuando, siendo el espacio muestral  $\Omega$  finito, todos los sucesos elementales tienen la misma probabilidad, diremos que son **equiprobables** y podremos utilizar la conocida **Regla de Laplace**

$$P(A) = \frac{\text{casos favorables}}{\text{casos posibles}}$$

*La Teoría de la Probabilidad no es, en el fondo, más que sentido común reducido a cálculo. (Laplace, Théorie Analytique des Probabilités)*

## Un ejemplo

- Una clase de primaria está formada por 60 niñas y 40 niños. Se observa que 26 niñas y 14 niños usan gafas. Si un estudiante es elegido al azar, ¿cuál es la probabilidad de que use gafas?

## Definición axiomática de Kolmogorov

Sea  $\Omega$  el espacio muestral, y sea  $\mathcal{P}(\Omega)$  el conjunto formado por todos los sucesos. Se define la **probabilidad** como una aplicación  $P : \mathcal{P}(\Omega) \rightarrow [0, 1]$  que cumple las siguientes condiciones:

- $P(\Omega) = 1$   
La probabilidad del suceso seguro es 1.
- $A \cap B = \emptyset \Rightarrow P(A \cup B) = P(A) + P(B)$   
Si  $A$  y  $B$  son sucesos **incompatibles**, entonces la probabilidad de su unión es la suma de sus probabilidades.

## Definición axiomática de Kolmogorov

A partir de la definición anterior se pueden sacar una serie de consecuencias:

- 1  $P(\emptyset) = 0$
- 2 Si  $A_1, A_2, \dots, A_n$  son sucesos **incompatibles dos a dos**, se cumple

$$P(A_1 \cup A_2 \cup \dots \cup A_n) = P(A_1) + P(A_2) + \dots + P(A_n)$$

- 3  $P(A^c) = 1 - P(A)$
- 4 Si  $A \subset B$ , entonces  $P(A) \leq P(B)$
- 5 Si  $A$  y  $B$  son dos sucesos cualesquiera (ya no necesariamente incompatibles) se cumple

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

## Un ejemplo

Una tabla de contingencia clásica es la presentada por Sir Ronald Fisher en 1940, que presenta la clasificación de 5387 escolares escoceses según su color de pelo y color de ojos.

$X \setminus Y$	rubio	pelirrojo	castaño	oscuro	negro	
claros	688	116	584	188	4	1580
azules	326	38	241	110	3	718
castaños	343	84	909	412	26	1774
oscuros	98	48	403	681	85	1315
total	1455	286	2137	1391	118	5387

Cuadro: Color de ojos y el color del pelo (Fisher, 1940)

Se elige una persona de la clase al azar

- 1 ¿Cuál es la probabilidad de que la persona elegida tenga ojos castaños?
- 2 ¿Cuál es la probabilidad de que la persona elegida tenga pelo rubio?
- 3 ¿Cuál es la probabilidad de que la persona elegida tenga ojos castaños o pelo rubio?
- 4 ¿Cuál es la probabilidad de que la persona elegida tenga ojos castaños y pelo rubio?
- 5 ¿Cuál es la probabilidad de que la persona elegida tenga pelo castaño o pelo rubio?

## Probabilidad condicionada

- El concepto de probabilidad condicionada es uno de los más importantes en Teoría de la Probabilidad.
- La probabilidad condicionada pone de manifiesto el hecho de que las probabilidades cambian cuando la información disponible cambia. Por ejemplo, ¿Cuál es la probabilidad de sacar un 1 al lanzar un dado? ¿Cuál es la probabilidad de sacar un 1 al lanzar un dado si sabemos que el resultado ha sido un número impar?

## Probabilidad condicionada

La probabilidad del suceso  $A$  **condicionada** al suceso  $B$  se define:

$$P(A/B) = \frac{P(A \cap B)}{P(B)}, \quad \text{siendo } P(B) \neq 0$$

## Probabilidad condicionada

La probabilidad del suceso  $A$  **condicionada** al suceso  $B$  se define:

$$P(A/B) = \frac{P(A \cap B)}{P(B)}, \quad \text{siendo } P(B) \neq 0$$

También se deduce de manera inmediata que

$$P(A \cap B) = P(A) \cdot P(B/A) = P(B) \cdot P(A/B)$$

## Un ejemplo

Volvemos al ejemplo de Fisher de clasificación de 5387 escolares escoceses según su color de pelo y color de ojos.

$X \setminus Y$	rubio	pelirrojo	castaño	oscuro	negro	
claros	688	116	584	188	4	1580
azules	326	38	241	110	3	718
castaños	343	84	909	412	26	1774
oscuros	98	48	403	681	85	1315
total	1455	286	2137	1391	118	5387

Cuadro: Color de ojos y el color del pelo (Fisher, 1940)

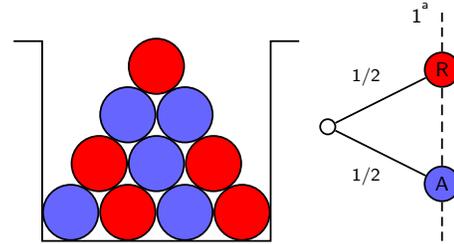
Se elige una persona de la clase al azar

- 1 ¿Cuál es la probabilidad de que una persona con ojos castaños tenga pelo rubio?
- 2 ¿Cuál es la probabilidad de que una persona con ojos oscuros tenga pelo rubio?

- Regla del producto.
- Ley de las probabilidades totales
- Regla de Bayes

La regla del producto es muy útil en experimentos aleatorios que tienen varias etapas. Las diversas etapas y alternativas se suelen representar en un diagrama de árbol tal como se muestra en el siguiente ejemplo.

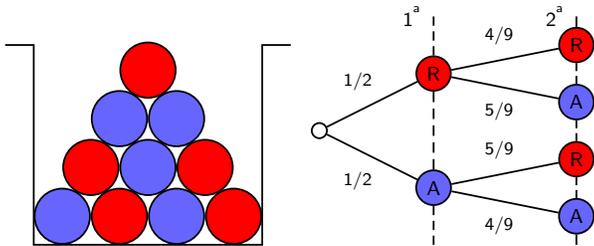
**Ejemplo:** En la urna de la figura se extraen (sin reemplazamiento) dos bolas. Calcula la probabilidad de que las dos sean rojas



La regla del producto

La regla del producto es muy útil en experimentos aleatorios que tienen varias etapas. Las diversas etapas y alternativas se suelen representar en un diagrama de árbol tal como se muestra en el siguiente ejemplo.

**Ejemplo:** En la urna de la figura se extraen (sin reemplazamiento) dos bolas. Calcula la probabilidad de que las dos sean rojas



Un ejemplo en medicina de la regla del producto

- La probabilidad de sobrevivir a cierta operación de trasplante es 0.55. Si un paciente sobrevive a la operación, la probabilidad de que su cuerpo rechace el trasplante en menos de un mes es 0.2. ¿Cuál es la probabilidad de que sobreviva a estas etapas críticas?

La regla del producto

**La regla del producto.** Si tenemos los sucesos  $A_1, A_2, \dots, A_n$  tales que  $P(A_1 \cap A_2 \cap \dots \cap A_n) \neq 0$ , entonces se cumple

$$P(A_1 \cap A_2 \cap \dots \cap A_n) = P(A_1) \cdot P(A_2/A_1) \cdot P(A_3/A_1 \cap A_2) \cdots P(A_n/A_1 \cap A_2 \cap \dots \cap A_{n-1})$$

Independencia de sucesos

Dos sucesos  $A$  y  $B$  son **independientes** si

$$P(A \cap B) = P(A) \cdot P(B)$$

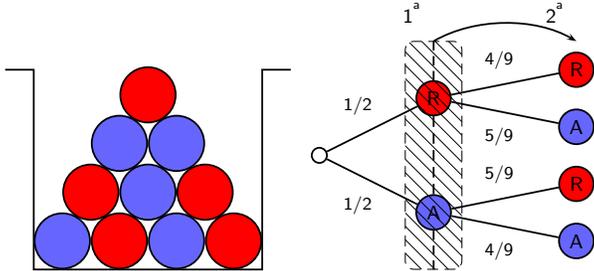
Comentarios:

- Si  $P(B) > 0$ ,  $A$  y  $B$  son independientes si y sólo si  $P(A/B) = P(A)$ , esto es, el conocimiento de la ocurrencia de  $B$  no modifica la probabilidad de ocurrencia de  $A$ .
- Si  $P(A) > 0$ ,  $A$  y  $B$  son independientes si y sólo si  $P(B/A) = P(B)$ , esto es, el conocimiento de la ocurrencia de  $A$  no modifica la probabilidad de ocurrencia de  $B$ .
- No debemos confundir sucesos **independientes** con sucesos **incompatibles**

## La ley de las probabilidades totales

La ley de las probabilidades totales considera todas las ramas que llegan al resultado final observado.

**Ejemplo:** Calcula la probabilidad de al extraer dos bolas (sin reemplazamiento) la segunda sea roja



## Ley de las probabilidades totales

A menudo, la probabilidad de ocurrencia de un suceso  $B$  se calcula más fácilmente en términos de probabilidades condicionadas. La idea es encontrar una sucesión de sucesos mutuamente excluyentes como se indica a continuación.

**Sistema completo de sucesos.** Es una partición del espacio muestral, esto es, es una colección de sucesos  $A_1, A_2, \dots, A_n$  (subconjuntos del espacio muestral) verificando

- $A_1 \cup A_2 \cup \dots \cup A_n = \Omega$  (son exhaustivos, cubren todo el espacio muestral)
- son incompatibles dos a dos (si se verifica uno de ellos, no puede a la vez ocurrir ninguno de los otros).

**Ley de las probabilidades totales.** Sea  $A_1, A_2, \dots, A_n$  un sistema completo de sucesos. Entonces se cumple que:

$$P(B) = P(A_1) \cdot P(B/A_1) + P(A_2) \cdot P(B/A_2) + \dots + P(A_n) \cdot P(B/A_n)$$

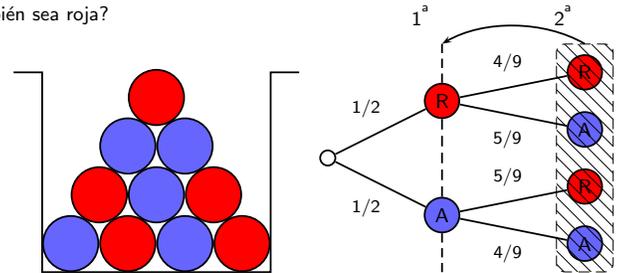
## Un ejemplo en medicina de la ley de probabilidades totales

- La probabilidad de que una unidad de sangre proceda de un donante remunerado es 0.67. Si el donante es remunerado, la probabilidad de que la unidad contenga el suero de la hepatitis es 0.0144. Si el donante es desinteresado, esta probabilidad es 0.0012. Un paciente recibe una unidad de sangre. ¿Cuál es la probabilidad de que contraiga hepatitis como consecuencia de ello?

## Teorema de Bayes

Los resultados de un experimento dan información sobre lo que ocurrió en las etapas intermedias.

**Ejemplo:** Si la segunda bola es roja, ¿cuál es la probabilidad de que la primera también sea roja?



## Teorema de Bayes

Consideremos un experimento que se realiza en dos etapas:

- en la primera, tenemos un sistema completo de sucesos  $A_1, A_2, \dots, A_n$  con probabilidades  $P(A_i)$  que denominamos **probabilidades a priori**.
- En una segunda etapa, ha ocurrido el suceso  $B$  y se conocen las probabilidades condicionadas  $P(B/A_i)$  de obtener en la segunda etapa el suceso  $B$  cuando en la primera etapa se obtuvo el suceso  $A_i$ ,  $i = 1, \dots, n$ .

## Teorema de Bayes

Consideremos un experimento que se realiza en dos etapas:

- en la primera, tenemos un sistema completo de sucesos  $A_1, A_2, \dots, A_n$  con probabilidades  $P(A_i)$  que denominamos **probabilidades a priori**.
- En una segunda etapa, ha ocurrido el suceso  $B$  y se conocen las probabilidades condicionadas  $P(B/A_i)$  de obtener en la segunda etapa el suceso  $B$  cuando en la primera etapa se obtuvo el suceso  $A_i$ ,  $i = 1, \dots, n$ .

En estas condiciones el teorema de Bayes permite calcular las probabilidades  $P(A_i/B)$ , que son probabilidades condicionadas en sentido inverso. Reciben el nombre de **probabilidades a posteriori**, pues se calculan después de haber observado el suceso  $B$ .



**Incidencia:** La incidencia es una medida del número de casos nuevos de una enfermedad en un período determinado. Podría considerarse como una tasa que cuantifica las personas que enfermarán en un periodo de tiempo.

**Incidencia:** La incidencia es una medida del número de casos nuevos de una enfermedad en un período determinado. Podría considerarse como una tasa que cuantifica las personas que enfermarán en un periodo de tiempo.

- La incidencia (incidencia acumulada) se calcula como el número de nuevos casos de la enfermedad objeto de estudio en un período específico de tiempo dividido entre el tamaño de la población que inicialmente estaba sana. Por ejemplo, durante un período de 1 año se siguió a 525 mujeres sanas, con colesterol y tensión arterial normal, para detectar la presencia de cardiopatía isquémica, registrándose al final del período 15 casos de cardiopatía isquémica. La incidencia acumulada en este caso sería:

$$IA = \frac{15}{525} = 0.028 \text{ en un año.}$$

### Pruebas diagnósticas: Sensibilidad y especificidad. Prevalencia e incidencia.

- A los médicos les interesa tener mayor capacidad para determinar sin equivocarse la presencia o ausencia de una enfermedad en un paciente a partir de los resultados (positivos o negativos) de pruebas o de los síntomas (presentes o ausentes) que se manifiestan.
- Es importante tener en cuenta que las pruebas de detección no siempre son infalibles y que los procedimientos pueden dar **falsos positivos** o **falsos negativos**.



Un **falso positivo** resulta cuando una prueba indica que el estado es positivo, cuando en realidad el paciente no está enfermo.



Un **falso negativo** resulta cuando una prueba indica que el estado es negativo, cuando en realidad el paciente está enfermo.

### Pruebas diagnósticas: Sensibilidad y especificidad. Prevalencia e incidencia.

Para evaluar la utilidad de los resultados de una prueba, debemos contestar a las siguientes preguntas:

- 1 Dado que un individuo tiene la enfermedad, ¿qué probabilidad existe de que la prueba resulte positiva?
- 2 Dado que un individuo no tiene la enfermedad, ¿qué probabilidad existe de que la prueba resulte negativa?
- 3 Dada un resultado positivo de una prueba de detección, ¿qué probabilidad existe de que el individuo tenga la enfermedad?
- 4 Dada un resultado negativo de una prueba de detección, ¿qué probabilidad existe de que el individuo no tenga la enfermedad?

### Dado que un individuo tiene la enfermedad, ¿qué probabilidad existe de que la prueba resulte positiva?

Relacionando estas ideas con los conceptos de probabilidad que hemos visto anteriormente, definiremos los siguientes sucesos:

- + = El resultado de la prueba diagnóstica es positivo.
- - = El resultado de la prueba diagnóstica es negativo.
- E = El paciente tiene la enfermedad.
- S = El paciente no tiene la enfermedad.

**Sensibilidad:** La sensibilidad de una prueba es la probabilidad de un resultado positivo de la prueba dada la presencia de la enfermedad. Se trata, por lo tanto, de una probabilidad condicionada, la de que el resultado de la prueba sea positivo condicionada a que el paciente sufre la enfermedad.

$$\text{Sensibilidad} = P(+/E)$$

## Sensibilidad de una prueba diagnóstica

La sensibilidad de un determinado test de anticuerpos del VIH es del 95%.

$$P(+/E) = 0.95$$

## Sensibilidad de una prueba diagnóstica

La sensibilidad de un determinado test de anticuerpos del VIH es del 95%.

$$P(+/E) = 0.95$$



Dado que un individuo no tiene la enfermedad, ¿qué probabilidad existe de que la prueba resulte negativa?

## Especificidad de una prueba diagnóstica

La especificidad de un determinado test de anticuerpos del VIH es del 99%.

$$P(-/S) = 0.99$$

**Especificidad:** La especificidad de una prueba es la probabilidad de un resultado negativo de la prueba dada la ausencia de la enfermedad. Se trata, por lo tanto, de una probabilidad condicionada, la de que el resultado de la prueba sea negativo condicionada a que el paciente está sano.

$$\text{Especificidad} = P(-/S)$$

La especificidad de un determinado test de anticuerpos del VIH es del 99%.

$$P(-/S) = 0.99$$

## Especificidad de una prueba diagnóstica

La especificidad de un determinado test de anticuerpos del VIH es del 99%.

$$P(-/S) = 0.99$$

Dado un resultado positivo de una prueba de detección, ¿qué probabilidad existe de que el individuo tenga la enfermedad?

**Valor predictivo positivo:** El valor predictivo positivo de una prueba es la probabilidad de que un individuo tenga la enfermedad, dado que el individuo presenta un resultado positivo en la prueba de detección. Se trata, de nuevo, de una probabilidad condicionada.

$$\text{Valor predictivo positivo} = P(E/+)$$



Dado un resultado positivo de una prueba de detección, ¿qué probabilidad existe de que el individuo tenga la enfermedad?

Teniendo en cuenta que la prevalencia del VIH en adultos en África subsahariana es del 5.2%, ¿cuál es el valor predictivo positivo en dicha población de un determinado test de anticuerpos del VIH cuya sensibilidad es del 95% y cuya especificidad es del 99%?

Dado un resultado negativo de una prueba de detección, ¿qué probabilidad existe de que el individuo no tenga la enfermedad?

**Valor predictivo negativo:** El valor predictivo negativo de una prueba es la probabilidad de que un individuo esté sano, dado que el individuo presenta un resultado negativo en la prueba de detección.

$$\text{Valor predictivo negativo} = P(S/-)$$

Dado un resultado negativo de una prueba de detección, ¿qué probabilidad existe de que el individuo no tenga la enfermedad?

Teniendo en cuenta que la prevalencia del VIH en adultos en África subsahariana es del 5.2%, ¿cuál es el valor predictivo negativo en dicha población de un determinado test de anticuerpos del VIH cuya sensibilidad es del 95% y cuya especificidad es del 99%?

### Algunas cuestiones importantes

- Hemos visto que los valores de sensibilidad y especificidad definen la validez de la prueba diagnóstica. Sin embargo no proporcionan información relevante a la hora de tomar una decisión sobre el estado de salud del paciente.
- La sensibilidad y especificidad son propiedades intrínsecas a la prueba diagnóstica (independientes de la prevalencia de la enfermedad).
- Los valores predictivos (positivo y negativo) dependen de la prevalencia.

### Algunas cuestiones importantes

Teniendo en cuenta que la prevalencia del VIH en adultos en Europa es del 0.3%, ¿cuáles son los valores predictivos positivo y negativo en dicha población de un determinado test de anticuerpos del VIH cuya sensibilidad es del 95% y cuya especificidad es del 99%?

## Introducción

- En el tema de Estadística Descriptiva hemos estudiado variables, entendiéndolas como mediciones que se efectúan sobre los individuos de una muestra. Así, la Estadística Descriptiva nos permitía analizar los distintos valores que tomaban las variables sobre una muestra ya observada. Se trataba, pues, de un estudio posterior a la realización del experimento aleatorio.

## Introducción

- En el tema de Estadística Descriptiva hemos estudiado variables, entendiéndolas como mediciones que se efectúan sobre los individuos de una muestra. Así, la Estadística Descriptiva nos permitía analizar los distintos valores que tomaban las variables sobre una muestra ya observada. Se trataba, pues, de un estudio posterior a la realización del experimento aleatorio.
- En este tema trataremos las variables situándonos antes de la realización del experimento aleatorio. Por tanto, haremos uso de los conceptos del tema anterior (Probabilidad), mientras que algunos desarrollos serán análogos a los del tema de Estadística Descriptiva.

## Variable aleatoria

Al realizar un experimento aleatorio generalmente estamos interesados en alguna función del resultado más que en el resultado en sí mismo. Por ejemplo, al arrojar un dado dos veces podríamos estar interesados sólo en la suma de los puntos obtenidos y no en el par de valores que dio origen a ese valor de la suma. De manera informal, esa cantidad de interés se denomina **variable aleatoria**.

- **Variable** porque toma distintos valores
- **aleatoria** porque el valor observado no puede ser predicho antes de la realización del experimento, aunque sí se sabe cuáles son sus posibles valores.

Dado que el valor de una variable aleatoria (v.a.) es determinado por el resultado de un experimento, podremos asignar probabilidades a los posibles valores o conjuntos de valores de la variable.

## Variable aleatoria

### Definición

Llamamos **variable aleatoria** a una aplicación del espacio muestral asociado a un experimento aleatorio en  $\mathbb{R}$ , que a cada resultado de dicho experimento le asigna un número real, obtenido por la medición de cierta característica.

$$\begin{aligned} X : \Omega &\longrightarrow \mathbb{R} \\ \omega &\longrightarrow X(\omega) \end{aligned}$$

Denotamos la variable aleatoria por una letra mayúscula. El conjunto imagen de esa aplicación es el conjunto de valores que puede tomar la variable aleatoria, que serán denotados por letras minúsculas.

## Variables aleatorias

De modo idéntico a lo dicho en el tema de Descriptiva, podemos clasificar las variables aleatorias en **discretas** y **continuas** en función del conjunto de valores que pueden tomar.

- Así, será discreta si dichos valores se encuentran separados entre sí. Por tanto será representable por conjuntos discretos, como  $\mathbb{Z}$  o  $\mathbb{N}$ . Para dichas variables veremos:
  - Función de probabilidad o función de masa
  - Función de distribución
- Será continua cuando el conjunto de valores que puede tomar es un intervalo. Para dichas variables veremos:
  - Función de densidad
  - Función de distribución

Si  $X$  es una variable discreta, su distribución viene dada por los valores que puede tomar y las probabilidades de que aparezcan. Si  $x_1 < x_2 < \dots < x_n$  son los posibles valores de la variable  $X$ , las diferentes probabilidades de que ocurran estos sucesos,

$$\begin{aligned} p_1 &= P(X = x_1), \\ p_2 &= P(X = x_2), \\ &\vdots \\ p_n &= P(X = x_n). \end{aligned}$$

constituyen la distribución de  $X$ . Esta función se denomina **función de probabilidad o función de masa**. La función de probabilidad se puede representar análogamente al diagrama de barras.

**Ejemplo:** Los servicios médicos de un equipo de fútbol establecen un período de entre 7 y 9 días de baja para un futbolista que ha sufrido una fuerte contusión en el tríceps sural. Además se estima que

- La probabilidad de que el período de baja sea de 7 días es 0.4.
- La probabilidad de que el período de baja sea de 8 días es 0.5.
- La probabilidad de que de que el período de baja sea de 9 días es 0.1.

Comprueba que se trata efectivamente de una distribución de probabilidad y a represéntala.

**Definición**

La **función de distribución** de una variable aleatoria se define como:

$$\begin{aligned} F : \mathbb{R} &\longrightarrow \mathbb{R} \\ x_0 &\longrightarrow F(x_0) = P(X \leq x_0) \end{aligned}$$

**Ejemplo:** Los servicios médicos de un equipo de fútbol establecen un período de entre 7 y 9 días de baja para un futbolista que ha sufrido una fuerte contusión en el tríceps sural. Además se estima que

- La probabilidad de que el período de baja sea de 7 días es 0.4.
- La probabilidad de que el período de baja sea de 8 días es 0.5.
- La probabilidad de que de que el período de baja sea de 9 días es 0.1.

Calcula y representa la función de distribución. Interpreta los resultados.

Suponiendo que la variable  $X$  toma los valores  $x_1 \leq x_2 \leq \dots \leq x_n$ , la función de distribución viene definida por:

$$\begin{aligned} F(x_1) &= P(X \leq x_1) = P(X = x_1) \\ F(x_2) &= P(X \leq x_2) = P(X = x_1) + P(X = x_2) \\ &\vdots \\ F(x_n) &= P(X \leq x_n) = P(X = x_1) + \dots + P(X = x_n) = 1 \end{aligned}$$

La función de distribución es siempre no decreciente y verifica que,

$$\begin{aligned} F(-\infty) &= 0, \\ F(+\infty) &= 1. \end{aligned}$$

- Los conceptos que permiten resumir una distribución de frecuencias utilizando valores numéricos pueden utilizarse también para describir la distribución de probabilidad de una variable aleatoria.

## Media y varianza de variables aleatorias.

Para distinguir entre las propiedades de los conjuntos de datos y las de las distribuciones de probabilidad, usaremos cierta terminología y ciertos símbolos que describimos a continuación.

- Las propiedades de los datos se llaman **propiedades muestrales**. Por ejemplo, hablamos en el tema 1 de la media muestral  $\bar{x}$  o de la desviación típica muestral  $s$ .
- Las propiedades de las distribuciones de probabilidad se llaman **propiedades poblacionales**.
  - Usaremos la letra griega  $\mu$  para denotar la **media poblacional**.
  - Usaremos la letra griega  $\sigma$  para denotar la **desviación típica poblacional**.

## Media y Varianza poblacional de una variable aleatoria discreta.

- Consideremos el ejemplo del futbolista que ha sufrido una fuerte contusión en el tríceps sural. Estamos interesados en el número de días de baja del jugador.

$x_i$	$p_i$
7	0.4
8	0.5
9	0.1

## Media y Varianza poblacional de una variable aleatoria discreta.

- Consideremos el ejemplo del futbolista que ha sufrido una fuerte contusión en el tríceps sural. Estamos interesados en el número de días de baja del jugador.

$x_i$	$p_i$
7	0.4
8	0.5
9	0.1

- ¿Cómo definirías el número medio (o número esperado) de días que el jugador pasará de baja?

$$\mathbb{E}(X) = \mu = \sum_i x_i p_i = 7 \cdot 0,4 + 8 \cdot 0,5 + 9 \cdot 0,1 = 7,7$$

- ¿Cómo definirías la varianza de la variable  $X$ ?

$$\text{Var}(X) = \sigma^2 = \sum_i (x_i - \mu)^2 p_i = (7-7,7)^2 \cdot 0,5 + (8-7,7)^2 \cdot 0,5 + (9-7,7)^2 \cdot 0,1 = 0,41$$

## Propiedades de la media y varianza de una variable aleatoria discreta.

### Propiedades

Sea  $X$  una variable aleatoria discreta con valores  $x_i$ . Entonces:

- $\mathbb{E}(a + bX) = a + b\mathbb{E}(X)$
- $\text{Var}(X) = \mathbb{E}(X^2) - (\mathbb{E}(X))^2$
- $\text{Var}(a + bX) = b^2 \text{Var}(X)$

## Propiedades de la media y varianza de una variable aleatoria discreta.

- Consideremos el ejemplo del futbolista que ha sufrido una fuerte contusión en el tríceps sural. Por cada lesión que sufre el jugador el seguro le debe pagar 5000 euros, además de 1000 euros por cada día de baja. ¿Cuánto dinero espera recibir el jugador del seguro?

## Principales modelos de distribuciones discretas

- Estudiaremos distribuciones de variables aleatorias **discretas** que han adquirido una especial relevancia por ser adecuadas para modelizar una gran cantidad de situaciones.
- Caracterizaremos estas distribuciones mediante la función de masa y función de distribución.
- Calcularemos también los momentos (media y varianza) y destacaremos las propiedades de mayor utilidad.

## Principales modelos de distribuciones discretas: Variable Bernoulli

### Variable Bernoulli

En muchas ocasiones nos encontramos ante experimentos aleatorios con sólo dos posibles resultados: Éxito y fracaso (cara o cruz en el lanzamiento de una moneda, ganar o perder un partido, aprobar o suspender un examen, recuperarse o no recuperarse de una enfermedad...)

Se pueden modelizar estas situaciones mediante la variable aleatoria

$$X = \begin{cases} 1 & \text{si Éxito} \\ 0 & \text{si Fracaso} \end{cases}$$

Lo único que hay que conocer es la probabilidad de éxito,  $p$ , ya que los valores de  $X$  son siempre los mismos y la probabilidad de fracaso es  $q = 1 - p$ . Un experimento de este tipo se llama **experimento de Bernoulli**  $Be(p)$ .

## Principales modelos de distribuciones discretas: Variable Bernoulli

### Variable Bernoulli

En muchas ocasiones nos encontramos ante experimentos aleatorios con sólo dos posibles resultados: Éxito y fracaso (cara o cruz en el lanzamiento de una moneda, ganar o perder un partido, aprobar o suspender un examen, recuperarse o no recuperarse de una enfermedad...)

Se pueden modelizar estas situaciones mediante la variable aleatoria

$$X = \begin{cases} 1 & \text{si Éxito} \\ 0 & \text{si Fracaso} \end{cases}$$

Lo único que hay que conocer es la probabilidad de éxito,  $p$ , ya que los valores de  $X$  son siempre los mismos y la probabilidad de fracaso es  $q = 1 - p$ . Un experimento de este tipo se llama **experimento de Bernoulli**  $Be(p)$ .

- Calcula la función de masa y la función de distribución de una  $Be(p)$ .
- Si  $X \in Be(p)$ , entonces:
  - $\mu = p$
  - $\sigma^2 = p(1 - p)$

## Principales modelos de distribuciones discretas: Variable Binomial

**Ejemplo:** Una pareja descubre que la probabilidad de que un hijo de la pareja sufra una determinada enfermedad genética es 0.6. Si la pareja se plantea tener tres hijos, ¿cuál es la probabilidad de que exactamente uno de ellos sufra la enfermedad genética?

Cada hijo es independiente de los demás y podemos considerarlo como un ensayo de Bernoulli, donde el éxito es estar sano ( $p = 0.4$ ). Lo que hacemos es repetir el experimento 3 veces y queremos calcular la probabilidad de que el número de éxitos sea igual a 2 (es decir, 2 hijos sanos y 1 enfermo)

## Principales modelos de distribuciones discretas: Variable Binomial

### Variable Binomial

Empezando con una prueba de Bernoulli con probabilidad de éxito  $p$ , vamos a construir una nueva variable aleatoria al repetir  $n$  veces la prueba de Bernoulli. La variable aleatoria **binomial**  $X$  es el número de éxitos en  $n$  repeticiones de una prueba de Bernoulli con probabilidad de éxito  $p$ .

Debe cumplirse:

- Cada prueba individual puede ser un éxito o un fracaso
- La probabilidad de éxito,  $p$ , es la misma en cada prueba
- Las pruebas son independientes. El resultado de una prueba no tiene influencia sobre los resultados siguientes

## Principales modelos de distribuciones discretas: Variable Binomial

### Variable Binomial

La variable aleatoria **binomial**  $X$  es el número de éxitos en  $n$  repeticiones de una prueba de Bernoulli con probabilidad de éxito  $p$ , es decir:

$$X = \text{Número de éxitos en las } n \text{ pruebas}$$

Denotaremos esta variable como  $Bin(n, p)$ .

## Principales modelos de distribuciones discretas: Variable Binomial

### Variable Binomial

La variable aleatoria **binomial**  $X$  es el número de éxitos en  $n$  repeticiones de una prueba de Bernoulli con probabilidad de éxito  $p$ , es decir:

$$X = \text{Número de éxitos en las } n \text{ pruebas}$$

Denotaremos esta variable como  $Bin(n, p)$ .

- ¿Qué valores toma una  $Bin(n, p)$ ?
- ¿Cuál es su función de masa?

## Principales modelos de distribuciones discretas: Variable Binomial

### Variable Binomial

La variable aleatoria **binomial**  $X$  es el número de éxitos en  $n$  repeticiones de una prueba de Bernoulli con probabilidad de éxito  $p$ , es decir:

$X$  = Número de éxitos en las  $n$  pruebas

La probabilidad de obtener  $k$  éxitos en  $n$  pruebas es

$$P(X = k) = \binom{n}{k} \cdot p^k \cdot (1 - p)^{n-k}$$



El coeficiente binomial

$$\binom{n}{k} = \frac{n!}{k!(n-k)!}$$

representa el número de subconjuntos diferentes de  $k$  elementos que se pueden definir a partir de un total de  $n$  elementos (**combinaciones** de  $n$  elementos tomados de  $k$  en  $k$ ).



## Coeficientes binomiales

El coeficiente binomial

$$\binom{n}{k} = \frac{n!}{k!(n-k)!}$$

representa el número de subconjuntos diferentes de  $k$  elementos que se pueden definir a partir de un total de  $n$  elementos (**combinaciones** de  $n$  elementos tomados de  $k$  en  $k$ ).



## Coeficientes binomiales

El coeficiente binomial

$$\binom{n}{k} = \frac{n!}{k!(n-k)!}$$

representa el número de subconjuntos diferentes de  $k$  elementos que se pueden definir a partir de un total de  $n$  elementos (**combinaciones** de  $n$  elementos tomados de  $k$  en  $k$ ).

Por ejemplo, si para un partido de dobles de la Copa Davis tenemos a tres jugadores ({Robredo, Feliciano López, Verdasco}), el entrenador tendrá

$$\binom{3}{2} = \frac{3!}{2!1!} = 3$$

posibles formas de elegir a los jugadores del partido ({Robredo, Feliciano López}, {Robredo, Verdasco}, {Feliciano López, Verdasco}).



## Principales modelos de distribuciones discretas: Variable Binomial

### Variable Binomial

La variable aleatoria **binomial**  $X$  es el número de éxitos en  $n$  repeticiones de una prueba de Bernoulli con probabilidad de éxito  $p$ , es decir:

$X$  = Número de éxitos en las  $n$  pruebas

• La media y la varianza de una  $Bin(n, p)$  son:

- $\mu = n \cdot p$
- $\sigma^2 = n \cdot p \cdot (1 - p)$



## Principales modelos de distribuciones discretas: Poisson

- En muchas circunstancias (llamadas a una centralita telefónica de un hospital, número de leucocitos en una gota de sangre, ...) el número de individuos susceptibles de dar lugar a un éxito es muy grande.
- Para modelizar estas situaciones mediante una distribución binomial tendremos problemas al escoger el parámetro  $n$  (demasiado grande o incluso difícil de determinar) y al calcular la distribución de probabilidad (la fórmula resulta inviable).



## Principales modelos de distribuciones discretas: Poisson

### Variable Poisson

Una variable aleatoria  $X$  tiene distribución de **Poisson** de parámetro  $\lambda$ , y lo denotamos  $X \in Poisson(\lambda)$ , si es discreta y

$$P(X = k) = e^{-\lambda} \frac{\lambda^k}{k!} \quad \text{si } k \in \{0, 1, 2, 3, \dots\}$$

La media y la varianza de la Poisson de parámetro  $\lambda$  son:

- $\mu = \lambda$
- $\sigma^2 = \lambda$



Ejemplo

La probabilidad de que una persona se desmaye en un concierto es  $p = 0,005$ . ¿Cuál es la probabilidad de que en un concierto al que asisten 3000 personas se desmayen 18?

- Utilizaremos la distribución de Poisson como aproximación de la distribución binomial cuando  $n$  sea grande y  $p$  pequeño, en base al límite que hemos visto.
- Como criterio podremos aproximar cuando  $n > 50$  y  $p < 0,1$ .

Ejemplo

La probabilidad de que una persona se desmaye en un concierto es  $p = 0,005$ . ¿Cuál es la probabilidad de que en un concierto al que asisten 3000 personas se desmayen 18?

La variable  $X$  = Número de personas que se desmayan en el concierto sigue una distribución  $Bin(3000, 0,005)$ . Queremos calcular

$$P(X = 18) = \binom{3000}{18} \cdot 0,005^{18} \cdot 0,995^{2982} = 0,07071.$$

Estos valores están fuera de las tablas de la binomial y son difíciles de calcular, por eso es preferible aproximar por una Poisson de parámetro  $\lambda = np = 3000 \cdot 0,005 = 15$ . Entonces:

$$P(X = 18) \approx P(Poisson(15) = 18) = e^{-15} \frac{15^{18}}{18!} = 0,07061.$$

Definimos el **proceso de Poisson** como un experimento aleatorio que consiste en contar el número de ocurrencias de determinado suceso en un intervalo de tiempo, verificando:

- El número medio de sucesos por unidad de tiempo es constante. A esa constante la llamamos **intensidad del proceso**.
- Los números de ocurrencias en subintervalos disjuntos son independientes.

Ejemplo

El número de nacimientos en un hospital constituye un proceso de Poisson con intensidad de 10 nacimientos por semana. ¿Cuál es la probabilidad de que se produzcan al menos tres nacimientos en una semana?

## Ejemplo

El número de nacimientos en un hospital constituye un proceso de Poisson con intensidad de 10 nacimientos por semana. ¿Cuál es la probabilidad de que se produzcan al menos tres nacimientos en una semana?

$$P(X \geq 3) = 1 - P(X < 3) = 1 - [P(X = 0) + P(X = 1) + P(X = 2)]$$

## Ejemplo

El número de nacimientos en un hospital constituye un proceso de Poisson con intensidad de 10 nacimientos por semana. ¿Cuál es la probabilidad de que se produzcan al menos tres nacimientos en una semana?

$$\begin{aligned} P(X \geq 3) &= 1 - P(X < 3) = 1 - [P(X = 0) + P(X = 1) + P(X = 2)] \\ &= 1 - \left[ e^{-10} \frac{10^0}{0!} + e^{-10} \frac{10^1}{1!} + e^{-10} \frac{10^2}{2!} \right] \end{aligned}$$

¿Cuál es la probabilidad de que se produzcan 5 nacimientos un día?

Bioestadística. Curso 2012-2013  
 Grado en Medicina  
 Capítulo 4. Variables aleatorias continuas

Beatriz Pateiro López

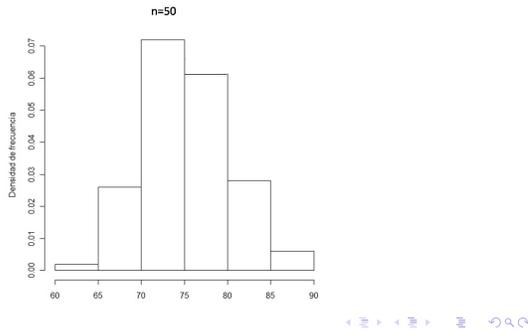
- Una variable aleatoria es **continua** cuando puede tomar cualquier valor en un intervalo.
  - el peso de una persona
  - el contenido de paracetamol en un lote de pastillas
  - el tiempo de recuperación de una operación,...
- El estudio de las variables continuas es más sutil que el de las discretas. Recordemos que la construcción del histograma es más delicado que el del diagrama de barras ya que depende de la elección de las clases.

Variables aleatorias continuas

Ejemplo

En un estudio sobre atención a la tercera edad se desea evaluar la edad a la que las personas mayores deciden ingresar en un centro geriátrico.

- Se registra la edad a la que ingresaron los 50 residentes de un determinado centro gerontológico y se construye el histograma correspondiente.



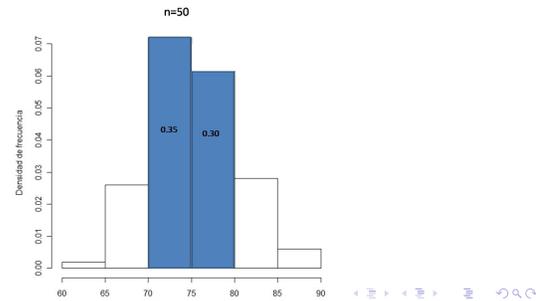
Variables aleatorias continuas

Ejemplo

En un estudio sobre atención a la tercera edad se desea evaluar la edad a la que las personas mayores deciden ingresar en un centro geriátrico.

- Se registra la edad a la que ingresaron los 50 residentes de un determinado centro gerontológico y se construye el histograma correspondiente.

Sea  $A$  el suceso "El residente ingresa con edad entre 70 y 80 años".



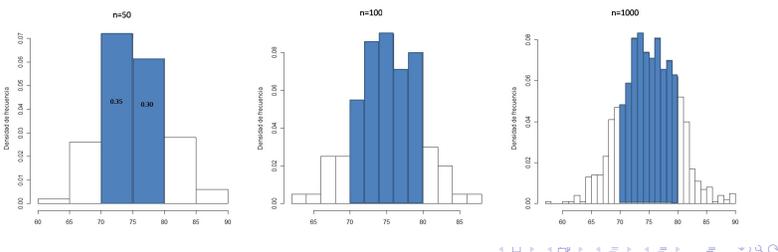
Variables aleatorias continuas

Ejemplo

En un estudio sobre atención a la tercera edad se desea evaluar la edad a la que las personas mayores deciden ingresar en un centro geriátrico.

- Se registra la edad a la que ingresaron los 50 residentes de un determinado centro gerontológico y se construye el histograma correspondiente.
- Se registra la edad a la que ingresaron los 100 residentes de un determinado centro gerontológico y se construye el histograma correspondiente.
- Se registra la edad a la que ingresaron los 1000 residentes de un determinado centro gerontológico y se construye el histograma correspondiente.

Sea  $A$  el suceso "El residente ingresa con edad entre 70 y 80 años".

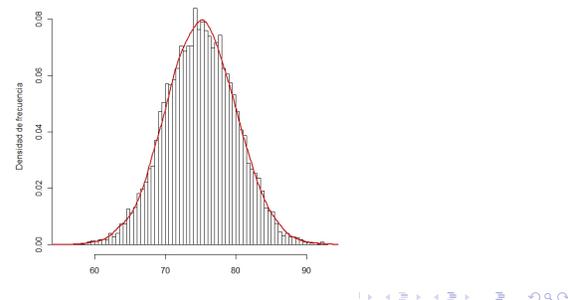


Variables aleatorias continuas

Ejemplo

En un estudio sobre atención a la tercera edad se desea evaluar la edad a la que las personas mayores deciden ingresar en un centro geriátrico.

- Idealmente, se registra la edad de todos los residentes de centros gerontológicos y se construye el histograma correspondiente.



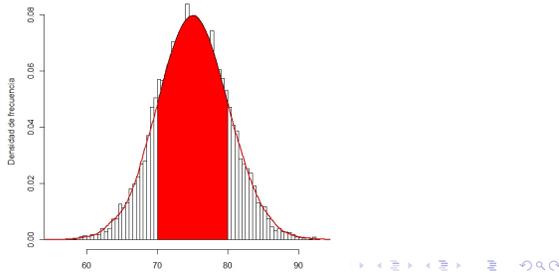
## Variables aleatorias continuas

### Ejemplo

En un estudio sobre atención a la tercera edad se desea evaluar la edad a la que las personas mayores deciden ingresar en un centro geriátrico.

- Idealmente, se registra la edad de todos los residentes de centros gerontológicos y se construye el histograma correspondiente.

Sea  $A$  el suceso "El residente ingresa con edad entre 70 y 80 años".



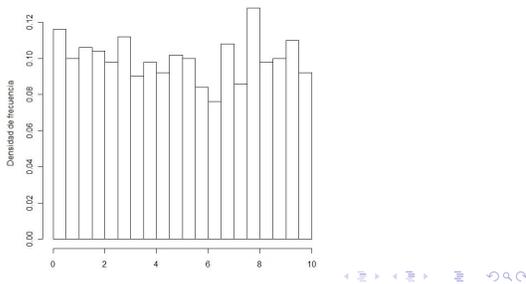
## Variables aleatorias continuas

- Tomando más observaciones de una variable continua y haciendo más finas las clases, el histograma tiende a estabilizarse en una curva suave que describe la distribución de la variable.
- Esta función,  $f(x)$ , se llama **función de densidad** de la variable  $X$ .
- La función de densidad constituye una idealización de los histogramas de frecuencia o un **modelo** del cual suponemos que proceden las observaciones.
- La función de densidad cumple dos propiedades básicas: es no negativa y el área total que contiene es uno.

## Variables aleatorias continuas. Función de densidad

### Ejemplo

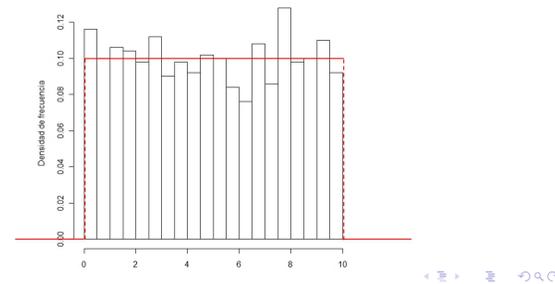
Un estudiante va todos los días a la facultad en la línea 1 del autobús urbano. Llega a la parada a las 3 de la tarde y cuenta el tiempo (en minutos) que tiene que esperar hasta que llega el autobús. A continuación se muestra el histograma correspondiente al tiempo de espera de los últimos 1000 días. A la vista del histograma, ¿cómo modelizarías el tiempo de espera?



## Variables aleatorias continuas. Función de densidad

### Ejemplo

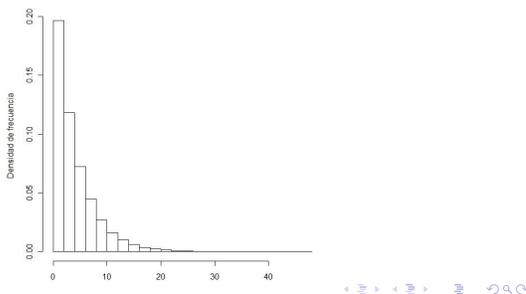
Un estudiante va todos los días a la facultad en la línea 1 del autobús urbano. Llega a la parada a las 3 de la tarde y cuenta el tiempo (en minutos) que tiene que esperar hasta que llega el autobús. A continuación se muestra el histograma correspondiente al tiempo de espera de los últimos 1000 días. A la vista del histograma, ¿cómo modelizarías el tiempo de espera?



## Variables aleatorias continuas. Función de densidad

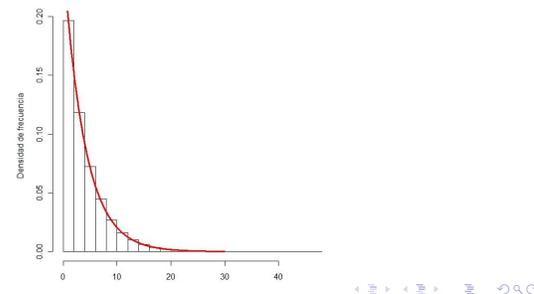
### Ejemplo

Un estudiante va todos los días a la facultad en la línea 6 del autobús urbano. Llega a la parada a las 3 de la tarde y cuenta el tiempo (en minutos) que tiene que esperar hasta que llega el autobús. A continuación se muestra el histograma correspondiente al tiempo de espera de los últimos 1000 días. A la vista del histograma, ¿cómo modelizarías el tiempo de espera?



### Ejemplo

Un estudiante va todos los días a la facultad en la línea 6 del autobús urbano. Llega a la parada a las 3 de la tarde y cuenta el tiempo (en minutos) que tiene que esperar hasta que llega el autobús. A continuación se muestra el histograma correspondiente al tiempo de espera de los últimos 1000 días. A la vista del histograma, ¿cómo modelizarías el tiempo de espera?



Una función  $f(x)$ , definida sobre el conjunto de todos los números reales  $\mathbb{R}$ , se denomina **función de densidad** si

- $f(x) \geq 0$ .
- $\int_{-\infty}^{\infty} f(x) dx = 1$ .

**Definición**

La **función de distribución** de una variable aleatoria se define como:

$$F : \mathbb{R} \rightarrow \mathbb{R}$$

$$x_0 \rightarrow F(x_0) = P(X \leq x_0)$$

La función de densidad expresa probabilidades por áreas.

- La probabilidad de que una variable  $X$  sea menor que un determinado valor  $x_0$  se obtiene calculando el área de la función de densidad hasta el punto  $x_0$ , es decir,

$$F(x_0) = P(X \leq x_0) = \int_{-\infty}^{x_0} f(x) dx,$$

- La probabilidad de que la variable tome un valor entre  $x_0$  y  $x_1$  es,

$$P(x_0 \leq X \leq x_1) = \int_{x_0}^{x_1} f(x) dx.$$

**Propiedades**

Sea  $X$  una variable aleatoria continua con función de densidad  $f(x)$ . Entonces:

- $\mathbb{E}(a + bX) = a + b\mathbb{E}(X)$
- $\text{Var}(X) = \mathbb{E}(X^2) - (\mathbb{E}(X))^2$
- $\text{Var}(a + bX) = b^2 \text{Var}(X)$

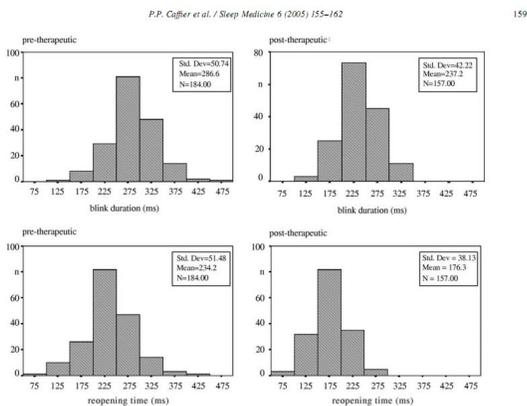


Fig. 2. Example of individual histograms of blink duration and reopening time of pre- and post-therapeutic measurement of one male OSA patient with EDS.

The spontaneous eye-blink as sleepiness indicator in patients with obstructive sleep apnoea syndrome-a pilot study.

Sleep Medicine 6 (2005) 155-162.

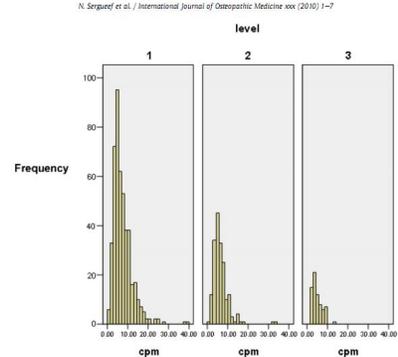


Fig. 2. Frequency histograms of cranial rhythmic impulse (CRI) rates partitioned by level of training. Level 1, 1 yr (N = 483); Level 2, 2 yr (N = 190); Level 3, 3-25 yr (N = 74). Each bar represents a CRI range of 143 counts per minute (cpm); frequency is the number of the total 727 participants in a given range for each training level.

The palpated cranial rhythmic impulse (CRI): Its normative rate and examiner experience. International Journal of Osteopathic Medicine (2010)

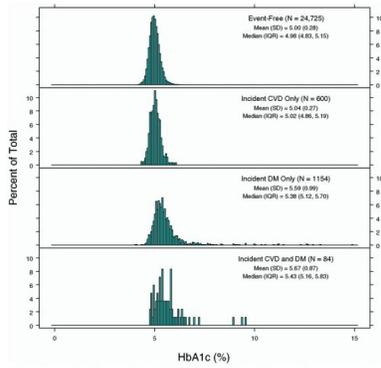


Figure 1 Histograms of HbA1c distribution according to 4 main groups: individuals remaining disease-free (N = 24,725), developing incident cardiovascular disease only (N = 600), developing incident diabetes mellitus only (N = 1154), or developing both cardiovascular disease and diabetes mellitus (N = 84). SD = standard deviation; IQR = interquartile range; CVD = cardiovascular disease; DM = diabetes mellitus; HbA1c = hemoglobin A1c.

Hemoglobin A1c Predicts Diabetes but Not Cardiovascular Disease in Nondiabetic Women. *The American Journal of Medicine* (2007)

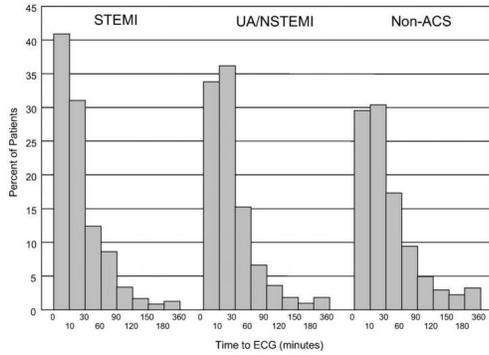


Fig. 1 Histogram showing the time to ECG for each of the patient groups.

Door-to-ECG time in patients with chest pain presenting to the ED. *American Journal of Emergency Medicine* (2006)

Ejemplo

Un centro hospitalario dispone de 3 máquinas de electrocardiograma (máquina de ECG). A continuación se muestra el histograma correspondiente al tiempo (medido en minutos) de 500 registros de la actividad eléctrica del corazón producidos con la primera máquina. A la vista del histograma. ¿cómo modelizarías el tiempo de registro de la primera máquina?

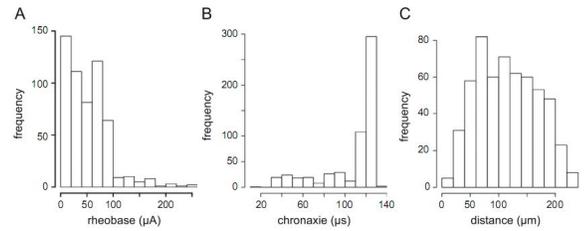
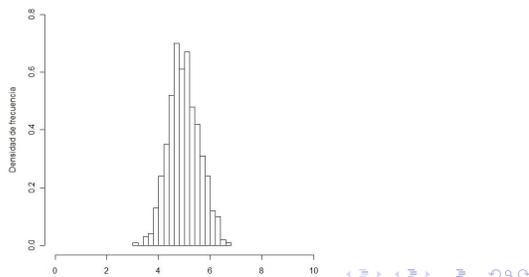


Fig. 5. Strength-duration characteristics of generated axons. (A) Histogram of rheobase amplitudes. (B) Histogram of chronaxie times. (C) Histogram of distance between the site of action potential initiation and the center of the stimulating electrode.

Modeling potential generation during single and dual electrode stimulation of CA3 axons in hippocampal slice. *Computers in Biology and Medicine* (2010)

For the between-run precision. For the recovery tests with three spiked pool-serums, values between 100.9% and 104.7% and a maximal RSD of 1.6% were obtained. The limit of detection and the limit of quantification were determined at 0.5 and 1.1 µg/L, respectively, by measuring the diluent as a blank solution [15]. In order to check the performance of the analysis method during the whole measuring period, an aliquot of the pool-serum sample was quantified in each measuring series. A mean concentration ± standard deviation (S.D.) of 104.4 ± 3.3 µg/L (n = 93) was thereby obtained. By plotting these values in a Quality Control Chart, no drift effect was observed visually.

Statistical method

The statistical evaluation was carried out with the software Systat version 10. Influences of the age, gender and region/area variables on the selenium concentrations of the blood donors and the subjects from the medical practice were evaluated by the analysis of variance (one-way ANOVA). The Scheffé post hoc test

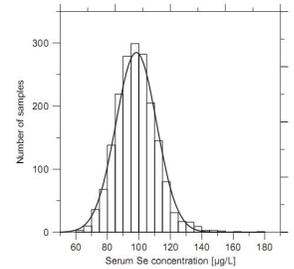
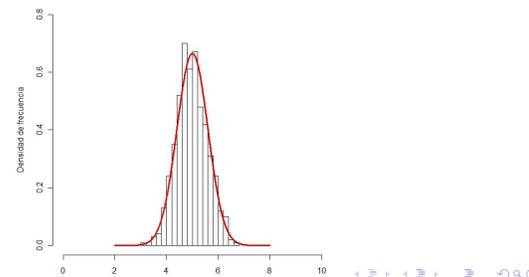


Fig. 1. Histogram of the serum selenium concentrations. The bar width is 5 µg/L; the line is a normal profile adjusted to the measured values.

Selenium status of the Swiss population: Assessment and change over a decade. *Journal of Trace Elements in Medicine and Biology* (2008)

Ejemplo

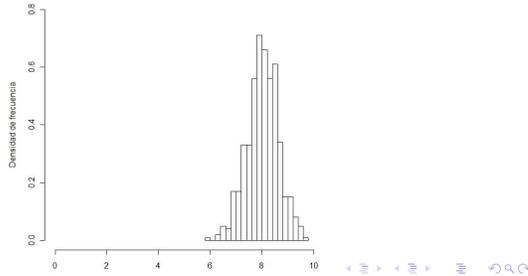
Un centro hospitalario dispone de 3 máquinas de electrocardiograma (máquina de ECG). A continuación se muestra el histograma correspondiente al tiempo (medido en minutos) de 500 registros de la actividad eléctrica del corazón producidos con la primera máquina. A la vista del histograma. ¿cómo modelizarías el tiempo de registro de la primera máquina?



## Principales modelos de distribuciones continuas: Variable Normal

### Ejemplo

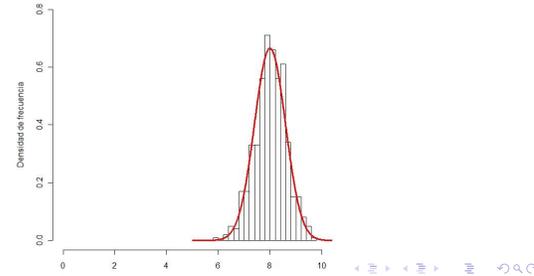
Un centro hospitalario dispone de 3 máquinas de electrocardiograma (máquina de ECG). A continuación se muestra el histograma correspondiente al tiempo (medido en minutos) de 500 registros de la actividad eléctrica del corazón producidos con la **segunda máquina**. A la vista del histograma. ¿cómo modelizarías el tiempo de registro de la segunda máquina?



## Principales modelos de distribuciones continuas: Variable Normal

### Ejemplo

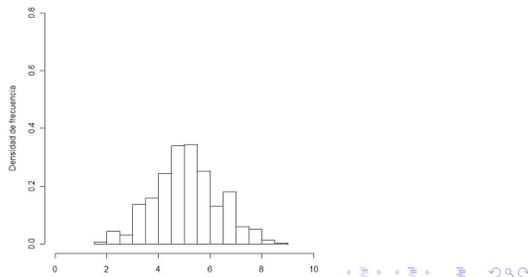
Un centro hospitalario dispone de 3 máquinas de electrocardiograma (máquina de ECG). A continuación se muestra el histograma correspondiente al tiempo (medido en minutos) de 500 registros de la actividad eléctrica del corazón producidos con la **segunda máquina**. A la vista del histograma. ¿cómo modelizarías el tiempo de registro de la segunda máquina?



## Principales modelos de distribuciones continuas: Variable Normal

### Ejemplo

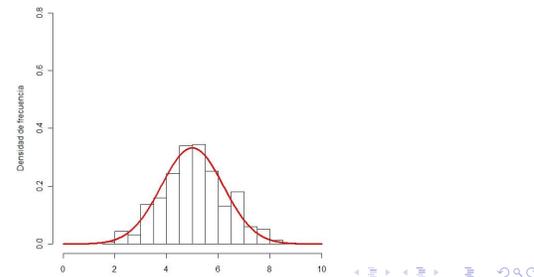
Un centro hospitalario dispone de 3 máquinas de electrocardiograma (máquina de ECG). A continuación se muestra el histograma correspondiente al tiempo (medido en minutos) de 500 registros de la actividad eléctrica del corazón producidos con la **tercera máquina**. A la vista del histograma. ¿cómo modelizarías el tiempo de registro de la tercera máquina?



## Principales modelos de distribuciones continuas: Variable Normal

### Ejemplo

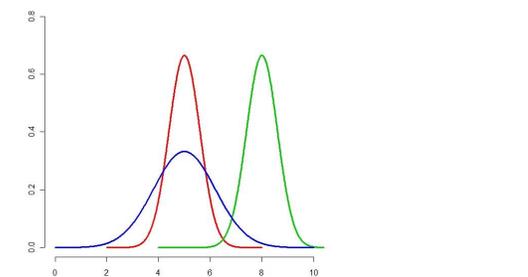
Un centro hospitalario dispone de 3 máquinas de electrocardiograma (máquina de ECG). A continuación se muestra el histograma correspondiente al tiempo (medido en minutos) de 500 registros de la actividad eléctrica del corazón producidos con la **tercera máquina**. A la vista del histograma. ¿cómo modelizarías el tiempo de registro de la tercera máquina?



## Principales modelos de distribuciones continuas: Variable Normal

### Ejemplo

Un centro hospitalario dispone de 3 máquinas de electrocardiograma (máquina de ECG). Supongamos que modelizamos el tiempo de registro de las tres máquinas mediante las siguientes curvas. ¿Qué tienen en común dichas curvas? ¿Qué las diferencia?



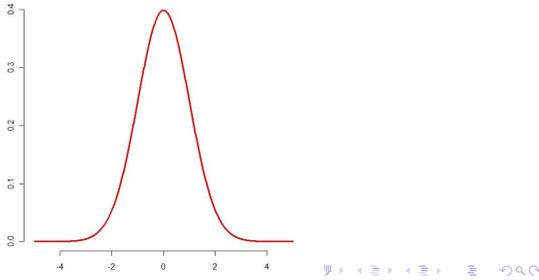
## Principales modelos de distribuciones continuas: Variable Normal

- La distribución **normal** es la más importante y de mayor uso de todas las distribuciones continuas de probabilidad.
- Por múltiples razones se viene considerando la más idónea para modelizar una gran diversidad de mediciones de la Física, Química o Biología.
- La normal es una familia de variables que depende de dos parámetros, la media y la varianza.
- Dado que todas están relacionadas entre sí mediante una transformación muy sencilla, empezaremos estudiando la denominada **normal estándar** para luego definir la familia completa.

Variable Normal Estándar

Una variable aleatoria continua  $Z$  se dice se dice que tiene distribución **normal estándar**, y lo denotamos  $Z \in N(0, 1)$ , si su función de densidad viene dada por:

$$f(z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2} \quad \text{si } z \in \mathbb{R}$$



Supongamos entonces que  $Z \in N(0, 1)$ . ¿Cómo calcularías  $P(Z \leq 1)$ ?

Variable Normal Estándar

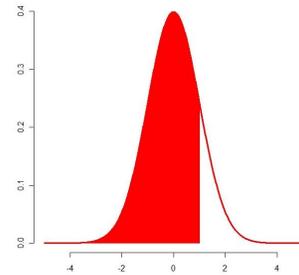
Una variable aleatoria continua  $Z$  se dice se dice que tiene distribución **normal estándar**, y lo denotamos  $Z \in N(0, 1)$ , si su función de densidad viene dada por:

$$f(z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2} \quad \text{si } z \in \mathbb{R}$$

- $Z \in N(0, 1)$  toma valores en toda la recta real. ( $f(z) > 0 \quad \forall z \in \mathbb{R}$ )
- $f$  es simétrica en torno a cero.
- Si  $Z \in N(0, 1)$  entonces  $\mu = 0$  y  $\sigma^2 = 1$ .

Supongamos entonces que  $Z \in N(0, 1)$ . ¿Cómo calcularías  $P(Z \leq 1)$ ?

$$P(Z \leq 1) = \int_{-\infty}^1 f(z) dz = \int_{-\infty}^1 \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2} dz$$



Supongamos entonces que  $Z \in N(0, 1)$ . ¿Cómo calcularías  $P(Z \leq 1)$ ?

$$P(Z \leq 1) = \int_{-\infty}^1 f(z) dz = \int_{-\infty}^1 \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2} dz$$

- La probabilidad inducida vendrá dada por el área bajo la densidad.
- Como no existe una expresión explícita para el área existen tablas con algunas probabilidades ya calculadas.
- Las tablas que nosotros utilizaremos proporcionan el valor de la función de distribución,  $\Phi(z_0) = P(Z \leq z_0)$ , de la normal estándar para valores positivos de  $z$ , donde  $z$  está aproximado hasta el segundo decimal.

Supongamos que  $Z \in N(0, 1)$ . Calcula usando las tablas de la normal estándar:

- $P(Z \leq 1,64)$
- $P(Z > 1)$
- $P(Z \leq -0,53)$
- $P(Z > -1,23)$
- $P(-1,96 \leq Z \leq 1,96)$
- $P(-1 \leq Z \leq 2)$
- ¿Cuánto vale aproximadamente  $P(Z > 4,2)$ ?

Variable Normal

Efectuando un cambio de localización y escala sobre la normal estándar, podemos obtener una distribución con la misma forma pero con la media y desviación típica que queramos.

Si  $Z \in N(0, 1)$  entonces

$$X = \mu + \sigma Z$$

tiene **distribución normal de media  $\mu$  y desviación típica  $\sigma$** .

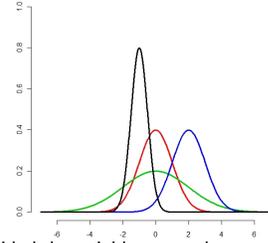
Denotaremos  $X \in N(\mu, \sigma)$ .

- Si  $X \in N(\mu, \sigma)$  entonces la media de  $X$  es  $\mu$  y su varianza es  $\sigma^2$ .

Variable Normal

Sea  $X \in N(\mu, \sigma)$ . La función de densidad de una  $N(\mu, \sigma)$  es

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma^2} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad x \in \mathbb{R}$$



Funciones de densidad de variables normales con distintas medias y varianzas. En rojo densidad de una  $N(0, 1)$

Supongamos entonces que  $X \in N(\mu, \sigma)$ . ¿Cómo calcularías  $P(X \leq 1)$ ?

Supongamos entonces que  $X \in N(\mu, \sigma)$ . ¿Cómo calcularías  $P(X \leq 1)$ ?

$$P(X \leq 1) = \int_{-\infty}^1 f(x) dx = \int_{-\infty}^1 \frac{1}{\sqrt{2\pi}\sigma^2} e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx$$

En la práctica sólo disponemos de la tabla de la distribución normal estándar. Para efectuar cálculos sobre cualquier distribución normal hacemos la transformación inversa, esto es, le restamos la media y dividimos por la desviación típica. A este proceso le llamamos **estandarización** de una variable aleatoria.

$$\text{Si } X \in N(\mu, \sigma) \text{ entonces } Z = \frac{X - \mu}{\sigma} \in N(0, 1).$$

Ejemplo

Supongamos que  $X \in N(5, 2)$ . ¿Cómo calcularías  $P(X \leq 1)$ ?

Ejemplo

Supongamos que  $X \in N(5, 2)$ . ¿Cómo calcularías  $P(X \leq 1)$ ?

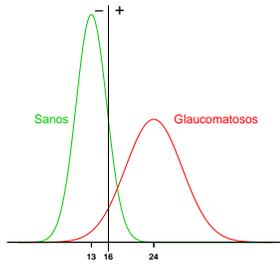
$$P(X \leq 1) = P\left(\frac{X - 5}{2} \leq \frac{1 - 5}{2}\right) = P(Z \leq -2)$$

donde  $Z = \frac{X - 5}{2} \in N(0, 1)$ .

## Puntos de corte para el diagnóstico de enfermedades

**Ejemplo:** Queremos estudiar la capacidad diagnóstica de la tonometría ocular en el diagnóstico del glaucoma.

- Se establece como criterio diagnóstico una cifra de tensión ocular de 16mmHg.
- Los estudios determinan que la tensión ocular en pacientes sanos se distribuye como una normal de media 13mmHg y desviación típica 2.7mmHg.
- También se establece que la tensión ocular en pacientes glaucomatosos se distribuye como una normal de media 24mmHg y desviación típica 5mmHg.



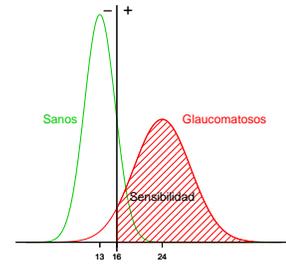
- 1 ¿Cuál es la sensibilidad y la especificidad de la prueba si el punto de corte es 16mmHg?
- 2 ¿Cuál es la probabilidad de falso positivo? ¿Y la de falso negativo?



## Puntos de corte para el diagnóstico de enfermedades

**Ejemplo:** Queremos estudiar la capacidad diagnóstica de la tonometría ocular en el diagnóstico del glaucoma.

- Se establece como criterio diagnóstico una cifra de tensión ocular de 16mmHg.
- Los estudios determinan que la tensión ocular en pacientes sanos se distribuye como una normal de media 13mmHg y desviación típica 2.7mmHg.
- También se establece que la tensión ocular en pacientes glaucomatosos se distribuye como una normal de media 24mmHg y desviación típica 5mmHg.



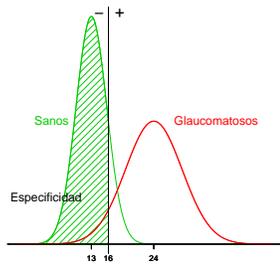
- 1 ¿Cuál es la sensibilidad y la especificidad de la prueba si el punto de corte es 16mmHg?
- 2 ¿Cuál es la probabilidad de falso positivo? ¿Y la de falso negativo?



## Puntos de corte para el diagnóstico de enfermedades

**Ejemplo:** Queremos estudiar la capacidad diagnóstica de la tonometría ocular en el diagnóstico del glaucoma.

- Se establece como criterio diagnóstico una cifra de tensión ocular de 16mmHg.
- Los estudios determinan que la tensión ocular en pacientes sanos se distribuye como una normal de media 13mmHg y desviación típica 2.7mmHg.
- También se establece que la tensión ocular en pacientes glaucomatosos se distribuye como una normal de media 24mmHg y desviación típica 5mmHg.



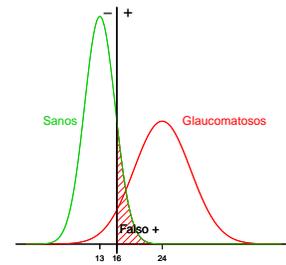
- 1 ¿Cuál es la sensibilidad y la especificidad de la prueba si el punto de corte es 16mmHg?
- 2 ¿Cuál es la probabilidad de falso positivo? ¿Y la de falso negativo?



## Puntos de corte para el diagnóstico de enfermedades

**Ejemplo:** Queremos estudiar la capacidad diagnóstica de la tonometría ocular en el diagnóstico del glaucoma.

- Se establece como criterio diagnóstico una cifra de tensión ocular de 16mmHg.
- Los estudios determinan que la tensión ocular en pacientes sanos se distribuye como una normal de media 13mmHg y desviación típica 2.7mmHg.
- También se establece que la tensión ocular en pacientes glaucomatosos se distribuye como una normal de media 24mmHg y desviación típica 5mmHg.



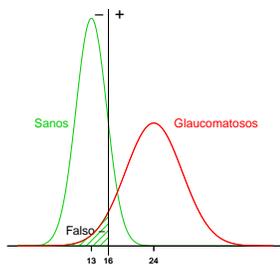
- 1 ¿Cuál es la sensibilidad y la especificidad de la prueba si el punto de corte es 16mmHg?
- 2 ¿Cuál es la probabilidad de falso positivo? ¿Y la de falso negativo?



## Puntos de corte para el diagnóstico de enfermedades

**Ejemplo:** Queremos estudiar la capacidad diagnóstica de la tonometría ocular en el diagnóstico del glaucoma.

- Se establece como criterio diagnóstico una cifra de tensión ocular de 16mmHg.
- Los estudios determinan que la tensión ocular en pacientes sanos se distribuye como una normal de media 13mmHg y desviación típica 2.7mmHg.
- También se establece que la tensión ocular en pacientes glaucomatosos se distribuye como una normal de media 24mmHg y desviación típica 5mmHg.



- 1 ¿Cuál es la sensibilidad y la especificidad de la prueba si el punto de corte es 16mmHg?
- 2 ¿Cuál es la probabilidad de falso positivo? ¿Y la de falso negativo?



## Introducción

### Bioestadística. Curso 2012-2013 Grado en Medicina Capítulo 5. Inferencia estadística

Beatriz Pateiro López

- Nuestro objetivo es el estudio de una población y sus características.
- Llamaremos **parámetro** a una característica numérica que nos interese conocer de la población.  
Ejemplos:
  - la presión sistólica **media** de una población,
  - nivel de colesterol **medio**,
  - **proporción** de pacientes que responden satisfactoriamente a un medicamento para la diabetes,...
- En la práctica contaremos con una muestra representativa de la población.

## Introducción

- **Capítulo 1:** conceptos básicos de Estadística Descriptiva, que nos proporcionaban herramientas para resumir, ordenar y extraer los aspectos más relevantes de la información de la muestra.
- **Capítulo 2:** bases para trabajar con incertidumbres o probabilidades.
- **Capítulos 3 y 4:** principales modelos de variables aleatorias.

## Introducción

- **Capítulo 1:** conceptos básicos de Estadística Descriptiva, que nos proporcionaban herramientas para resumir, ordenar y extraer los aspectos más relevantes de la información de la muestra.
- **Capítulo 2:** bases para trabajar con incertidumbres o probabilidades.
- **Capítulos 3 y 4:** principales modelos de variables aleatorias.

### INFERENCIA ESTADÍSTICA

Ahora podremos empezar a hacer inferencia sobre la población de interés basándonos en lo que observamos en una muestra

## Introducción

Dependiendo de los objetivos, podremos clasificar las labores de inferencia en dos grandes categorías:

- 1ª) en la que el interés se centra en **estimar o aproximar el valor de un parámetro**

**Ejemplo:** la proporción de pacientes que responden a un determinado medicamento para la diabetes

- 2ª) en la que el interés se centra en **contrastar posibles valores de un parámetro**

**Ejemplo:** determinar si el nivel de colesterol medio en hombres es superior al nivel de colesterol medio en mujeres

## Introducción

### Los sondeos no dan un ganador claro en las elecciones en Reino Unido

A tres días para los comicios los conservadores se mantienen en cabeza en las encuestas con un 33% de los votos, seguidos por liberaldemócratas y laboristas con el 28%

Internacional | 03/05/2010 - 12:43h | 05/05/2010 - 18:21h

1 vista [Compartir](#) [Notificar error](#) [Tengo más información](#) [A A](#)

LONDRES. (EUROPA PRESS) - A falta de tres días para las elecciones generales en **Reino Unido**, los últimos sondeos publicados este lunes no ofrecen un ganador claro, si bien los conservadores se mantienen en cabeza, seguidos por liberaldemócratas y laboristas.

Según el sondeo de ICM para **'The Guardian'**, que publica hoy el diario, los conservadores obtendrían el 33% de los votos. Igual que hace una semana, mientras que los laboristas se mantienen en el 28% y los liberaldemócratas caen dos puntos y empatan con el partido gobernante.

## Suspense total a 15 días de las elecciones legislativas británicas

Escrito por Denis Hiault LONDRES (AFP)  
Viernes, 23 abril 2010 13:00

Recomendar Sé el primero de tus amigos en recomendar esto.

El suspense parece total a menos de dos semanas de unas elecciones generales británicas que inicialmente se anunciaban como un trámite para los conservadores, debido al avance de los liberales demócratas y a la volatilidad de los votantes que favorecen un parlamento sin mayoría absoluta.

Los analistas destacaban unánimemente este viernes la multitud de escenarios posibles cuando los tres principales partidos se mueven en una horquilla que va del 27% al 32% de intención de voto, corta victoria de los Tories de David Cameron pese a una campaña considerada trabajosa hasta en su propio campo; mantenimiento del impopular Gordon Brown gracias a un sistema electoral muy favorable a los laboristas, tanto que un tercer lugar podría garantizarle el mayor número de diputados; formación de alianzas o de un gobierno de coalición en el que los "Lib Dems" tendrían la llave. O incluso la ausencia de una solución viable, lo que obligaría a convocar nuevas elecciones.

## La Voz de Galicia.es

PORTADA GALICIA DEPORTES SOCIEDAD DINERO ESPAÑA MUNDO OPINIÓN BLOGS OJO Y CULTURA SERVICIOS TI  
A Coruña A Mariña Arousa Barbanza Carballo Deza Ferrol Lemos Lugo Ourense Pontevedra Santiago

## El consello destaca que el 99% de los viticultores cumplieron la ley

18/3/2011

Valoración (0 votos)

Me gusta

Rías Baixas quiso dejar ayer muy claro que el número de viticultores que incumple la normativa y vendimia más de lo permitido es anecdótico. De hecho, la denominación de origen afirma que más del 99% de los agricultores cumplieron con la normativa durante la vendimia del 2009. Además, el consello argumentó que la pertenencia a la denominación de origen es una cuestión voluntaria.

## Público.es

Iniciar sesi  
Registr

Portada Opinión Internacional España Catalunya Dinero Ciencias Culturas Deportes TV

## La ONU afirma que menos del 5% de la población mundial es adicta a drogas ilegales

EFE | Viena | 10/03/2008 16:14 |

Recomendar

- 1 **Estimación Puntual.** Consiste en aventurar un valor, calculado a partir de la muestra, que esté lo más próximo posible al verdadero parámetro.
- 2 **Intervalos de Confianza.** Dado que la estimación puntual conlleva un cierto error, construimos un intervalo que con alta probabilidad contenga al parámetro. La amplitud del intervalo nos da idea del margen de error de nuestra estimación.
- 3 **Contrastes de Hipótesis.** Se trata de responder a preguntas muy concretas sobre la población, y se reducen a un problema de decisión sobre la veracidad de ciertas hipótesis.

¿En qué problema de inferencia enmarcarías las siguientes noticias?

- 1 El insomnio, que es la falta de sueño a la hora de dormir, afecta entre un 10 y 20% de la población general, pero se dispara hasta 32% en los mayores de 65 años.
- 2 El resultado del síndrome de piernas inquietas es una interrupción del sueño que puede dar lugar a insomnio y somnolencia diurna. La prevalencia de este trastorno aumenta con la edad, estimándose que lo padecen entre un 10 y un 20% de los mayores de 65 años.
- 3 Según un estudio el 25% de la población sufre problemas mentales por la situación económica. El mismo estudio afirma que el 40% de la población utiliza el alcohol para evadirse de la situación económica. Sin embargo, hay otros análisis que dudan de la veracidad de dichas conclusiones.

- Una **muestra aleatoria simple** de tamaño  $n$  está formada por  $n$  variables

$$X_1, X_2, \dots, X_n$$

independientes y con la misma distribución que  $X$ .

- Llamamos **realización muestral** a los valores concretos que tomaron las  $n$  variables aleatorias después de la obtención de la muestra.
- Un **estadístico** es una función de la muestra aleatoria, y por tanto nace como resultado de cualquier operación efectuada sobre la muestra.
- Al valor del estadístico obtenido con una realización muestral concreta se le llama **estimación**.
- Un estadístico es también una variable aleatoria y por ello tendrá una cierta distribución, que se denomina **distribución del estadístico en el muestreo**.

## Teorema Central del Límite

El siguiente resultado nos permitirá calcular la distribución en el muestreo de muchos estadísticos de interés.

### Teorema Central del Límite

Si  $X_1, X_2, \dots, X_n$  son variables aleatorias independientes y con la misma distribución  $X$ , donde  $X$  tiene media  $\mu$  y varianza  $\sigma^2$ , entonces para  $n$  grande, la variable

$$\frac{X_1 + X_2 + \dots + X_n}{n}$$

es aproximadamente normal con media  $\mu$  y varianza  $\sigma^2/n$ .

$$\frac{X_1 + X_2 + \dots + X_n}{n} \xrightarrow{d} N\left(\mu, \frac{\sigma}{\sqrt{n}}\right).$$

## Distribuciones asociadas con la normal

Además del modelo normal, existen otros modelos que desempeñan un papel importante en la inferencia estadística. Entre ellos se encuentran

- la distribución  $\chi^2$
- la distribución  $t$  de Student.

## La distribución $\chi^2$

La  $\chi_n^2$  con  $n$  grados de libertad es otro modelo de variable aleatoria continua

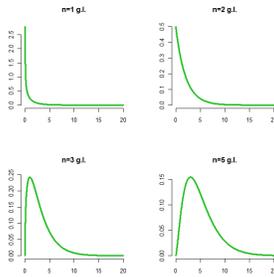


Figura : En verde densidades de variables  $\chi_n^2$  para distintos valores de  $n$ .

### Propiedades.

- 1 La variable Chi-cuadrado toma valores en  $[0, +\infty)$ .
- 2 La distribución Chi-cuadrado es asimétrica.

## La distribución $t$ de Student

La  $t$  de Student con  $k$  grados de libertad es otro modelo de variable aleatoria continua

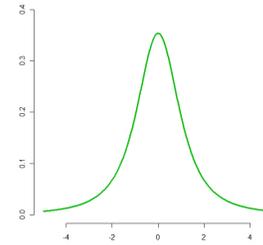


Figura : En verde densidad de una  $t$  de Student con 2 grados de libertad

## La distribución $t$ de Student

La  $t$  de Student con  $k$  grados de libertad es otro modelo de variable aleatoria continua como los vistos en el tema anterior.

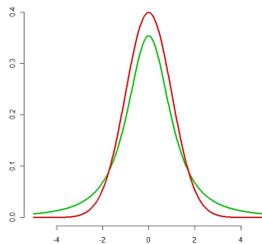


Figura : En verde densidad de una  $t$  de Student con 2 grados de libertad y en rojo densidad de una  $N(0,1)$

## La distribución $t$ de Student

La  $t$  de Student con  $k$  grados de libertad es otro modelo de variable aleatoria continua como los vistos en el tema anterior.

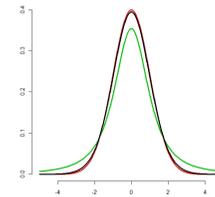


Figura : En verde densidad de una  $t$  de Student con 2 grados de libertad, en rojo  $N(0,1)$  y en negro densidad de una  $t$  de Student con 20 grados de libertad

### Propiedades.

- 1 La variable  $t$  de Student toma valores en toda la recta real.
- 2 La distribución  $t$  de Student es simétrica en torno al origen.
- 3  $t_k \xrightarrow{d} N(0,1)$  cuando  $k \rightarrow \infty$ .

- **Estimación Puntual.** Consiste en aventurar un valor, calculado a partir de la muestra, que esté lo más próximo posible al verdadero parámetro.
- **Intervalos de Confianza.** Dado que la estimación puntual conlleva un cierto error, construimos un intervalo que con alta probabilidad contenga al parámetro. La amplitud del intervalo nos da idea del margen de error de nuestra estimación.
- **Contrastes de Hipótesis.** Se trata de responder a preguntas muy concretas sobre la población, y se reducen a un problema de decisión sobre la veracidad de ciertas hipótesis.

Introducción

- **Estimación Puntual.** Consiste en aventurar un valor, calculado a partir de la muestra, que esté lo más próximo posible al verdadero parámetro.

Estimación puntual (de una proporción)

Sea  $X_1, X_2, \dots, X_n$  una muestra aleatoria simple donde

$$X_i = \begin{cases} 1 & , \text{ con probabilidad } p \\ 0 & , \text{ con probabilidad } 1 - p \end{cases}$$

Estimación puntual de una proporción  $p$

$$\hat{p} = \frac{X_1 + X_2 + \dots + X_n}{n}$$

Para  $n$  grande, por el Teorema Central de Límite:

Distribución de  $\hat{p}$

$$\hat{p} \sim N\left(p, \sqrt{\frac{p(1-p)}{n}}\right)$$

Estimación puntual (de una media)

Sea  $X_1, X_2, \dots, X_n$  una muestra aleatoria simple con  $X_i \sim N(\mu, \sigma)$ .

Estimación puntual de la media  $\mu$

$$\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n}$$

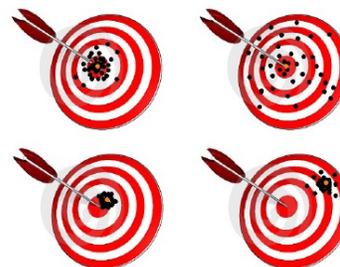
Entonces,

Distribución de  $\bar{X}$

$$\bar{X} \in N\left(\mu, \frac{\sigma}{\sqrt{n}}\right)$$

Propiedades de un estimador

Supongamos que queremos estimar un parámetro desconocido  $\theta$  y lo hacemos mediante el estadístico  $\hat{\theta}$



- $\hat{\theta}$  es **insesgado** si  $\mathbb{E}(\hat{\theta}) = \theta$
- Si además  $\text{Var}(\hat{\theta}) \rightarrow 0$  cuando  $n \rightarrow \infty$ , el estimador es **consistente**

## Intervalo de confianza

- **Intervalos de Confianza.** Dado que la estimación puntual conlleva un cierto error, construimos un intervalo que con alta probabilidad contenga al parámetro. La amplitud del intervalo nos da idea del margen de error de nuestra estimación.
- Un intervalo de confianza es un intervalo construido en base a la muestra y, por tanto, aleatorio, que contiene al parámetro con una cierta probabilidad, conocida como **nivel de confianza**.

## Intervalo de confianza

- Sea  $\theta$  el parámetro desconocido y  $\alpha \in [0, 1]$ .
- Se dice que el intervalo  $[L_1, L_2]$  tiene un nivel de confianza  $1 - \alpha$  si

$$P(L_1 \leq \theta \leq L_2) \geq 1 - \alpha$$

## Intervalo de confianza

- Sea  $\theta$  el parámetro desconocido y  $\alpha \in [0, 1]$ .
- Se dice que el intervalo  $[L_1, L_2]$  tiene un nivel de confianza  $1 - \alpha$  si

$$P(L_1 \leq \theta \leq L_2) \geq 1 - \alpha$$

- Los valores de  $L_1$  y  $L_2$  **dependerán de la muestra!!!!**.

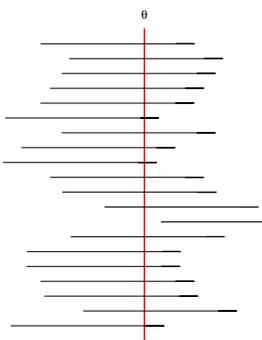
## Intervalo de confianza

- Sea  $\theta$  el parámetro desconocido y  $\alpha \in [0, 1]$ .
- Se dice que el intervalo  $[L_1, L_2]$  tiene un nivel de confianza  $1 - \alpha$  si

$$P(L_1 \leq \theta \leq L_2) \geq 1 - \alpha$$

- Los valores de  $L_1$  y  $L_2$  **dependerán de la muestra!!!!**.
- El nivel de confianza con frecuencia se expresa en porcentaje. Así, un intervalo de confianza del 95 % es un intervalo de extremos aleatorios que contiene al parámetro con una probabilidad de 0,95.

## Interpretación del nivel de confianza $1 - \alpha$



- Dada una realización muestral, el intervalo construido puede contener o no al parámetro desconocido
- Esperamos que el  $100(1 - \alpha) \%$  de los intervalos contengan al parámetro desconocido

## Intervalo de confianza para la media $\mu$ de una población normal ( $\sigma^2$ conocida)

Sea  $X_1, X_2, \dots, X_n$  una muestra formada por  $n$  variables independientes y con la misma distribución  $N(\mu, \sigma)$

- Recordamos que es este caso

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \in N(0, 1)$$

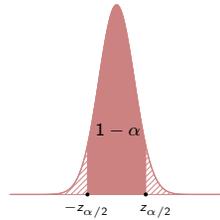
- Este estadístico (pivote) nos servirá para construir un intervalo de confianza con nivel de confianza  $1 - \alpha$  para la media  $\mu$  cuando la **varianza  $\sigma^2$  es conocida**.

### Intervalo de confianza para la media $\mu$ de una población normal ( $\sigma^2$ conocida)

Sea  $X_1, X_2, \dots, X_n$  una muestra formada por  $n$  variables independientes y con la misma distribución  $N(\mu, \sigma)$ . Supongamos que  $\sigma^2$  es conocida.

- Sea  $z_{\alpha/2}$  el valor tal que  $P(Z > z_{\alpha/2}) = \alpha/2$ , siendo  $Z \in N(0, 1)$ . Entonces:

$$P\left(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq z_{\alpha/2}\right) = 1 - \alpha$$

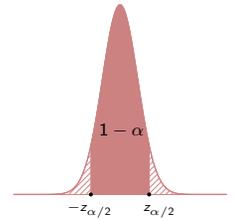


### Intervalo de confianza para la media $\mu$ de una población normal ( $\sigma^2$ conocida)

Sea  $X_1, X_2, \dots, X_n$  una muestra formada por  $n$  variables independientes y con la misma distribución  $N(\mu, \sigma)$ . Supongamos que  $\sigma^2$  es conocida.

- Sea  $z_{\alpha/2}$  el valor tal que  $P(Z > z_{\alpha/2}) = \alpha/2$ , siendo  $Z \in N(0, 1)$ . Entonces:

$$P\left(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq z_{\alpha/2}\right) = 1 - \alpha$$



- Equivalentemente,

$$P\left(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha$$

### Intervalo de confianza para la media $\mu$ de una población normal ( $\sigma^2$ conocida)

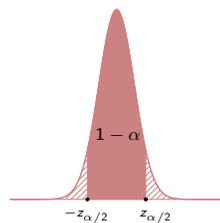
Sea  $X_1, X_2, \dots, X_n$  una muestra formada por  $n$  variables independientes y con la misma distribución  $N(\mu, \sigma)$ . Supongamos que  $\sigma^2$  es conocida.

- Sea  $z_{\alpha/2}$  el valor tal que  $P(Z > z_{\alpha/2}) = \alpha/2$ , siendo  $Z \in N(0, 1)$ . Entonces:

$$P\left(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq z_{\alpha/2}\right) = 1 - \alpha$$

- Equivalentemente,

$$P\left(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha$$



Intervalo de confianza de nivel  $1 - \alpha$  para la media  $\mu$  cuando  $\sigma^2$  es conocida

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

### Intervalo de confianza para la media $\mu$ de una población normal ( $\sigma^2$ desconocida)

Sea  $X_1, X_2, \dots, X_n$  una muestra formada por  $n$  variables independientes y con la misma distribución  $N(\mu, \sigma)$ .

- En la práctica no es habitual conocer la varianza de la variable de interés.

### Intervalo de confianza para la media $\mu$ de una población normal ( $\sigma^2$ desconocida)

Sea  $X_1, X_2, \dots, X_n$  una muestra formada por  $n$  variables independientes y con la misma distribución  $N(\mu, \sigma)$ .

- En la práctica no es habitual conocer la varianza de la variable de interés.
- Cuando la varianza  $\sigma^2$  es desconocida, usaremos como estadístico (pivote) para construir un intervalo de confianza para la media  $\mu$

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

- Recuerda que:

$$S = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}$$

Intervalo de confianza de nivel  $1 - \alpha$  para la media  $\mu$  cuando  $\sigma^2$  es conocida

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

**Ejemplo:** Un investigador está interesado en determinar el nivel medio de determinada proteína en el cuerpo humano. Para ello toma una muestra de 10 individuos y obtiene el nivel de proteína de cada uno de ellos. Los resultados son los siguientes:

22, 20, 24, 18, 23, 25, 26, 20, 19, 23

- ¿Cómo estimarías el nivel medio de proteína a partir de esta muestra?
- Nuevas investigaciones determinan que la variable de interés es aproximadamente normal con varianza igual a 45. Construye un intervalo de confianza para el nivel medio de proteína en el cuerpo humano con nivel de confianza del 95%.
- ¿Cuál sería el intervalo de confianza para un nivel de confianza del 90%?

## Intervalo de confianza para la media $\mu$ de una población normal ( $\sigma^2$ desconocida)

Sea  $X_1, X_2, \dots, X_n$  una muestra formada por  $n$  variables independientes y con la misma distribución  $N(\mu, \sigma)$ .

- En la práctica no es habitual conocer la varianza de la variable de interés.
- Cuando la varianza  $\sigma^2$  es desconocida, usaremos como estadístico (pivote) para construir un intervalo de confianza para la media  $\mu$

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

- Recuerda que:

$$S = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}$$

- En este caso:

$$\frac{\bar{X} - \mu}{S/\sqrt{n}} \in t_{n-1}$$

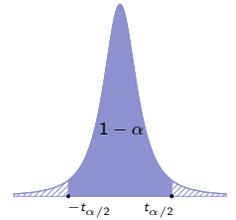
Capítulo 6. Estimación puntual e Intervalos de confianza

## Intervalo de confianza para la media $\mu$ de una población normal ( $\sigma^2$ desconocida)

Sea  $X_1, X_2, \dots, X_n$  una muestra formada por  $n$  variables independientes y con la misma distribución  $N(\mu, \sigma)$ . Supongamos que  $\sigma^2$  es desconocida.

- Sea  $t_{\alpha/2}$  el valor tal que  $P(T > t_{\alpha/2}) = \alpha/2$ , donde  $T$  es una variable  $t$  de Student con  $n-1$  grados de libertad. Entonces:

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



Capítulo 6. Estimación puntual e Intervalos de confianza

## Intervalo de confianza para la media $\mu$ de una población normal ( $\sigma^2$ desconocida)

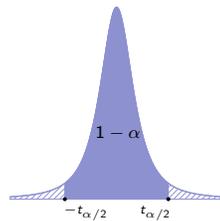
Sea  $X_1, X_2, \dots, X_n$  una muestra formada por  $n$  variables independientes y con la misma distribución  $N(\mu, \sigma)$ . Supongamos que  $\sigma^2$  es desconocida.

- Sea  $t_{\alpha/2}$  el valor tal que  $P(T > t_{\alpha/2}) = \alpha/2$ , donde  $T$  es una variable  $t$  de Student con  $n-1$  grados de libertad. Entonces:

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

- Equivalentemente,

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



Capítulo 6. Estimación puntual e Intervalos de confianza

## Intervalo de confianza para la media $\mu$ de una población normal ( $\sigma^2$ desconocida)

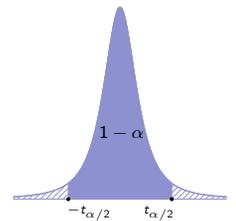
Sea  $X_1, X_2, \dots, X_n$  una muestra formada por  $n$  variables independientes y con la misma distribución  $N(\mu, \sigma)$ . Supongamos que  $\sigma^2$  es desconocida.

- Sea  $t_{\alpha/2}$  el valor tal que  $P(T > t_{\alpha/2}) = \alpha/2$ , donde  $T$  es una variable  $t$  de Student con  $n-1$  grados de libertad. Entonces:

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

- Equivalentemente,

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



Capítulo 6. Estimación puntual e Intervalos de confianza

Intervalo de confianza de nivel  $1 - \alpha$  para la media  $\mu$  cuando  $\sigma^2$  es desconocida

$$\left(\bar{X} - t_{\alpha/2} \frac{S}{\sqrt{n}}, \bar{X} + t_{\alpha/2} \frac{S}{\sqrt{n}}\right) \quad t \text{ de Student con } n-1 \text{ g.l.}$$

Capítulo 6. Estimación puntual e Intervalos de confianza

Capítulo 6. Estimación puntual e Intervalos de confianza

## Intervalo de confianza para la media $\mu$ de una población normal ( $\sigma^2$ desconocida)

Intervalo de confianza de nivel  $1 - \alpha$  para la media  $\mu$  cuando  $\sigma^2$  es desconocida

$$\left(\bar{X} - t_{\alpha/2} \frac{S}{\sqrt{n}}, \bar{X} + t_{\alpha/2} \frac{S}{\sqrt{n}}\right) \quad t \text{ de Student con } n-1 \text{ g.l.}$$

**Ejemplo:** Considera las siguientes medidas, correspondientes al Volumen Espiratorio Forzado<sup>1</sup> (litros) de 10 sujetos de un estudio que examina la respuesta al ozono entre adolescentes que sufren asma.

3,50, 2,60, 2,75, 2,82, 4,05, 2,25, 2,68, 3,00, 4,02, 2,85

- ¿Cómo estimarías el Volumen Espiratorio Forzado medio?
- Construye un intervalo de confianza para el Volumen Espiratorio Forzado medio con nivel de confianza del 95 %.
- ¿Cuál sería el intervalo de confianza para un nivel de confianza del 90 %?

<sup>1</sup>El Volumen Espiratorio Forzado es la cantidad de aire expulsado durante el primer segundo de la espiración máxima, realizada tras una inspiración máxima

Capítulo 6. Estimación puntual e Intervalos de confianza

## Intervalo de confianza para la diferencia de medias de poblaciones normales

- En algunas ocasiones estamos interesados en estimar la diferencia de medias  $\mu_1 - \mu_2$  de dos poblaciones.
- Tenemos dos muestras:
  - Una muestra formada por  $n_1$  variables independientes y con la misma distribución  $N(\mu_1, \sigma_1)$
  - Una muestra formada por  $n_2$  variables independientes y con la misma distribución  $N(\mu_2, \sigma_2)$
- Suponemos que las muestras son **independientes** (los individuos donde se han obtenido las mediciones de la población 1 son distintos de los individuos donde se han obtenido las mediciones de la población 2).
- Suponemos que las **varianzas  $\sigma_1^2$  y  $\sigma_2^2$  son conocidas**.

$$\frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \in N(0, 1)$$

Capítulo 6. Estimación puntual e Intervalos de confianza

Capítulo 6. Estimación puntual e Intervalos de confianza

Capítulo 6. Estimación puntual e Intervalos de confianza

## Intervalo de confianza para la diferencia de medias de poblaciones normales

**Intervalo de confianza de nivel  $1 - \alpha$  para la diferencia de medias  $\mu_1 - \mu_2$  de poblaciones normales. Muestras independientes y varianzas conocidas**

$$\left( (\bar{X}_1 - \bar{X}_2) - z_{\alpha/2} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}, (\bar{X}_1 - \bar{X}_2) + z_{\alpha/2} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} \right)$$

**Ejemplo:** Un equipo de investigación está interesado en la diferencia en el nivel de ácido úrico en pacientes con y sin un determinado síndrome. Se recogieron en un hospital especializado en dicha enfermedad, los niveles de ácido úrico de 12 individuos con el síndrome. Se obtuvo una media muestral de 4.5 unidades. En otro hospital general se recogieron los niveles de ácido úrico de 15 individuos sin el síndrome. En ese caso la media muestral obtenida fue 3.4 unidades. Asumimos que ambas poblaciones se distribuyen según una normal con varianzas 1 y 1.5, respectivamente. Calcula el intervalo de confianza para la diferencia de medias  $\mu_1 - \mu_2$  al 95%.

## Intervalo de confianza para la diferencia de medias de poblaciones normales

- En algunas ocasiones estamos interesados en estimar la diferencia de medias  $\mu_1 - \mu_2$  de dos poblaciones.
- Tenemos dos muestras:
  - Una muestra formada por  $n_1$  variables independientes y con la misma distribución  $N(\mu_1, \sigma_1)$
  - Una muestra formada por  $n_2$  variables independientes y con la misma distribución  $N(\mu_2, \sigma_2)$
- Suponemos que las muestras son **independientes** (los individuos donde se han obtenido las mediciones de la población 1 son distintos de los individuos donde se han obtenido las mediciones de la población 2).
- Suponemos que las **varianzas  $\sigma_1^2$  y  $\sigma_2^2$  son desconocidas pero iguales**. Sea:

$$S_p^2 = \frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2}$$

$$\frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{S_p^2}{n_1} + \frac{S_p^2}{n_2}}} \in t_{n_1 + n_2 - 2}$$

## Intervalo de confianza para la diferencia de medias de poblaciones normales

**Intervalo de confianza de nivel  $1 - \alpha$  para la diferencia de medias  $\mu_1 - \mu_2$  de poblaciones normales. Muestras independientes y varianzas desconocidas pero iguales**

$$\left( (\bar{X}_1 - \bar{X}_2) - t_{\alpha/2} \sqrt{\frac{S_p^2}{n_1} + \frac{S_p^2}{n_2}}, (\bar{X}_1 - \bar{X}_2) + t_{\alpha/2} \sqrt{\frac{S_p^2}{n_1} + \frac{S_p^2}{n_2}} \right) \quad t \text{ con } n_1 + n_2 - 2 \text{ g.l.}$$

**Ejemplo:** Un equipo de investigación está interesado en determinar la diferencia en el número medio de días de tratamiento necesario en pacientes con dos tipos de desórdenes mentales. Por un lado se determinó el nº de días de tratamiento en 18 pacientes con esquizofrenia. El número medio de días fue 4.7 con una desviación típica muestral de 9.3 días. Por otro lado se determinó el nº de días de tratamiento en 10 pacientes con trastorno bipolar. El número medio de días fue 8.8 con una desviación típica muestral de 11.5 días. Calcula el intervalo de confianza para la diferencia de medias  $\mu_1 - \mu_2$  al 95%. Se supone que el número de días de tratamiento es aproximadamente normal y las varianzas son iguales en ambos desórdenes.

## Intervalo de confianza para la diferencia de medias de poblaciones normales

- En ocasiones nos interesará comparar dos métodos o tratamientos.
- En ese caso es natural que los individuos donde se aplican los tratamientos sean los mismos.
- Se supone  $X_1 \in N(\mu_1, \sigma_1)$  y  $X_2 \in N(\mu_2, \sigma_2)$  pero  $X_1$  y  $X_2$  **no son independientes**.
- Consideraremos la variable  $D = X_1 - X_2$

$$\frac{\bar{D} - (\mu_1 - \mu_2)}{S_D / \sqrt{n}} \in t_{n-1}$$

**Ejemplo:** Se quiere estudiar los efectos del abandono de la bebida sobre la presión sistólica en individuos alcohólicos. Para ello se mide la presión sistólica en 10 individuos alcohólicos antes y después de 2 meses de haber dejado al bebida.

Sujeto	1	2	3	4	5	6	7	8	9	10
$X_1$ presión antes	140	165	160	160	175	190	170	175	155	160
$X_2$ presión después	145	150	150	160	170	175	160	165	145	170

## Intervalo de confianza para la diferencia de medias de poblaciones normales

**Intervalo de confianza de nivel  $1 - \alpha$  para la para la diferencia de medias  $\mu_1 - \mu_2$ . Muestras apareadas**

$$\left( \bar{D} - t_{\alpha/2} \frac{S_D}{\sqrt{n}}, \bar{D} + t_{\alpha/2} \frac{S_D}{\sqrt{n}} \right) \quad t \text{ con } n-1 \text{ g.l.}$$

**Ejemplo:** Se quiere estudiar los efectos del abandono de la bebida sobre la presión sistólica en individuos alcohólicos. Para ello se mide la presión sistólica en 10 individuos alcohólicos antes y después de 2 meses de haber dejado al bebida. Calcula el IC para  $\mu_1 - \mu_2$  al 95%.

Sujeto	1	2	3	4	5	6	7	8	9	10
$X_1$ presión antes	140	165	160	160	175	190	170	175	155	160
$X_2$ presión después	145	150	150	160	170	175	160	165	145	170

## Intervalo de confianza para la diferencia de medias de poblaciones normales

**Intervalo de confianza de nivel  $1 - \alpha$  para la para la diferencia de medias  $\mu_1 - \mu_2$ . Muestras apareadas**

$$\left( \bar{D} - t_{\alpha/2} \frac{S_D}{\sqrt{n}}, \bar{D} + t_{\alpha/2} \frac{S_D}{\sqrt{n}} \right) \quad t \text{ con } n-1 \text{ g.l.}$$

**Ejemplo:** Se quiere estudiar los efectos del abandono de la bebida sobre la presión sistólica en individuos alcohólicos. Para ello se mide la presión sistólica en 10 individuos alcohólicos antes y después de 2 meses de haber dejado al bebida. Calcula el IC para  $\mu_1 - \mu_2$  al 95%.

Sujeto	1	2	3	4	5	6	7	8	9	10
$X_1$ presión antes	140	165	160	160	175	190	170	175	155	160
$X_2$ presión después	145	150	150	160	170	175	160	165	145	170
Diferencias $D_i$	-5	15	10	0	5	15	10	10	10	-10

## Intervalo de confianza para la diferencia de medias de poblaciones normales

Intervalo de confianza de nivel  $1 - \alpha$  para la diferencia de medias  $\mu_1 - \mu_2$ . Muestras apareadas

$$\left( \bar{D} - t_{\alpha/2} \frac{S_D}{\sqrt{n}}, \bar{D} + t_{\alpha/2} \frac{S_D}{\sqrt{n}} \right) \quad t \text{ con } n-1 \text{ g.l.}$$

**Ejemplo:** Se quiere estudiar los efectos del abandono de la bebida sobre la presión sistólica en individuos alcohólicos. Para ello se mide la presión sistólica en 10 individuos alcohólicos antes y después de 2 meses de haber dejado al bebida. Calcula el IC para  $\mu_1 - \mu_2$  al 95 %.

Sujeto	1	2	3	4	5	6	7	8	9	10
$X_1$ presión antes	140	165	160	160	175	190	170	175	155	160
$X_2$ presión después	145	150	150	160	170	175	160	165	145	170
Diferencias $D_i$	-5	15	10	0	5	15	10	10	10	-10

$$\bar{D} = \frac{-5 + 15 + \dots + 10 - 10}{10} = 6, \quad S_D^2 = \frac{(-5 - 6)^2 + \dots + (-10 - 6)^2}{9} = 71,111.$$

## Intervalo de confianza para la diferencia de medias de poblaciones normales

Intervalo de confianza de nivel  $1 - \alpha$  para la diferencia de medias  $\mu_1 - \mu_2$ . Muestras apareadas

$$\left( \bar{D} - t_{\alpha/2} \frac{S_D}{\sqrt{n}}, \bar{D} + t_{\alpha/2} \frac{S_D}{\sqrt{n}} \right) \quad t \text{ con } n-1 \text{ g.l.}$$

**Ejemplo:** Se quiere estudiar los efectos del abandono de la bebida sobre la presión sistólica en individuos alcohólicos. Para ello se mide la presión sistólica en 10 individuos alcohólicos antes y después de 2 meses de haber dejado al bebida. Calcula el IC para  $\mu_1 - \mu_2$  al 95 %.

Sujeto	1	2	3	4	5	6	7	8	9	10
$X_1$ presión antes	140	165	160	160	175	190	170	175	155	160
$X_2$ presión después	145	150	150	160	170	175	160	165	145	170
Diferencias $D_i$	-5	15	10	0	5	15	10	10	10	-10

$$\bar{D} = \frac{-5 + 15 + \dots + 10 - 10}{10} = 6, \quad S_D^2 = \frac{(-5 - 6)^2 + \dots + (-10 - 6)^2}{9} = 71,111.$$

$$\left( \bar{D} - t_{\alpha/2} \frac{S_D}{\sqrt{n}}, \bar{D} + t_{\alpha/2} \frac{S_D}{\sqrt{n}} \right) = \left( 6 - 2,26 \frac{8,4327}{\sqrt{10}}, 6 + 2,26 \frac{8,4327}{\sqrt{10}} \right) = (-0,0266, 12,0266).$$

## Intervalo de confianza para una proporción $p$

Intervalo de confianza de nivel  $1 - \alpha$  para la proporción  $p$

$$\left( \hat{p} - z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}, \hat{p} + z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \right)$$

**Ejemplo:** Una encuesta del proyecto "Pew Internet and American Life Project"<sup>2</sup> llevada a cabo en 2010 determina que el 16% de los usuarios de internet utilizan la red para consultar información sobre resultados de pruebas médicas. La encuesta, que forma parte de un estudio sobre el uso de internet en América, se basa en entrevistas telefónicas a un total de 3001 adultos. Asumimos que los encuestados fueron elegidos de manera aleatoria. Construye un intervalo de confianza al 95% para la proporción de usuarios de internet que consultan información sobre resultados de pruebas médicas en América.

<sup>2</sup><http://www.pewinternet.org/>

## Intervalo de confianza para la diferencia de proporciones $p_1 - p_2$

Intervalo de confianza de nivel  $1 - \alpha$  para la diferencia de proporciones  $p_1 - p_2$

$$\left( (\hat{p}_1 - \hat{p}_2) - z_{\alpha/2} \sqrt{\frac{\hat{p}_1(1-\hat{p}_1)}{n_1} + \frac{\hat{p}_2(1-\hat{p}_2)}{n_2}}, (\hat{p}_1 - \hat{p}_2) + z_{\alpha/2} \sqrt{\frac{\hat{p}_1(1-\hat{p}_1)}{n_1} + \frac{\hat{p}_2(1-\hat{p}_2)}{n_2}} \right)$$

**Ejemplo:** En un centro educativo se llevó a cabo un estudio para conocer la prevalencia del tabaquismo entre los jóvenes y estudiar las diferencias en el porcentaje de fumadores entre hombres y mujeres. Para ello se seleccionaron dos muestras independientes en cada una de estas poblaciones: 220 alumnos, entre los que había 50 fumadores y 280 alumnas, de las cuales fumaban 90. Calcula el intervalo de confianza para la diferencia de proporciones de fumadores en ambos sexos al 95 %.

## Intervalo de confianza para la diferencia de proporciones $p_1 - p_2$

- En algunas ocasiones estamos interesados en estimar la diferencia de proporciones  $p_1 - p_2$  de dos poblaciones.
- Tenemos dos muestras:
  - Una muestra formada por  $n_1$  variables independientes de la población 1.
  - Una muestra formada por  $n_2$  variables independientes de la población 2.
- Suponemos que las muestras son **independientes** (los individuos donde se han obtenido las mediciones de la población 1 son distintos de los individuos donde se han obtenido las mediciones de la población 2).

Intervalo de confianza de nivel  $1 - \alpha$  para la diferencia de proporciones  $p_1 - p_2$

$$\left( (\hat{p}_1 - \hat{p}_2) - z_{\alpha/2} \sqrt{\frac{\hat{p}_1(1-\hat{p}_1)}{n_1} + \frac{\hat{p}_2(1-\hat{p}_2)}{n_2}}, (\hat{p}_1 - \hat{p}_2) + z_{\alpha/2} \sqrt{\frac{\hat{p}_1(1-\hat{p}_1)}{n_1} + \frac{\hat{p}_2(1-\hat{p}_2)}{n_2}} \right)$$

Beatriz Pateiro López

Contraste de hipótesis

- Los procedimientos de inferencia que hemos realizado hasta ahora son:
  - La estimación puntual
  - Los intervalos de confianza
- En este tema vamos a ver otro procedimiento de inferencia basado en **contrastes de hipótesis** en el que el objetivo de la experimentación está orientado a corroborar una hipótesis inicial sobre la población de estudio.

Contraste de hipótesis

- Cuando un investigador trata de entender o explicar algo, generalmente formula su problema de investigación por medio de una hipótesis
- **Ejemplo:** No sé si la edad media que tienen las mujeres gallegas cuando deciden tener su primer hijo es igual que en el resto de España (29.3 años)

**Hipótesis nula**  
 $H_0 : \mu = 29.3$

- Tomo una muestra de 6 mujeres gallegas embarazadas primerizas



- $\bar{X} = 30.5$  años
- ¿Existe suficiente evidencia en los datos para rechazar  $H_0$ ?
- ¿O la diferencia entre  $\bar{X}$  y el valor hipotético de  $\mu$  puede ser debido al azar?

Contraste de hipótesis

- Cuando un investigador trata de entender o explicar algo, generalmente formula su problema de investigación por medio de una hipótesis
- **Ejemplo:** No sé si la edad media que tienen las mujeres gallegas cuando deciden tener su primer hijo es igual que en el resto de España (29.3 años)

**Hipótesis nula**  
 $H_0 : \mu = 29.3$

- Tomo una muestra de 36 mujeres gallegas embarazadas primerizas



- $\bar{X} = 30.5$  años
- ¿Existe suficiente evidencia en los datos para rechazar  $H_0$ ?
- ¿O la diferencia entre  $\bar{X}$  y el valor hipotético de  $\mu$  puede ser debido al azar?

Contraste de hipótesis

- Llamaremos **hipótesis nula**, y la denotamos por  $H_0$ , a la que se da por cierta antes de obtener la muestra. Goza de **presunción de inocencia**.
- Llamaremos **hipótesis alternativa**, y la denotamos por  $H_1$  (o  $H_a$ ) a lo que sucede cuando no es cierta la hipótesis nula.
- Por gozar la hipótesis nula de presunción de inocencia, sobre la hipótesis alternativa recae la carga de la prueba. Por tanto, cuando rechazamos  $H_0$  en favor de  $H_1$  es porque hemos encontrado pruebas significativas a partir de la muestra.

Contraste de hipótesis

Representamos este problema de decisión mediante el siguiente gráfico:

		Decisión	
		No se rechaza $H_0$	Se rechaza $H_0$
Realidad	$H_0$ es verdadera	Decisión correcta	Error tipo I
	$H_0$ es falsa	Error tipo II	Decisión correcta

Observamos que se puede tomar una decisión correcta o errónea.

- **Error de tipo I:** cuando rechazamos la hipótesis nula, siendo cierta.
- **Error de tipo II:** cuando aceptamos la hipótesis nula, siendo falsa.

## Contraste de hipótesis. Analogía con un juicio

Supongamos un juicio en el que se trata de decidir la culpabilidad o inocencia de un acusado.



- **Hipótesis nula:** el acusado es inocente (todo acusado es inocente hasta que se demuestre lo contrario).
- **Hipótesis alternativa:** el acusado es culpable.
- **Juicio:** es el procedimiento en el cual se trata de probar la culpabilidad del acusado y la evidencia debe ser muy fuerte para que se rechace la inocencia ( $H_0$ ) en favor de la culpabilidad ( $H_a$ ).
- **Decisión:** el veredicto.
- **Error de tipo I:** condenar a un inocente.
- **Error de tipo II:** absolver a un culpable.

## Contraste de hipótesis

- La probabilidad del error de tipo I se denota por  $\alpha$  y se denomina **nivel de significación**.

Nivel de significación	
$\alpha$	= $P(\text{Rechazar } H_0/H_0 \text{ es cierta})$

- La probabilidad del error de tipo II se denota por  $\beta$

$$\beta = P(\text{No rechazar } H_0/H_0 \text{ es falsa})$$

- **Potencia:** Es la probabilidad de detectar que una hipótesis es falsa.

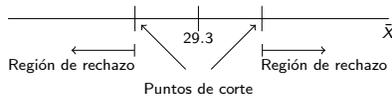
Potencia	
Potencia	= $P(\text{Rechazar } H_0/H_0 \text{ es falsa}) = 1 - \beta$

### Región crítica. Contrastes bilaterales y unilaterales

- Debemos establecer una regla de decisión para determinar cuando rechazamos o no la hipótesis nula  $H_0$
- **Ejemplo:** ¿Difiere la edad media de las madres primerizas en Galicia de la edad media de las madres primerizas en el resto de España (29.3 años)?

Contraste bilateral	
$H_0$	: $\mu = 29.3$
$H_1$	: $\mu \neq 29.3$

- Si estamos interesados en determinar si  $\mu$  **difiere significativamente** de 29.3, deberíamos rechazar  $H_0$  si  $\bar{X}$  está "lejos" de 29.3 en **ambas direcciones**.

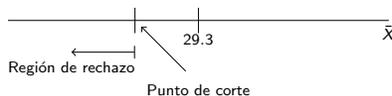


### Región crítica. Contrastes bilaterales y unilaterales

- Debemos establecer una regla de decisión para determinar cuando rechazamos o no la hipótesis nula  $H_0$
- **Ejemplo:** ¿Es la edad media de las madres primerizas en Galicia menor que la edad media de las madres primerizas en el resto de España (29.3 años)?

Contraste unilateral	
$H_0$	: $\mu \geq 29.3$
$H_1$	: $\mu < 29.3$

- Si estamos interesados en determinar si  $\mu$  **es significativamente menor** que 29.3, deberíamos rechazar  $H_0$  si  $\bar{X}$  está "lejos" de 29.3 en **una sola dirección**.

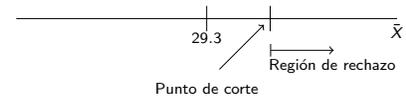


### Región crítica. Contrastes bilaterales y unilaterales

- Debemos establecer una regla de decisión para determinar cuando rechazamos o no la hipótesis nula  $H_0$
- **Ejemplo:** ¿Es la edad media de las madres primerizas en Galicia mayor que la edad media de las madres primerizas en el resto de España (29.3 años)?

Contraste unilateral	
$H_0$	: $\mu \leq 29.3$
$H_1$	: $\mu > 29.3$

- Si estamos interesados en determinar si  $\mu$  **es significativamente mayor** que 29.3, deberíamos rechazar  $H_0$  si  $\bar{X}$  está "lejos" de 29.3 en **una sola dirección**.



## Contraste de hipótesis

Las etapas en la resolución de un contraste de hipótesis son:

- Especificar las hipótesis nula  $H_0$  y alternativa  $H_1$ .
- Elegir un estadístico de contraste apropiado, para medir la discrepancia entre la hipótesis y la muestra.
- Fijar el nivel de significación  $\alpha$  en base a cómo de importante se considere rechazar  $H_0$  cuando realmente es cierta.
- Al fijar un nivel de significación,  $\alpha$ , se obtiene implícitamente una división en dos regiones del conjunto de posibles valores del estadístico de contraste:
  - La **región de rechazo** o región crítica que tiene probabilidad  $\alpha$  (bajo  $H_0$ ).
  - La **región de aceptación** que tiene probabilidad  $1 - \alpha$  (bajo  $H_0$ ).
- Si el valor del estadístico cae en la región de rechazo, los datos no son compatibles con  $H_0$  y la rechazamos. Entonces se dice que el contraste es **estadísticamente significativo**, es decir existe evidencia estadísticamente significativa a favor de  $H_1$ .
- Si el valor del estadístico cae en la región de aceptación, no existen razones suficientes para rechazar la hipótesis nula con un nivel de significación  $\alpha$ , y el contraste se dice **estadísticamente no significativo**, es decir no existe evidencia a favor de  $H_1$ .

## Contraste de hipótesis

Las etapas en la resolución de un contraste de hipótesis son:

- Especificar las hipótesis nula  $H_0$  y alternativa  $H_1$ .
- Elegir un estadístico de contraste apropiado, para medir la discrepancia entre la hipótesis y la muestra.
- Fijar el nivel de significación  $\alpha$  en base a cómo de importante se considere rechazar  $H_0$  cuando realmente es cierta.
- Al fijar un nivel de significación,  $\alpha$ , se obtiene implícitamente una división en dos regiones del conjunto de posibles valores del estadístico de contraste:
  - La **región de rechazo** o región crítica que tiene probabilidad  $\alpha$  (bajo  $H_0$ ).
  - La **región de no rechazo** que tiene probabilidad  $1 - \alpha$  (bajo  $H_0$ ).
- Si el valor del estadístico cae en la región de rechazo, los datos no son compatibles con  $H_0$  y la rechazamos. Entonces se dice que el contraste es **estadísticamente significativo**, es decir existe evidencia estadísticamente significativa a favor de  $H_1$ .
- Si el valor del estadístico cae en la región de aceptación, no existen razones suficientes para rechazar la hipótesis nula con un nivel de significación  $\alpha$ , y el contraste se dice **estadísticamente no significativo**, es decir no existe evidencia a favor de  $H_1$ .

### Contraste sobre la media de una población normal con varianza conocida

Sea  $X_1, X_2, \dots, X_n$  una muestra formada por  $n$  variables independientes y con la misma distribución  $N(\mu, \sigma)$ .

- Supongamos que la varianza  $\sigma^2$  es conocida
- Se desea contrastar una hipótesis relativa a la media,  $\mu$ .

**Contraste bilateral  
(hipótesis nula simple)**

$$H_0 : \mu = \mu_0$$

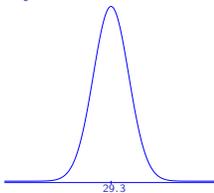
$$H_1 : \mu \neq \mu_0$$

- El sentido común nos aconseja rechazar la hipótesis nula de que la media poblacional es  $\mu_0$  cuando la media muestral  $\bar{X}$  sea muy distinta de  $\mu_0$ .

### Contraste sobre la media de una población normal con varianza conocida

- Se sabe que la edad de las madres primerizas en Galicia sigue una distribución normal con una desviación típica  $\sigma = 2$  años.
- Tomamos una muestra de 36 madres primerizas gallegas. Queremos contrastar si la edad media de las madres primerizas en Galicia difiere de la edad media de las madres primerizas en el resto de España (29.3 años).

Si  $H_0$  es cierta, la distribución de  $\bar{X}$  es  $N(29.3, 2/6)$



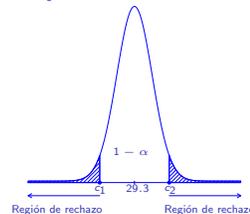
### Contraste sobre la media de una población normal con varianza conocida

- Se sabe que la edad de las madres primerizas en Galicia sigue una distribución normal con una desviación típica  $\sigma = 2$  años.
- Tomamos una muestra de 36 madres primerizas gallegas. Queremos contrastar si la edad media de las madres primerizas en Galicia difiere de la edad media de las madres primerizas en el resto de España (29.3 años).

### Contraste sobre la media de una población normal con varianza conocida

- Se sabe que la edad de las madres primerizas en Galicia sigue una distribución normal con una desviación típica  $\sigma = 2$  años.
- Tomamos una muestra de 36 madres primerizas gallegas. Queremos contrastar si la edad media de las madres primerizas en Galicia difiere de la edad media de las madres primerizas en el resto de España (29.3 años).

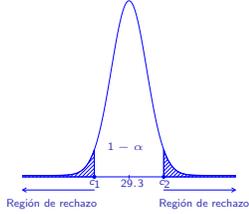
Si  $H_0$  es cierta, la distribución de  $\bar{X}$  es  $N(29.3, 2/6)$



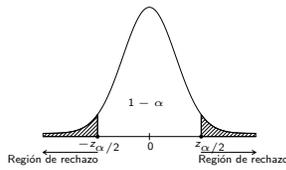
## Contraste sobre la media de una población normal con varianza conocida

- Se sabe que la edad de las madres primerizas en Galicia sigue una distribución normal con una desviación típica  $\sigma = 2$  años.
- Tomamos una muestra de 36 madres primerizas gallegas. Queremos contrastar si la edad media de las madres primerizas en Galicia difiere de la edad media de las madres primerizas en el resto de España (29.3 años).

Si  $H_0$  es cierta, la distribución de  $\bar{X}$  es  $N(29.3, 2/6)$



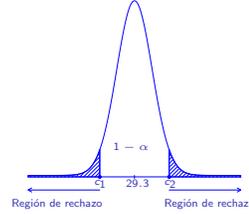
Si  $H_0$  es cierta, la distribución de  $\frac{\bar{X}-29.3}{0.333}$  es  $N(0, 1)$



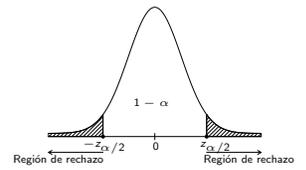
## Contraste sobre la media de una población normal con varianza conocida

- Se sabe que la edad de las madres primerizas en Galicia sigue una distribución normal con una desviación típica  $\sigma = 2$  años.
- Tomamos una muestra de 36 madres primerizas gallegas. Queremos contrastar si la edad media de las madres primerizas en Galicia difiere de la edad media de las madres primerizas en el resto de España (29.3 años).
- Observamos que  $\bar{X} = 30.5$  años. En base a la muestra, ¿podrías concluir que la edad media de las madres primerizas en Galicia difiere de la edad media de las madres primerizas en el resto de España?

Si  $H_0$  es cierta, la distribución de  $\bar{X}$  es  $N(29.3, 2/6)$



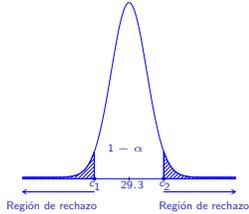
Si  $H_0$  es cierta, la distribución de  $\frac{\bar{X}-29.3}{0.333}$  es  $N(0, 1)$



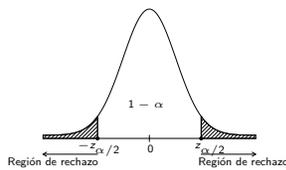
## Contraste sobre la media de una población normal con varianza conocida

- Se sabe que la edad de las madres primerizas en Galicia sigue una distribución normal con una desviación típica  $\sigma = 2$  años.
- Tomamos una muestra de 36 madres primerizas gallegas. Queremos contrastar si la edad media de las madres primerizas en Galicia difiere de la edad media de las madres primerizas en el resto de España (29.3 años).
- Observamos que  $\bar{X} = 30.5$  años. En base a la muestra, ¿podrías concluir que la edad media de las madres primerizas en Galicia difiere de la edad media de las madres primerizas en el resto de España?

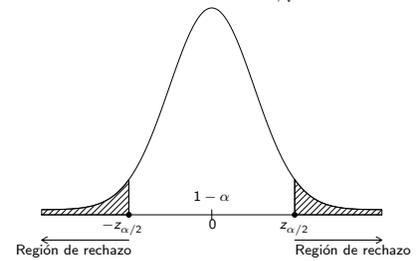
Si  $H_0$  es cierta, la distribución de  $\bar{X}$  es  $N(29.3, 2/6)$



Si  $H_0$  es cierta, la distribución de  $\frac{\bar{X}-29.3}{0.333}$  es  $N(0, 1)$



Si  $H_0$  es cierta, la distribución de  $\frac{\bar{X}-\mu_0}{\sigma/\sqrt{n}}$  es  $N(0, 1)$



## Contraste sobre la media de una población normal con varianza conocida

Rechazamos la hipótesis nula  $H_0 : \mu = \mu_0$  frente a  $H_1 : \mu \neq \mu_0$  si

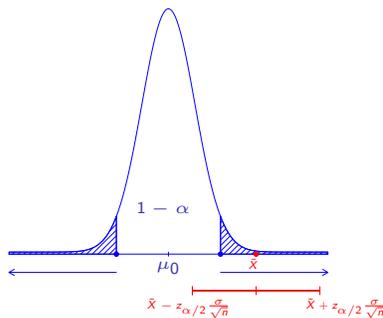
$$\frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \leq -z_{\alpha/2} \quad \text{ó} \quad \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \geq z_{\alpha/2}$$

Rechazamos la hipótesis nula  $H_0 : \mu = 29.3$  frente a  $H_1 : \mu \neq 29.3$  si

$$\frac{30.5 - 29.3}{0.333} \leq -z_{\alpha/2} \quad \text{ó} \quad \frac{30.5 - 29.3}{0.333} \geq z_{\alpha/2}$$

## Relación entre el contraste bilateral y los Intervalos de confianza

- $H_0 : \mu = \mu_0$
- Si  $H_0$  es cierta, la distribución de  $\bar{X}$  es  $N\left(\mu_0, \frac{\sigma}{\sqrt{n}}\right)$



- Rechazamos  $H_0 : \mu = \mu_0$  con una significación  $\alpha$  si  $\mu_0$  no pertenece al intervalo de confianza para  $\mu$  de nivel  $1 - \alpha$

## Contraste sobre la media de una población normal con varianza conocida

Sea  $X_1, X_2, \dots, X_n$  una muestra formada por  $n$  variables independientes y con la misma distribución  $N(\mu, \sigma)$ .

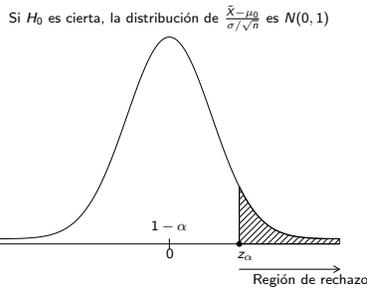
- Supongamos que la varianza  $\sigma^2$  es conocida
- Se desea contrastar una hipótesis relativa a la media,  $\mu$ .

**Contraste unilateral  
(hipótesis nula compuesta)**

$$H_0 : \mu \leq \mu_0 \\ H_1 : \mu > \mu_0$$

- El sentido común nos aconseja rechazar la hipótesis nula de que la media poblacional es  $\mu_0$  cuando la media muestral  $\bar{X}$  sea "considerablemente mayor" que  $\mu_0$ .

Contraste sobre la media de una población normal con varianza conocida



Rechazamos la hipótesis nula  $H_0 : \mu \leq \mu_0$  frente a  $H_1 : \mu > \mu_0$  si

$$\frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \geq z_\alpha$$

Contraste sobre la media de una población normal con varianza conocida

Sea  $X_1, X_2, \dots, X_n$  una muestra formada por  $n$  variables independientes y con la misma distribución  $N(\mu, \sigma)$ .

- Supongamos que la varianza  $\sigma^2$  es conocida
- Se desea contrastar una hipótesis relativa a la media,  $\mu$ .

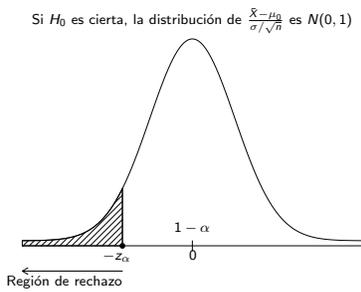
**Contraste unilateral (hipótesis nula compuesta)**

$$H_0 : \mu \geq \mu_0$$

$$H_1 : \mu < \mu_0$$

- El sentido común nos aconseja rechazar la hipótesis nula de que la media poblacional es  $\mu_0$  cuando la media muestral  $\bar{X}$  sea "considerablemente menor" que  $\mu_0$ .

Contraste sobre la media de una población normal con varianza conocida



Rechazamos la hipótesis nula  $H_0 : \mu \geq \mu_0$  frente a  $H_1 : \mu < \mu_0$  si

$$\frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \leq -z_\alpha$$

El p-valor

- A medida que el nivel de significación  $\alpha$  disminuye es más difícil rechazar la hipótesis nula (manteniendo los mismos datos).
- Hay un valor de  $\alpha$  a partir del cual ya no podemos rechazar  $H_0$ . A dicho valor se le llama el p-valor del contraste y se denota por  $p$ .
- Es decir, si el nivel de significación es menor que  $p$  ya no se rechaza  $H_0$ .

- Si  $\alpha < p$  no podemos rechazar  $H_0$  a nivel  $\alpha$ .
- Si  $\alpha > p$  podemos rechazar  $H_0$  a nivel  $\alpha$ .

Contraste sobre la media de una población normal con varianza desconocida

Sea  $X_1, X_2, \dots, X_n$  una muestra formada por  $n$  variables independientes y con la misma distribución  $N(\mu, \sigma)$ .

- Supongamos que  $\sigma^2$  es desconocida
- Se desea contrastar una hipótesis relativa a la media,  $\mu$ .
- Si  $H_0$  es cierta,

$$\frac{\bar{X} - \mu_0}{S/\sqrt{n}} \in t_{n-1}$$

- Recuerda que:

$$S = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}$$

Contraste sobre la media de una población normal con varianza desconocida

Rechazamos la hipótesis nula  $H_0 : \mu = \mu_0$  frente a  $H_1 : \mu \neq \mu_0$  si

$$\frac{\bar{X} - \mu_0}{S/\sqrt{n}} \leq -t_{\alpha/2} \quad \text{ó} \quad \frac{\bar{X} - \mu_0}{S/\sqrt{n}} \geq t_{\alpha/2}$$

Rechazamos la hipótesis nula  $H_0 : \mu \leq \mu_0$  frente a  $H_1 : \mu > \mu_0$  si

$$\frac{\bar{X} - \mu_0}{S/\sqrt{n}} \geq t_\alpha$$

Rechazamos la hipótesis nula  $H_0 : \mu \geq \mu_0$  frente a  $H_1 : \mu < \mu_0$  si

$$\frac{\bar{X} - \mu_0}{S/\sqrt{n}} \leq -t_\alpha$$

$t$  con  $n - 1$  g.l.

## Contrastes referidos a las medias de dos poblaciones normales

- En algunas ocasiones estamos interesados en contrastes sobre la diferencia de medias  $\mu_1 - \mu_2$  de dos poblaciones.
- Tenemos dos muestras:
  - Una muestra formada por  $n_1$  variables independientes y con la misma distribución  $N(\mu_1, \sigma_1)$
  - Una muestra formada por  $n_2$  variables independientes y con la misma distribución  $N(\mu_2, \sigma_2)$
- Suponemos que las muestras son **independientes** (los individuos donde se han obtenido las mediciones de la población 1 son distintos de los individuos donde se han obtenido las mediciones de la población 2).
- Suponemos que las **varianzas  $\sigma_1^2$  y  $\sigma_2^2$  son conocidas**.

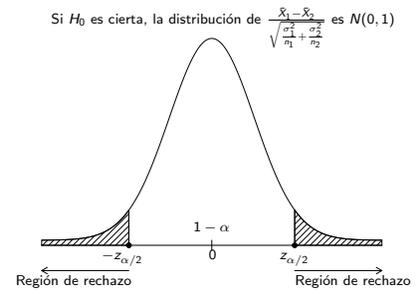
**Contraste bilateral  
(hipótesis nula simple)**

$$H_0 : \mu_1 = \mu_2$$

$$H_1 : \mu_1 \neq \mu_2$$

- El sentido común nos aconseja rechazar la hipótesis nula de que  $\mu_1 = \mu_2$  cuando  $\bar{X}_1 - \bar{X}_2$  sea muy distinta de 0.

## Contrastes referidos a las medias de dos poblaciones normales



**Rechazamos la hipótesis nula  $H_0 : \mu_1 = \mu_2$  frente a  $H_1 : \mu_1 \neq \mu_2$  si**

$$\frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \leq -z_{\alpha/2} \quad \text{ó} \quad \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \geq z_{\alpha/2}$$

## Contrastes referidos a las medias de dos poblaciones normales

**Rechazamos la hipótesis nula  $H_0 : \mu_1 \leq \mu_2$  frente a  $H_1 : \mu_1 > \mu_2$  si**

$$\frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \geq z_{\alpha}$$

**Rechazamos la hipótesis nula  $H_0 : \mu_1 \geq \mu_2$  frente a  $H_1 : \mu_1 < \mu_2$  si**

$$\frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \leq -z_{\alpha}$$

## Contrastes referidos a las medias de dos poblaciones normales

- En algunas ocasiones estamos interesados en contrastes sobre la diferencia de medias  $\mu_1 - \mu_2$  de dos poblaciones.
- Tenemos dos muestras:
  - Una muestra formada por  $n_1$  variables independientes y con la misma distribución  $N(\mu_1, \sigma_1)$
  - Una muestra formada por  $n_2$  variables independientes y con la misma distribución  $N(\mu_2, \sigma_2)$
- Suponemos que las muestras son **independientes** (los individuos donde se han obtenido las mediciones de la población 1 son distintos de los individuos donde se han obtenido las mediciones de la población 2).
- Suponemos que las **varianzas  $\sigma_1^2$  y  $\sigma_2^2$  son desconocidas pero iguales**.
- Recuerda que si suponemos que las varianzas de las dos poblaciones son iguales el mejor estimador de la varianza será:

$$S_p^2 = \frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2}$$

## Contrastes referidos a las medias de dos poblaciones normales

**Rechazamos la hipótesis nula  $H_0 : \mu_1 = \mu_2$  frente a  $H_1 : \mu_1 \neq \mu_2$  si**

$$\frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{S_p^2}{n_1} + \frac{S_p^2}{n_2}}} \leq -t_{\alpha/2} \quad \text{ó} \quad \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{S_p^2}{n_1} + \frac{S_p^2}{n_2}}} \geq t_{\alpha/2}$$

**Rechazamos la hipótesis nula  $H_0 : \mu_1 \leq \mu_2$  frente a  $H_1 : \mu_1 > \mu_2$  si**

$$\frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{S_p^2}{n_1} + \frac{S_p^2}{n_2}}} \geq t_{\alpha}$$

**Rechazamos la hipótesis nula  $H_0 : \mu_1 \geq \mu_2$  frente a  $H_1 : \mu_1 < \mu_2$  si**

$$\frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{S_p^2}{n_1} + \frac{S_p^2}{n_2}}} \leq -t_{\alpha}$$

$t$  con  $n_1 + n_2 - 2$  g.l.

## Contrastes referidos a las medias de dos poblaciones normales

- En ocasiones nos interesará comparar dos métodos o tratamientos.
- En ese caso es natural que los individuos donde se aplican los tratamientos sean los mismos.
- Se supone  $X_1 \in N(\mu_1, \sigma_1)$  y  $X_2 \in N(\mu_2, \sigma_2)$  pero  $X_1$  y  $X_2$  **no son independientes**.
- Consideraremos la variable  $D = X_1 - X_2$

Contrastes referidos a las medias de dos poblaciones normales

Rechazamos la hipótesis nula  $H_0 : \mu_1 = \mu_2$  frente a  $H_1 : \mu_1 \neq \mu_2$  si

$$\frac{\bar{D}}{S_D/\sqrt{n}} \leq -t_{\alpha/2} \quad \text{ó} \quad \frac{\bar{D}}{S_D/\sqrt{n}} \geq t_{\alpha/2}$$

Rechazamos la hipótesis nula  $H_0 : \mu_1 \leq \mu_2$  frente a  $H_1 : \mu_1 > \mu_2$  si

$$\frac{\bar{D}}{S_D/\sqrt{n}} \geq t_{\alpha}$$

Rechazamos la hipótesis nula  $H_0 : \mu_1 \geq \mu_2$  frente a  $H_1 : \mu_1 < \mu_2$  si

$$\frac{\bar{D}}{S_D/\sqrt{n}} \leq -t_{\alpha}$$

$t$  con  $n - 1$  g.l.

Contraste sobre una proporción (muestras grandes)

Rechazamos la hipótesis nula  $H_0 : p = p_0$  frente a  $H_1 : p \neq p_0$  si

$$\frac{\hat{p} - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}} \leq -z_{\alpha/2} \quad \text{ó} \quad \frac{\hat{p} - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}} \geq z_{\alpha/2}$$

Rechazamos la hipótesis nula  $H_0 : p \leq p_0$  frente a  $H_1 : p > p_0$  si

$$\frac{\hat{p} - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}} \geq z_{\alpha}$$

Rechazamos la hipótesis nula  $H_0 : p \geq p_0$  frente a  $H_1 : p < p_0$  si

$$\frac{\hat{p} - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}} \leq -z_{\alpha}$$

Datos categóricos

- Los datos categóricos son datos que provienen de experimentos cuyos resultados son de tipo categórico, es decir, se presentan en diferentes categorías que pueden o no estar ordenadas.
- **Ejemplo:** Se hizo un estudio consistente en experimentar la efectividad de dos tratamientos analgésicos para la reducción del dolor en 165 pacientes con cefalea. Se registró el tipo de dolor (ausente, leve, moderado o intenso) que manifestaron sufrir los pacientes sometidos a cada tratamiento.
  - De los 83 pacientes sometidos al tratamiento A:
    - 12 manifestaron no sufrir dolor de cabeza,
    - 24 dolor leve,
    - 31 dolor moderado y
    - 16 dolor intenso.
  - De los 82 pacientes sometidos al tratamiento B,
    - 20 manifestaron no sufrir dolor de cabeza,
    - 18 dolor leve,
    - 30 dolor moderado y
    - 14 dolor intenso.

Tablas de contingencia  $r \times s$

Tratamiento	Dolor				Total
	Ausente	Leve	Moderado	Intenso	
A	12	24	31	16	83
B	20	18	30	14	82
Total	32	42	61	30	165

Tabla de contingencia  $2 \times 4$  (2 filas, 4 columnas)

Tablas de contingencia  $2 \times 2$

- Una tabla de contingencia  $2 \times 2$  está formada por dos filas y dos columnas.
- Se utiliza para representar datos de dos variables, cada una de las cuales presenta dos únicos valores o categorías.

Variable 2	Variable 1	
	Valor 1	Valor 2
Valor 1	a	b
Valor 2	c	d

Tablas de contingencia  $2 \times 2$

- Una tabla de contingencia  $2 \times 2$  está formada por dos filas y dos columnas.
- Se utiliza para representar datos de dos variables, cada una de las cuales presenta dos únicos valores o categorías.

Variable 2	Variable 1		Total
	Valor 1	Valor 2	
Valor 1	a	b	a + b
Valor 2	c	d	c + d
Total	a + c	b + d	a + b + c + d

Tablas de contingencia  $2 \times 2$

- **Ejemplo de Fundamentals of Biostatistics, Rosner, B. (2000)**
- Estudio caso/control:
  - Casos: mujeres con cáncer de mama
  - Controles: mujeres sin cáncer de mama

Tipo	Edad al tener el primer hijo	
	$\geq 30$	$\leq 29$
Caso	683	2537
Control	1498	8747

- Ejemplo de Fundamentals of Biostatistics, Rosner, B. (2000)
- Estudio caso/control:
  - Casos: mujeres con cáncer de mama
  - Controles: mujeres sin cáncer de mama

Tipo	Edad al tener el primer hijo		Total
	≥ 30	≤ 29	
Caso	683	2537	3220
Control	1498	8747	10245
Total	2181	11284	13465

¿Existe una relación significativa entre el desarrollo de la enfermedad y la edad a la que la mujer tiene el primer hijo?

Las pruebas Chi-cuadrado, o pruebas  $\chi^2$  de Pearson, son un grupo de contrastes de hipótesis que se aplican en dos situaciones básicas:

- Para comprobar afirmaciones acerca de la distribución de una variable aleatoria: Test de bondad de ajuste.
- Para determinar si dos variables son independientes estadísticamente: Test  $\chi^2$  de independencia.

Test Chi-cuadrado de independencia

Test Chi-cuadrado de independencia en tablas de contingencia 2 × 2

- El test  $\chi^2$  de independencia nos permite determinar si dos variables cualitativas  $X$  e  $Y$  están o no asociadas.
- Si concluimos que las variables no están relacionadas podremos decir con un determinado nivel de confianza, previamente fijado, que ambas son independientes.

Test Chi-cuadrado de independencia

$$\begin{cases} H_0 : X \text{ e } Y \text{ son independientes} \\ H_1 : X \text{ e } Y \text{ no son independientes} \end{cases}$$

- Ejemplo de Fundamentals of Biostatistics, Rosner, B. (2000)
- Estudio caso/control:
  - Casos: mujeres con cáncer de mama
  - Controles: mujeres sin cáncer de mama

Tipo	Edad al tener el primer hijo		Total
	≥ 30	≤ 29	
Caso	683 (521.561)	2537 (2698.439)	3220
Control	1498 (1659.439)	8747 (8585.561)	10245
Total	2181	11284	13465

¿Existe una relación significativa entre el desarrollo de la enfermedad y la edad a la que la mujer tiene el primer hijo?

Test Chi-cuadrado de independencia en tablas de contingencia 2 × 2

Test Chi-cuadrado de independencia en tablas de contingencia 2 × 2

- Ejemplo de Fundamentals of Biostatistics, Rosner, B. (2000)
- Estudio caso/control:
  - Casos: mujeres con cáncer de mama
  - Controles: mujeres sin cáncer de mama

Tipo	Edad al tener el primer hijo		Total
	≥ 30	≤ 29	
Caso	683 (521.561)	2537 (2698.439)	3220
Control	1498 (1659.439)	8747 (8585.561)	10245
Total	2181	11284	13465

¿Existe una relación significativa entre el desarrollo de la enfermedad y la edad a la que la mujer tiene el primer hijo?

- El estadístico del contraste es:

$$\chi^2 = \sum_{\text{todas las celdas}} \frac{(\text{observados} - \text{esperados})^2}{\text{esperados}}$$

- Comparamos ahora los datos observados con los datos esperados (entre paréntesis). Si dichos valores son considerablemente distintos, deberíamos rechazar la hipótesis nula de independencia.

## Test Chi-cuadrado de independencia en tablas de contingencia 2 x 2

- El estadístico del contraste es:

$$\chi^2 = \sum_{\text{todas las celdas}} \frac{(\text{observados} - \text{esperados})^2}{\text{esperados}}$$

- Deberemos rechazar  $H_0$  cuando el valor de  $\chi^2$  sea "grande".

## Test Chi-cuadrado de independencia en tablas de contingencia 2 x 2

- El estadístico del contraste es:

$$\chi^2 = \sum_{\text{todas las celdas}} \frac{(\text{observados} - \text{esperados})^2}{\text{esperados}}$$

- Deberemos rechazar  $H_0$  cuando el valor de  $\chi^2$  sea "grande".
- Bajo  $H_0$ , el estadístico se distribuyen aproximadamente según una distribución Chi-cuadrado.
  - Para una tabla  $r \times s$ : Distribución Chi-cuadrado con  $(r - 1)(s - 1)$  g.l.
  - Para una tabla  $2 \times 2$ : Distribución Chi-cuadrado con 1 g.l.

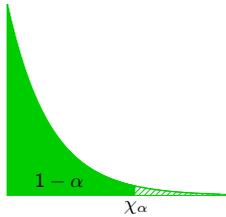
## Test Chi-cuadrado de independencia en tablas de contingencia 2 x 2

## Test Chi-cuadrado de independencia en tablas de contingencia 2 x 2

Rechazamos la hipótesis nula  $H_0 : X$  e  $Y$  son independientes en tablas  $2 \times 2$  si

$$\chi^2 = \sum_{\text{todas las celdas}} \frac{(\text{observados} - \text{esperados})^2}{\text{esperados}} \geq \chi_\alpha$$

donde  $\chi_\alpha$  es el punto que deja a su derecha una probabilidad  $\alpha$  en una distribución Chi-cuadrado con 1 grado de libertad



Para que la aproximación por la distribución Chi-cuadrado sea buena, es conveniente que las frecuencias esperadas sean grandes.

- En tablas  $2 \times 2$  se pide que todos los valores esperados sean mayores que 5.
- Aun así, en tablas  $2 \times 2$  la aproximación a la Chi-cuadrado puede no ser buena y, por eso, se suele aplicar la llamada **corrección por continuidad de Yates**.

$$\chi_{\text{corregido}}^2 = \sum_{\text{todas las celdas}} \frac{(|\text{observados} - \text{esperados}| - 0.5)^2}{\text{esperados}}$$

## Test Chi-cuadrado de independencia en tablas de contingencia r x s

## Test Chi-cuadrado de independencia en tablas de contingencia r x s

- Ejemplo estado de salud y capacidad de pago de servicios sanitarios

Estado de Salud	Pago servicios sanitarios				Total
	Casi nunca	Normalmente no	Normalmente sí	Siempre	
Excelente	4	20	21	99	144
Bueno	12	43	59	195	309
Normal	11	21	15	58	105
Deficiente	8	9	8	17	42
Total	35	93	103	369	600

¿Existe una relación significativa entre el estado de salud y la capacidad que tienen los pacientes de hacer frente al pago de los servicios sanitarios?

- Ejemplo estado de salud y capacidad de pago de servicios sanitarios

Estado de Salud	Pago servicios sanitarios				Total
	Casi nunca	Normalmente no	Normalmente sí	Siempre	
Excelente	4(8.40)	20(22.32)	21(24.72)	99(88.56)	144
Bueno	12(18.02)	43(47.90)	59(53.04)	195(190.04)	309
Normal	11(6.13)	21(16.27)	15(18.02)	58(64.57)	105
Deficiente	8(2.45)	9(6.51)	8(7.21)	17(25.83)	42
Total	35	93	103	369	600

¿Existe una relación significativa entre el estado de salud y la capacidad que tienen los pacientes de hacer frente al pago de los servicios sanitarios?

## Test Chi-cuadrado de independencia en tablas de contingencia $r \times s$

- El estadístico del contraste es:

$$\chi^2 = \sum_{\text{todas las celdas}} \frac{(\text{observados} - \text{esperados})^2}{\text{esperados}}$$

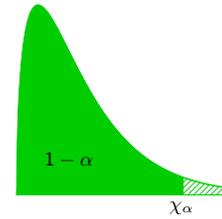
- Deberemos rechazar  $H_0$  cuando el valor de  $\chi^2$  sea "grande".
- Bajo  $H_0$ , el estadístico se distribuyen aproximadamente según una distribución Chi-cuadrado.
  - Para una tabla de contingencia de  $r$  filas y  $s$  columnas: Distribución Chi-cuadrado con  $(r - 1)(s - 1)$  g.l.

## Test Chi-cuadrado de independencia en tablas de contingencia $r \times s$

Rechazamos la hipótesis nula  $H_0 : X$  e  $Y$  son independientes en tablas  $r \times s$  si

$$\chi^2 = \sum_{\text{todas las celdas}} \frac{(\text{observados} - \text{esperados})^2}{\text{esperados}} \geq \chi_{\alpha}$$

donde  $\chi_{\alpha}$  es el punto que deja a su derecha una probabilidad  $\alpha$  en una distribución Chi-cuadrado con  $(r - 1)(s - 1)$  grados de libertad



Beatriz Pateiro López

- En el primer capítulo nos hemos ocupado de la descripción de variables estadísticas **unidimensionales**.
- Lo habitual es que tendamos a considerar un conjunto amplio de características para describir a cada uno de los individuos de la población, y que estas características puedan presentar relación entre ellas.
- Nos centraremos en el estudio de variables estadísticas **bidimensionales**.
- Representaremos por  $(X, Y)$  la variable bidimensional estudiada, donde  $X$  y  $Y$  son las variables unidimensionales correspondientes a las primera y segunda características, respectivamente, medidas para cada individuo.

Ejemplos

- ¿Existe relación entre la altura en el peso? ¿de qué tipo es esa relación?
- ¿Cómo se relaciona la cantidad de dinero que se ha invertido un laboratorio para anunciar un nuevo fármaco con las cifras de ventas durante el primer mes?
- ¿Está relacionada la altura de un padre con la de su hijo? ¿cómo?
- ¿Está relacionado el Volumen Expiratorio Forzado con la estatura?

Ejemplo Volumen Expiratorio Forzado y estatura

- EL Volumen Expiratorio Forzado (VEF) es una medida de la función pulmonar.
- Se cree que el VEF está relacionado con la estatura.
- Nos interesa estudiar la variable bidimensional  $(X, Y)$ :
  - $X$  es la estatura de niños de 10 a 15 años de edad.
  - $Y$  es el VEF.
- A continuación se muestra la estatura (en cm.) y el VEF (en l.) de 12 niños en ese rango de edad:

Estatura	134	138	142	146	150	154	158	162	166	170	174	178
VEF	1.7	1.9	2.0	2.1	2.2	2.5	2.7	3.0	3.1	3.4	3.8	3.9

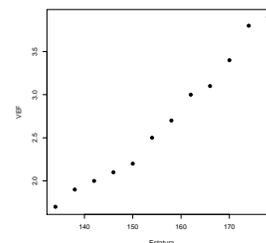
El diagrama de dispersión

- La representación gráfica más útil de dos variables continuas es el **diagrama de dispersión**.
- Consiste en representar en un eje de coordenadas los pares de observaciones  $(x_i, y_i)$ .
- La nube así dibujada refleja la posible relación entre las variables.
- A mayor relación entre las variables más estrecha y alargada será la nube.

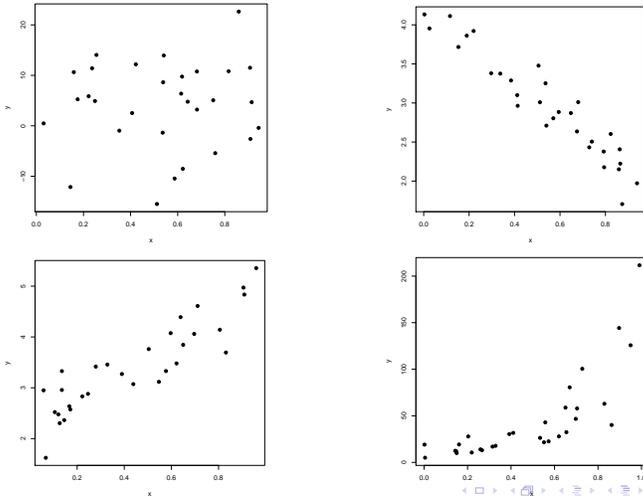
El diagrama de dispersión

- La representación gráfica más útil de dos variables continuas es el **diagrama de dispersión**.
- Consiste en representar en un eje de coordenadas los pares de observaciones  $(x_i, y_i)$ .
- La nube así dibujada refleja la posible relación entre las variables.
- A mayor relación entre las variables más estrecha y alargada será la nube.

Estatura	134	138	142	146	150	154	158	162	166	170	174	178
VEF	1.7	1.9	2.0	2.1	2.2	2.5	2.7	3.0	3.1	3.4	3.8	3.9



## Diagramas de dispersión



## Covarianza

- La mayoría de las medidas características estudiadas en el caso unidimensional (como por ejemplo la media) pueden extenderse al caso bidimensional.
- Además, en el contexto bidimensional surgen nuevas medidas que nos permiten cuantificar la dispersión conjunta de dos variables estadísticas.

### Covarianza entre X e Y

$$\text{Cov}(X, Y) = s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}).$$

## Covarianza

- La mayoría de las medidas características estudiadas en el caso unidimensional (como por ejemplo la media) pueden extenderse al caso bidimensional.
- Además, en el contexto bidimensional surgen nuevas medidas que nos permiten cuantificar la dispersión conjunta de dos variables estadísticas.

### Covarianza entre X e Y

$$\text{Cov}(X, Y) = s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}).$$

- La covarianza puede interpretarse como una medida de relación lineal entre las variables X e Y.

## Covarianza

- La mayoría de las medidas características estudiadas en el caso unidimensional (como por ejemplo la media) pueden extenderse al caso bidimensional.
- Además, en el contexto bidimensional surgen nuevas medidas que nos permiten cuantificar la dispersión conjunta de dos variables estadísticas.

### Covarianza entre X e Y

$$\text{Cov}(X, Y) = s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}).$$

- La covarianza puede interpretarse como una medida de relación lineal entre las variables X e Y.
- La covarianza de (X, Y) es igual a la de (Y, X), es decir,  $s_{xy} = s_{yx}$ .

## Covarianza

- La mayoría de las medidas características estudiadas en el caso unidimensional (como por ejemplo la media) pueden extenderse al caso bidimensional.
- Además, en el contexto bidimensional surgen nuevas medidas que nos permiten cuantificar la dispersión conjunta de dos variables estadísticas.

### Covarianza entre X e Y

$$\text{Cov}(X, Y) = s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}).$$

- La covarianza puede interpretarse como una medida de relación lineal entre las variables X e Y.
- La covarianza de (X, Y) es igual a la de (Y, X), es decir,  $s_{xy} = s_{yx}$ .
- La covarianza de (X, X) es igual a la varianza de X, es decir  $s_{xx} = s_x^2$

## Ejemplo Volumen Expiratorio Forzado y estatura: covarianza

Para los datos del ejemplo sobre el VEF y la estatura se obtiene que:

Para los datos del ejemplo sobre el VEF y la estatura se obtiene que:

- La estatura media es  $\bar{x} = 156$  centímetros.
- El VEF medio es  $\bar{y} = 2.691$  litros.
- La covarianza entre  $X$  e  $Y$  se calcula como
 
$$s_{xy} = \frac{(134 - 156) \cdot (1.7 - 2.691) + \dots + (178 - 156) \cdot (3.9 - 2.691)}{11} = 10.672$$
- El signo de la covarianza nos indica que hay una relación positiva, es decir, a medida que aumenta la estatura aumenta el VEF.

- La covarianza cambia si modificamos las unidades de medida de las variables.
- Esto es un inconveniente porque no nos permite comparar la relación entre distintos pares de variables medidas en diferentes unidades.
- La solución es utilizar el **coeficiente de correlación lineal**

#### Coeficiente de correlación lineal entre $X$ e $Y$

$$r_{xy} = \frac{s_{xy}}{s_x s_y}$$

### Coeficiente de correlación lineal

- La covarianza cambia si modificamos las unidades de medida de las variables.
- Esto es un inconveniente porque no nos permite comparar la relación entre distintos pares de variables medidas en diferentes unidades.
- La solución es utilizar el **coeficiente de correlación lineal**

#### Coeficiente de correlación lineal entre $X$ e $Y$

$$r_{xy} = \frac{s_{xy}}{s_x s_y}$$

- La correlación lineal toma valores entre  $-1$  y  $1$  y sirve para investigar la relación lineal entre las variables.

### Coeficiente de correlación lineal

- La covarianza cambia si modificamos las unidades de medida de las variables.
- Esto es un inconveniente porque no nos permite comparar la relación entre distintos pares de variables medidas en diferentes unidades.
- La solución es utilizar el **coeficiente de correlación lineal**

#### Coeficiente de correlación lineal entre $X$ e $Y$

$$r_{xy} = \frac{s_{xy}}{s_x s_y}$$

- La correlación lineal toma valores entre  $-1$  y  $1$  y sirve para investigar la relación lineal entre las variables.
- Si toma valores cercanos a  $-1$  diremos que hay una relación inversa entre  $X$  e  $Y$ .

### Coeficiente de correlación lineal

- La covarianza cambia si modificamos las unidades de medida de las variables.
- Esto es un inconveniente porque no nos permite comparar la relación entre distintos pares de variables medidas en diferentes unidades.
- La solución es utilizar el **coeficiente de correlación lineal**

#### Coeficiente de correlación lineal entre $X$ e $Y$

$$r_{xy} = \frac{s_{xy}}{s_x s_y}$$

- La correlación lineal toma valores entre  $-1$  y  $1$  y sirve para investigar la relación lineal entre las variables.
- Si toma valores cercanos a  $-1$  diremos que hay una relación inversa entre  $X$  e  $Y$ .
- Si toma valores cercanos a  $+1$  diremos que hay una relación directa entre  $X$  e  $Y$ .

### Coeficiente de correlación lineal

- La covarianza cambia si modificamos las unidades de medida de las variables.
- Esto es un inconveniente porque no nos permite comparar la relación entre distintos pares de variables medidas en diferentes unidades.
- La solución es utilizar el **coeficiente de correlación lineal**

#### Coeficiente de correlación lineal entre $X$ e $Y$

$$r_{xy} = \frac{s_{xy}}{s_x s_y}$$

- La correlación lineal toma valores entre  $-1$  y  $1$  y sirve para investigar la relación lineal entre las variables.
- Si toma valores cercanos a  $-1$  diremos que hay una relación inversa entre  $X$  e  $Y$ .
- Si toma valores cercanos a  $+1$  diremos que hay una relación directa entre  $X$  e  $Y$ .
- Si toma valores cercanos a cero diremos que no existe relación lineal entre  $X$  e  $Y$ .

Para los datos del ejemplo sobre el VEF y la estatura se obtiene que:

Para los datos del ejemplo sobre el VEF y la estatura se obtiene que:

- La desviación típica de la estatura es  $s_x = 14.422$  centímetros.
- La desviación típica del VEF es  $s_y = 0.748$  litros.
- El coeficiente de correlación lineal entre  $X$  e  $Y$  será

$$r_{xy} = \frac{10.672}{14.422 \cdot 0.7488} = 0.9881$$

- La correlación es próxima a 1 y por lo tanto la relación entre ambas variables es directa.

### Modelo de regresión lineal

- El tipo de relación más sencilla que se establece entre un par de variables es la **relación lineal**  $Y = \beta_0 + \beta_1 X$
- Sin embargo, este modelo supone que una vez determinados los valores de los parámetros  $\beta_0$  y  $\beta_1$  es posible predecir exactamente la respuesta  $Y$  dado cualquier valor de la variable de entrada  $X$ .
- En la práctica tal precisión casi nunca es alcanzable, de modo que lo máximo que se puede esperar es que la ecuación anterior sea válida sujeta a un error aleatorio, es decir, la relación entre la **variable dependiente** ( $Y$ ) y la **variable regresora** ( $X$ ) se articula mediante una **recta de regresión**.

#### Recta de regresión

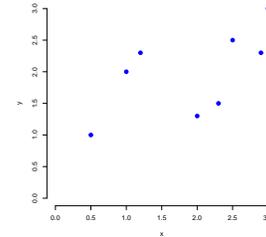
$$Y = \beta_0 + \beta_1 X + \varepsilon.$$

### Modelo de regresión lineal

#### Recta de regresión

$$Y = \beta_0 + \beta_1 X + \varepsilon.$$

- Dada una muestra  $(x_1, y_1), \dots, (x_n, y_n)$  de la variable bidimensional  $(X, Y)$ , ¿Cuál es la recta que mejor ajusta los datos?



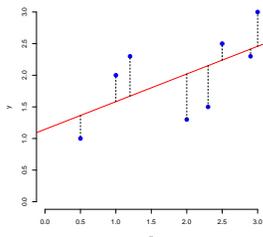
- El objetivo es determinar los valores de los parámetros desconocidos  $\beta_0$  y  $\beta_1$  (mediante estimadores  $\hat{\beta}_0$  y  $\hat{\beta}_1$ ) de manera que la recta definida ajuste de la mejor forma posible a los datos.

### El método de mínimos cuadrados

- El **método de mínimos cuadrados** consiste en encontrar los valores  $\hat{\beta}_0$  y  $\hat{\beta}_1$  que, dada la muestra de partida, minimizan la suma de los errores al cuadrado.
- Los estimadores  $\hat{\beta}_0$  y  $\hat{\beta}_1$  se determinan minimizando las **distancias verticales** entre los puntos observados,  $y_i$ , y las ordenadas previstas por la recta para dichos puntos  $\hat{y}_i$

#### El método de mínimos cuadrados

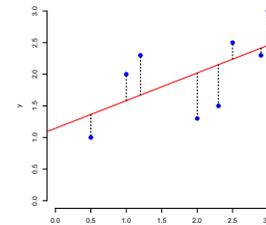
$$M(\beta_0, \beta_1) = \frac{1}{n} \sum_{i=1}^n \varepsilon_i^2 = \frac{1}{n} \sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_i))^2.$$



### El método de mínimos cuadrados

#### Coefficientes estimados por el método de mínimos cuadrados

$$\hat{\beta}_1 = \frac{s_{xy}}{s_x^2} \quad \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$$



#### Recta de regresión de $Y$ sobre $X$

$$y = \hat{\beta}_0 + \hat{\beta}_1 x$$

## Ejemplo Volumen Expiratorio Forzado y estatura: recta de regresión

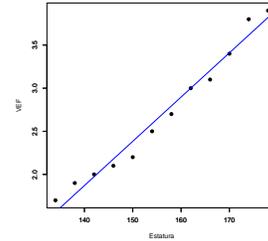
Para los datos del ejemplo sobre el VEF y la estatura se obtiene que:

## Ejemplo Volumen Expiratorio Forzado y estatura: recta de regresión

Para los datos del ejemplo sobre el VEF y la estatura se obtiene que:

- $\hat{\beta}_1 = \frac{10,672}{14,422^2} = 0.0513$
- $\hat{\beta}_0 = 2.691 - 156 \cdot 0.0513 = -5.312$
- La recta de regresión será entonces

$$y = \hat{\beta}_0 + \hat{\beta}_1 x = -5.312 + 0.0513x$$



## Descomposición de la variabilidad

- La variabilidad de toda la muestra se denomina **variabilidad total (VT)**.

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

- La variabilidad total se descompone en dos sumandos:
  - La variabilidad explicada (VE).

$$VE = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2.$$

- La variabilidad no explicada (VNE) por la regresión.

$$VNE = \sum_{i=1}^n (y_i - \hat{y}_i)^2.$$

### Descomposición de la variabilidad

$$VT = VE + VNE.$$

## Coefficiente de determinación

- El **coeficiente de determinación ( $R^2$ )** se define como la proporción de variabilidad de la variable dependiente que es explicada por la regresión

### Coefficiente de determinación

$$R^2 = \frac{VE}{VT} = 1 - \frac{VNE}{VT}.$$

- En el modelo de regresión lineal simple, el coeficiente de determinación coincide con el cuadrado del coeficiente de correlación.

$$R^2 = r_{xy}^2$$

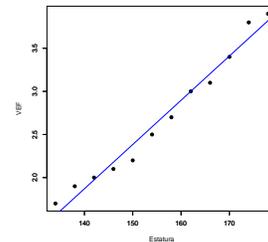
## Ejemplo Volumen Expiratorio Forzado y estatura: coeficiente de determinación

Para los datos del ejemplo sobre el VEF y la estatura se obtiene que:

## Ejemplo Volumen Expiratorio Forzado y estatura: coeficiente de determinación

Para los datos del ejemplo sobre el VEF y la estatura se obtiene que:

- $R^2 = 0.9881^2 = 0.976$
- Con el modelo de regresión lineal simple hallado, la variable X es capaz de explicar el 97.6% de la variación de Y.



## Capítulo 2: Probabilidad

1. Un hospital clasifica a cada paciente según disponga o no de seguro médico y según su estado de salud, que puede ser catalogado como bueno, aceptable, serio o crítico. El administrador registra primero un 0 si el paciente no tiene seguro y un 1 si lo tiene y después registra una de las letras b, a, s, c, según el estado en que se encuentre el paciente. Considera el experimento consistente en otorgar un código a un paciente nuevo.
  - a) ¿Cuál es el espacio muestral de este experimento?
  - b) Indica cuál es el suceso de que el paciente está en estado serio o crítico.
  - c) Indica cuál es el suceso de que el paciente está en estado serio o crítico y no tiene seguro.
  - d) Indica cuál es el suceso de que el paciente tiene seguro.
2. Estudios sobre la depresión muestran que la aplicación de un determinado tratamiento mejora el estado del 72 % de aquellas personas sobre las que se aplica, no produce efecto alguno en un 10 % y empeora el estado en el resto. Se trata a un paciente que sufre depresión por estos medios.
  - a) ¿Cuál es la probabilidad de que empeore?
  - b) ¿Cuál es la probabilidad de que el tratamiento no vaya en detrimento de su estado?
3. El 4 % de las personas de una población son daltónicas, el 18 % son hipertensas y el 0.5 % son daltónicas e hipertensas. ¿Cuál es el porcentaje de personas que son daltónicas o hipertensas?
4. La diabetes constituye un problema delicado durante el embarazo, tanto para la salud de la madre como para la del hijo. Entre las embarazadas diabéticas se presentan toxemias en un 25 % de los casos, hidroamnios en un 21 % y deterioro fetal en un 15 %. En un 6 % de los casos se dan otras complicaciones. Supongamos que no fuera posible que dos de estas complicaciones pudiesen presentarse simultáneamente en un mismo embarazo. El espacio muestral  $\Omega$  para el experimento que consiste en la observación del embarazo es:

$$\Omega = \{\text{toxemia, hidroamnios, deterioro fetal, otros, normal}\}$$

- a) ¿Cuál es la probabilidad de que exista algún tipo de complicación?
  - b) ¿Cuál es la probabilidad de que, al seleccionar aleatoriamente a una embarazada diabética demos con un embarazo normal?
5. Los pacientes que llegan a una clínica pueden seleccionar entre una de tres secciones para ser atendidos. Supongamos que los médicos se asignan al azar a las secciones y que los pacientes no tienen preferencia especial por ninguna de las secciones. Tres pacientes llegan a la clínica y se registra a la sección que escogen.
    - a) ¿Cuáles son los puntos muestrales para este experimento?

- b) Sea  $A$  el suceso "cada sección recibe un paciente". Indicar los puntos muestrales de  $A$  y calcular la probabilidad de dicho suceso.
6. El 60 % de los individuos de una población están vacunados contra una cierta enfermedad. Durante una epidemia se sabe que el 20 % la ha contraído y que 2 de cada 100 individuos están vacunados y son enfermos. Calcular el porcentaje de vacunados que enferma y el de vacunados entre los que están enfermos.
7. Se sabe que entre la población total de Estados Unidos, el 55 % padece de obesidad , el 20 % es hipertensa, y el 60 % es obesa o hipertensa. ¿Es independiente el que una persona sea obesa de que padezca hipertensión?
8. Según datos de un estudio sobre la calidad del sistema sanitario a nivel mundial, en un determinado país el 61 % de las personas recibe asistencia sanitaria pública, el 24 % de las personas contrata asistencia sanitaria privada, y el 8 % comparten asistencia pública y privada.
- a) Calcula el porcentaje de personas que tienen cobertura sanitaria de algún tipo.
- b) ¿Cuál es la probabilidad de que un habitante de dicho país reciba asistencia pública si sabemos que está pagando asistencia sanitaria privada?
- c) ¿Son independientes los sucesos "recibir asistencia sanitaria pública" y "contratar asistencia sanitaria privada"?
- d) ¿Cuál es la probabilidad de que un habitante de dicho país contrate asistencia privada sabiendo que no recibe asistencia sanitaria pública?
9. Sninsky y otros realizaron un estudio para evaluar la eficacia y seguridad de una preparación de mesalamina oral recubierta de polímero sensible al pH en pacientes con actividad de leve a moderada de colitis ulcerosa. En la siguiente tabla se muestran los resultados del tratamiento al final de seis semanas, por tratamiento recibido:

Resultado	Grupo en tratamiento		
	Placebo	Mesalamina 1.6 g/día	Mesalamina 2.4 g/día
En remisión	2	6	6
Mejorado	8	13	15
Estable	12	11	14
Empeorado	22	14	8

- a) ¿Cuál es la probabilidad de que un paciente seleccionado aleatoriamente entre en remisión al final de seis semanas?
- b) ¿Cuál es la probabilidad de que un paciente que recibe placebo logre la remisión al final de las seis semanas?
- c) ¿Cuál es la probabilidad de que un paciente seleccionado aleatoriamente haya entrado en remisión y sea uno de los que recibió placebo?
- d) ¿Cuál es la probabilidad de que un paciente seleccionado aleatoriamente sea uno de los que recibieron dosis de 2.4 g/día o esté en la lista de pacientes mejorados, o posea ambas condiciones?
10. Considérense dos pruebas clínicas  $F$  y  $H$  que resultan positivas en el 40 % y 30 %, respectivamente, de los individuos que tienen cierta deficiencia en la sangre. Ambas pruebas clínicas se consideran independientes. Si un individuo tiene la deficiencia, calcular:

- a) La probabilidad de que ambas pruebas den positivas.
  - b) La probabilidad de que una sola de ellas de positiva.
  - c) La probabilidad de que ambas den positivas si se sabe que la  $F$  ha dada positiva.
11. Estamos interesados en saber cuál de dos análisis A y B es mejor para el diagnóstico de una enfermedad, de la cual sabemos que la presenta un 10 % de los individuos de la población. El porcentaje de resultados falsos positivos del análisis A es del 15 % y el de B es del 22 %. El porcentaje de falsos negativos de A es del 7 % y de B es del 3 %. ¿Cuál es la probabilidad de acertar en el diagnóstico con cada método?
  12. Elegido un individuo al azar y observado por rayos X, se diagnosticó que estaba tuberculoso. La probabilidad de que en la población de la que se eligió el individuo, uno de ellos sea tuberculoso es de 0.01. La sensibilidad de la prueba es de 0.97 y la probabilidad de falso positivo es 0.001. ¿Cuál es la probabilidad de que el individuo sea tuberculoso, habiéndolo diagnosticado como tal por rayos X?
  13. Una enfermedad puede estar producida por tres virus A, B y C. en el laboratorio hay 3 tubos de ensayo con el virus A, 2 tubos con el virus B y 5 tubos con el virus C. La probabilidad de que el virus A produzca la enfermedad es de  $1/3$ , que la produzca B es de  $2/3$  y que la produzca el virus C es de  $1/7$ . Se inocula un virus a un animal y contrae la enfermedad, ¿Cuál es la probabilidad de que el virus que se inocule sea el C?
  14. Los estudios epidemiológicos indican que el 20 % de los ancianos sufre un deterioro neuropsicológico. Sabemos que la tomografía axial computerizada (TAC) es capaz de detectar este trastorno en el 80 % de los que lo sufren, pero también da un 3 % de falsos positivos entre las personas sanas. Si tomamos un anciano al azar y da positivo en el TAC, ¿cuál es la probabilidad de que esté realmente enfermo?
  15. Una ambulancia en la plaza Roja, al trasladarse hacia el hospital, puede hacerlo por la calle Fray Rosendo Salvado, República del Salvador o San Pedro de Mezonzo, con probabilidades 0.2 , 0.7 y 0.1, respectivamente. La probabilidad de que la ambulancia sufra un atasco por la calle Fray Rosendo Salvado es 0.5, por la calle República del Salvador es 0.6 y por la calle San Pedro de Mezonzo es 0.4.
    - a) Calcula la probabilidad de que la ambulancia quede atrapada en un atasco.
    - b) Si la ambulancia ha llegado al hospital sin sufrir ningún atasco, ¿cuál es la probabilidad de que haya elegido circular por la calle Fray Rosendo Salvado?
  16. Con el objeto de diagnosticar la colelietasis se usan ultrasonidos. Tal técnica tiene una sensibilidad del 91 % y una especificidad del 98 %. En la población que nos ocupa la probabilidad de colelietasis es de 0.2.
    - a) Si a un individuo de tal población se le aplican los ultrasonidos y dan positivos, ¿cuál es la probabilidad de que sufra colelietasis?
    - b) Si el resultado fuese negativo, ¿cuál sería la probabilidad de que no tenga la enfermedad?
  17. Una población está formada por tres grupos étnicos: A (30 %), B (10 %) y C (60 %). Los porcentajes del carácter "ojos claros" son, respectivamente, 20 %, 40 % y 5 %. Si un individuo elegido al azar tiene los ojos claros, ¿a qué grupo es más probable que pertenezca?

18. Un equipo de investigación médica pretende evaluar la utilidad de cierto síntoma (llamado S) para el diagnóstico de determinada enfermedad. En una muestra aleatoria independiente de 775 pacientes con esa enfermedad, 744 pacientes presentaron el síntoma. En una muestra aleatoria independiente de 1380 individuos sin la enfermedad, 21 presentaron el síntoma.
- a) Para el contexto de este ejercicio, ¿qué es un falso positivo?
  - b) ¿Qué es un falso negativo?
  - c) Calcular la sensibilidad del síntoma
  - d) Calcular la especificidad del síntoma
  - e) Supongamos que la tasa de la enfermedad en la población general es 0.001, ¿cuál es el valor que predice la positividad del síntoma?
  - f) ¿Cuál es el valor que predice la negatividad del síntoma?
  - g) Calcular los valores que predicen la positividad y la negatividad del síntoma para las siguientes tasas hipotéticas: 0.0001, 0.01, 0.10.
  - h) Con base en los resultados obtenidos en el apartado g), ¿qué se puede concluir acerca de los valores que predicen el síntoma?

## Capítulo 3: Variables aleatorias

1. Sea  $X$  la variable aleatoria que expresa el número de pacientes con enfermedades articulares en centros de salud con las siguientes probabilidades:

$x_j$	0	1	2	3	4	5	6	7
$p_i$	0.230	0.322	0.177	0.155	0.067	0.024	0.015	0.01

Comprueba que se trata efectivamente de una distribución de probabilidad y represéntala. Calcula y representa la función de distribución. ¿Cuál es el número medio de pacientes con enfermedades articulares?

2. En el grupo de adultos ( $> 16$  años) la probabilidad de sobrevivir al trasplante de médula ósea en talasemia es 0.6. Un centro hospitalario planea realizar trasplantes de médula ósea a 3 pacientes adultos.
- Escribe el espacio muestral correspondiente al posible resultado de las 3 operaciones de trasplante.
  - Considera la variable  $X$  =Número de pacientes que sobreviven al trasplante. Calcula y representa la función de masa y la función de distribución de la variable  $X$ .
  - ¿Cuál es la probabilidad de que sobrevivan exactamente 2 pacientes al trasplante de médula?
3. Supongamos que el 40 % de los enfermos de una determinada dolencia se recuperan. Si en un centro hospitalario hay 4 pacientes internados que sufren de esa dolencia,
- ¿Cuál es la probabilidad de que 2 se recuperen?
  - ¿Cuál es la probabilidad de que todos se recuperen?
  - ¿Cuál es la probabilidad de que al menos 2 se recuperen?
4. La probabilidad de que un paciente que acude a una consulta de atención primaria sea derivado a otra consulta es 0.2. Si a una consulta de atención primaria acuden 5 pacientes calcula:
- La probabilidad de que sean derivados exactamente 3 pacientes.
  - La probabilidad de que sean derivados exactamente 5 pacientes.
  - La probabilidad de que sean derivados menos de 5 pacientes.
  - Calcula el número medio de pacientes derivados a otra consulta, la varianza y la desviación típica.
5. En un hospital, el número medio de pancreatitis agudas atendidas al día es 0.9. Calcula la probabilidad de que un día determinado sean atendidas 3 pancreatitis agudas en dicho hospital.

6. Se estima que la probabilidad de que haya complicaciones graves en pacientes con fallos coronarios ingresados en la UCI es 0.05. Si en la UCI de un determinado hospital hay ingresados 60 pacientes con fallos coronarios, ¿cuál es la probabilidad de que ninguno de ellos sufra complicaciones graves?
7. En un hospital, el número medio de ingresos por día en la unidad de quemados es 8.4. Calcula:
  - a) La probabilidad de que una semana haya exactamente 7 ingresos en la unidad de quemados.
  - b) La probabilidad de que un día haya exactamente dos ingresos en la unidad de quemados.
  - c) La probabilidad de que un día haya al menos un ingreso en la unidad de quemados.
8. Un estudio sobre salud laboral establece que el 9 % de los profesores que imparten clase en centros de Primaria y Secundaria se da de baja por sufrir alguna patología psiquiátrica, siendo la más común la depresión, aunque también hay casos de estrés o neurosis.
  - a) Supongamos que un determinado centro de primaria cuenta con 7 docentes. ¿cuál es la probabilidad de que ninguno de ellos solicite la baja por alguna patología psiquiátrica?
  - b) ¿cuál es la probabilidad que ningún docente solicite la baja por alguna patología psiquiátrica en un centro con 60 docentes?
9. El gerente de un centro de atención primaria sabe, por experiencia, que el 20 % de las personas que solicitan cita previa no asisten a la consulta. Si el centro da 10 citas pero solo puede atender a 8 pacientes, ¿cuál es la probabilidad de que todas las personas que acuden con cita previa a la consulta sean atendidas?
10. Diez individuos entran en contacto con un portador de tuberculosis. La probabilidad de que la enfermedad se contagie del portador a un sujeto cualquiera es de 0.1. ¿Cuántos individuos se espera que contraigan la enfermedad?
11. Sea  $X$  una variable con distribución binomial, con media 2 y varianza  $4/3$ .
  - a) Determina la función de distribución de  $X$  y represéntala gráficamente.
  - b) Calcula la media y varianza de  $Y=4X+3$ .

## Capítulo 4: Variables aleatorias continuas

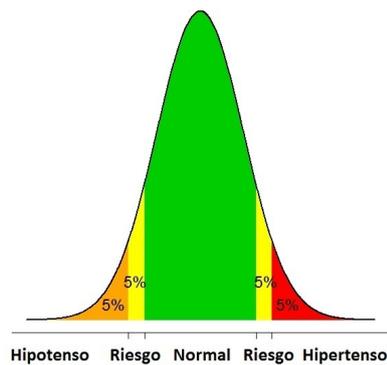
1. Comprueba que en una normal estándar  $N(0, 1)$ :
  - a) Aproximadamente el 68 % del área encerrada bajo la función de densidad está contenida entre  $-1$  y  $+1$ .
  - b) Aproximadamente el 95 % del área encerrada bajo la función de densidad está contenida entre  $-2$  y  $+2$ .
  - c) Aproximadamente el 99 % del área encerrada bajo la función de densidad está contenida entre  $-3$  y  $+3$ .
2. Sea  $Z$  una variable aleatoria normal estándar. Calcula:
  - a) El área encerrada por la función de densidad entre  $z = 0$  y  $z = 1.35$ .
  - b)  $P(Z \leq 2)$
  - c)  $P(-0.5 \leq Z \leq 2.65)$
  - d) El valor de  $z$  ( $z > 0$ ) de manera que el área encerrada entre  $0$  y  $z$  sea  $0.2$ .
  - e) El valor de  $z$  tal que la probabilidad de obtener un valor mayor que  $z$  sea  $0.1$ .
3. Los errores en el peso proporcionado por la báscula de un ambulatorio son normales de media  $0$  y desviación  $1$  kg. Calcula la probabilidad de que la diferencia entre el peso real de un paciente y el proporcionado por la báscula no supere los  $500$  gr. (bien por exceso o bien por defecto).
4. La capacidad vital es la cantidad de aire que es posible expulsar de los pulmones después de haber inspirado completamente. Hemos calculado la capacidad vital estandarizada CVE en una población infantil (la CVE se calcula como la capacidad vital corregida adecuadamente mediante la media y desviación típica). Se asume que la capacidad vital estandarizada se distribuye como una normal  $N(0, 1)$ .
  - a) Si se considera que la salud pulmonar de un niño es débil cuando su capacidad vital estandarizada es menor que  $-1.5$ , ¿qué porcentaje de la población estudiada presenta una salud pulmonar débil?
  - b) Un niño tiene un crecimiento pulmonar normal si su capacidad vital estandarizada está entre  $-1.5$  y  $1.5$ . ¿Qué porcentaje de la población presenta un crecimiento pulmonar normal?
  - c) Completa las siguiente frases:
    - 1) Según el modelo, el 90 % de la población infantil tiene una capacidad vital estandarizada menor que aproximadamente \_\_\_\_\_.
    - 2) Según el modelo, el 20 % de la población infantil con mayor capacidad pulmonar estandarizada tiene una CVE mayor que aproximadamente \_\_\_\_\_.
5. Los valores de sodio sérico en adultos sanos se distribuye como una variable normal de media  $141\text{mM}$  y varianza  $9\text{ mM}^2$ . Asumiendo dicha distribución:

- a) ¿Qué porcentaje de adultos tienen un nivel de sodio sérico inferior a 137mM?
- b) ¿Qué porcentaje de adultos tienen un nivel de sodio sérico de entre 137 y 145mM?
6. El nivel de colesterol en la sangre se mide de acuerdo a un índice llamado LDL. Para el caso de personas adultas, la distribución del colesterol en la sangre es aproximadamente normal y en el caso de los hombres tiene una media de 4.8 unidades LDL con una desviación estándar igual a 0.6 unidades. El nivel normal (o riesgo normal) de colesterol se considera aquel que queda entre los límites  $\mu \pm \sigma$  en unidades LDL. Una persona con más de  $\mu + \sigma$  pero menos de  $\mu + 2\sigma$  unidades LDL tiene un nivel de riesgo moderado. Si tiene un nivel de  $\mu + 2\sigma$  o superior se considera de alto riesgo y se hace propenso a sufrir un infarto. Por otra parte, si el nivel de colesterol en la sangre de un adulto está por debajo de  $\mu - \sigma$  unidades, se considera de riesgo bajo.
- a) ¿Cuáles son los porcentajes de población de hombres adultos que están incluidos en cada uno de los 4 niveles de riesgo descritos?
- b) ¿A partir de qué nivel de colesterol se encuentra el 10 % de la población de hombres adultos con mayor riesgo?
7. Dada una variable  $X \in N(\mu, \sigma)$
- a) ¿Qué porcentaje del área encerrada bajo la función de densidad está contenida entre  $\mu - \sigma$  y  $\mu + \sigma$ ?
- b) ¿Qué porcentaje del área encerrada bajo la función de densidad está contenida entre  $\mu - 2\sigma$  y  $\mu + 2\sigma$ ?
- c) ¿Qué porcentaje del área encerrada bajo la función de densidad está contenida entre  $\mu - 3\sigma$  y  $\mu + 3\sigma$ ?
8. La presión arterial sistólica corresponde al valor máximo de la tensión arterial en sístole. Se asume que la presión sistólica se distribuye como una variable normal, donde el valor medio y la desviación típica dependen de la edad. Se muestra a continuación la media y desviación típica para 3 grupos de edad.

	Presión sistólica (mmHg)	
	Media	Desviación típica
20-24 años	123.9	13.74
40-44 años	129.0	15.07
55-64 años	139.8	19.99

- a) ¿Qué porcentaje de la población de entre 20 y 24 años presenta una presión sistólica inferior a 150 mmHg?
- b) ¿Qué porcentaje de la población de entre 40 y 44 años presenta una presión sistólica superior a 100 mmHg?
- c) ¿Qué porcentaje de la población de entre 55 y 64 años presenta una presión sistólica de entre 130 y 145 mmHg?

Además, un modelo de hipertensión-hipotensión aceptado es el que se muestra a continuación.



Calcula, para cada grupo de edad, los límites de presión sistólica que clasifican a un paciente como hipotenso, hipertenso, en riesgo o con presión sanguínea normal.

9. Para ayudar a la evaluación del pronóstico de pacientes con una determinada enfermedad pulmonar se calculan dos índices, independientes entre sí. Se asume que el primero de los índices se distribuye según una normal  $N(120, 10)$  y que el segundo se distribuye según una normal  $N(15, 3)$ . Se consideran susceptibles de una revisión más profunda aquellos pacientes que en el primer índice superen el valor 142. También son susceptibles de una revisión más profunda aquellos pacientes que en el segundo índice presenten un valor inferior a 8. ¿Qué porcentaje de pacientes son susceptibles de una revisión más profunda?
10. Una determinada prueba mide los niveles de las tres células sanguíneas básicas: glóbulos rojos, blancos y plaquetas. Se asume que el nivel de glóbulos blancos se distribuye según una normal de media 14 y desviación típica 3.6. Además una persona se clasifica en un grupo de riesgo de infección cuando su nivel de glóbulos blancos es inferior a 10.
  - a) ¿Cuál es la probabilidad de que un paciente sea clasificado en el grupo de riesgo de infección?
  - b) Si se realiza la prueba en 9 pacientes de manera independiente:
    - 1) ¿Cuál es la probabilidad de que al menos 2 de ellos sean clasificados en el grupo de riesgo de infección?
    - 2) ¿Cuál es el número esperado de pacientes en el grupo de riesgo?
11. Un estudio realizado en un hospital de EEUU determinó que el peso al nacer se distribuye como una normal de media 109 onzas y desviación típica 13 onzas. Sabiendo que una onza equivale a 28.35 gramos:
  - a) ¿Cuál es el peso medio al nacer en gramos?
  - b) Si  $X$  denota el peso al nacer en gramos. ¿Cuál es la varianza de  $X$ ?
  - c) Si  $Y$  denota el peso al nacer en kilos, ¿Cuál es la desviación típica de  $Y$ ?
  - d) ¿Cuál es la probabilidad de que un niño al nacer peso menos de 3200 gramos?
12. El coeficiente intelectual de una población sigue una distribución normal de media 100 y desviación típica 15. ¿Cuál de las siguientes afirmaciones es correcta?
  - a) El 95 % central de los individuos de la población estarán situados entre 85 y 115.
  - b) El 95 % central de los individuos de la población estarán situados entre 50 y 150.

- c) El 95 % central de los individuos de la población estarán situados entre 70 y 130.
13. Queremos estudiar la capacidad diagnóstica de una prueba de glucemia. En base a la experiencia se determina que el nivel de glucosa en sangre de pacientes sanos se distribuye como una normal de media 80 mg/dl y desviación típica 10 mg/dl. También se sabe que el nivel de glucosa en sangre de pacientes diabéticos se distribuye como una normal de media 160 mg/dl y desviación típica 31.4 mg/dl.
- a) Si la prueba de glucemia establece que un individuo está enfermo cuando su nivel de glucosa es superior a 100 mg/dl, ¿Cuál es la sensibilidad y especificidad de la prueba diagnóstica?
- b) ¿Cuál es la sensibilidad y especificidad de la prueba diagnóstica si el punto de corte se establece en 90 mg/dl.?

## Capítulo 6: Estimación puntual e Intervalos de confianza

1. La exostosis auditiva externa (EAE) es una anomalía ósea del canal auditivo externo. Esta lesión está asociada a una prolongada inmersión en agua fría y aparece con frecuencia en individuos que participan en actividades acuáticas. Un estudio publicado en una revista especializada en Otorrinolaringología pretende determinar la prevalencia de EAE en una población de surfistas. Para ello se sometió a 307 surfistas profesionales a un cuestionario.
  - a) De los 307 surfistas encuestados, 132 afirmaron haber necesitado tratamiento médico para infecciones de oído en alguna ocasión. ¿Cómo estimarías la proporción de surfistas que sufren infecciones de oído en base a la muestra? Calcula el intervalo de confianza para la proporción de surfistas que sufren algún tipo de infección de oído con un nivel de confianza del 95 %. Calcula el intervalo de confianza para la proporción de surfistas que sufren algún tipo de infección de oído con un nivel de confianza del 90 %.
  - b) Los surfistas encuestados en este estudio surfean fundamentalmente en aguas frías (por debajo de 12°C). Se cree que la prevalencia de EAE es distinta en surfistas de aguas templadas. Supongamos que de los 307 surfistas examinados 230 fueron diagnosticados de EAE y que en otro estudio realizado a 75 surfistas de aguas templadas, 30 fueron diagnosticados de EAE. Construye un intervalo de confianza al 90 % para la diferencia de prevalencias de EAE entre surfistas de aguas frías y surfistas de aguas templadas.

*Los datos del apartado a) están tomados del artículo "Prevalence of external auditory canal exostoses in surfers". Arch Otolaryngol Head Neck Surg. 1999*

2. Una empresa de tecnología que elabora productos para el cuidado de la salud comercializa electrodos adhesivos redondos. Estamos interesados en determinar el diámetro medio de dichos electrodos. Se sabe que el proceso de producción sigue una distribución normal y padece una desviación típica de 0.1 cm. Construye un intervalo de confianza para el diámetro medio de los electrodos al 95 % utilizando que en una muestra de 25 electrodos fabricados por la empresa el diámetro medio fue de 3.5 cm.
3. Supongamos que la proporción real de fumadores en una determinada comunidad se conoce y es igual a 0.4. Si queremos estimar dicha proporción de fumadores a partir de una muestra de tamaño  $n = 100$ , ¿cuál es la probabilidad de que la proporción estimada sea correcta salvo un error de  $\pm 3\%$ ? ¿Y si se realiza la estimación con una muestra de tamaño  $n = 200$ ?
4. Cierta empresa se ha propuesto comercializar un aparato para analizar la concentración de glucosa en sangre. Los fabricantes son conocedores de que su método presenta un error de medición cuya desviación típica es de 2.4 mg/l. Sin embargo, dado que desconocen la media, se han decidido a tomar una muestra que les permita estimarla. A continuación consta tal muestra de los errores de medición (en mg/l):

0.51	-2.75	1.83	2.97	-0.82	2.32	-0.69	-2.19
1.47	-1.54	0.30	-1.25	0.18	-0.21	-1.95	-3.67

Elabora una estimación del error medio y construye un intervalo de confianza a un nivel del 99 %, suponiendo que los errores siguen una distribución normal.

5. Se pretende conocer la media y la varianza del tiempo de eliminación de un medicamento. Para ello se han observado los tiempos en una muestra de pacientes obteniéndose los siguientes datos (en horas):

5.64	7.83	6.92	5.31	8.85	7.94	6.04	5.19
7.33	8.24	7.68	6.47	6.09	8.75	5.87	7.28

Supón que los datos proceden de una distribución normal y, en base a ello, confecciona estimaciones para la media y la varianza. Calcula el intervalo de confianza a un nivel del 90 % para el tiempo medio de eliminación del medicamento.

6. Para estudiar si la presión ejercida en la parte superior del brazo aumenta o no el tiempo de hemorragia, 29 personas fueron sometidas a una presión de 40 mmHg y a continuación se les practicó una punción digital obteniéndose un tiempo medio de hemorragia de 2.192 minutos con una desviación estándar de 0.765 minutos. Otras 33 personas actuaron como controles, no se les aplicó presión y su tiempo medio de hemorragia al pincharles un dedo fue de 1.407 minutos con una desviación estándar de 0.588 minutos. Determina con un nivel de confianza de 95 % un intervalo de confianza para la diferencia de los tiempos medios de hemorragia entre los tratados y los controles. Se asume que los tiempos de hemorragia en ambos grupos son normales y con la misma varianza.
7. En un estudio sobre nutrición se analizó la ganancia de peso de 16 niños sometidos a una dieta especial durante un periodo de 3 meses. Se observó una ganancia media de peso 2.49 kg. Un grupo de control formado por 16 niños de constitución física similar fue sometido a una dieta normal durante el mismo periodo de tiempo, observándose una ganancia media de peso de 2.05 kg. Se supone que la desviación estándar para la ganancia de peso es 2 kg.
- Determina con un nivel de confianza de 95 % un intervalo de confianza para la diferencia en la ganancia media de peso entre niños tratados y los controles.
  - ¿Cuál sería el intervalo de confianza si suponemos que tanto el grupo control como el de tratamiento estaba formado por 50 niños? Compáralo con el intervalo calculado en el apartado anterior.
8. Un investigador está planeando hacer un estudio sobre el nivel medio de presión sistólica en pacientes con hipertensión. Algunos resultados previos indican que la presión sistólica es aproximadamente normal con una desviación típica de 15 mmHg.
- Si el investigador desea obtener un intervalo de confianza para el nivel medio de presión sistólica de longitud 4 mmHg con una confianza de 95 %, ¿cuántos pacientes hipertensos tendrían que ser incluidos en el estudio?
  - Si el investigador decide mantener el nivel de confianza en el 95 % pero desea que el intervalo obtenido para el nivel medio de presión sistólica sea más pequeño, ¿tendrá que aumentar o disminuir el tamaño de la muestra? Calcula el número de pacientes que debe considerar para tener un intervalo de longitud 3mmHg con confianza 95 %.

- c) ¿Cuál será la longitud del intervalo de confianza al 95 % para el nivel medio de presión sistólica si hace el estudio sobre 100 pacientes? ¿Qué pasará con la longitud del intervalo si reduce el estudio a 50 pacientes manteniendo el nivel de confianza? ¿Y si hace el estudio sobre 100 pacientes pero construye el intervalo de confianza al 99°
9. Según reconoce Sanidad, es cada vez más elevada la prevalencia de pacientes polimedicados (que toman 6 o más medicamentos) en el nivel asistencial. Esto hace necesario reforzar las estrategias para optimizar los recursos. Un centro de salud ha llevado a cabo un estudio para conocer la prevalencia de polimedicados. Se han seleccionado 649 pacientes de los cuales 149 están sometidos a tratamientos que superan los 6 medicamentos. Calcula un intervalo de confianza para la prevalencia de polimedicados con un nivel de confianza del 95 %.
10. Para estudiar el efecto del ejercicio físico sobre el nivel de triglicérido, se ha realizado el siguiente experimento con 11 individuos: previo al ejercicio se tomaron muestras de sangre para determinar el nivel de triglicérido por 100 mililitros de sangre de cada sujeto. Después los individuos fueron sometidos a un programa de ejercicios que se centraba diariamente en carreras y marchas. Al final del periodo de ejercicios, se tomaron nuevamente muestras de sangre y se obtuvo una segunda lectura del nivel de triglicérido. De este modo, se dispone de dos conjuntos de observaciones del nivel de triglicérido por 100 mililitros de sangre de los sujetos:

Sujeto	1	2	3	4	5	6	7	8	9	10	11
Previo	68	77	94	73	37	131	77	24	99	629	116
Posterior	95	90	86	58	47	121	136	65	131	630	104

Suponiendo normalidad en el nivel de triglicérido, construye un intervalo de confianza de nivel 95 % para la diferencia entre el nivel medio de triglicérido antes y después del programa de ejercicios.

## Capítulos 7 y 8: Contrastes de hipótesis

1. Según fuentes estadísticas, en la actualidad la edad media de las madres primerizas en España es de 29.3 años.

a) Tomamos una muestra de 36 madres primerizas gallegas y observamos que la edad media de dichas mujeres es 30.5 años. Asumimos que la edad de las madres primerizas en Galicia sigue una distribución normal con una desviación típica de 2 años. Para una significación del 5 %, ¿podemos concluir que la edad media de las madres primerizas en Galicia difiere de la de España?

b) Se considera ahora una muestra de 10 madres primerizas de Portugal. Sus edades son:

30 28 27 28 28 28 24 23 31 30

Asumimos que la edad de las madres primerizas en Portugal también sigue una distribución normal con una desviación típica de 2 años.

- 1) Para una significación del 5 %, ¿podemos concluir que la edad media de las madres primerizas en Portugal difiere de la de España?
- 2) Calcula el  $p$ -valor del contraste.
- 3) Para una significación del 1 %, ¿podemos concluir que la edad media de las madres primerizas en Portugal difiere de la de España?

2. Según datos de 2003, el 62.68 % de los jóvenes españoles de entre 18 y 29 años afirman utilizar preservativo siempre que mantienen relaciones sexuales con parejas ocasionales. Tras una campaña preventiva sobre el uso del preservativo llevada a cabo en los últimos años, se realizó encuesta a 3150 jóvenes de entre 18 y 29 años. De ellos, 2047 afirmaron utilizar preservativo siempre que mantienen relaciones sexuales con parejas ocasionales. ¿Se puede concluir que la campaña preventiva ha sido efectiva para una significación del 5 %?

*Puedes encontrar datos sobre salud en España en la web del Instituto Nacional de Estadística:*

[http://www.ine.es/inebmenu/mnu\\_salud.htm](http://www.ine.es/inebmenu/mnu_salud.htm)

3. Cierta empresa se ha propuesto comercializar un aparato para analizar la concentración de glucosa en sangre. Los fabricantes son conocedores de que su método presenta un error de medición cuya desviación típica es de 2.4 mg/l. Sin embargo, dado que desconocen la media, se han decidido a tomar una muestra que les permita estimarla. A continuación consta tal muestra de los errores de medición (en mg/l):

0.51 -2.75 1.83 2.97 -0.82 2.32 -0.69 -2.19  
1.47 -1.54 0.30 -1.25 0.18 -0.21 -1.95 -3.67.

a) ¿Es el error medio significativamente distinto de cero para una significación 0.1? ¿Cómo contestarías a la pregunta utilizando el intervalo de confianza construido en el boletín 6?

- b) ¿Es el error medio significativamente distinto de cero para una significación 0.05?
- c) Supongamos ahora que las observaciones provienen de un aparato cuyo error de medición presenta una desviación típica de 0.67 mg/l. ¿Dirías ahora que el error medio es significativamente distinto de cero para una significación 0.05? Calcula e interpreta el p-valor.
4. Para conocer el uso que hombres y mujeres hacen de los servicios sanitarios es necesario realizar estudios que permitan conocer mejor los factores que intervienen en sus decisiones y en las del personal sanitario. Según la Encuesta Nacional de Salud de 2003, un 17 % de las mujeres acuden a consulta médica con frecuencia. Se lleva a cabo un estudio en el que participan 2150 hombres. Del total de los hombres, 275 afirman haber acudido a consulta médica durante las dos semanas anteriores al momento de la encuesta. ¿Se puede concluir que el uso de los servicios sanitarios por parte de los hombres es menor que el de las mujeres?

*En la Encuesta Nacional de Salud se analizan las diferencias entre hombres y mujeres en el estado de salud o en los hábitos de consulta. Algunos estudios apuntan, para explicar el diferente uso de los servicios, a una mayor medicalización de la salud de las mujeres o la práctica más frecuente de conductas de riesgo por parte de los hombres, sobre todo en edades tempranas.*

[http://www.msps.es/organizacion/sns/planCalidadSNS/e02\\_t05.htm](http://www.msps.es/organizacion/sns/planCalidadSNS/e02_t05.htm)

5. Para estudiar si la presión ejercida en la parte superior del brazo aumenta o no el tiempo de hemorragia, 29 personas fueron sometidas a una presión de 40 mmHg y a continuación se les practicó una punción digital obteniéndose un tiempo medio de hemorragia de 2.192 minutos con una desviación estándar de 0.765 minutos. Otras 33 personas actuaron como controles, no se les aplicó presión y su tiempo medio de hemorragia al pincharles un dedo fue de 1.407 minutos con una desviación estándar de 0.588 minutos. Se asume que los tiempos de hemorragia en ambos grupos son normales y con la misma varianza.
- a) ¿Se puede concluir que el tiempo medio de hemorragia es significativamente distinto al ejercer presión en la parte superior del brazo que al no ejercer presión? (significación 0.05).
- b) ¿Se puede concluir que el tiempo medio de hemorragia es significativamente mayor al ejercer presión en la parte superior del brazo? (significación 0.05).
6. Para estudiar el efecto del ejercicio físico sobre el nivel de triglicérido, se ha realizado el siguiente experimento con 11 individuos: previo al ejercicio se tomaron muestras de sangre para determinar el nivel de triglicérido por 100 mililitros de sangre de cada sujeto. Después los individuos fueron sometidos a un programa de ejercicios que se centraba diariamente en carreras y marchas. Al final del periodo de ejercicios, se tomaron nuevamente muestras de sangre y se obtuvo una segunda lectura del nivel de triglicérido. De este modo, se dispone de dos conjuntos de observaciones del nivel de triglicérido por 100 mililitros de sangre de los sujetos:

Sujeto	1	2	3	4	5	6	7	8	9	10	11
Previo	68	77	94	73	37	131	77	24	99	629	116
Posterior	95	90	86	58	47	121	136	65	131	630	104

Suponiendo normalidad en el nivel de triglicérido, ¿hay pruebas suficientes para afirmar que el ejercicio físico produce cambios en el nivel de triglicérido?

7. En un estudio sobre nutrición se analizó la ganancia de peso de 16 niños sometidos a una dieta especial durante un periodo de 3 meses. Se observó una ganancia media de peso 3.05 kg. Un

grupo de control formado por 16 niños de constitución física similar fue sometido a una dieta normal durante el mismo periodo de tiempo, observándose una ganancia media de peso de 2.05 kg. Se supone que la desviación estándar para la ganancia de peso es 2 kg.

- a) ¿Se puede concluir que la ganancia media de peso es significativamente mayor en los niños sometidos a la dieta especial? (significación 0.05)
- b) Calcula el  $p$ -valor del contraste.

8. Se trata de estudiar el efecto de un tratamiento dirigido a elevar el colesterol HDL. Para ello se ha medido el colesterol HDL de 10 pacientes. A continuación se les ha sometido al tratamiento y se ha vuelto a medir el colesterol HDL. Los datos se muestran a continuación. Determinar si

Caso N°	HDL pre-tratamiento	HDL post-tratamiento
1	81	85
2	37	38
3	35	37
4	64	72
5	46	51
6	37	45
7	45	38
8	43	58
9	21	25
10	51	61

hay suficiente evidencia estadística, a nivel 0.01, para afirmar que el tratamiento es efectivo.

9. Una compañía farmacéutica afirma que cierto medicamento elimina el dolor de cabeza en un cuarto de hora en el 90 % de los casos. Tomada una muestra de 200 pacientes a los que se les administró el medicamento, se observó la desaparición del dolor en 170 de ellos. Contrastar la hipótesis de la compañía para un nivel de significación del 5 %.
10. Registramos los niveles en plasma de determinado ácido graso en 30 pacientes de Retinitis Pigmentosa (RP) y en 32 voluntarios sanos (S), y los resultados fueron los siguientes:

RP	$n = 30$	Media =35.8	Desviación típica=20.5
S	$n = 32$	Media =45.8	Desviación típica=30.1

- a) Suponiendo que las poblaciones son normales y a la vista de los resultados obtenidos, ¿podemos concluir que la media es significativamente más baja en los pacientes de RP?
  - b) Estimar mediante un intervalo de confianza del 95 % el valor medio en personas sanas.
11. A un grupo de 10 enfermos se les suministra un antidepresivo. Mediante pruebas adecuadas se valora en 4 el valor inicial de ese tipo de enfermos. Después de la administración del medicamento, el estado del paciente tuvo las siguientes puntuaciones:

3 5 4.5 7 6 6.5 4 5.5 7 7

A la vista de los datos, ¿puede decirse que los enfermos han mejorado significativamente? (Existe mejoría si la puntuación es mayor de 4. Utilizar un nivel de significación de 0.01.)

## Capítulo 9: Contrastes para datos categóricos

1. La siguiente tabla muestra la clasificación de 1343 niños según el grado de cumplimiento de su calendario vacunal y el nivel socio-cultural de sus padres. Determina si existe una asociación significativa entre el grado de cumplimiento del calendario vacunal de los niños y el nivel socio-cultural de sus padres.

	Cumplimiento calendario vacunal		
Nivel socio-cultural	Bajo	Medio	Alto
Bajo	114	229	228
Medio bajo	7	134	277
Medio alto	7	63	150
Alto	2	38	94

2. Para evaluar el efecto de la exposición a asbesto sobre el riesgo de fallecer por cáncer de pulmón, un estudio comparó un grupo de 6.245 trabajadores expuestos a este agente con otro grupo de 7.895 trabajadores sin exposición a este factor. A lo largo de 22 años de seguimiento, en el primer grupo se presentaron 76 defunciones por cáncer en el aparato respiratorio, en tanto que en el grupo no expuesto el número de defunciones por esta causa fue 28. Construye la tabla de contingencia correspondiente y determina si existe una asociación significativa entre la exposición a asbesto y el riesgo de fallecer por cáncer de pulmón.

*El asbesto es un grupo de minerales naturales fibrosos. Se ha venido utilizando en el aislamiento de los edificios, como componente de diversos productos (tejas, tuberías de agua, mantas ignífugas y envases médicos), como aditivo de los plásticos y en la industria automovilística.*

<http://www.who.int/mediacentre/factsheets/fs343/es/index.html>

3. Un estudio transversal para conocer la prevalencia de osteoporosis y su relación con algunos factores de riesgo potenciales (ver web de Investigación e Innovación Sanitaria de la Consellería de Sanidade de la Xunta de Galicia) incluyó a 400 mujeres con edades entre 50 y 54 años. A cada una se le realizó una densitometría de columna y en cada caso se completó un cuestionario de antecedentes. Se pretende determinar si existe una asociación significativa entre la prevalencia de osteoporosis y antecedentes de dieta pobre en calcio. De las 80 pacientes que presentaban osteoporosis 58 presentaban antecedentes de dieta pobre en calcio, en tanto que entre las 320 que no tenían osteoporosis, el número de mujeres con este antecedente era de 62.
  - a) Construye la tabla de contingencia correspondiente y determina, para un nivel de significación del 1 %, si existe una asociación significativa entre la prevalencia de osteoporosis y antecedentes de dieta pobre en calcio.
  - b) Calcula el estadístico Chi-cuadrado corregido (corrección de Yates) y determina en base a ese estadístico si, para un nivel de significación del 5 %, existe una asociación significativa entre la prevalencia de osteoporosis y antecedentes de dieta pobre en calcio.

4. Supongamos que se quiere estudiar la posible asociación entre el hecho de que una gestante fume durante el embarazo y que el niño presente bajo peso al nacer. Para responder a esta pregunta se realiza un estudio de seguimiento sobre una cohorte de 2000 gestantes, a las que se interroga sobre su hábito tabáquico durante la gestación y se determina además el peso del recién nacido. Los resultados de este estudio se muestran en la siguiente tabla:

Gestante	Recién nacido de bajo peso	
	Sí	No
Fumadora	43	204
No fumadora	105	1645

- a) ¿Se puede concluir que existe una relación estadísticamente significativa entre el hecho de que una gestante fume durante el embarazo y que el niño presente bajo peso al nacer?
- b) Calcula el estadístico Chi-cuadrado corregido (corrección de Yates) y determina si existe una relación estadísticamente significativa entre el hecho de que una gestante fume durante el embarazo y que el niño presente bajo peso al nacer.

Ejemplo tomado de <http://www.fisterra.com/mbe/investiga/chi/chi.asp#ji>

5. En un estudio sobre VIH se pretende determinar si existe asociación significativa entre la edad del paciente y el nivel de linfocitos CD4. Para ello se determina el nivel de linfocitos CD4 (<200, 200-500, >500) en pacientes de 3 grupos de edad. ¿Se puede concluir que existe una relación estadísticamente significativa entre el nivel de linfocitos y la edad del paciente?

Nivel de linfocitos	Edad		
	≤ 30 años	31 – 40 años	≥ 41 años
<200	6	30	6
200-500	20	72	21
>500	19	49	12

6. Se quiere estudiar la posible asociación entre la presencia de infección postoperatoria (IPO) y la diabetes (DIAB) en una población de operados. En una muestra de 1337 personas de edad < 65 años y en otra de 892 de edad ≥ 65 años se obtuvieron los siguientes resultados. ¿Existe asociación significativa entre IPO y diabetes en cada grupo de edad?

DIAB	< 65 años	
	IPO	NO IPO
Sí	15	29
No	190	1103

DIAB	≥ 65 años	
	IPO	NO IPO
Sí	28	65
No	215	584

7. Se realizó un estudio de seguimiento para detectar la posible asociación entre enfermedades cardiovasculares y el exceso de peso. Se eligieron 1990 hombres con edades entre 55 y 59 años de estatura similar. Tras 5 años de seguimiento se observaron los datos resumidos en la tabla. ¿Se puede admitir que el exceso de peso se asocia con el infarto de miocardio?

Infarto	Peso				
	55 – 64 kg.	65 – 74 kg.	75 – 84 kg.	85 – 94 kg.	> 95 kg.
Sí	8	18	48	93	23
No	290	680	550	205	75

## Capítulo 10: Regresión y correlación

- Se lleva a cabo un estudio, por medio de detectores radioactivos, sobre la capacidad corporal para absorber hierro y plomo. En el estudio participaron 6 personas y después de 10 días se obtuvieron los siguientes resultados.

Hierro	1.7	2.2	3.5	4.3	8.0	6.0
Plomo	2.1	3.0	1.8	2.5	4.2	4.0

- Representa el diagrama de dispersión de los datos. ¿Te parece adecuado considerar un modelo de regresión lineal para explicar el valor del plomo en función del hierro?
  - Calcula y representa la recta de regresión del valor del plomo sobre el valor del hierro.
  - ¿Cuál es el coeficiente de correlación lineal?
  - ¿Qué valor de plomo cabe esperar para una persona con un nivel de hierro igual a 2.2?
  - Calcula el porcentaje de explicación de la recta.
- Para tener valores comparables del gasto cardíaco entre distintos sujetos se utiliza un determinado índice cardíaco. Se ha medido dicho índice cardíaco ( $Y$ ) en 7 pacientes de diferentes edades.

$X = \text{Edad}$	15	20	30	40	50	60	70
$Y = \text{Índice cardíaco}$	6.5	5.6	5.4	6	4.6	1.4	0.1

- Calcula la recta de regresión de  $Y$  sobre  $X$ .
  - ¿Cuál es el coeficiente de correlación lineal? ¿Y el de determinación?
- Se ha llevado a cabo un estudio sobre un total de 6 pacientes. Se ha determinado en cada uno de ellos la concentración de una determinada sustancia A en sangre ( $X$ ) y la concentración de una determinada sustancia B en sangre ( $Y$ ). Ambas variables se miden en mg/100ml:

$X$	$Y$
8	0.12
50	0.71
81	1.09
102	1.38
140	1.95
181	2.50

- Obtén la ecuación de la recta de regresión que explique  $Y$  en función de  $X$  por el método de mínimos cuadrados.
- Estudia el grado de asociación lineal de la muestra anterior.

c) Supongamos que sabemos que un nuevo paciente tiene una concentración en sangre de la sustancia A igual a 95, pero hemos extraviado su correspondiente medida de la concentración de la sustancia B. Haz una predicción de dicha concentración.

4. De una variable estadística bidimensional  $(X, Y)$  sabemos que:

- La recta de regresión de  $Y$  sobre  $X$  es  $Y = 2 + 0.5X$ .
- La recta de regresión de  $X$  sobre  $Y$  es  $X = -4 + 2Y$ .
- $s_X = 3$ .

Halla la covarianza entre  $X$  e  $Y$  y la varianza de  $Y$ .

5. Registramos la evolución del nivel de creatinina en pacientes tratados con Captopril después de ser sometidos a diálisis.

Días transcurridos	1	5	10	15	20	25	35
Creatinina (mg/dl)	5.7	5.2	4.8	4.5	4.2	4	3.8

- a) ¿Cuál es la covarianza entre ambas variables?
- b) Calcula y representa la recta de regresión que exprese el nivel de creatinina en función de los días de tratamiento.
- c) Calcula la variabilidad no explicada (suma de cuadrados no explicada) y la variabilidad explicada (suma de cuadrados explicada por la recta de regresión).
- d) ¿Cuál es la variabilidad total?
- e) Calcula e interpreta el coeficiente de determinación de la recta de regresión.

6. Se han estudiado el cociente intelectual de 100 niños ( $X$ ) y sus calificaciones en Matemáticas ( $Y$ ) obteniéndose los siguientes resultados:

$$\bar{x} = 110 \quad \bar{y} = 2.5 \quad s_x = 10 \quad s_y = 0.5$$

Además se sabe que el coeficiente de correlación entre ambas variables es de 0.85.

- a) ¿Qué nota se puede predecir para un niño con un cociente intelectual de 125?
- b) ¿Cuál es la ecuación de la recta de regresión de  $X$  sobre  $Y$ ?