

eman ta zabal zazu



Universidad del País Vasco
Euskal Herriko Unibertsitatea
The University of the Basque Country

E.U.I.T.I. Bilbao

Asignatura:
MÉTODOS ESTADÍSTICOS
DE LA INGENIERÍA

E.U.I.T.I. Bilbao

Asignatura:
MÉTODOS ESTADÍSTICOS
DE LA INGENIERÍA

PARTE 2:
ESTADÍSTICA INFERENCIAL

0. RECORDATORIO


Estadística inferencial. Rama de la Estadística que estudia procedimientos para hacer inferencias, éstos es, para deducir propiedades de una población a partir de la información obtenida de una muestra

Objetivos básicos. A partir de la información proporcionada por una muestra:

- ▶ **estimación:** estimar (evaluar) un parámetro desconocido de la población
- ▶ **contraste de hipótesis:** realización de una prueba estadística cuyo objeto es estudiar si una determinada afirmación sobre una población se confirma o se rechaza

El matrimonio es la principal causa de divorcio

Groucho Marx
Julius Henry Marx




E.U.I.T.I. Bilbao

Asignatura:
MÉTODOS ESTADÍSTICOS
DE LA INGENIERÍA


TEMA 5:
DISTRIBUCIONES MUESTRALES

EL PROBLEMA QUE TIENE EL MUNDO REAL ES QUE LOS CONJUNTOS DE COSAS SON TAN GRANDES QUE RESULTA MUY DIFÍCIL CONSEGUIR LA INFORMACIÓN QUE QUEREMOS:

UNA POBLACIÓN EN ELECCIONES: ¿QUÉ PORCENTAJE ESTÁ A FAVOR DE CADA CANDIDATO?



PRODUCTOS MANUFACTURADOS: ¿QUÉ PROPORCIÓN RESULTARÁ DEFECTUOSA?



PEPINILLOS: ¿CUÁL ES SU TAMAÑO MEDIO?



¡LOS ENVASADORES DE PEPINILLOS NECESITAN SABERLO!

EL PROCEDIMIENTO COMPLETO, LABORIOSO, CONCIENZUDO, COMO LO HARÍA UN CASTOR, DE CONTESTAR A TODAS ESTAS PREGUNTAS SERÍA MEDIR TODOS Y CADA UNO DE LOS PEPINILLOS DEL MUNDO (POR EJEMPLO) Y HACER LOS CÁLCULOS.



La estadística en comic
L. Gocking, W. Smith
(2002)

NUESTRO MÉTODO ES TOMAR UNA MUESTRA... UN SUBCONJUNTO RELATIVAMENTE PEQUEÑO DE LA POBLACIÓN TOTAL, IGUAL QUE CUANDO SE HACE UN SONDEO DE OPINIÓN DURANTE UNAS ELECCIONES.

¿QUÉ PIENSA DE LOS SONDEOS DE OPINIÓN?



Pocas observaciones y mucho razonamiento conducen al error; muchas observaciones y poco razonamiento, a la verdad.



http://es.wikipedia.org/wiki/Alexis_Carrel

Alexis Carrel
Premio Nobel en Medicina (1912)

1. RESUMEN

Se llama la atención acerca de que los estadísticos muestrales son, en realidad, variables aleatorias. Así, se analiza la distribución de probabilidad de la media muestral y de la varianza muestral en diversas situaciones.

Palabras clave:

- ▶ distribuciones en el muestreo
- ▶ t de Student
- ▶ F de Snedecor
- ▶ *chi-cuadrado*

2. ÍNDICE DEL TEMA

5.1. Introducción

5.2. Muestreo

5.3. Muestreo aleatorio: tipos

5.3.1. simple

5.3.2. estratificado

5.3.3. por conglomerado

5.3.3. sistemático

5.4. Distribuciones en el muestreo

5.5. Media muestral

5.6. Teorema central del límite

2. ÍNDICE DEL TEMA

5.7. Distribuciones asociadas a la normal

5.7.1. *chi*-cuadrado

5.7.2. *t* de Student

5.7.3. *F* de Snedecor

3. INTRODUCCIÓN

▶ **población**: conjunto de todos los elementos objeto de un estudio

▶ **muestra**: subconjunto de una población


letras griegas

▶ **parámetro**: es una magnitud numérica obtenida de una población (es una cantidad fija, generalmente desconocida)


letras latinas

▶ **estadístico**: es una magnitud numérica cuyo valor viene **determinado** por la muestra (media muestral y varianza muestral, por ejemplo); se utilizan para estimar los parámetros de una población

3. INTRODUCCIÓN



3. INTRODUCCIÓN



3. INTRODUCCIÓN

- ▶ la mayor parte de las veces, la distribución de la población no es conocida completamente
- ▶ se usará una muestra para realizar inferencias sobre ella
- ▶ Ejemplo. Se fabrica un nuevo tipo de baterías para coches eléctricos
 - durarán un número aleatorio de kilómetros siguiendo una distribución de probabilidad desconocida
 - para averiguar cuál es esa distribución de probabilidad se puede fabricar un cierto número de baterías y probarlas en carretera
 - los datos resultantes (número de kms. recorridos con cada batería) constituyen una muestra extraída de la distribución

4. MUESTREO

Muestreo : conjunto de técnicas empleadas para la selección de una muestra a partir de una población

- ▶ al seleccionar una muestra, se espera que sus propiedades se puedan extrapolar a la población
- ▶ este proceso permite ahorrar recursos, obteniéndose resultados parecidos a los que se tendrían en el caso de realizar un estudio de toda la población
- ▶ **tipos**
 - muestreo no aleatorio o de juicio: se emplea el conocimiento y la opinión personal para identificar aquellos elementos de la población que deben incluirse en la muestra
 - muestreo aleatorio o de probabilidad: todos los elementos de la población tienen la oportunidad de ser escogidos

5. MUESTREO ALEATORIO: TIPOS

Muestra aleatoria simple: recopilación de datos de una v.a. X de una determinada población mediante la repetición del experimento al que está asociada.

Dos condiciones básicas:

- todos los elementos de la población deben tener la misma probabilidad de estar en la muestra
- las distintas observaciones de la muestra deben ser independientes entre sí

▶ ventajas

- sencillo y de fácil comprensión, cálculo rápido de media y varianza, existen paquetes informáticos para su análisis

▶ desventajas

- debe conocerse de antemano el listado de toda la población, muestras pequeñas pueden no ser representativas

5. MUESTREO ALEATORIO: TIPOS

Muestreo estratificado: la población se divide en grupos homogéneos (estratos) y después se toma una muestra aleatoria simple de cada estrato cuyo tamaño depende de un número o cuota asignado.

Criterios para la elección de la cuota:

- proporcional al tamaño relativo del estrato en la población
- proporcional a la variabilidad del estrato , de forma que los más variables están más representados

▶ ventajas

- tiende a asegurar que la muestra represente a la población de forma adecuada, estimaciones más precisas

▶ desventajas

- debe conocerse la distribución en la población de las variables usadas para la estratificación

5. MUESTREO ALEATORIO: TIPOS

Muestreo por conglomerado: la población se divide en conglomerados (clusters) de elementos y, luego, se selecciona una muestra aleatoria de estos clusters.

- la variabilidad dentro de cada grupo es grande y entre los grupos es pequeña
- es como si cada grupo fuese una pequeña representación de la población en sí misma

▶ ventajas

- eficiente cuando la población es grande y dispersa, reduce costes, no es necesario el listado completo de la población

▶ desventajas

- el error estándar es mayor que en el muestreo estratificado ó en el aleatorio y, además, su cálculo es complejo

5. MUESTREO ALEATORIO: TIPOS

Conglomerado vs. estratificación

► muestreo por conglomerado

- en la muestra sólo está representado un subconjunto de todos los conglomerados
- variabilidad grande en cada grupo y pequeña entre los grupos
- funciona si hay pocas diferencias entre los *clusters* y son muy heterogéneos

► muestreo estratificado

- en la muestra están representados todos los estratos
- variabilidad pequeña en cada estrato y grande entre ellos
- funciona tanto mejor cuanto mayor sean las diferencias entre los estratos y más homogéneos sean internamente

5. MUESTREO ALEATORIO: TIPOS

Muestreo sistemático: los elementos de la muestra se seleccionan de la población de una forma uniforme medida respecto al tiempo, al orden, al espacio, ...

► procedimiento:

- listado de los N elementos de la población
- determinar el tamaño, n , de la muestra
- definir un intervalo de salto, k tal que: $k \approx \frac{N}{n}$ donde $k \in Z$
- arranque aleatorio, r : $1 \leq r \leq k$
- hasta completar la muestra, se toman los elementos:

$$r+k, r+2k, r+3k, \dots$$

5. MUESTREO ALEATORIO: TIPOS

Muestreo sistemático: los elementos de la muestra se seleccionan de la población de una forma uniforme medida respecto al tiempo, al orden, al espacio, ...

▶ ventajas

- fácil de aplicar, no siempre es necesario tener un listado de toda la población, cuando la población está ordenada según una tendencia conocida se asegura una cobertura de elementos de todos los tipos

▶ desventajas

- sensible a las posibles periodicidades en el listado de los elementos de la población con lo que puede obtenerse una muestra que no sea representativa de la población

5. DISTRIBUCIONES MUESTRALES

- ▶ para obtener información sobre un parámetro de la población:
 - se selecciona una muestra representativa de la población
 - se obtiene el estadístico adecuado de la muestra
 - con ese estadístico se estima el parámetro de la población
- ▶ los valores que toma el estadístico en cada una de las muestras de tamaño n (x_1, x_2, \dots, x_n) son, a su vez, v.a. independientes que siguen la misma distribución de probabilidad (**distribución poblacional**)
- ▶ la muestra se usará para inferir sobre esa distribución y, al menos, aproximar su forma

5. DISTRIBUCIONES MUESTRALES


- ▶ para valorar el grado de validez de las inferencias es necesario conocer la distribución de probabilidad del estadístico considerado
- ▶ esa distribución de probabilidad se denomina **distribución muestral**
- ▶ la distribución muestral depende de:
 - la distribución de la población
 - el estadístico utilizado
 - el tamaño muestral

5. DISTRIBUCIONES MUESTRALES

► se observa una v.a. X

- muestra aleatoria simple 1:


$$\{x_1^1, x_2^1, \dots, x_n^1\}$$



$$\begin{cases} \text{media} : \bar{x}_1 \\ \text{desviación típica} : s_1 \end{cases}$$

- muestra aleatoria simple 2:


$$\{x_1^2, x_2^2, \dots, x_n^2\}$$



$$\begin{cases} \text{media} : \bar{x}_2 \\ \text{desviación típica} : s_2 \end{cases}$$

- muestra aleatoria simple n :

$$\{x_1^n, x_2^n, \dots, x_n^n\}$$



$$\begin{cases} \text{media} : \bar{x}_n \\ \text{desviación típica} : s_n \end{cases}$$

5. DISTRIBUCIONES MUESTRALES

- ▶ los valores resultantes en cada muestra son resultado del azar; entonces, generalmente, no coinciden
- ▶ para cada muestra se obtienen diferentes medias y desviaciones típicas
- ▶ por tanto, la media muestral y la varianza muestral (en general, cualquier estadístico de una muestra aleatoria simple) son, en realidad variables aleatorias y, como tales, tienen su distribución, su media, su varianza, ...

$$\{ \bar{x}_1, \bar{x}_2, \dots, \bar{x}_n \} \quad \{ s_1, s_2, \dots, s_n \}$$

muestras de dichas variables

5. DISTRIBUCIONES MUESTRALES

▶ Recordatorio

Estadístico muestral: valor referido a una muestra de una variable aleatoria (media, varianza, ...)

Parámetro poblacional: valor referido a la distribución poblacional de una variable aleatoria (media, varianza, ...)

▶ Asociados a estos dos conceptos se tiene:

Distribución muestral de un estadístico muestral es su distribución de probabilidad

Error estándar de un estadístico muestral es la desviación típica de su distribución muestral

5. DISTRIBUCIONES MUESTRALES

▶ Problema

- bastante difícil conocer la distribución en el muestreo de los estadísticos muestrales

▶ Solución

- si la variable que se observa sigue una distribución normal se conocen de forma exacta las distribuciones en el muestreo de los dos parámetros más importantes: la media y la varianza (es el caso más sencillo y, a su vez, el más importante)
- si la variable observada no sigue una distribución normal: el teorema central del límite indica que si una variable es suma de otras variables su distribución es aproximadamente normal con lo que, todavía, se puede confiar en que lo que hagamos para variables normales pueda ser válido

6. MEDIA MUESTRAL

► sea una muestra de tamaño n (x_1, x_2, \dots, x_n) de una población de tamaño N

- media poblacional: μ

- varianza poblacional: σ^2

- media muestral:
$$\bar{X} = \frac{x_1 + x_2 + \dots + x_n}{n}$$

► \bar{X} : también es una v.a.; se demuestra que:


- esperanza: $E[\bar{X}] = \mu$

- varianza: $Var[\bar{X}] = \frac{\sigma^2}{n}$

- desviación típica: $SD[\bar{X}] = \sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}}$

La dispersión disminuye a medida que aumenta el tamaño muestral, n

Ross, M.S.; Introducción a la Estadística;
Ed. Reverté S.A. (2005)



6. MEDIA MUESTRAL

- **Ejemplo de comprobación.** Sea una población formada por los números:

$$\{x_1 = 2, x_2 = 4, x_3 = 6, x_4 = 8\} \rightarrow N=4$$

$$\mu = \frac{1}{N} \sum_{i=1}^{i=4} x_i = \frac{2+4+6+8}{4} = 5$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^{i=4} x_i^2 - \bar{x}^2} = \sqrt{5} = 2.236$$

- se consideran todas las muestras posibles de tamaño $n=2$

	ELEMENTO 1	ELEMENTO 2	MEDIA		ELEMENTO 1	ELEMENTO 2	MEDIA
MUESTRA 1	2	2	2	MUESTRA 9	6	2	4
MUESTRA 2	2	4	3	MUESTRA 10	6	4	5
MUESTRA 3	2	6	4	MUESTRA 11	6	6	6
MUESTRA 4	2	8	5	MUESTRA 12	6	8	7
MUESTRA 5	4	2	3	MUESTRA 13	8	2	5
MUESTRA 6	4	4	4	MUESTRA 14	8	4	6
MUESTRA 7	4	6	5	MUESTRA 15	8	6	7
MUESTRA 8	4	8	6	MUESTRA 16	8	8	8

6. MEDIA MUESTRAL


► Ejemplo de comprobación.

- la media de las medias muestrales es:

$$\bar{X} = \frac{1}{16} \sum_{i=1}^{i=16} \bar{x}_i = \frac{2+3+4+5+\dots+6+8}{16} = 5 \quad \rightarrow \quad \bar{X} = \mu$$

- la desviación típica de las medias muestrales es:

$$\sigma_{\bar{X}} = \sqrt{\frac{1}{N} \sum_{i=1}^{i=16} \bar{x}_i^2 - \bar{X}^2} = \sqrt{2.5} = 1.581$$



$$\sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}} = \frac{2.236}{\sqrt{2}} = 1.581$$

6. MEDIA MUESTRAL

► Ejemplo de comprobación.

- función de masa de probabilidad de la distribución muestral de la media muestral:


\bar{X}_i	2	3	4
$p(\bar{x}_i) = P(\bar{X} = \bar{x}_i)$	$\frac{1}{16} = 0.0625$	$\frac{2}{16} = 0.125$	$\frac{3}{16} = 0.1875$

\bar{X}_i	5	6	7	8
$p(\bar{x}_i) = P(\bar{X} = \bar{x}_i)$	$\frac{4}{16} = 0.25$	$\frac{3}{16} = 0.1875$	$\frac{2}{16} = 0.125$	$\frac{1}{16} = 0.0625$

6. MEDIA MUESTRAL

► Ejemplo de comprobación.

- representación gráfica de la función de masa de probabilidad de la distribución muestral de la media muestral:



6. MEDIA MUESTRAL

▶ en la afirmación: $SD[\bar{X}] = \sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}}$ se asume que:

- la población es infinita (**suficientemente grande**), ó
- el muestreo se realiza con reemplazamiento

▶ en caso contrario, se debe utilizar un *factor de corrección para poblaciones finitas*:

$$SD[\bar{X}] = \sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}} \cdot \sqrt{\frac{N-n}{N-1}}$$

- N : tamaño de la población
- n : tamaño de la muestra

7. TEOREMA CENTRAL DEL LÍMITE

- ▶ sea X_1, X_2, \dots, X_n una muestra aleatoria procedente de una población de media μ y desviación típica σ
- ▶ si n tiende a infinito (para **valores suficientemente grandes** de n) la suma:

$$Y = \sum_{i=1}^{i=n} X_i$$

sigue aproximadamente una distribución normal

$$Y \approx N(n \cdot \mu; \sqrt{n} \cdot \sigma)$$

7. TEOREMA CENTRAL DEL LÍMITE

► **Ejemplo.** Una compañía aseguradora de automóviles tiene 10000 asegurados. Si el gasto anual que un asegurado ocasiona a la compañía tiene por media 260 euros con una desviación típica de 800 euros, aproximar la probabilidad de que el gasto total que la compañía debe afrontar en un año sobrepase los 2,8 millones de euros

Solución

- X_i : gasto ocasionado por el asegurado i ($i=1,2, \dots, 10000$)
- por el teorema central del límite

$$\left. \begin{array}{l} n \cdot \mu = 2.6 \times 10^6 \\ \sigma \cdot \sqrt{n} = 8 \times 10^4 \end{array} \right\} \Rightarrow \sum_{i=1}^{i=n} X_i = Y \approx N(2.6 \times 10^6 ; 8 \times 10^4)$$

7. TEOREMA CENTRAL DEL LÍMITE

- **Ejemplo.** Una compañía aseguradora de automóviles tiene 10000 asegurados. Si el gasto anual que un asegurado ocasiona a la compañía tiene por media 260 euros con una desviación típica de 800 euros, aproximar la probabilidad de que el gasto total que la compañía debe afrontar en un año sobrepase los 2,8 millones de euros

Solución

- entonces:

$$P(Y > 2.8 \times 10^6) = P\left(Z > \frac{2.8 \times 10^6 - 2.6 \times 10^6}{8 \times 10^4}\right) \approx P\left(Z > \frac{0.2 \times 10^6}{8 \times 10^4}\right) =$$

tipificación

$$= P(Z > 2.5) = 1 - P(Z \leq 2.5) = 1 - 0.9938 = 0.0062$$

tablas

Excel: =1-DISTR.NORM(2800000;2600000;80000;1)

7. TEOREMA CENTRAL DEL LÍMITE

► generalización

- se puede demostrar que, aunque las v.a. X_1, X_2, \dots, X_n sigan distribuciones distintas, la variable Y sigue aproximadamente una distribución normal siendo, como antes:

$$Y = \sum_{i=1}^{i=n} X_i$$

- es más, si todas las variables aleatorias tienden a ser, más ó menos, de la misma magnitud, de forma que ninguna de ellas domine el valor de la suma, se puede demostrar que la suma de un gran número de variables aleatorias independientes sigue, aproximadamente, una distribución normal

7. TEOREMA CENTRAL DEL LÍMITE

Distribución de la media muestral

- ▶ sea X_1, X_2, \dots, X_n una muestra aleatoria procedente de una población de media μ y desviación típica σ

- ▶ sea la media muestral:

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

- ▶ el producto de una normal, Y , por una constante, $\frac{1}{n}$, sigue siendo normal: $X \approx N(\mu; \sigma) \Rightarrow k \cdot X \approx N(k \cdot \mu; k \cdot \sigma)$

- ▶ entonces, si el tamaño muestral es grande, por el teorema central del límite se tiene:

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

7. TEOREMA CENTRAL DEL LÍMITE

Distribución de la media muestral

► tipificación

$$\bar{X} \approx N\left(\mu; \frac{\sigma}{\sqrt{n}}\right) \longrightarrow \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} = Z \approx N(0; 1)$$

► además:

$$P(\bar{X} \leq a) = P\left(\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq \frac{a - \mu}{\sigma/\sqrt{n}}\right) \approx P\left(Z \leq \frac{a - \mu}{\sigma/\sqrt{n}}\right)$$

7. TEOREMA CENTRAL DEL LÍMITE

Distribución de la media muestral

- **Ejemplo.** El nivel de colesterol en la sangre de una población de trabajadores tiene media 202 mg/dl y desviación típica 14.
- si se selecciona una muestra de 36 trabajadores, aproximar la probabilidad de que la media muestral de sus niveles de colesterol esté comprendida entre 198 y 206 mg/dl
 - repetir el apartado anterior para un tamaño muestral de 64

Solución

- a. del teorema central del límite se deduce, como $n=36$:

$$\bar{X} \approx N\left(202; \frac{7}{3}\right) \quad \longrightarrow \quad \frac{\bar{X} - 202}{\frac{7}{3}} = Z \approx N(0; 1)$$

7. TEOREMA CENTRAL DEL LÍMITE

Distribución de la media muestral

► Ejemplo.

Solución

a.
$$P(198 \leq \bar{X} \leq 206) = P\left(\frac{198 - 202}{\frac{7}{3}} \leq \frac{\bar{X} - 202}{\frac{7}{3}} \leq \frac{206 - 202}{\frac{7}{3}}\right) \approx$$

$$\approx P(-1.714 \leq Z \leq 1.714) = \Phi(1.714) - \Phi(-1.714) =$$

$$= \Phi(1.714) - [1 - \Phi(1.714)] = 2 \cdot \Phi(1.714) - 1 = 0.9128$$

tipificación

tablas

b. procediendo de forma análoga para $n=64$:

$$P(198 \leq \bar{X} \leq 206) \approx 0.9780$$

Nota. Al aumentar el tamaño muestral también aumenta la probabilidad de que la media muestral difiera de la poblacional en menos de 4 unidades

7. TEOREMA CENTRAL DEL LÍMITE

Distribución de la media muestral

► Ejemplo.

Solución. Sin tipificar, usando *Excel*

a.
$$P(198 \leq \bar{X} \leq 206) \approx 0,91352373 =$$

$$= \text{DISTR.NORM}(206; 202; 7/3; 1) - \text{DISTR.NORM}(198; 202; 7/3; 1)$$

b.
$$P(198 \leq \bar{X} \leq 206) \approx 0,97772902 =$$


$$= \text{DISTR.NORM}(206; 202; 7/4; 1) - \text{DISTR.NORM}(198; 202; 7/4; 1)$$

7. TEOREMA CENTRAL DEL LÍMITE


Tamaño de la muestra

- ▶ el teorema central del límite deja abierta la cuestión de cuán grande debe ser el tamaño, n , de la muestra para que la aproximación normal sea válida
- ▶ respuesta: depende de la distribución de la población que subyace a los datos muestrales
 - si la distribución subyacente es normal, la media muestral es siempre normal independientemente del tamaño de la muestra
 - regla empírica: puede usarse la aproximación normal siempre que el tamaño muestral sea, como mínimo, 30 ($n \geq 30$)
 - en la mayoría de los casos la aproximación normal es válida para tamaños muestrales mucho más reducidos


8. RESUMEN



8. RESUMEN



8. RESUMEN



8. RESUMEN

- **Ejemplo.** En un municipio, el consumo medio por vivienda de energía eléctrica es de 25Kwh con una desviación típica de 6kwh. Se toma una muestra de 50 viviendas:
- obtener la distribución muestral de las medias de consumo de la muestra en Kwh
 - calcular la probabilidad de que el consumo medio del grupo de viviendas sea superior a 26Kwh

Solución

- a. del teorema central del límite se deduce, como $n=50$:

$$\left. \begin{array}{l} \bullet \mu=25 \\ \bullet \sigma=6 \\ \bullet n=50 \end{array} \right\} \Rightarrow \bar{X} \approx N \left(25; \frac{6}{\sqrt{50}} \right) = N (25; 0.849)$$

8. RESUMEN

- **Ejemplo.** En un municipio, el consumo medio, por vivienda, de energía eléctrica es de 25Kwh con una desviación típica de 6kwh. Se toma una muestra de 50 viviendas:
- obtener la distribución muestral de las medias de consumo de la muestra en Kwh
 - calcular la probabilidad de que el consumo medio del grupo de viviendas sea superior a 26Kwh

Solución

- b.** del teorema central del límite se deduce, como $n=50$:

$$\begin{aligned} P(\bar{X} > 26) &= P\left(\frac{\bar{X} - 25}{0.849} > \frac{26 - 25}{0.849}\right) \approx P(Z > 1.178) = \\ &= 1 - P(Z \leq 1.178) = 1 - 0.881 = 0.119 \end{aligned}$$

Excel: =1-DISTR.NORM(26;25;6/RAIZ(50);1)~ 0,11929641

8. RESUMEN

► **Ejemplo.** El peso del azúcar envasado en paquetes es una variable aleatoria normal de media 400gr. y desviación típica 30gr. Se toma una muestra aleatoria simple de 25 paquetes. Calcular la probabilidad de que el promedio quede fuera del intervalo (390,410).

Solución

- del teorema central del límite se deduce, como $n=25$:

$$\bar{X} \approx N\left(\mu; \frac{\sigma}{\sqrt{n}}\right) = N\left(400; \frac{30}{\sqrt{25}}\right) = N(400; 6)$$

- ◇ media poblacional: $\mu=400$
- ◇ desviación típica de la población: $\sigma=30$
- ◇ tamaño de la muestra: $n=25$

8. RESUMEN

► **Ejemplo.** El peso del azúcar envasado en paquetes es una variable aleatoria normal de media 400gr. y desviación típica 30gr. Se toma una muestra aleatoria simple de 25 paquetes. Calcular la probabilidad de que el promedio quede fuera del intervalo (390,410).


Solución

- se pide calcular: $P(\bar{X} \notin (390, 410))$

$$P(\bar{X} \notin (390, 410)) = 1 - P(\bar{X} \in (390, 410)) =$$

$$= 1 - P(390 < \bar{X} < 410) = 1 - P\left(\frac{390 - 400}{6} < Z < \frac{410 - 400}{6}\right) =$$

$$= 1 - P(-1.666666667 < Z < 1.666666667) = 0.0955807$$




8. RESUMEN

► **Ejemplo.** El peso del azúcar envasado en paquetes es una variable aleatoria normal de media 400gr. y desviación típica 30gr. Se toma una muestra aleatoria simple de 25 paquetes. Calcular la probabilidad de que el promedio quede fuera del intervalo (390,410).

Solución

- se pide calcular: $P(\bar{X} \notin (390, 410))$



$$P(\bar{X} \notin (390, 410)) = 1 - P(\bar{X} \in (390, 410)) \approx 0,0955807$$


Excel: =1-(DISTR.NORM(410;400;6;1)-DISTR.NORM(390;400;6;1))

8. RESUMEN

- **Ejemplo.** El peso del azúcar envasado en paquetes es una variable aleatoria normal de media 400gr. y desviación típica 30gr. Se toma una muestra aleatoria simple de 25 paquetes. Calcular la probabilidad de que el promedio quede fuera del intervalo (390,410).

Solución

- se pide calcular: $P(\bar{X} \notin (390, 410))$



$$P(\bar{X} \notin (390, 410)) = 2 \cdot P(\bar{X} < 390) \approx 0,0955807$$

Excel: =2*DISTR.NORM(390;400;6;1)

9. DISTRIBUCIONES ASOCIADAS A LA NORMAL

- ▶ cuando se va a hacer inferencia estadística se ha visto que la distribución normal aparece de forma casi inevitable.
- ▶ dependiendo del problema, se pueden encontrar otras (asociadas):
 - χ^2 -cuadrado
 - t de Student
 - F de Fisher-Snedecor
- ▶ resultan directamente de operar con distribuciones normales
- ▶ típicamente aparecen como distribuciones de ciertos estadísticos

Sus funciones de densidad son muy poco tratables por lo que los cálculos se realizan con ordenador (también, muchos valores de sus funciones de distribución están tabulados)

10. DISTRIBUCIÓN *J*I-CUADRADO

Si Z_1, Z_2, \dots, Z_k son variables aleatorias normales estándar e independientes entonces se dice que la variable

$$X = \sum_{i=1}^{i=k} Z_i^2 = Z_1^2 + Z_2^2 + \dots + Z_k^2$$

es una variable aleatoria ***ji*-cuadrado** (ó *chi*-cuadrado) con k grados de libertad

► notación: $\chi_k^2 \approx \sum_{i=1}^{i=k} Z_i^2 = Z_1^2 + Z_2^2 + \dots + Z_k^2$ ó $X \approx \chi_k^2$

► parámetro: k (número de grados de libertad)

► es una de las distribuciones más utilizadas en estadística inferencial (describe la distribución muestral de la varianza muestral)

10. DISTRIBUCIÓN *JI*-CUADRADO

► ¿qué son los grados de libertad?

- se pueden definir como el número de valores que se pueden elegir libremente
- ejemplo: sea una muestra de tamaño $n=2$, los valores de la muestra son x e y , y se sabe que tienen una media de 10

$$\frac{x+y}{2} = 10 \Rightarrow x+y = 20 \Rightarrow \begin{cases} x = 0 \Rightarrow y = 20 \\ x = 1 \Rightarrow y = 19 \\ \dots \dots \dots \\ x = 20 \Rightarrow y = 0 \end{cases}$$

si $x = 5 \Rightarrow y = 15$

y no es libre de tomar cualquier valor

The diagram illustrates the constraint on the values of x and y. It starts with the equation (x+y)/2 = 10, which simplifies to x+y = 20. This equation is shown in a box. An arrow points from this box to a list of possible values for x and y: x=0 implies y=20, x=1 implies y=19, and so on, up to x=20 implies y=0. Another arrow points from the box to a specific example: 'si x=5 implies y=15'. A green box with a diagonal line through it contains the text 'y no es libre de tomar cualquier valor', indicating that y is not free to take any value because it is determined by x.

- este ejemplo se puede generalizar para cualquier n en donde dada la media de los valores sólo quedan $(n-1)$ elementos que pueden definirse libremente y uno es función de la media y el resto de los elementos

10. DISTRIBUCIÓN *JI*-CUADRADO


► función de densidad

$$f(x) = \frac{x^{\frac{k}{2}-1} \cdot e^{-\frac{x}{2}}}{2^{\frac{k}{2}} \cdot \Gamma\left(\frac{k}{2}\right)} \quad (x \geq 0)$$

- función gamma: $\Gamma(x) = \int_0^{\infty} t^{x-1} \cdot e^{-t} dt$
- función asimétrica positiva, sólo tienen densidad los valores positivos (suma de cuadrados)
- se hace más simétrica, incluso casi gaussiana, al aumentar el número de grados de libertad.
- normalmente se consideran anómalos aquellos valores de la variable de la **cola de la derecha**


10. DISTRIBUCIÓN *JI*-CUADRADO

► función de densidad




10. DISTRIBUCIÓN *JI*-CUADRADO

► función de densidad



10. DISTRIBUCIÓN *JI*-CUADRADO

► función de distribución acumulada



10. DISTRIBUCIÓN *JI*-CUADRADO

- ▶ esperanza matemática (media):

$$E[\chi_k^2] = k$$

- ▶ varianza:

$$\text{Var}[\chi_k^2] = 2k$$

- ▶ desviación típica:

$$\text{SD}[\chi_k^2] = \sqrt{2k}$$

10. DISTRIBUCIÓN *JI*-CUADRADO

► propiedades:

- la suma de dos v.a. independientes y continuas *ji*-cuadrado es también una v.a. continua *ji*-cuadrado cuyo número de grados de libertad es la suma de los grados de libertad de las dos variables:

$$\chi_k^2 + \chi_n^2 = \chi_{k+n}^2$$

- por el teorema central del límite, cuando $k > 30$:


$$\sqrt{2 \cdot \chi_k^2} \approx N\left(\sqrt{2k-1}; 1\right)$$

10. DISTRIBUCIÓN *JI*-CUADRADO

► ejemplo

- $P(\chi_{16}^2 \leq 23.54183) = 0.90$

n	0.30	0.20	0.10
1	1.07420	1.64238	2.70554
2	2.40794	3.21888	4.60518
3	3.66487	4.64163	6.25139
4	4.87843	5.98862	7.77943
5	6.06443	7.28927	9.23635
6	7.23113	8.55806	10.64464
7	8.38343	9.80325	12.01703
8	9.52446	11.03009	13.36156
9	10.65637	12.24214	14.68366
10	11.78072	13.44196	15.98717
11	12.89867	14.63142	17.27501
12	14.01110	15.81199	18.54934
13	15.11872	16.98479	19.81193
14	16.22209	18.15077	21.06414
15	17.32169	19.31065	22.30712
16	18.41789	20.46507	23.54182



- $P(\chi_{16}^2 > 23.54183) = 0.10$

10. DISTRIBUCIÓN *JI*-CUADRADO

► **ejemplo.** Calcular: $P(\chi_{12}^2 \leq 20)$

- tablas

$$P(\chi_{12}^2 \leq 18.54934) = 0.900$$

$$P(\chi_{12}^2 \leq 21.02606) = 0.950$$

n	α			
	0.30	0.20	0.10	0.05
1	1.07420	1.64238	2.70554	3.84146
2	2.40794	3.21888	4.60518	5.99148
3	3.66487	4.64163	6.25139	7.81472
4	4.87843	5.98862	7.77943	9.48773
5	6.06443	7.28927	9.23635	11.07048
6	7.23113	8.55806	10.64464	12.59158
7	8.38343	9.80325	12.01703	14.06713
8	9.52446	11.03009	13.36156	15.50731
9	10.65637	12.24214	14.68366	16.91896
10	11.78072	13.44196	15.98717	18.30703
11	12.89867	14.63142	17.27501	19.67515
12	14.01110	15.81199	18.54934	21.02606

- el valor pedido no se encuentra en las tablas, por tanto, debe realizarse una **interpolación lineal**
- **Excel:** =1-DISTR.CHI(20;12)=0,93291404

10. DISTRIBUCIÓN *JI*-CUADRADO

► **ejemplo.** Calcular: $P(\chi_{12}^2 \leq 20)$

- interpolación lineal: parte de dos puntos conocidos de una función y determina los valores intermedios con la recta que une estos dos puntos


$$f(x) \approx \frac{f(b) - f(a)}{b - a} \cdot (x - a) + f(a) \quad (a < x < b)$$

- en este caso:

$$\left. \begin{aligned} (a, f(a)) &= (18.54934, 0.900) \\ (b, f(b)) &= (21.02606, 0.950) \\ x &= 20 \end{aligned} \right\}$$

- operando:

$$P(\chi_{12}^2 \leq 20) \approx f(x) = 0.929286$$



10. DISTRIBUCIÓN *JI*-CUADRADO

► **ejemplo.** Calcular: χ_0^2 tal que $P(\chi_{20}^2 \geq \chi_0^2) = 0.100$

$$\chi_0^2 \text{ tal que } P(\chi_{23}^2 \leq \chi_0^2) = 0.950$$

- tablas

$$\chi_0^2 = \chi_{20; 0.100}^2 = 28.41197$$

- tablas

$$P(\chi_{23}^2 \leq \chi_0^2) = 0.950 \Rightarrow P(\chi_{23}^2 > \chi_0^2) = 0.05$$

$$\chi_0^2 = \chi_{23; 0.050}^2 = 35.17246$$

n	α			
	0.30	0.20	0.10	0.05
1	1.07420	1.64238	2.70554	3.84146
2	2.40794	3.21888	4.60518	5.99148
3	3.66487	4.64163	6.25139	7.81472
4	4.87843	5.98862	7.77943	9.48773
5	6.06443	7.28927	9.23635	11.07048
6	7.23113	8.55806	10.64464	12.59158
7	8.38343	9.80325	12.01703	14.06713
8	9.52446	11.03009	13.36156	15.50731
9	10.65637	12.24214	14.68366	16.91896
10	11.78072	13.44196	15.98717	18.30703
11	12.89867	14.63142	17.27501	19.67515
12	14.01110	15.81199	18.54934	21.02606
13	15.11872	16.98479	19.81193	22.36203
14	16.22209	18.15077	21.06414	23.68478
15	17.32169	19.31065	22.30712	24.99580
16	18.41789	20.46507	23.54182	26.29622
17	19.51102	21.61456	24.76903	27.58710
18	20.60135	22.75955	25.98942	28.86932
19	21.68913	23.90042	27.20356	30.14351
20	22.77454	25.03750	28.41197	31.41042
21	23.85779	26.17109	29.61509	32.67056
22	24.93901	27.30145	30.81329	33.92446
23	26.01837	28.42879	32.00689	35.17246
24	27.09589	29.55282	33.19624	36.41503

10. DISTRIBUCIÓN *JI*-CUADRADO

► **ejemplo.** Calcular: $P(\chi_{41}^2 > 32)$

- aproximación con la normal ($k=41$)

$$\sqrt{2 \cdot \chi_{41}^2} \approx N\left(\sqrt{2(41)-1}; 1\right) = N(9; 1)$$

$$\begin{aligned} P(\chi_{41}^2 > 32) &\approx P\left(\sqrt{2\chi_{41}^2} > \sqrt{2(32)} = 8\right) = \\ &= P(Z > -1) = 0.8413 \end{aligned}$$

- **Excel:**

$$= \text{DISTR.CHI}(32; 41) \sim 0,84194476$$

11. DISTRIBUCIÓN t DE STUDENT

Si Y, Z_1, Z_2, \dots, Z_n son $n+1$ variables aleatorias normales estándar e independientes entonces se dice que la v.a.

$$X = \frac{Y}{\sqrt{\frac{1}{n} \sum_{i=1}^n Z_i^2}} = \frac{Y}{\sqrt{\frac{1}{n} (Z_1^2 + Z_2^2 + \dots + Z_n^2)}}$$

sigue una distribución **t de Student** con n grados de libertad

- ▶ notación: $X \approx t_n$
- ▶ parámetro: n (número de grados de libertad)
- ▶ es una distribución que surge al estimar la media de una población con un tamaño muestral pequeño

11. DISTRIBUCIÓN t DE STUDENT

- ▶ es una distribución que surge al estimar la media de una población con un tamaño muestral pequeño
- ▶ además, normalmente se desconoce la desviación típica σ
- ▶ William Gosset "Student" define una nueva variable aleatoria, la t , utilizada en estos supuestos
 - en la variable: $Z = \frac{\bar{X} - \mu}{\sigma / \sqrt{n}} \approx N(0; 1)$
 - estima (y sustituye) σ utilizando la desviación típica muestral

$$t = \frac{\bar{X} - \mu}{s / \sqrt{n}}$$

11. DISTRIBUCIÓN t DE STUDENT


► función de densidad

$$f(x) = \frac{\Gamma\left(\frac{n+1}{2}\right)}{\sqrt{n \cdot \pi} \cdot \Gamma\left(\frac{n}{2}\right)} \cdot \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}}$$

- función gamma: $\Gamma(x) = \int_0^{\infty} t^{x-1} \cdot e^{-t} dt$
- simétrica con respecto al cero
- gráfica parecida a la de la normal estándar pero presenta mayor dispersión con lo que es más aplanada
- a medida que aumentan los grados de libertad, su gráfica más se acerca a la de la normal estándar $N(0,1)$; para $n \geq 30$ la distribución t tiende a $N(0,1)$ 
- se consideran valores anómalos los que se alejan de cero (positivos o negativos)

11. DISTRIBUCIÓN t DE STUDENT

► función de densidad



11. DISTRIBUCIÓN t DE STUDENT

▶ esperanza matemática (media): $E[t_n] = 0$

▶ varianza: $Var[t_n] = \frac{n}{n-2}$

12. DISTRIBUCIÓN F DE SNEDECOR

Si $Y_1, Y_2, \dots, Y_n, Z_1, Z_2, \dots, Z_m$ son $n+m$ v.a. normales estándar e independientes entonces se dice que la v.a.

$$X = \frac{\frac{1}{n} \sum_{i=1}^n Y_i^2}{\frac{1}{m} \sum_{i=1}^m Z_i^2} = \frac{\frac{1}{n} (Y_1^2 + Y_2^2 + \dots + Y_n^2)}{\frac{1}{m} (Z_1^2 + Z_2^2 + \dots + Z_m^2)}$$

sigue una distribución **F de Snedecor** (ó F de Fisher ó F de Fisher-Snedecor con n grados de libertad en el numerador y m grados de libertad en el denominador

- ▶ notación: $X \approx F_{n;m}$
- ▶ parámetros: n, m (grados de libertad)
- ▶ es una distribución que surge al estimar el cociente de varianzas de dos poblaciones normales

12. DISTRIBUCIÓN F DE SNEDECOR


► función de densidad

$$f(x) = \frac{1}{B\left(\frac{n}{2}, \frac{m}{2}\right)} \cdot \left(\frac{nx}{nx+m}\right)^{\frac{n}{2}} \cdot \left(1 - \frac{nx}{nx+m}\right)^{\frac{m}{2}} \cdot x^{-1}$$

- función gamma: $B(x, y) = 2 \int_0^{\frac{\pi}{2}} \cos^{2x-1} \theta \cdot \sin^{2y-1} \theta d\theta$
- sólo toma valores positivos
- es asimétrica
- normalmente, se consideran valores anómalos los de la cola de la derecha
- relación con ji-cuadrado: $F_{n; \infty} = \chi_n^2$

12. DISTRIBUCIÓN F DE SNEDECOR

► función de densidad



12. DISTRIBUCIÓN F DE SNEDECOR

▶ esperanza matemática (media): $E[F_{n;m}] = \frac{m}{m-2} \quad (m > 2)$

▶ varianza: $Var[F_{n;m}] = \frac{2m^2(n+m-2)}{n \cdot (m-2)^2 \cdot (m-4)} \quad (m > 4)$

▶ propiedades:

• relación con la distribución χ^2 -cuadrado:


$$F_{n;\infty} = \chi_n^2$$

• relación con la distribución t de Student:

$$F_{1;m} = t_m$$

• si $F_{n;m;1-\alpha}$ es el valor que deja a su derecha una probabilidad α :

$$F_{n;m;\alpha} = \frac{1}{F_{n;m;1-\alpha}} \quad P(F_{n;m} > F_{n;m;\alpha}) = \alpha$$



13. DISTRIBUCIONES ASOCIADAS A LA NORMAL

- ▶ propiedad reproductiva de la distribución normal: si X_1, X_2, \dots, X_n son variables aleatorias normales independientes, con $E[X_i] = \mu_i$ y $\text{Var}[X_i] = \sigma_i^2$, entonces:

$$a_1 \cdot X_1 + a_2 \cdot X_2 + \dots + a_n \cdot X_n = Y \approx N \left(\sum_{i=1}^{i=n} a_i \cdot \mu_i ; \sqrt{\sum_{i=1}^{i=n} a_i^2 \cdot \sigma_i^2} \right)$$

13. DISTRIBUCIONES ASOCIADAS A LA NORMAL

- ▶ sea X_1, X_2, \dots, X_n una muestra aleatoria simple de una población normal con media μ y varianza σ^2 y sea la **cuasivarianza** muestral:

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

- ▶ la variable aleatoria $\frac{(n-1) \cdot \hat{s}^2}{\sigma^2} = \frac{(n-1) \cdot S^2}{\sigma^2}$

sigue una distribución **ji-cuadrado** con $n-1$ grados de libertad

$$\frac{(n-1) \cdot \hat{s}^2}{\sigma^2} = \frac{(n-1) \cdot S^2}{\sigma^2} \approx \chi_{n-1}^2$$