

IN627

**Profesor:**  
Rodrigo Niño  
Emilio Polit

1

## 3. Estadística para la Investigación de Mercados

2

## 1. Muestreo y Tamaño de muestra



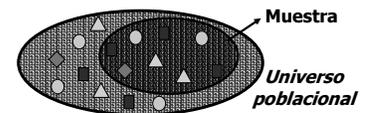
3

### Muestreo

#### ¿Qué es una muestra?



- Grupo de elementos que es un subconjunto del universo y que serán contactados para obtener información.



#### Muestra vs Censo

- Más práctica y económica.
- Permite proyectar los resultados de la muestra al total de la población.

4

### Proceso de Muestreo



5

### Definición de la Población Objetivo

- La especificación de la población representada debe ser precisa en elementos, unidades de muestreo y tiempo.
- Se deben considerar los siguientes lineamientos:
  - Objetivos de la investigación.
  - Alternativas sobre la población a ser estudiada (por ej. Compradores vs. Consumidores).
  - Conocimiento del mercado.
  - Unidades de muestreo apropiadas.
  - Dejar claro lo que será excluido.
  - Evitar la sobredefinición.



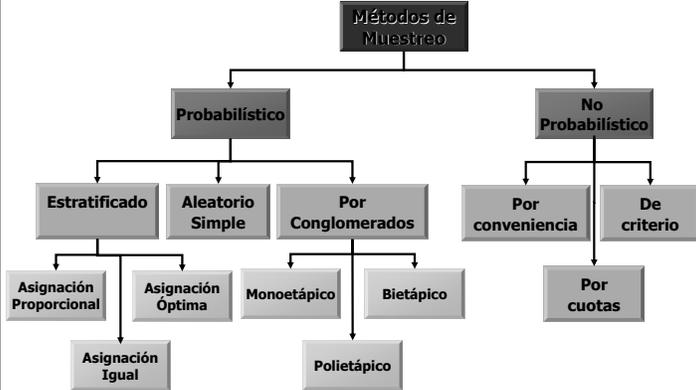
#### Ejemplo:

1. Elementos: dueñas de casa, mujeres, entre 18 y 55 años, que han comprado leche líquida en los últimos 30 días en...
2. Unidades: supermercados
3. Tiempo: entre el 1 y 15 de septiembre 2003



6

## Métodos de muestreo



La muestra se obtendrá de un marco de muestreo (registro de las unidades que componen la población)

7

## Muestras probabilísticas

- Todas las unidades de la población tienen una probabilidad conocida y mayor que cero de ser seleccionadas en la muestra.
- Permite analizar la representatividad de la muestra.
- A partir de la muestra es posible calcular un intervalo de confianza de la variable de interés en la población.
- Se utilizan cuando se requiere una estimación muy precisa de la variable a estudiar en la población.
- Hay 3 grandes tipos de métodos de muestreo probabilístico:
  - Muestreo aleatorio simple (SRS).
  - Estratificado.
  - Por Conglomerados.



8

## Muestras probabilísticas: Aleatorio Simple

- Todas las muestras posibles de un tamaño dado y cada unidad o elemento tienen igual probabilidad de ser seleccionadas.
- Se requiere una clasificación organizada que enumere a todas las unidades de la población.
- Se selecciona aleatoriamente.

### Ventajas:

- Fácil de entender y aplicar.

### Desventajas:

- No siempre son factibles (ej.: enumeración).
- Pueden ser costosas (ej.: área geográfica).
- Distorsiones en muestras pequeñas.



9

## Muestras probabilísticas: Sistemático

- La muestra se elabora partiendo de un elemento elegido arbitrariamente, seleccionando los elementos siguientes de la lista con un salto constante.

### Ventajas:

- Fácil de utilizar
- No hay que generar números aleatorios ( $n_{muestra}$ )

### Desventajas:

- No siempre son factibles (ej.: enumeración)
- Pueden ser costosas (ej.: área geográfica)
- Distorsiones en muestras pequeñas

10

## Muestras probabilísticas: Estratificado

- Dividir a los elementos en subpoblaciones (estratos) según una variable clasificatoria que reduzca la varianza de la subpoblación (estratos homogéneos)
- Dentro de cada estrato, seleccionar una muestra independiente (ej.: SRS)
- Se miden las variables de interés en cada muestra, se pondera y se estima un total para la población



GSE, Edad, Sexo, Ciudad, etc.

### Ventajas:

- Más eficaz que SRS
- Reduce significativamente el intervalo de confianza

### Desventajas:

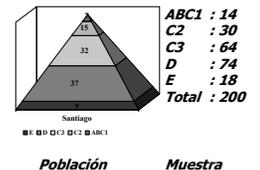
- Más complejo que SRS
- Más costoso que SRS

11

## Muestras probabilísticas: Estratificado

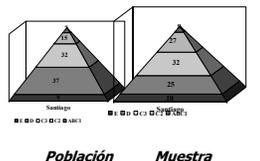
### Asignación Proporcional

- El número de elementos seleccionados es proporcional al tamaño del estrato con respecto a la población. En el peor de los casos será tan eficaz como SRS.



### Asignación No Proporcional u Óptima

- Hay una doble ponderación de los elementos: tamaño del estrato al que pertenece y varianza de la variable a calcular.

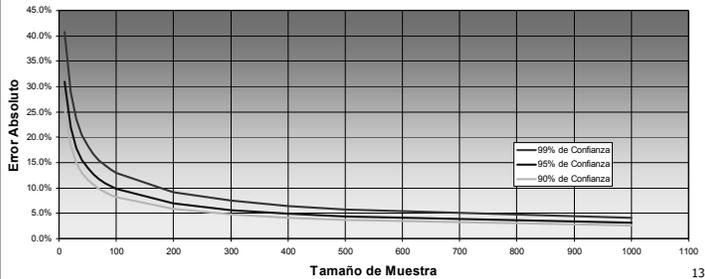


12

## Muestras probabilísticas: Error muestral máximo vs. Tamaño de la muestra

$$Error = \frac{t_{1-\frac{\alpha}{2}, n-1} * S_{n-1}}{\sqrt{n}} \sqrt{\frac{N-n}{N-1}}$$

Error Estadístico Máximo para una Proporción



13

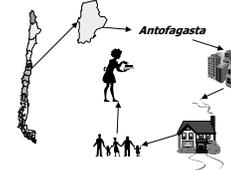
## Muestras probabilísticas: Por Conglomerados

- Se realiza una partición (excluyente y exhaustiva) de la población de unidades de muestreo en grupos cerrados a partir de una variable de clasificación.
- Se selecciona una muestra dentro del conjunto de grupos cerrados (ej.: SRS, salto sistemático o proporcional al tamaño).
- Se selecciona una muestra dentro de cada conjunto de grupos cerrados elegidos en la etapa anterior (ej.: SRS).
- Puede haber varias fases.



### Ejemplo:

- Región
- Ciudad
- Manzana
- Casa
- Familia
- Población objetivo



14

## Muestras probabilísticas: Por Conglomerados

### Ventajas:

- Factibilidad de muestreo (muchas veces el marco muestral disponible está en grupos cerrados)
- Económico (menores costos de desplazamiento que SRS)



### Desventajas:

- Estimaciones menos precisas a igual tamaño de muestra ya que generalmente los grupos son más homogéneos en su interior, lo que reduce la varianza de la muestra y la sesga respecto a la de la población.

15

## Tamaño de Muestras Probabilísticas

- Se deben tomar en cuenta los siguientes enfoques prácticos:

- Reglas empíricas (por ej. ideal usar al menos 100 casos por segmento de análisis).
- Restricción presupuestaria.
- Valor de la información.
- Utilización de estudios comparables.
- Analizar los factores que determinan el tamaño:

- ⇒ Número de grupos y subgrupos dentro de la muestra (por ej. análisis detallado por segmento).
- ⇒ Variabilidad de la población (por ej. si todos los individuos de la población objetivo se comportaran igual nos bastaría considerar una muestra de 1 caso).

16

## Muestras probabilísticas: Tratamiento de la No Respuesta

### Motivos asociados a este fenómeno

- Simplemente no quiere responder.
- No tiene la capacidad o conocimiento suficiente para contestar.
- No se encuentra.
- Es inaccesible.

### Implicancias

- Agrandar la muestra.
- Analizar el sesgo producido por dejar de lado a los que no responden.

### Soluciones

- Mejorar el diseño de la encuesta (por ej. preguntas de perfilamiento al final del cuestionario).
- Reintento de generar la respuesta (por ej. visitas repetidas al mismo hogar para maximizar su probabilidad de respuesta).
- Estimar el efecto asociado a la no respuesta (por ej. considerar que este grupo puede tener una opinión negativa de mi servicio).

17

## Muestras no probabilísticas

- No hay forma de establecer la probabilidad de seleccionar un determinado elemento → resultados no se pueden proyectar estadísticamente a la población.
- No necesariamente son inexactas o peores que las probabilísticas. Pueden ser o no representativas dependiendo del método y controles de selección.
- Se utilizan en estudios de investigación de mercados.
- Las muestras probabilísticas son más caras. Aquí se eliminan los costos y problemas asociados a generar un marco muestral del cual seleccionar la muestra.
- Aumentar el tamaño muestral no resuelve los problemas de sesgo que se presenten (por ej. una parte de la población objetivo puede quedar fuera del muestreo por definición).
- La decisión acerca del tamaño de la muestra está relacionada directamente con el costo de la investigación.
- El tamaño de la muestra no depende del tamaño de la población en estudio.

18

## Muestras por conveniencia

- La muestra la selecciona el entrevistador, sólo restringido a considerar elementos dispuestos a participar.
- La falta de respuestas es un problema importante en este tipo de muestras.
- No hay forma de determinar la representatividad de la muestra.



### Ejemplo:

- Entrevistar mujeres en un centro comercial sin normas sobre cuotas.
- Encuestas por correo, e-mail o Internet.
- Muestra para un focus group (en general).



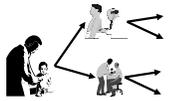
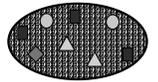
19

## Muestras de criterio o de juicio

- Se selecciona una muestra de elementos que parece representar a la población a analizar.

### Ejemplos:

- Estudio de concepto entre usuarios de video clubes con una frecuencia promedio quincenal o superior.
- Mercados de prueba: selección de una región geográfica que se cree es representativa del todo el mercado.
- Diseño de "bola de nieve", se le pide a los entrevistados que identifiquen a otras personas que pertenecen a la población en estudio.



20

## Muestras por cuotas

- Se selecciona un número específico (cuota) de encuestados que reúnan ciertas características (GSE, edad, sexo, etc.) para construir una muestra que sea representativa de la población en las características con cuota.



- Se agregan elementos a la muestra hasta que se completa la cuota.

### Ejemplo:

- Muestra por cuotas en encuestas en locación central.

GSE	Segmento					Total
	Madres	Niñas		Niños		
		6-9	10-12	6-9	10-12	
ABC1	40	20	20	20	20	120
C2	40	20	20	20	20	120
C3	40	20	20	20	20	120
D	40	20	20	20	20	120
Total	160	80	80	80	80	480

¿En que se diferencia una muestra estratificada de una muestra por cuotas?

21

## 2. Muestreo y estimaciones

22

## Muestreo Aleatorio Simple

- Todos los elementos de la población tienen una probabilidad conocida, no nula, de ser elegidos. Pero al no ser devueltos a la población, la probabilidad de que salga un elemento determinado depende de las extracciones anteriores en el caso de población finita.



- Consiste en elegir n elementos de una población de N elementos.

- Las muestras posibles son:

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

$$N! = N * (N-1) * (N-2) * \dots * 3 * 2$$

$$\binom{N}{n} = \frac{N(N-1)(N-2)\dots 3 * 2}{(N-n)(N-n-1)\dots 3 * 2 * n(n-1)(n-2)\dots 3 * 2}$$

### Ejemplo:

- ¿Cuántas muestras de 100 elementos pueden ser obtenidas de una población de 120?

$$\binom{120}{100} = \frac{120!}{20!100!} = 29.462.227.291.176.600.000.000$$

23

## Muestreo Aleatorio Simple

- La probabilidad de que una muestra sea elegida es:

$$\text{Prob(muestra específica)} = \frac{1}{\binom{N}{n}}$$

- La probabilidad de que un elemento forme parte de una muestra dada será:

$$\frac{\text{Número de muestras probables}}{\text{Número de muestras posibles}} = \frac{\binom{N-1}{n-1}}{\binom{N}{n}} = \frac{n}{N}$$

- Por lo tanto, la media y varianza muestral de una variable podrá variar de muestra en muestra.

- En la medida que se aumenta el tamaño de la muestra (n), entonces el error cometido por elegir una muestra determinada disminuye (error muestral). Esto debido a que la cantidad de muestras posibles de escoger disminuye y en consecuencia, también la probabilidad de variación del indicador de muestra en muestra.

24

## Muestreo Aleatorio Simple



### ¿Cómo hacer un muestreo aleatorio?

1. Con un listado de elementos de la población y usando números aleatorios: tablas o una función generadora (por ej. con Excel).

#### Ejemplo:

- ¿Cómo elegir una muestra de 10 elementos de una población de 1000?

N° Muestra	N° Aleatorio	N° Población
1	0.73812	738
2	0.29499	295
3	0.34016	340
4	0.93316	933
5	0.79095	791
6	0.17945	180
7	0.59108	591
8	0.20253	203
9	0.22276	223
10	0.95729	957

25

## Muestreo Aleatorio Simple



### ¿Cómo hacer un muestreo aleatorio?

2. Con un listado de elementos de la población y muestreo sistemático con arranque aleatorio.

#### Ejemplo:

- Elegir una muestra de 6 a partir de una población de 20.
- El arranque puede ser aleatorio manual o generado a partir de una lista de números aleatorios o una función generadora (por ej. Excel).

$$K = \left[ \frac{N}{n} \right] = \left[ \frac{20}{6} \right] = [3.33333...] = 3$$

Elegido aleatoriamente entre los K primeros elementos

N° Población
1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20

26

## Muestreo Aleatorio Simple



### ¿Cómo hacer un muestreo aleatorio?

3. Rutas aleatorias.
- En ocasiones no se dispone de un listado poblacional.
  - En este método se seleccionan los elementos que se encuentran en una ruta seguida por el entrevistador de acuerdo a normas dadas.

27

## Muestreo Aleatorio Simple



- ¿Cómo estimar parámetros de la población a partir de la muestra?

	Población	Muestra
Total	$Y = \sum_{i=1}^N Y_i$	$\hat{Y} = N\bar{y} = y$
Media	$\bar{Y} = \frac{\sum_{i=1}^N Y_i}{N}$	$\hat{\bar{Y}} = \frac{\sum_{i=1}^n y_i}{n} = \bar{y}$
Proporción	$P = \frac{\sum_{i=1}^N A_i}{N}$	$\hat{P} = \frac{\sum_{i=1}^n a_i}{n} = p$

- Las  $Y_i$  representan los valores de la variable medida en el  $i$ -ésimo elemento de la población (por ej. edad, frecuencia de consumo, opinión sobre un servicio, etc.).
- Las  $A_i$  son variables dicotómicas (0 ó 1), tomando el valor 1 en el caso de poseer la característica (por ej. género).

28

## Muestreo Aleatorio Simple



- Las estimaciones obtenidas a partir de la muestra están afectadas por el error estadístico o error muestral. Este error, en el caso del muestreo probabilístico es medible.

	Población	Muestra
Total	$S^2 = \frac{\sum_{i=1}^N (Y_i - \bar{Y})^2}{N}$	$\hat{S}^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n-1} = s^2$
Media	$S_{\bar{Y}}^2 = \frac{S^2}{N}$	$\hat{S}_{\bar{Y}}^2 = \frac{N-n}{N} \cdot \frac{s^2}{n} = s_{\bar{y}}^2$
Proporción	$S_p^2 = \frac{P*(1-P)}{N}$	$\hat{S}_p^2 = \frac{N-n}{N} \cdot \frac{P*(1-P)}{n-1} = s_p^2$

- Si  $n/N < 5\%$  se aproxima a población infinita y se eliminan los factores de corrección por tamaño de muestra.

29

## Muestreo Aleatorio Simple



- El grado de confianza de una estimación es la probabilidad de que el verdadero valor en la población se encuentre entre dos valores determinados, llamados límites del intervalo de confianza.

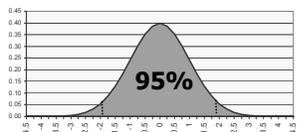
$$\text{Estimación} \pm \text{Error} = E \pm K * \hat{S}_E$$

Error estándar de la muestra

- El valor de la población que deseamos estimar estará comprendido con una probabilidad o grado de confianza definido, entre los valores que resultan de sumar o restar el error estadístico al valor obtenido del estimador muestral.
- El coeficiente K depende del grado de confianza elegido:

Confianza	K
99.73%	3.00
99.00%	2.58
98.00%	2.33
96.00%	2.05
95.45%	2.00
95.00%	1.96
90.00%	1.64
80.00%	1.28
68.27%	1.00

$$K = \text{NORMINV}((A2+(1-A2)/2), 0, 1)$$



30

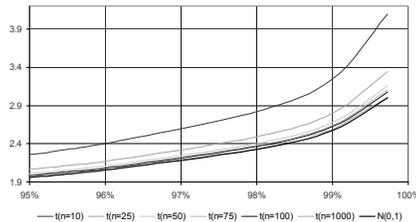
## Muestreo Aleatorio Simple



- En rigor K sigue una distribución t-Student de n-1 grados de libertad en vez de una normal, pues la varianza poblacional es desconocida. Sin embargo, la distribución normal es una buena aproximación para muestras grandes (n>50).

`=TINV(1-A2,25-1)`

Confianza	t(n=10)	t(n=25)	t(n=50)	t(n=75)	t(n=100)	t(n=1000)	N(0,1)
99.73%	4.09	3.34	3.16	3.10	3.08	3.01	3.00
99.00%	3.25	2.80	2.68	2.64	2.63	2.58	2.58
98.00%	2.82	2.49	2.40	2.38	2.38	2.33	2.33
96.00%	2.40	2.17	2.11	2.09	2.08	2.06	2.06
95.45%	2.32	2.11	2.05	2.03	2.03	2.00	2.00
95.00%	2.26	2.06	2.01	1.99	1.98	1.96	1.96
90.00%	1.83	1.71	1.68	1.67	1.66	1.65	1.64
80.00%	1.38	1.32	1.30	1.29	1.29	1.28	1.28
68.27%	1.06	1.02	1.01	1.01	1.01	1.00	1.00



`=NORMINV(A2+(1-A2)/2,0,1)`

31

## Muestreo Aleatorio Simple



- Para el caso de la media, tenemos:

$$\text{Error} = K * \hat{S}_{\bar{y}} = K * \sqrt{\frac{N-n}{N} * \frac{s^2}{n}}$$

- Despejando n:

$$n = \frac{NK^2 s^2}{Ne^2 + K^2 s^2}$$

- Es decir, el tamaño de la muestra depende del K (grado de confianza), el error estadístico que estamos dispuestos a tolerar y de la variabilidad de los datos.

- Normalmente s es desconocida y lo que se hace es hacer una sobreestimación de él para asegurar que la muestra no tenga un error estadístico mayor al deseado (por ej. ponerse en el peor de los casos). Otra alternativa es estimarla a través de una muestra piloto.

- Si la población es infinita:

$$n_{\infty} = \frac{K^2 s^2}{e^2}$$

32

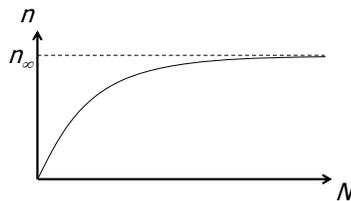
## Muestreo Aleatorio Simple



- La muestra con población finita se relaciona de la siguiente forma con la de población infinita:

$$n = \frac{N * n_{\infty}}{N + n_{\infty}}$$

- Gráficamente:



$n_{\infty}$ : Es el tamaño de muestra para una población infinita

- Es decir, por mucho que aumente el tamaño de la población, el tamaño de muestra necesario para niveles dados de confianza, error estadístico y dispersión de los datos es prácticamente el mismo.

33

## Muestreo Aleatorio Simple



- En el caso de estimaciones de totales tenemos:

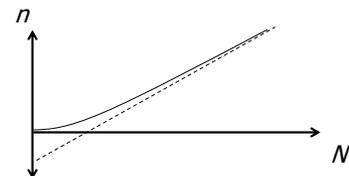
$$\text{Error} = K * \hat{S}_{\bar{y}} = K * \sqrt{N(N-n) \frac{s^2}{n}}$$

- Despejando n:

$$n = \frac{N^2 K^2 s^2}{e^2 + NK^2 s^2}$$

- En este caso, el tamaño de la muestra aumenta al aumentar el N.

- Gráficamente:



34

## Muestreo Aleatorio Simple



- Para el caso de una proporción tendremos:

$$\text{Error} = K * \hat{S}_p = K * \sqrt{\frac{N-n}{N-1} \frac{pq}{n}}$$

- Despejando n:

$$n = \frac{K^2 pq N}{e^2 (N-1) + K^2 pq}$$

- Si la población es infinita:

$$n_{\infty} = \frac{K^2 pq}{e^2}$$

- Cuando los valores de p y q no se conocen se recomienda tomar p = q = 0.5, pues eso considera la máxima varianza posible de los datos (el peor de los casos).

$$n = \frac{N}{1 + \frac{1}{N-1} n_{\infty}} \cong \frac{N n_{\infty}}{N + n_{\infty}}$$

- Es decir, aproximadamente igual a la ecuación vista para la media.

35

## Muestreo Aleatorio Simple



### Ejemplo:

- Se tienen 200.000 facturas y se desea estimar la proporción de ellas que tienen errores.

- Se seleccionaron 56 facturas a través de un muestreo aleatorio simple y se encontraron 2 con errores (3.57%)

- ¿Cuál es el error de la estimación con un 95% de confianza?

$$\text{Error} = K * \hat{S}_p = 2 * \sqrt{\frac{200.000 - 56}{200.000 - 1} * \frac{0.0357 * 0.9643}{56}} = 0.0496$$

- Es decir, el verdadero valor en la población está con un 95% de probabilidad entre:

$$L_{\text{inferior}} = \bar{p} - \text{Error} = 0.0357 - 0.0496 = -0.0139 = -1.4\%$$

$$L_{\text{superior}} = \bar{p} + \text{Error} = 0.0357 + 0.0496 = 0.0853 = 8.5\%$$

- Por lo tanto, dado los resultados de la muestra y su error no se puede concluir si existen o no errores significativos en las facturas (por ej. si el límite fijado fuera de 5%).

36

## Muestreo Aleatorio Simple

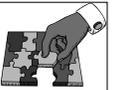


- ¿Cuál debería ser el tamaño de la muestra para que el error no sea más de un punto porcentual?

$$n = \frac{K^2 pqN}{e^2(N-1) + K^2 pq} = \frac{2^2 * 0.0357 * 0.9643 * 200000}{0.01^2 * (200000 - 1) + 2^2 * 0.0357 * 0.9643} = 1367,6 \approx 1368$$

37

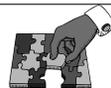
## Muestreo Aleatorio Estratificado



- Si el conocimiento de la población permite agrupar previamente sus elementos en subconjuntos o estratos de forma que sean más homogéneos.
- La obtención de una muestra con elementos de cada uno de ellos conlleva una mayor precisión de las estimaciones que el muestreo aleatorio simple.
- Si la selección de la muestra en cada estrato se hace mediante un muestreo aleatorio simple, se llama muestreo aleatorio estratificado.
- En un caso extremo, si cada estrato fuera de forma tal que cada uno tuviera elementos iguales dentro de él para la variable a estudiar, bastaría un elemento de cada estrato para tener una muestra representativa.
- No hay reglas definidas sobre el número de estratos a utilizar. En general, se puede decir que al aumentar el número de estratos aumenta la precisión.
- Por otro lado, un número elevado de estratos complica los cálculos y puede que su aporte a reducir la muestra sea mínimo.
- Para definir bien los estratos es necesario utilizar alguna variable conocida de la población que esté correlacionada con aquella que queremos investigar.

38

## Muestreo Aleatorio Estratificado



- Si representamos las poblaciones de L estratos por  $N_1, N_2, \dots, N_L$ :

$$\sum_{h=1}^L N_h = N \quad W_h = \frac{N_h}{N} \quad \sum_{h=1}^L W_h = 1$$

- $W_h$  es el peso relativo del estrato h en la población.
- Se llama afijación al reparto que se hace del tamaño de muestra n entre los diferentes estratos.
- Existen tres tipos de afijación:
  - Afijación igual: se le asigna a cada estrato el mismo número de muestra.

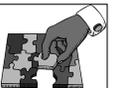
$$n_h = \frac{n}{L}$$

- Afijación proporcional: a cada estrato se le asigna una fracción de la muestra que es igual a la proporción que tiene el estrato en la población.

$$n_h = n * \frac{N_h}{N}$$

39

## Muestreo Aleatorio Estratificado



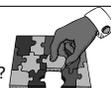
- Afijación óptima: se asigna a cada estrato un número de muestra proporcional al producto de su población por la desviación estándar del estrato en la muestra.

$$n_h = n * \frac{N_h * s_h}{\sum_{l=1}^L N_l * s_l}$$

- Este tipo de afijación es la que entrega una mejor precisión para un mismo tamaño de muestra, pues toma en cuenta el tamaño del estrato y la variabilidad de los datos a su interior.

40

## Muestreo Aleatorio Estratificado



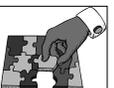
- ¿Cómo estimar parámetros de la población a partir de una muestra estratificada?

	Población	Muestra
Total	$Y = \sum_{i=1}^N Y_i$	$\hat{Y}_e = N \bar{y}_e = \sum_{i=1}^L N_i \bar{y}_i$
Media	$\bar{Y} = \frac{\sum_{i=1}^N Y_i}{N}$	$\hat{\bar{Y}}_e = \frac{\sum_{i=1}^L N_i * \bar{y}_i}{N} = \sum_{i=1}^L W_i * \bar{y}_i = \bar{y}_e$
Proporción	$P = \frac{\sum_{i=1}^N A_i}{N}$	$\hat{P}_e = \frac{\sum_{i=1}^L N_i * p_i}{N} = \sum_{i=1}^L W_i * p_i = p_e$

- Las  $Y_i$  representan los valores de la variable medida en el i-ésimo elemento de la población (ej.: edad, cantidades consumidas, opinión sobre un servicio, etc.).
- Las  $A_i$  son variables dicotómicas (0 ó 1), tomando el valor 1 en el caso de poseer la característica (ej.: rangos de ingreso, correcto/incorrecto, etc.).

41

## Muestreo Aleatorio Estratificado



- ¿Cómo estimar la variabilidad de los datos a partir de una muestra estratificada?

	Población	Muestra
Total	$S^2 = \frac{\sum_{i=1}^N (Y_i - \bar{Y})^2}{N}$	$\hat{S}_{Y_e}^2 = \sum_{i=1}^L N_i (N_i - n_i) \frac{s_{Y_i}^2}{n_i} = s_{Y_e}^2$
Media	$S_{\bar{Y}}^2 = \frac{S^2}{N}$	$\hat{S}_{\bar{Y}_e}^2 = \frac{1}{N^2} \sum_{i=1}^L N_i (N_i - n_i) \frac{s_{Y_i}^2}{n_i} = s_{\bar{Y}_e}^2$
Proporción	$S_p^2 = \frac{P*(1-P)}{N}$	$\hat{S}_{P_e}^2 = \frac{1}{N^2} \sum_{i=1}^L N_i^2 \frac{N_i - n_i}{N_i - 1} * \frac{P_i * (1 - P_i)}{n_i} = s_{P_e}^2$

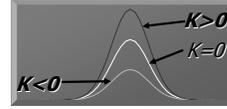
42

### 3. Análisis de Datos



### Kurtosis

- Es una medición de qué tan concentrado o aplanado está un conjunto de datos en comparación con la distribución normal.



- Un índice positivo indica una distribución más concentrada. En tanto que uno negativo indica una distribución relativamente plana.

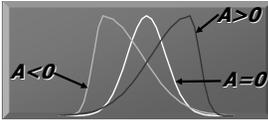
$$K = \frac{\sum_{i=1}^n \left(\frac{Y_i - \bar{Y}}{S}\right)^4}{N} - 3$$

- Donde S es la desviación estándar de la población. En el caso de estar trabajando con una muestra y desconocer S, entonces el estimador insesgado de K es:

$$\hat{K} = k = \frac{n(n+1)}{(n-1)(n-2)(n-3)} \sum_{i=1}^n \left(\frac{y_i - \bar{y}}{s}\right)^4 - 3 \frac{(n-1)^2}{(n-2)(n-3)}$$

### Asimetría (Skewness)

- Es una medición del grado de asimetría de una distribución alrededor de su media.



- Un índice positivo indica una distribución asimétrica hacia la derecha. En tanto que uno negativo indica asimetría hacia la izquierda.

$$A = \frac{\sum_{i=1}^n \left(\frac{Y_i - \bar{Y}}{S}\right)^3}{N}$$

- Donde S es la desviación estándar de la población. En el caso de estar trabajando con una muestra y desconocer S, entonces el estimador insesgado de A es:

$$\hat{A} = a = \frac{n}{(n-1)(n-2)} \sum_{i=1}^n \left(\frac{y_i - \bar{y}}{s}\right)^3$$

### Test de hipótesis

### Test de Hipótesis

- Se usan cuando se requiere probar o rechazar una idea preestablecida.
- Hipótesis: presunción de sobre una característica de la población.
- Ej. Un gerente de una empresa sanitaria estima que en promedio transcurren 7 días desde que se toma la lectura del medidor hasta que llega la cuenta al cliente. Se ha tomado una muestra de 36 boletas y se obtuvo que el tiempo promedio transcurrido fue de 8 días con una desviación estándar de la muestra de 2 días. ¿Debemos aceptar o rechazar la hipótesis del gerente?
- Es decir, ¿es 8 lo suficientemente lejano de 7 como para descartar la estimación del gerente?. O al contrario, ¿es lo suficientemente cercana como para validarla?
- Existen dos explicaciones para que explicar la diferencia entre el valor hipotético y el de la muestra:
  - La hipótesis es cierta y la diferencia observada se debe al error estadístico.
  - La hipótesis es falsa y el valor real será algún otro valor.
- Un test de hipótesis ayuda a determinar cuál es la explicación más probable.

### Test de Hipótesis

#### Pasos de un test de hipótesis



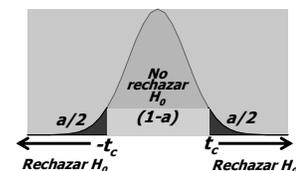
- Hipótesis Nula o Indiferente: Lo que se quiere probar

$$H_0 : \bar{Y} = 7 \text{ días}$$

- Hipótesis Alternativa: Compite con la H0, puede ser direccional o unidireccional.

$$H_1 : \bar{Y} \neq 7 \text{ días}$$

$$t = \frac{\bar{y} - \bar{Y}}{s / \sqrt{n}} = \frac{8 - 7}{2 / \sqrt{36}} = 3$$



## Test de Hipótesis

- Aplicando el último paso a nuestro ejemplo:

- $\alpha = 5\%$
- $n = 36$
- $t_{1-\alpha/2, n-1} = 2.03$  =TINV(0.05, 35)

- Como  $t > t_c$ , entonces se rechaza con un 95% de confianza que una muestra de 36 elementos con media de 8 días y desviación estándar de 2 provenga de una población con media 7 días.
- La verificación de hipótesis está sujeta a dos tipos de error (I y II).
- Tipo I: cuando la hipótesis nula es verdadera e incorrectamente la rechazamos
- Tipo II: cuando la hipótesis nula es falsa e incorrectamente no la rechazamos

49

## Test de Hipótesis

### Test de hipótesis para proporciones de una muestra

- Definición de Hipótesis

- Hipótesis Nula o Indiferente: Lo que se quiere probar

$$H_0: P = P^*$$

- Hipótesis Alternativa: Compite con la  $H_0$ , puede ser bidireccional o unidireccional.

$$H_1: P \neq P^*$$

- Método estadístico

$$Z = \frac{p - P^*}{\sqrt{\frac{P^*(1-P^*)}{n}}} \quad Z_c = Z_{1-\alpha/2}$$

- Regla de decisión

- Rechazar  $H_0$  si  $Z > Z_c$  ó  $Z < -Z_c$

50

## Test de Hipótesis

### Test de hipótesis para proporciones de una muestra

#### Ejemplo:

- Se realizaron 300 entrevistas para evaluar un nuevo producto y 74 de ellos declararon una intención futura de compra. La empresa ha establecido como su criterio de decisión que lanzará el producto si la proporción que está dispuesto a comprarlo es igual o superior al 19.5%. ¿Debería lanzar el producto?

$$H_0: P \leq 0.195$$

$$H_1: P > 0.195$$

$$p = \frac{74}{300} = 0.247$$

$$Z = \frac{p - P^*}{\sqrt{\frac{P^*(1-P^*)}{n}}} = \frac{0.247 - 0.195}{\sqrt{0.195 * 0.805 / 300}} = 2.27$$

$$Z_c = Z_{1-\alpha} = Z_{0.95} = 1.64$$

=NORMSINV(0.95)  
Test unidireccional

- Como  $Z > Z_c$ , entonces se rechaza la hipótesis nula y se debería lanzar el producto.

51

## Test de Hipótesis

### Test de hipótesis para proporciones de dos muestras independientes

- Definición de Hipótesis

- Hipótesis Nula o Indiferente: Lo que se quiere probar

$$H_0: P_1 = P_2$$

- Hipótesis Alternativa: Compite con la  $H_0$ , puede ser direccional o unidireccional.

$$H_1: P_1 \neq P_2$$

- Método estadístico

$$Z = \frac{p_1 - p_2}{s_{p_1 - p_2}} \quad s_{p_1 - p_2} = \sqrt{[p^*(1-p^*)] \left[ \frac{1}{n_1} + \frac{1}{n_2} \right]} \quad p^* = \frac{n_1 p_1 + n_2 p_2}{n_1 + n_2} \quad Z_c = Z_{1-\alpha/2}$$

- Regla de decisión

- Rechazar  $H_0$  si  $Z > Z_c$  ó  $Z < -Z_c$

52

## Test de Hipótesis

### Test de hipótesis para proporciones de dos muestras independientes

#### Ejemplo:

- Suponga que las proporciones de disposición positiva a la compra del nuevo producto en hombres y mujeres son de 28% y 21% respectivamente. En la muestra hay 150 hombres y 150 mujeres. ¿Hay diferencia entre hombres y mujeres en la intención de compra del producto?

$$H_0: P_1 = P_2$$

$$H_1: P_1 \neq P_2$$

$$p^* = \frac{n_1 p_1 + n_2 p_2}{n_1 + n_2} = \frac{150 * 0.28 + 150 * 0.21}{300} = 0.247$$

$$Z = \frac{p_1 - p_2}{s_{p_1 - p_2}} = \frac{0.28 - 0.21}{\sqrt{0.247 * 0.753 * \left[ \frac{1}{150} + \frac{1}{150} \right]}} = 1.41$$

$$Z_c = Z_{1-\alpha/2} = Z_{0.975} = 1.96$$

=NORMSINV(0.975)

- Como  $Z < Z_c$ , entonces no se puede rechazar  $H_0$ .

53

## Test de Hipótesis

### Test de hipótesis para proporciones para más de dos muestras independientes

- Definición de Hipótesis

- Hipótesis Nula o Indiferente: Lo que se quiere probar

$$H_0: P_1 = P_2 = P_3 = \dots = P_k = P_T$$

- Hipótesis Alternativa: Compite con la  $H_0$ , puede ser bidireccional o unidireccional.

$$H_1: \exists i / P_i \neq P_T$$

- Método estadístico

- Consideremos k muestras de tamaño  $n_{i_0}$  cada una de las cuales tiene  $x_i$  éxitos y  $(n_i - x_i)$  fracasos. Sea:

$$X_T = X_1 + \dots + X_k \quad n_T = n_1 + \dots + n_k \quad \chi_c^2 = \chi_{1-\alpha/2, k-1}^2$$

- Regla de decisión

- Rechazar  $H_0$  si  $\chi^2 > \chi_c^2$  ó  $\chi^2 < -\chi_c^2$

54

## Test de Hipótesis

### Test de hipótesis para proporciones para más de dos muestras independientes

- Entonces:

$$\chi^2 = \sum_{j=1}^2 \sum_{i=1}^k \frac{(o_{ij} - e_{ij})^2}{e_{ij}} \quad \chi_c^2 = \chi_{1-\alpha/2, k-1}^2$$

- Donde:

$o_{ij}$  = frecuencia observada en la muestra  $j$  ( $i=1 \rightarrow$  éxito,  $i=2 \rightarrow$  fracaso).  
 $e_{ij}$  = frecuencia esperada en la muestra  $j$  ( $i=1 \rightarrow$  éxito,  $i=2 \rightarrow$  fracaso).

$$e_{1j} = n_j \cdot P_T = n_j \cdot \frac{x_T}{n_T} \quad e_{2j} = n_j \cdot (1 - P_T) = n_j \cdot \frac{(n_T - x_T)}{n_T}$$

- 3. Regla de decisión

- Rechazar  $H_0$  si  $\chi^2 > \chi_c^2$  ó  $\chi^2 < -\chi_c^2$

55

## Test de Hipótesis

### Test de hipótesis para proporciones para más de dos muestras independientes

#### Ejemplo:

- Si 100 entrevistados eran entre 18-34 años, otros 100 entre 35-54 años y otros 100 de más de 55 años, y que los porcentajes de intención de compra de cada grupo fueron 5%, 21% y 48% respectivamente. ¿Podemos concluir que hay diferencias por edad?

$$H_0: P_1 = P_2 = P_3 = 0.247$$

$$H_1: \exists i / P_i \neq 0.247$$

$$\chi^2 = \sum_{i=1}^3 \sum_{j=1}^3 \frac{(o_{ij} - e_{ij})^2}{e_{ij}} = \frac{(5-24.7)^2}{24.7} + \frac{(21-24.7)^2}{24.7} + \frac{(48-24.7)^2}{24.7} + \frac{(95-75.3)^2}{75.3} + \frac{(79-75.3)^2}{75.3} + \frac{(52-75.3)^2}{75.3} = 50.79$$

=CHINV(0.05,2)

$$\chi_c^2 = \chi_{1-\alpha/2, k-1}^2 = \chi_{0.975, 2}^2 = 5.99$$

- Como  $\chi^2 > \chi_c^2$  se rechaza  $H_0 \rightarrow$  Sí, hay diferencias significativas por edad!

56

## Test de Hipótesis

### Test de hipótesis para la media de una muestra

- 1. Definición de Hipótesis

- Hipótesis Nula o Indiferente: Lo que se quiere probar.

$$H_0: \bar{Y} = Y^*$$

- Hipótesis Alternativa: Compite con la  $H_0$ , puede ser bidireccional o unidireccional.

$$H_1: \bar{Y} \neq Y^*$$

- 2. Método estadístico

- Si  $n > 30$  se puede aproximar por la distribución normal.

$$t = \frac{\bar{y} - Y^*}{s / \sqrt{n}} \quad t_c = t_{1-\alpha/2, n-1}$$

- 3. Regla de decisión

- Rechazar  $H_0$  si  $t > t_c$  ó  $t < -t_c$

57

## Test de Hipótesis

### Test de hipótesis para la media de una muestra

#### Ejemplo:

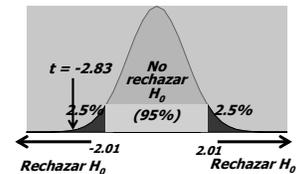
- A partir de una muestra aleatoria de 50 automóviles de un mismo modelo se midió el rendimiento en kilómetros por litro. El rendimiento promedio es de 11.4 km/lt. y la desviación estándar de la muestra es de 1.5. Si las especificaciones técnicas del rendimiento son 12 km/lt., ¿se rechaza o no la hipótesis de que las especificaciones son verdaderas?

$$H_0: \bar{Y} = 12$$

$$H_1: \bar{Y} \neq 12$$

=TINV(0.05,49)

$$t = \frac{\bar{y} - Y^*}{s / \sqrt{n}} = \frac{11.4 - 12}{1.5 / \sqrt{50}} = -2.83 \quad t_c = t_{97.5\%, 49} = 2.01$$



- Se rechaza  $H_0$  pues  $t < -t_c$

58

## Test de Hipótesis

### Test de hipótesis para las medias de dos muestras

- 1. Definición de Hipótesis

- Hipótesis Nula o Indiferente: Lo que se quiere probar.

$$H_0: \bar{Y}_1 = \bar{Y}_2$$

- Hipótesis Alternativa: Compite con la  $H_0$ , puede ser bidireccional o unidireccional.

$$H_1: \bar{Y}_1 \neq \bar{Y}_2$$

- 2. Método estadístico

$$t = \frac{\bar{y}_1 - \bar{y}_2}{s_{\bar{y}_1 - \bar{y}_2}} \quad s_{\bar{y}_1 - \bar{y}_2} = \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}} \quad t_c = t_{1-\alpha/2, n_1 + n_2 - 2}$$

- Si  $n > 30$  se puede aproximar por la distribución normal.

- 3. Regla de decisión

- Rechazar  $H_0$  si  $t > t_c$  ó  $t < -t_c$

59

## Test de Hipótesis

### Test de hipótesis para las medias de dos muestras

#### Ejemplo:

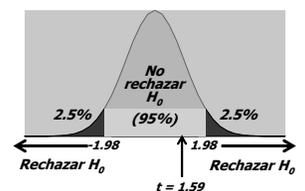
- Dos muestras aleatorias de 50 y 75 automóviles, cada una de un modelo diferente. Se midió el rendimiento en kilómetros por litro en cada grupo. El rendimiento promedio para el primer grupo fue de 11.4 km/lt y de 10.9 km/lt para el segundo. Las desviaciones estándar de cada muestra fueron de 1.5 y 2. ¿Se rechaza o no la hipótesis que ambos modelos tienen el mismo rendimiento?

$$H_0: \bar{Y}_1 = \bar{Y}_2 \quad H_1: \bar{Y}_1 \neq \bar{Y}_2$$

$$s_{\bar{y}_1 - \bar{y}_2} = \sqrt{\frac{1.5^2}{50} + \frac{2^2}{75}} = 0.314 \quad t = \frac{11.4 - 10.9}{0.314} = 1.59$$

=TINV(0.05,123)

$$t_c = t_{97.5\%, 123} = 1.98$$



- Se acepta  $H_0$  pues  $t < t_c$

60

## Test de Hipótesis

### Test de hipótesis para medias con más de dos muestras (ANOVA, análisis de varianza)

#### 1. Definición de Hipótesis

- Hipótesis Nula o Indiferente: Lo que se quiere probar.

$$H_0: \bar{Y}_1 = \bar{Y}_2 = \dots = \bar{Y}_k$$

- Hipótesis Alternativa: Compite con la  $H_0$ , puede ser bidireccional o unidireccional.

$$H_1: \exists i / \bar{Y}_i \neq \bar{Y}_j$$

#### 2. Método estadístico

$$F = \frac{\left[ \frac{BSS}{k-1} \right] / \left[ \frac{WSS}{n-k} \right]}{\frac{\sum_{i=1}^n \sum_{j=1}^k (y_{ij} - \bar{y})^2}{\sum_{i=1}^n n_i (\bar{y}_i - \bar{y})^2} + \sum_{i=1}^n \sum_{j=1}^k (y_{ij} - \bar{y}_i)^2} = F_{1-\alpha, k-1, n-k}$$

Suma total de los cuadrados (TSS)      Entresuma de los cuadrados (BSS)      Suma interna de los cuadrados (WSS)

#### 3. Regla de decisión

- Rechazar  $H_0$  si  $F > F_c$

61

## Test de Hipótesis

### Test de hipótesis para medias con más de dos muestras

#### 2. Método estadístico

i	Alternativa 1	Alternativa 2	Alternativa 3	Alternativa 4	Alternativa 5
1	0	3	5	9	7
2	1	2	7	10	8
3	2	1	4	10	8
4	1	2	4	7	5
5	1	2	5	9	7
$\bar{y}$	4.8				

i	Alternativa 1	Alternativa 2	Alternativa 3	Alternativa 4	Alternativa 5
1	23.04	3.24	0.04	17.64	4.84
2	14.44	7.84	4.84	27.04	10.24
3	7.84	14.44	0.64	27.04	10.24
4	14.44	7.84	0.64	4.84	0.04
TSS	201.2				

	Alternativa 1	Alternativa 2	Alternativa 3	Alternativa 4	Alternativa 5
BSS	178.2	31.36	0.16	70.56	19.36

i	Alternativa 1	Alternativa 2	Alternativa 3	Alternativa 4	Alternativa 5
1	1	1	0	0	0
2	0	0	4	1	1
3	1	1	1	1	1
4	0	0	1	4	4
WSS	22				

#### 3. Regla de decisión

- Se rechaza  $H_0$  pues  $F > F_c$   $F = \frac{179.2}{5-1} / \frac{22}{20-5} = 30.55$   $F_c = F_{95\%, 4, 15} = 3.06$

=FINV(0.05,4,15)

62

## Test de Hipótesis

### Test de hipótesis para la varianza de dos muestras

#### 1. Definición de Hipótesis

- Hipótesis Nula o Indiferente: Lo que se quiere probar.

$$H_0: \sigma_1^2 = \sigma_2^2$$

- Hipótesis Alternativa: Compite con la  $H_0$ , puede ser bidireccional o unidireccional.

$$H_1: \sigma_1^2 \neq \sigma_2^2$$

#### 2. Método estadístico

$$F = \frac{\sigma_1^2}{\sigma_2^2}, \text{ con } \sigma_1^2 > \sigma_2^2 \quad F_c = F_{1-\alpha, n_1-1, n_2-2}$$

#### 3. Regla de decisión

- Rechazar  $H_0$  si  $F > F_c$

63

## Test de Hipótesis

### Test de hipótesis para la varianza de dos muestras

#### Ejemplo:

- Se desea saber si hay diferencia entre hombres y mujeres fumadores en la varianza del consumo de cigarrillos. Para ello se tomó una muestra de 149 hombres y 139 mujeres, con consumos promedio de 24.21 y 24.92 cigarrillos por semana y desviaciones estándar de 4.9 y 4.79 respectivamente.

$$H_0: \sigma_m^2 = \sigma_f^2 \quad H_1: \sigma_m^2 \neq \sigma_f^2$$

$$F = \frac{4.9^2}{4.79^2} = 1.05$$

$$F_c = F_{95\%, 148, 138} = 1.32$$

=FINV(0.05,148,138)

- Se acepta  $H_0$  pues  $F < F_c$

64

## Test de Hipótesis

### Muestras relacionadas

- Cuando medimos en una misma muestra en distintos momentos del tiempo tendremos dos muestras que son dependientes.
- Normalmente entre ambas mediciones ha ocurrido un evento que afecta la medición (ej. publicidad).

### Test de hipótesis para la media entre dos muestras relacionadas

#### 1. Definición de Hipótesis

$$H_0: \bar{Y}_1 = \bar{Y}_2$$

$$H_1: \bar{Y}_1 \neq \bar{Y}_2$$

#### 2. Método estadístico

$$t = \frac{\sum d_i / n}{s_d / \sqrt{n}} \quad d_i = y_{i2} - y_{i1} \quad t_c = t_{1-\alpha/2, n-1}$$

#### 3. Regla de decisión

- Rechazar  $H_0$  si  $t > t_c$  ó  $t < -t_c$

65

## Test de Hipótesis

### Test de hipótesis para la media entre dos muestras relacionadas

#### Ejemplo:

- Se midió la actitud positiva de compra antes y después de la publicidad en una muestra de 10 personas. ¿Qué se puede concluir de los resultados del experimento?

n	Actitud Previa (y1)	Actitud Posterior (y2)	d
1	50	53	3
2	25	27	2
3	30	38	8
4	50	55	5
5	60	61	1
6	80	85	5
7	45	45	0
8	30	31	1
9	65	72	7
10	70	78	8
Promedio	50.5	54.5	4
desv. Est.	18.48	19.73	3.02

$$t = \frac{4}{3.02 / \sqrt{10}} = 4.19$$

$$t_c = t_{97.5\%, 9} = 2.26$$

=TINV(0.05,9)

- Como  $t > t_c$  entonces se rechaza  $H_0$ . Es decir, la publicidad tiene un efecto estadísticamente significativo en la actitud de compra.

66

## Test de Hipótesis

### Test de hipótesis para la media entre dos muestras relacionadas

#### Ejemplo:

- ¿Y si hubiésemos elegido el test para medias con muestras independientes?

$$s_{\bar{y}_1 - \bar{y}_2} = \sqrt{\frac{18.48^2}{10} + \frac{19.73^2}{10}} = 8.55 \quad t = \frac{\bar{y}_1 - \bar{y}_2}{s_{\bar{y}_1 - \bar{y}_2}} = \frac{50.5 - 54.5}{8.55} = -0.468 \quad t_c = t_{97.5\%, 18} = 2.10$$

=TINV(0.05,18)

- En este caso habríamos aceptado  $H_0$  y concluido que no hay diferencia en la conducta de presentar una actitud positiva hacia la compra antes y después de la publicidad.

67

## Test de Hipótesis

### Test de hipótesis para las proporciones entre dos muestras relacionadas

#### 1. Definición de Hipótesis

$$H_0: P_1 \geq P_2$$

$$H_1: P_1 < P_2$$

#### 2. Método estadístico

$$z = \frac{p_2 - p_1}{\left[ \frac{b+c - \{(b-c)^2/n\}}{n(n-1)} \right]^{1/2}}$$

		Antes		Total
		Sí	No	
Después	Sí	a	b	a+b
	No	c	d	c+d
Total		a+c	b+d	a+b+c+d

$$z_c = z_{1-\alpha}$$

#### 3. Regla de decisión

- Rechazar  $H_0$  si  $Z > Z_c$

68

## Test de Hipótesis

### Test de hipótesis para las proporciones entre dos muestras relacionadas

#### Ejemplo:

- Se midió la disposición a la compra antes y después de la publicidad en una muestra de 100 personas. ¿Qué se puede concluir de los resultados del experimento?

		ANTES		
		SÍ	NO	TOTAL
DESPUÉS	SÍ	23	7	30
	NO	2	68	70
TOTAL		25	75	100

$$z = \frac{0.30 - 0.25}{\left[ \frac{7 + 2 - \{(7-2)^2/100\}}{100 \cdot 99} \right]^{1/2}} = 1.68$$

$$z_c = z_{95\%} = 1.64$$

=NORMSINV(0.95)

- Como  $Z > Z_c$  entonces se rechaza  $H_0$ .

69