

BIOESTADÍSTICA BÁSICA

**Pruebas Paramétricas:
DISTRIBUCIÓN T/ F/
CORRELACIÓN PEARSON**

CLASE 4

**LIBRO DE EPIDEMIOLOGÍA Y ESTADÍSTICA
(ANTONIO VILLA ET AL)**

CAPITULO 16 - 17 -18

PRUEBAS PARAMÉTRICAS



Las pruebas paramétricas son una herramienta estadística que se utiliza para el análisis de los factores de la población.

Su cálculo implica una estimación de los parámetros de la población con base en muestras estadísticas.

Determinar las hipótesis planteadas.

COMPARACIÓN DE MEDIAS

USE LA DISTRIBUCIÓN Z

USE LA DISTRIBUCIÓN t

$$\bar{X} \pm z \frac{\sigma}{\sqrt{n}}$$

Si la desviación estándar es conocida o la muestra es >30

Si la desviación estándar no es conocida o la muestra es <30

$$\bar{X} \pm t \frac{s}{\sqrt{n}}$$

PERO ANTES, SE DEBE CONOCER A LA T DE
STUDENT

DISTRIBUCIÓN T


Cuando se requieren comparaciones de dos promedios se utiliza la distribución t.

A diferencia de la normal (Z), existen múltiples distribuciones t para cada tamaño.

Aquí aparece el concepto

GRADOS DE LIBERTAD:

El número de formas independientes por las que un sistema dinámico puede moverse.



La distribución T difiere de la de Z en que la varianza de t depende del tamaño de la muestra y siempre es mayor a uno.



Grados de libertad: $n-1$

CONTRASTES DE HIPÓTESIS

UNA MUESTRA
DOS MUESTRAS

UNA MUESTRA: Compara la media con un valor establecido, no con otra muestra.

A

One Sample Mean

```
graph TD; A[One Sample Mean] --> B[Test Statistic when sigma known]; A --> C[Test Statistic when sigma unknown];
```

Test Statistic when σ known

$$z = \frac{\bar{x} - \mu}{\left(\frac{\sigma}{\sqrt{n}} \right)}$$

\bar{x} : sample mean

μ : population mean

σ : population standard deviation

n : sample size

Test Statistic when σ unknown

$$t = \frac{\bar{x} - \mu}{\left(\frac{s}{\sqrt{n}} \right)}, \quad df = n - 1$$

\bar{x} : sample mean

μ : population mean

s : sample standard deviation

n : sample size

HIPÓTESIS

$$H_0: \mu = \mu_0$$

$$H_1: \mu < \mu_0 \quad \text{Unilateral izquierda (inferior)}$$

$$H_1: \mu > \mu_0 \quad \text{Unilateral derecha (superior)}$$

$$H_1: \mu \neq \mu_0 \quad \text{Bilateral}$$

REGLAS DE DECISIÓN

Bilateral

$$T_0 \geq T_c$$
$$-T_0 \leq -T_c$$

**Unilateral
Derecha**

$$T_0 > T_c$$


**Unilateral
Izquierda**

$$-T_0 < -T_c$$

Contraste bilateral (2 colas)

$$H_0 : \mu = \mu_0$$


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



Contraste unilateral (cola de la izquierda)

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

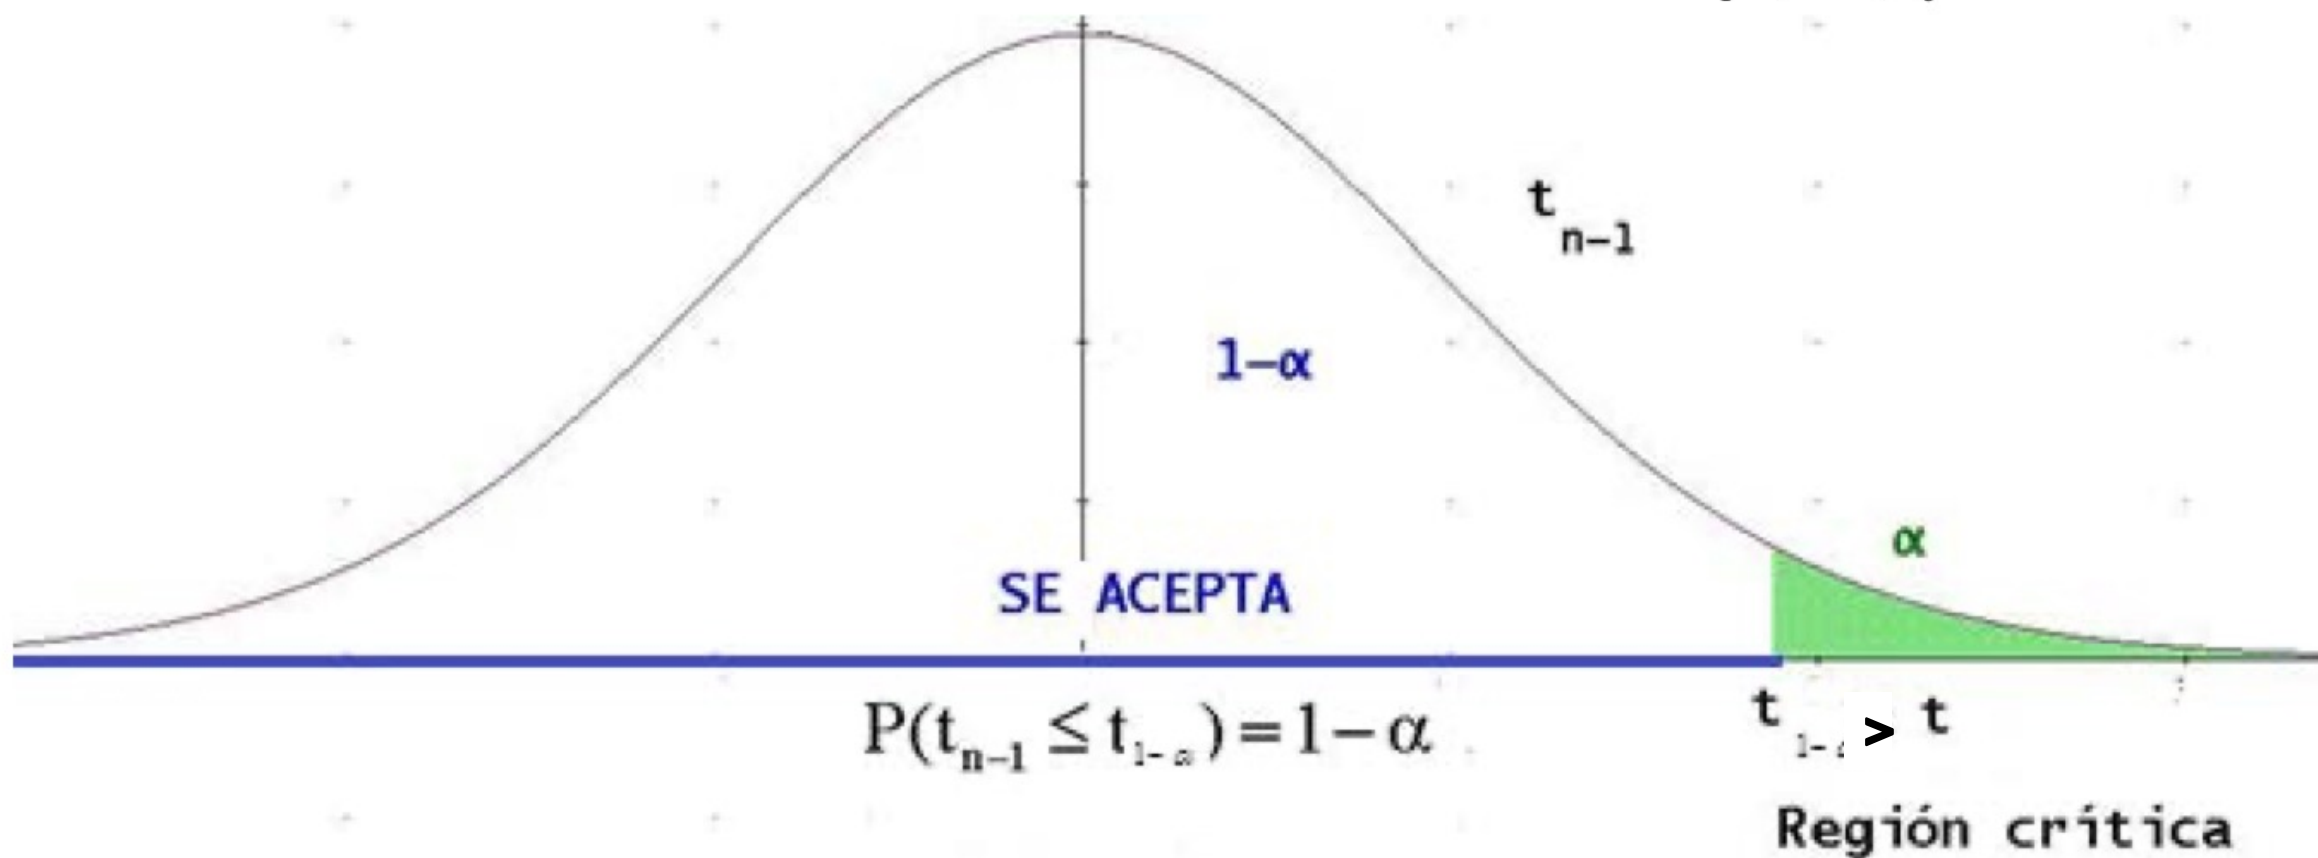
$$H_1 : \mu < \mu_0$$



Contraste unilateral (cola de la derecha)

$$H_0 : \mu \leq \mu_0$$

$$H_1 : \mu > \mu_0$$



La dirección médica de una clínica privada en Guayaquil, toma una muestra aleatoria de 16 mediciones sobre el tiempo de hospitalización, la media es de 5.4 días y una sd de 3.1 días. La dirección médica supone que el promedio de tiempo de hospitalización es mayor de 5 días. ¿Esta afirmación es correcta? Utiliza un nivel de significancia del 5%.

$$H_0: \mu \leq 5$$

$$H_1: \mu > 5$$

Un farmacéutico en Cuenca, toma una muestra aleatoria de 12 sobres de un medicamento. El peso promedio de cada sobre es de 15.97grs, y la sd es de 0,15. Una farmacéutica reconocida afirma que el peso promedio mínimo del medicamento es de 16grs por sobre. ¿Esta afirmación es correcta? Utiliza un nivel de confianza del 90%.

$$H_0: \mu \geq 16$$

$$H_1: \mu < 16$$

PRUEBA DE HIPOTESIS SOBRE LA MEDIA DE UNA DISTRIBUCIÓN NORMAL, VARIANZA DESCONOCIDA

LA EEQ publica cifras del número anual de Kilowatt-hora que gastan varios aparatos electrodomésticos. Se afirma que una aspiradora gasta un promedio de 46 kilowatt-hora al año. Si una **muestra aleatoria** de 12 hogares que se incluye en un estudio planeado indica que las aspiradoras gastan un promedio de 42 kilowatt-hora al año con una desviación estándar de 11.9 kilowatt-hora, ¿esto **sugiere** con un nivel de significancia de 0.05 que las aspiradoras gastan, en promedio, **menos de** 46 kilowatt-hora anualmente? Suponga que la población de kilowatt-hora es normal.


HIPÓTESIS

$$H_0: \mu = 46 \text{kw/h}$$

$$H_1: \mu < 46 \text{kw/h}$$

REGLAS DE DECISIÓN

$$t = \frac{\bar{x} - \mu_0}{s / \sqrt{n}}$$



$$t = \frac{42 - 46}{11.9 \div \sqrt{12}} = -1,16$$

T crítico

t test M5.xlsx

H_1



Región de rechazo

H_0

$\alpha = 0.05$

Región de aceptación

$t_L = -1.796$

$\mu = 46$

Como $-1.16 > -1.796$, por lo tanto se acepta la H_0 .

Se concluye que con un nivel de significancia del 0.05, el número promedio de kilowatt-hora que gastan al año las aspiradoras, sí es = 46.

DOS MUESTRAS: Compara la media entre dos muestras (A y B).



PAREADAS E INDEPENDIENTES

Grupos pareados/
correlacionados: dispone de
dos conjuntos de datos
cuantitativos continuos que
pertencen a un mismo grupo
de individuos.

Grupos independientes:
dispone de datos
cuantitativos continuos de
dos diferentes grupos de
individuos, no están
correlacionados.

Two Sample Means

Test Statistic when σ known

$$z = \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}$$

$$F = \frac{s_1^2}{s_2^2} = \frac{\text{larger variance}}{\text{smaller variance}}$$

If $F \leq t_{(\alpha, df)}^*$, then pool

If $F > t_{(\alpha, df)}^*$, then don't pool

HOMOCEDASTICIDAD

HETEROCEDASTICIDAD

Test Statistic when σ unknown
With **pooled** variances

$$t = \frac{(\bar{x}_1 - \bar{x}_2)}{\left(\sqrt{\frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}} \right) \left(\sqrt{\frac{1}{n_1} + \frac{1}{n_2}} \right)}$$

$$df = n_1 + n_2 - 2$$

Test Statistic when σ unknown
with **un-pooled** variances

$$t = \frac{(\bar{x}_1 - \bar{x}_2)}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$$

$$df = \frac{\left(\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2} \right)^2}{\left(\frac{1}{n_1 - 1} \right) \left(\frac{s_1^2}{n_1} \right)^2 + \left(\frac{1}{n_2 - 1} \right) \left(\frac{s_2^2}{n_2} \right)^2}$$

\bar{x}

1 y 2 = Media muestral del grupo 1 y grupo 2

n

1 y 2 = número de observaciones del grupo 1 y grupo 2

s^2


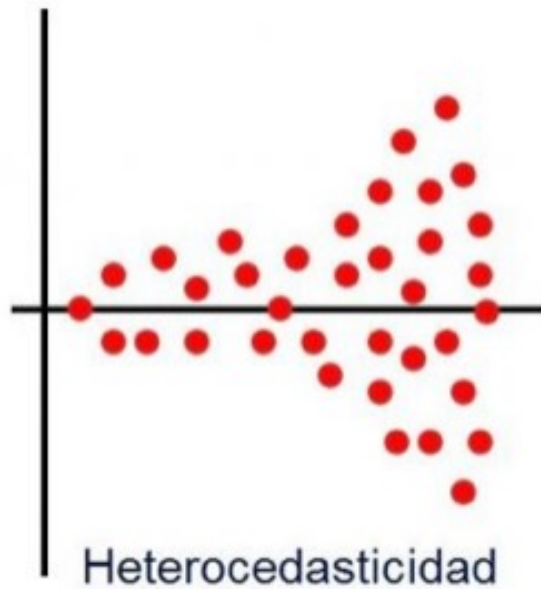
1 y 2 = varianza del grupo 1 y grupo 2

CONSIDERAR:

HETEROCEDASTICIDAD:



Se conoce con el nombre de Prueba t heterocedasticidad (test de Welch).



ENTONCES, SI EL EJERCICIO TIENE: 2 MUESTRAS + 2 MEDIAS MUESTRALES + 2 VARIANZAS

1. DETERMINAR NORMALIDAD DEL DATO

2. OBTENER EL F TEST PARA DETERMINAR HOMOCEDASTICIDAD O HETEROCEDASTICIDAD

3. EN FUNCIÓN DEL PASO 2, ELEGIR LA FORMULA CORRECTA DE T.

4. EN FUNCIÓN DEL PASO 2 Y 3, ELEGIR LA FORMULA DE LOS GRADOS DE LIBERTAD

5. COMPARAR EL T OBS CON EL T CRITICO

EXCEL =INV.T(0,05, GL)

PASO 2

F-TEST (RAZÓN DE VARIANZAS) *F* de Snedecor

El F-test, también conocido como contraste de la razón de varianzas, contrasta la hipótesis nula de que dos poblaciones normales tienen la misma varianza.


H0: Homocedasticidad

H1: Heterocedasticidad


El F-test estudia el cociente de varianzas

LA PRUEBA F QUE DIVIDE LA VARIANZA MÁS GRANDE ENTRE LA VARIANZA MAS PEQUEÑA

$$F_{obs} = \text{Varianza más grande} \div \text{Varianza más pequeña}$$



Para decidir si existe homocedasticidad, el valor de F_{obs} debe compararse con el valor




Si $F_{\text{obs}} > F_{\text{crítico}}$

Rechazo la H_0 y concluyo que hay heterocedasticidad.



Gl de F= n-1



Se desea evaluar si existe homocedasticidad entre las varianzas de dos grupos a los cuales, después, se les evaluará si existe una posible diferencia estadística entre sus promedios.

1. Primer grupo, esta formado por 16 personas, con una varianza de 7,75
2. Segundo grupo, esta formado por 11 personas, con una varianza de 2,18

$$F_{\text{obs}} = 7,75/2,18 = 3,56$$

➔ Al grupo con mayor varianza $n=16$ le corresponden: $gl = n-1$ $16-1 = 15$ $n1=15$

➔ Al grupo con menor varianza $n=11$ le corresponden $gl = n-1$ $11-1 = 10$ $n2=10$

[t test.xlsx](#)

$F_{\text{obs}} > F_{\text{crítico}}$

Heterocedasticidad = Test de Welch

PASO 3

ELEGIR LA FÓRMULA CORRECTA PARA EL T OBSERVADO

$$t = \frac{(\bar{x}_1 - \bar{x}_2)}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$$

PASO 4

ELEGIR LA FÓRMULA CORRECTA PARA EL T CRITICO

$$df = \frac{\left(\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2} \right)^2}{\left(\frac{1}{n_1 - 1} \right) \left(\frac{s_1^2}{n_1} \right)^2 + \left(\frac{1}{n_2 - 1} \right) \left(\frac{s_2^2}{n_2} \right)^2}$$



CALCULAR EN EXCEL =INV.T(0,05, GL)

La fórmula para calcular los grados de libertad para la prueba t de Welch se tiene en cuenta la diferencia entre las dos desviaciones estándar.

Sin embargo, si las dos muestras tienen las mismas desviaciones estándar, entonces los grados de libertad para la prueba t de Welch serán exactamente los mismos que los grados de libertad para la prueba t de Student

PASO 5

CONTRASTAR LA HIPÓTESIS

$$H_0 = \overline{XA} = \overline{XB}$$

Igualdad de medias

$$H_1 = \overline{XA} \neq \overline{XB}$$

Diferencia de medias

$t_{ob} > t_{cri}$ rechazo la H_0

- $t_{ob} < -t_{cri}$ rechazo la H_0




**APLICA PARA LOS DOS
(HOMOCEDASTICIDAD Y
HETEROCEDASTICIDAD)**

ENLACE DE T TEST

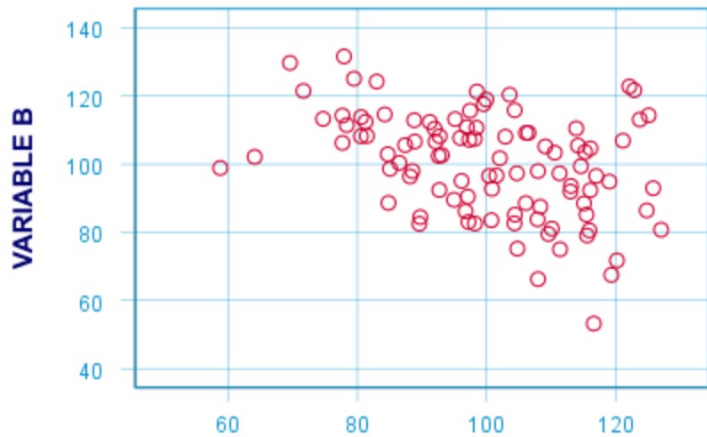
https://www.cienciadedatos.net/documentos/12_t-test




EJERCICIO EN EXCEL




CORRELATION = -0.4 **N = 100**



CORRELATION = 0.5 **N = 100**



CORRELATION = -0.6 **N = 100**



@www.ense_tutoriales.com

COEFICIENTES DE CORRELACIÓN

PEARSON

- **Relación o Asociación lineal entre dos variables cuantitativas u ordinales.**

- Los coeficientes de correlación de valores absolutos que oscilan entre -1 y 1. Hay que tomar en cuenta que tienen signos.

- Donde -1 y 1 indican correlaciones perfectas, negativas y positivas respectivamente
- 0 indica correlación nula.

OJO: CORRELACION NO ES CAUSALIDAD

TOMAR EN CUENTA

La magnitud o fuerza de la relación está especificada por el valor numérico del coeficiente, y el signo refleja la dirección de tal valor.



Dependiendo el signo (- o +), se especificará una relación perfecta negativa o positiva.

→ r es un coeficiente (no tiene unidades)

→ $-1 \leq r \leq 1$

Si $r \approx 1$ existe una correlación directa fuerte

Si $r \approx -1$ existe una correlación inversa fuerte

Si $r = 1$ o $r = -1$ hay una correlación funcional

Si $r \approx 0$ no existe una correlación lineal


COVARIANZA

Es el valor que refleja en qué cuantía dos variables aleatorias varían de forma conjunta respecto a sus medias.


Nos permite saber cómo se comporta una variable en función de lo que hace otra variable.

Por ejemplo:
cuando X sube
¿Cómo se comporta Y ?

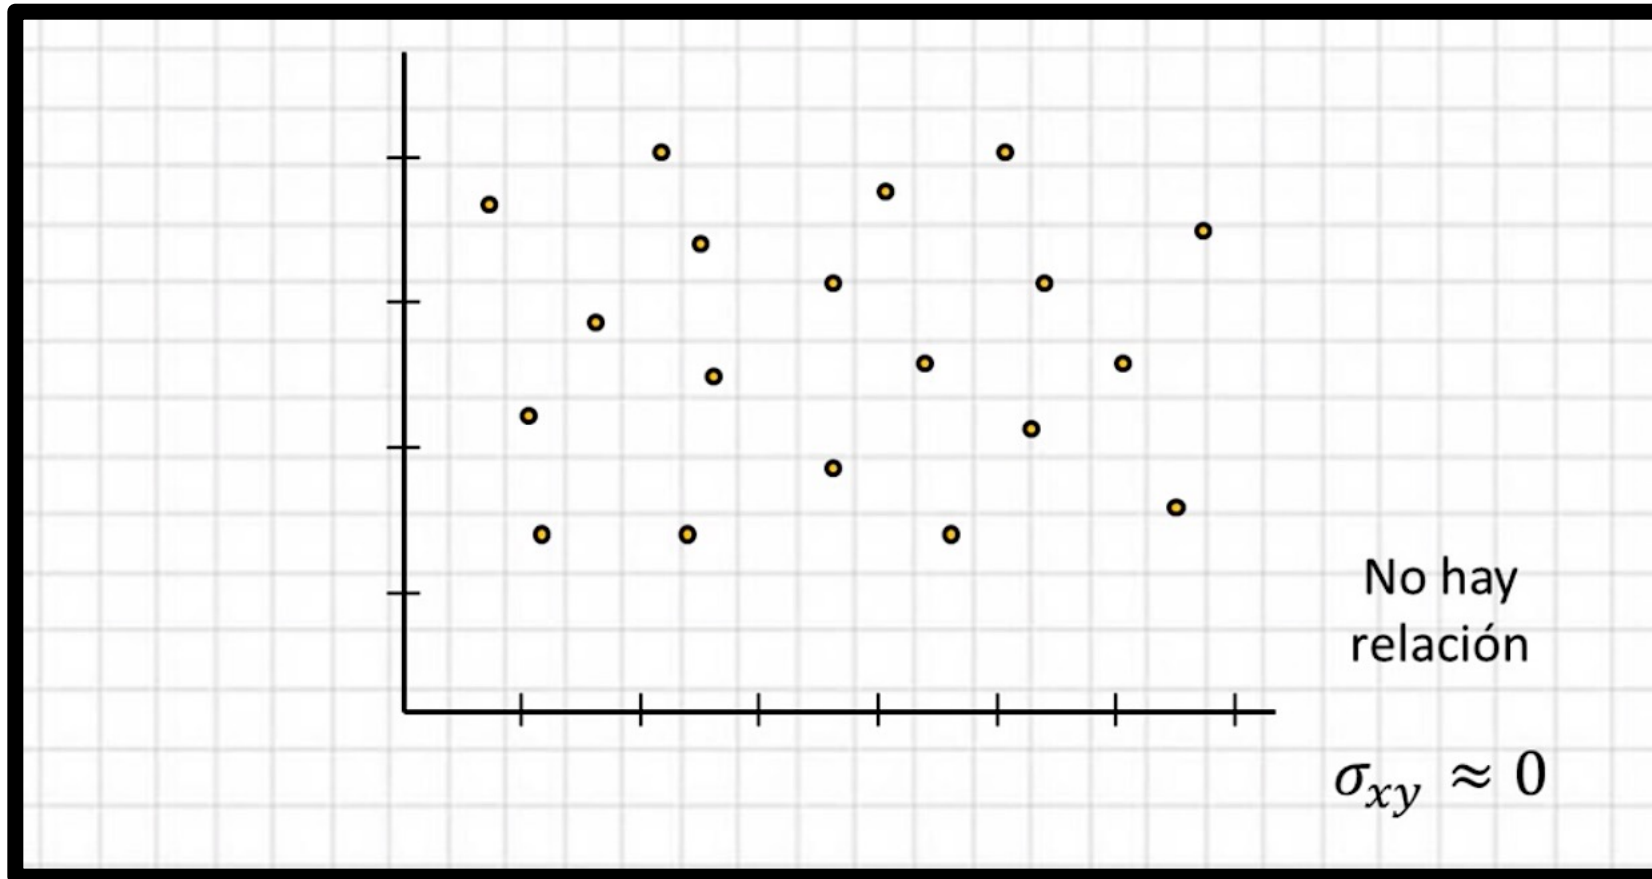
Cuando entre las dos variables hay una **relación directa**, la **covarianza** da un valor **positivo**




Cuando entre las dos variables hay una **relación inversa**, la **covarianza** da un valor **negativo**



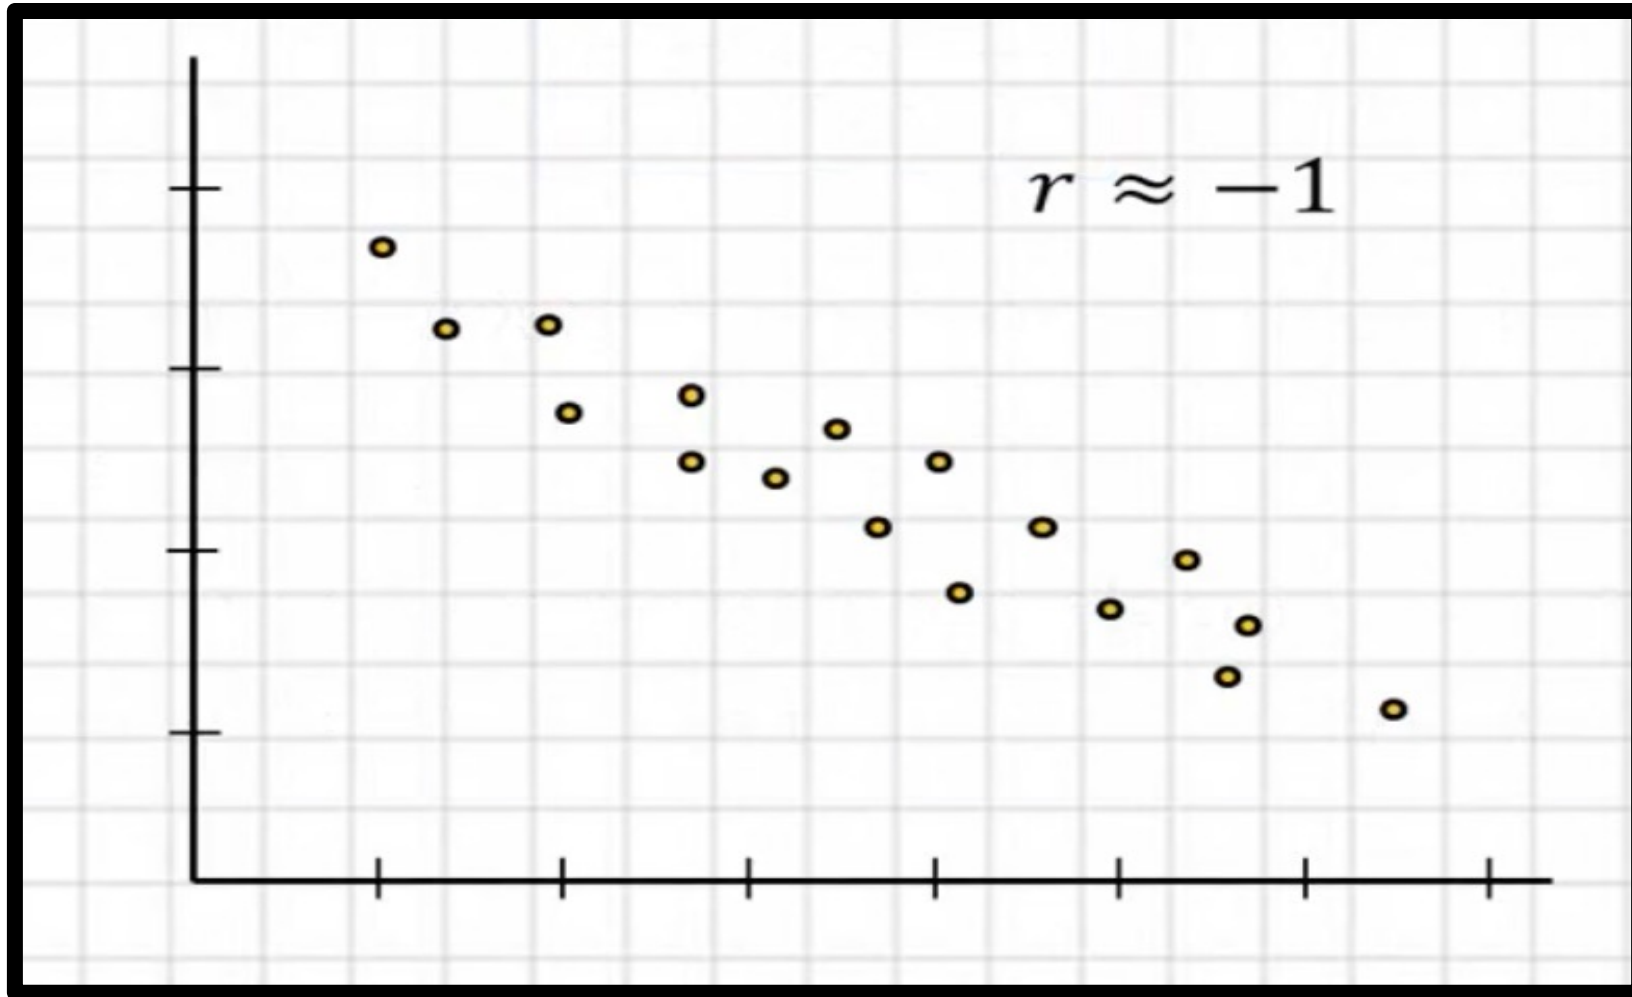
Cuando entre las dos variables **no hay una relación**, la **covarianza** da un valor **en torno a cero**




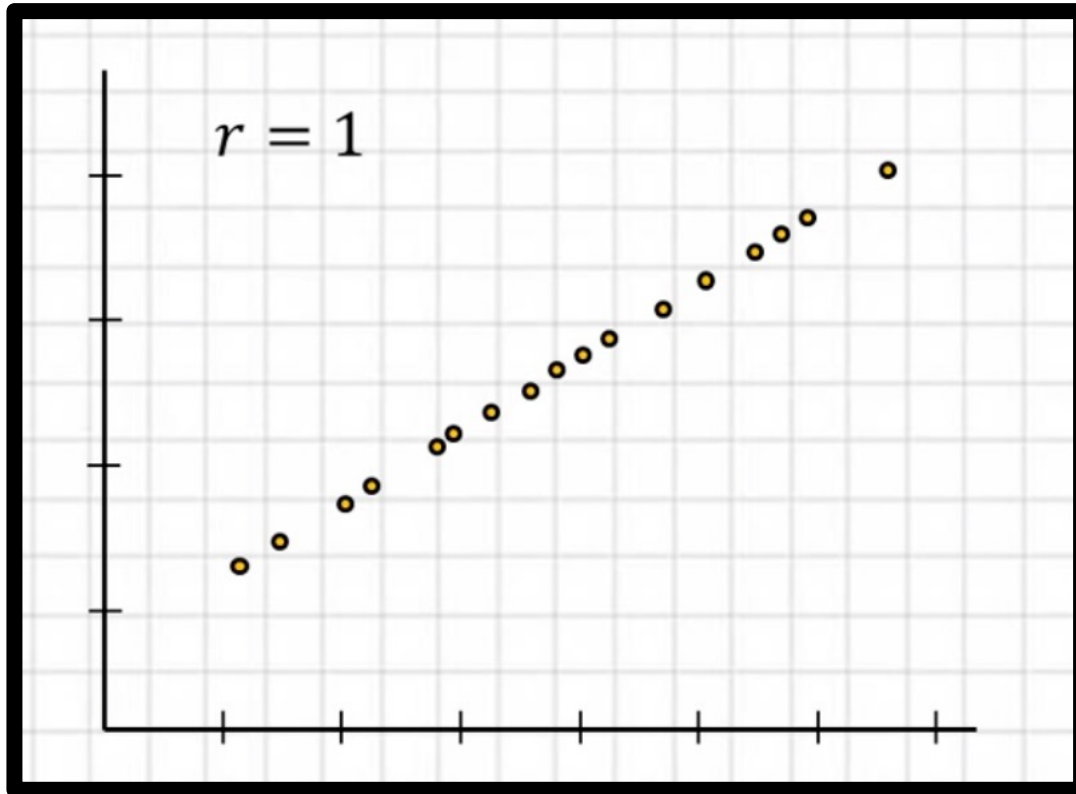
Si $r \approx 1$ existe una correlación directa fuerte





Si $r \approx -1$ existe una correlación inversa fuerte



Si $r = 1$ o $r = -1$ hay una correlación funcional



Si $r \approx 0$ no existe una correlación lineal



COEFICIENTE PARAMÉTRICAS

Se usa cuando las variables a comparar son CUANTITATIVAS.

✓ PEARSON

COEFICIENTE NO PARAMÉTRICAS

Se usa cuando una o ambas variables son de escala ordinal, o cuando las variables cuantitativas no siguen una distribución normal.

✓ SPEARMAN

CONSIDERAR LO SIGUIENTE:

FORMULACIÓN DE HIPÓTESIS

Ho: No hay correlación

H1: Si hay correlación

NIVEL DE SIGNIFICANCIA

5%, $p=0.05$

INDICE Y EL NIVEL DE CORRELACIÓN

0.00-0.099 = nula

0.10-0.40 = escasa


0.40-0.60= moderada

0.60-0.80= buena

0.80-1.0= fuerte

PEARSON

$$r_{xy} = \frac{\frac{\sum XY}{N} - \bar{X}\bar{Y}}{S_x S_y}$$



$$S_x = \sqrt{\frac{\sum X^2}{N} - \bar{X}^2}$$
$$S_y = \sqrt{\frac{\sum Y^2}{N} - \bar{Y}^2}$$

X	Y	X²	Y²	XY
105	4			
116	8			
103	2			
124	7			
137	9			
126	9			
112	3			
129	10			
118	7			
105	6			
1175	65			

X	Y	X ²	Y ²	XY
105	4	11025	16	420
116	8	13456	64	928
103	2	10609	4	206
124	7	15376	49	868
137	9	18769	81	1233
126	9	15876	81	1134
112	3	12544	9	336
129	10	16641	100	1290
118	7	13924	49	826
105	6	11025	36	630
1175	65	139245	489	7871



$$\bar{X} = \frac{\sum X}{N} =$$

$$\bar{Y} = \frac{\sum Y}{N} =$$

$$\bar{X} = \frac{\sum X}{N} = \frac{1175}{10} = 117.5$$

$$\bar{Y} = \frac{\sum Y}{N} = \frac{65}{10} = 6.5$$

X	Y	X ²	Y ²	XY
105	4	11025	16	420
116	8	13456	64	928
103	2	10609	4	206
124	7	15376	49	868
137	9	18769	81	1233
126	9	15876	81	1134
112	3	12544	9	336
129	10	16641	100	1290
118	7	13924	49	826
105	6	11025	36	630
1175	65	139245	489	7871



$$S_x = \sqrt{\frac{\sum X^2}{N} - \bar{X}^2} =$$

$$S_y = \sqrt{\frac{\sum Y^2}{N} - \bar{Y}^2} =$$

$$S_x = \sqrt{\frac{\sum X^2}{N} - \bar{X}^2} = \sqrt{\frac{139245}{10} - 117.5^2} = 10.874$$

$$S_y = \sqrt{\frac{\sum Y^2}{N} - \bar{Y}^2} = \sqrt{\frac{489}{10} - 6.5^2} = 2.579$$

X	Y	X ²	Y ²	XY
105	4	11025	16	420
116	8	13456	64	928
103	2	10609	4	206
124	7	15376	49	868
137	9	18769	81	1233
126	9	15876	81	1134
112	3	12544	9	336
129	10	16641	100	1290
118	7	13924	49	826
105	6	11025	36	630
1175	65	139245	489	7871



$$r_{xy} = \frac{\frac{\sum XY}{N} - \bar{X}\bar{Y}}{S_x S_y} =$$

$$r_{xy} = \frac{\frac{\sum XY}{N} - \bar{X}\bar{Y}}{S_x S_y} = \frac{\frac{7871}{10} - 117.5 * 6.5}{10.874 * 2.579} = 0.8327$$

EJERCICIO EN EXCEL

MUJERES INDÍGENAS RURALES