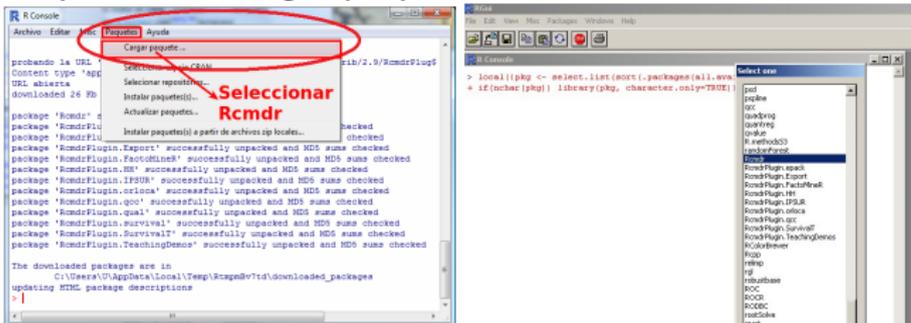


# Práctica 4. Contrastes para dos muestras

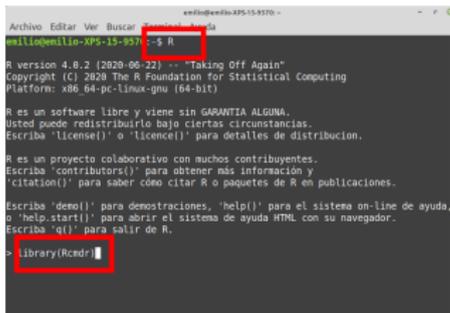
Departamento de Estadística  
Universidad de Oviedo

# Cargar el programa R y el paquete Rcommander

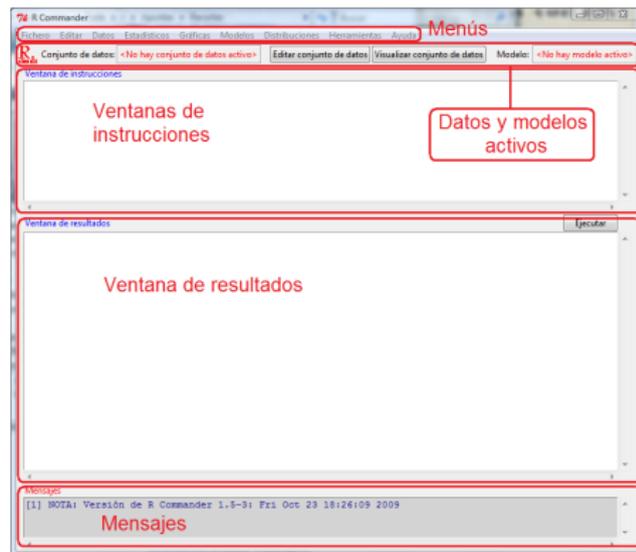
- Iniciamos el programa R.
- Cargamos el paquete RCommander. Dos opciones:
  - 1 Menú *Paquetes* → *Cargar paquete* → Seleccionamos **Rcmdr**.



- 2 Escribimos **library(Rcmdr)** en la consola y pulsamos retorno de carro.



# Cargar Rcommander

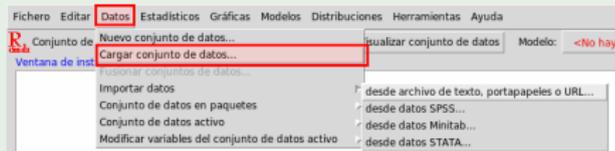


El fichero `acero.rda` se encuentra en el Campus Virtual. Hay que haberlo descargado previamente.

## Cargar la base de datos `acero.rda`

Datos

- ➔ Cargar conjunto de datos
- ➔ Seleccionar **`acero.rda`**



```
> load("/home/emilio/clases/acero.rda")
```

NOTA: El conjunto de datos `acero` tiene 117 filas y 20 columnas.

- Para visualizar la base de datos:

R Commander

Fichero Editar Datos Estadísticos Gráficas Modelos Distribuciones Herramientas Ayuda

Conjunto de datos: **acero** Editar conjunto de datos **Visualizar conjunto de datos** Modelo: modelo.maximo.c

Ventana de instrucciones

```
library(relimp, pos=4)
```

	consumo	pr.tbc	pr.cc	pr.ca	pr.galv1	pr.galv2	pr.pint	linea	averia	hora	r
1	135.311	6840	830	0	579	1401	0	1	Si	1	
2	84.082	443	903	58	611	1635	717	1	No	2	
3	131.615	7270	572	36	982	1969	243	1	No	3	
4	90.460	5031	694	122	896	1568	0	1	No	4	
5	120.043	9365	1054	157	403	1480	0	1	No	5	
6	153.678	9281	1003	172	605	1525	473	1	Si	6	
7	99.089	3223	1118	0	643	1424	732	1	No	7	
8	226.375	10490	1077	179	737	1333	93	1	No	8	
9	140.068	7394	1204	167	580	924	247	1	No	9	

Aparece una ventana con los datos disponibles. Moviendo el cursor hacia la izquierda o hacia abajo podemos recorrer toda la base de datos.

Tiene 20 variables (columnas)

Dispone de 117 observaciones (filas)

# Variables de la base de datos `acero`

- 1 `consumo` Consumo energético de la empresa (Megavatios/hora).
- 2 `pr.tbc` Producción del tren de bandas calientes (Toneladas de acero).
- 3 `pr.cc` Producción de colada continua (Toneladas de acero).
- 4 `pr.ca` Producción del convertidor de acero (Toneladas de acero).
- 5 `pr.galv1` Producción de galvanizado de tipo I (Tns. de acero).
- 6 `pr.galv2` Producción de galvanizado de tipo II (Tns. de acero).
- 7 `pr.pint` Producción de chapa pintada (Tns. de acero).
- 8 `linea` Línea de producción empleada (A o B).
- 9 `turno` Turno de mañana (M), tarde (T), noche (N).
- 10 `temperatura` Temperatura del sistema: Alta, Media y Baja.
- 11 `pres.aver` Presencia de averías: hubo Averías (A), no hubo averías (NoA).
- 12 `nun.aver` Número de averías detectadas.
- 13 `sistema` Activación de un sistema de detección de sobrecalentamiento: encendido (ON), apagado (OFF).
- 14 ...

## Toma de decisiones

$H_0$  (Hipótesis nula): Todo sigue igual

$H_1$  (Hipótesis alternativa): Se ha producido un cambio

Se rechaza, o no, la hipótesis nula: nunca se afirma que sea cierta.

- p-valor. Cuantifica el grado de compatibilidad de los datos con la  $H_0$ . Si es pequeño, se rechaza  $H_0$ .
- Intervalo de confianza. Cuantifica los límites de la variación. Permite estimar las consecuencias *prácticas* de esa variación.

Es mucho menos informativo decir que la proporción de niñas es significativamente distinta del 50%, que es lo que se deduce del p-valor, que decir que el intervalo de confianza de la proporción de niñas varía entre 48.45% y 48.77% al 95%.

Como ingenieros debemos plantear los distintos escenarios, las probabilidades asociadas y las consecuencias de los mismos.

## Repaso

En la práctica anterior se hicieron tests para una muestra:

- Tests sobre la media poblacional:

¿El consumo medio de alcohol está entre 125 y 225 gramos semanales?

1 Aplicar el test de Shapiro-Wilk sobre normalidad de los datos.

2 ¿Siguen los datos una distribución normal?

Sí → test t de Student para una muestra

No → test de Wilcoxon para una muestra

- Tests sobre porcentajes:
  - Test de proporciones para una muestra.

# Contraste de dos muestras

## Contrastando dos grupos.

¿El consumo de alcohol es mayor entre hombres que entre mujeres?

- Tests sobre proporciones: Test de proporciones para dos muestras.
- Test sobre varianzas: test F (bajo condiciones de normalidad); Levene (no normalidad)
- Tests sobre promedios:
  - 1 Realice el test de Shapiro-Wilk sobre normalidad;
  - 2 ¿Existe normalidad?
    - Sí (test paramétrico); ¿Cómo son las muestras?

Independientes	→	Test t para muestras independientes
Dependientes	→	Test t para muestras pareadas
    - No (test no paramétrico); ¿Cómo son las muestras?

Independientes	→	Test de Wilcoxon para dos muestras
Dependientes	→	Test de Wilcoxon pareado

# Contraste de proporciones

## Contraste de proporciones

Las posibilidades para contrastar las proporciones de dos muestras son:

$H_0 : p_A = p_B$	$H_0 : p_A \geq p_B$	$H_0 : p_A \leq p_B$
$H_1 : p_A \neq p_B$	$H_1 : p_A < p_B$	$H_1 : p_A > p_B$
two.sided	less	greater

siendo  $p_A$  y  $p_B$  las proporciones en el grupo  $A$  y  $B$ , respectivamente.

Ejemplo: ¿El porcentaje de aprobados es el mismo para hombres y para mujeres?

$$\begin{array}{l} H_0 : p_{\text{Hombres}} = p_{\text{Mujeres}} \\ H_1 : p_{\text{Hombres}} \neq p_{\text{Mujeres}} \end{array}$$

o lo que es lo mismo

$$\begin{array}{l} H_0 : p_{\text{Hombres}} - p_{\text{Mujeres}} = 0 \\ H_1 : p_{\text{Hombres}} - p_{\text{Mujeres}} \neq 0 \end{array}$$

Pista. Si la expresión *igual* aparece en la pregunta, entonces ponerla como  $H_0$ . En los demás casos, ponerla como  $H_1$ .

Regla de decisión (Interprete el intervalo de confianza)

- Si p-valor es pequeño, rechazamos  $H_0$ . Por lo tanto,  $H_1$  es cierta.
- Si p-valor es grande, no rechazamos  $H_0$  (esto no implica necesariamente que la hipótesis nula sea cierta).

## ¿El porcentaje de horas en las que hubo averías es menor en la línea A que en la B?

$$\begin{aligned} H_0 &: p_A \geq p_B \text{ (prop. averías igual o mayor en la línea A)} \\ H_1 &: p_A < p_B \end{aligned}$$



$$\begin{aligned} H_0 &: p_A - p_B \geq 0 \\ H_1 &: p_A - p_B < 0 \end{aligned}$$

Estadísticos

↳ Proporciones

↳ Test de proporciones para dos muestras

Seleccionamos  
línea y pres.aver

Opciones

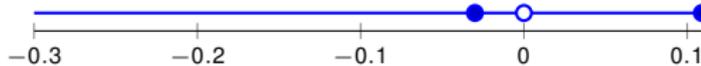
↳ Hipótesis alternativa: **Diferencia < 0**  
(debido a  $p_A - p_B < 0$ )

↳ OK



```
data: .Table
X-squared = 0.0673, df = 1, p-value = 0.3976
alternative hypothesis: less
95 percent confidence interval:
 -1.0000000 0.1095155
sample estimates:
 prop 1 prop 2
0.2295082 0.2500000
Como el p-valor (0.3976) es mayor que  $\alpha$  no se rechaza la hipótesis nula; no hay evidencias de que vaya más averías en la línea A.
```

Intervalo de confianza de la diferencia



## Test F para dos varianzas

Las hipótesis para este test son

$$H_0 : \sigma_A^2 = \sigma_B^2 \text{ (homocedasticidad)}$$

$$H_1 : \sigma_A^2 \neq \sigma_B^2 \text{ (heterocedasticidad)}$$

Regla de decisión (Interprete el intervalo de confianza.)

- Si p-valor es pequeño, rechazamos  $H_0$ . Por lo tanto,  $H_1$  es cierta.
- Si p-valor es grande, no rechazamos  $H_0$  (esto no implica necesariamente que la hipótesis nula sea cierta).

El consumo de alcohol en los hombres, ¿tiene la misma dispersión que el consumo de alcohol en las mujeres?

$$H_0 : \sigma_{\text{Hombres}}^2 = \sigma_{\text{Mujeres}}^2 \text{ (Varianzas iguales de consumo)}$$

$$H_1 : \sigma_{\text{Hombres}}^2 \neq \sigma_{\text{Mujeres}}^2 \text{ (Diferentes)}$$



$$H_0 : \frac{\sigma_{\text{Hombres}}^2}{\sigma_{\text{Mujeres}}^2} = 1$$

$$H_1 : \frac{\sigma_{\text{Hombres}}^2}{\sigma_{\text{Mujeres}}^2} \neq 1$$

## ¿Son iguales las varianzas de los consumos de la línea A y B? (suponiendo normalidad)

$$H_0 : \sigma_A^2 = \sigma_B^2 \text{ (Varianzas iguales de consumo)}$$

$$H_1 : \sigma_A^2 \neq \sigma_B^2 \text{ (Diferentes)}$$

$\Leftrightarrow$

$$H_0 : \frac{\sigma_A^2}{\sigma_B^2} = 1$$

$$H_1 : \frac{\sigma_A^2}{\sigma_B^2} \neq 1$$

Estadísticos

↳ Varianzas

↳ Test F para dos varianzas

Seleccionar variables **línea** y **consumo**

↳ OK



F test to compare two variances

data: consumo by linea

F = 0.7035, num df = 60, denom df = 55, **p-value = 0.1834**

Intervalo de confianza del cociente

alternative hypothesis: true ratio of variances is not equal to 1

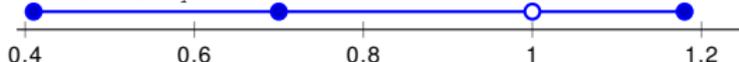
**95 percent confidence interval:**

**0.4158963 1.1828332**

sample estimates:

ratio of variances

0.7034893



Como el p-valor (0.1834) es mayor que  $\alpha$  no se rechaza la hipótesis nula. Podemos suponer que no hay diferencias significativas entre las varianzas de las líneas, es decir, las dos muestras provienen de poblaciones que tienen la misma varianza.

## Para contrastar dos medias, verificamos:

- 1 Si se puede admitir o no la normalidad.
- 2 La relación que hay entre los datos. Éstas pueden ser:
  - Independientes: Cuando deseamos comparar *dos grupos*. Ejemplo: ¿El consumo de alcohol es igual para los hombres y para las mujeres?

Sexo	...	Consumo	...
Hombre		10	
Hombre		12	
...		...	
Hombre		7	
Mujer		9	
Mujer		11	
...		...	
Mujer		8	

- Pareadas: Cuando queremos comparar *dos variables*. En este caso, cada individuo tiene un valor asociado en cada una de las dos variables. Ejemplo: ¿El gasto en alcohol es igual que el gasto en telefonía?

Alcohol	Telefonía
14	10
12	12
...	...
5	7

# Contraste de medias

El siguiente cuadro resume los diferentes contrastes de comparación de promedios que vamos a ver en las prácticas de laboratorio de esta asignatura:

	¿Distrib. Normal?	Independ.	Test - Contraste
Media de la diferencia	Sí	Sí	t para muestras independientes
Media de la diferencia	Sí	No	t para datos relacionados
Mediana de la diferencia	No	Sí	Wilcoxon para dos muestras
Mediana de la diferencia	No	No	Wilcoxon para muestras pareadas

Se compararán las medias o medianas de ambos grupos o variables.

$H_0 : \mu_A = \mu_B$	$H_0 : \mu_A \geq \mu_B$	$H_0 : \mu_A \leq \mu_B$
$H_1 : \mu_A \neq \mu_B$	$H_1 : \mu_A < \mu_B$	$H_1 : \mu_A > \mu_B$

## Muestras independientes

- Si consideramos sólo a los hombres, ¿sigue la variable consumo de alcohol una distribución normal?
- Si consideramos sólo a las mujeres, ¿sigue la variable consumo de alcohol una distribución normal?

Sexo	...	Consumo	...
Hombre		10	
Hombre		12	
...		...	 ?
Hombre		7	
Mujer		9	
Mujer		11	
...		...	 ?
Mujer		8	

¿La variable *consumo* sigue una distribución normal en la línea A? ¿Y en la línea B?

Estadísticos

↳ Resúmenes

↳ Test de Normalidad

Seleccionamos: **consumo**

Pinchamos en el botón test por grupos:

↳ Seleccionamos: **línea**

↳ Aceptar

Aceptar

(para eliminar el test por grupo, pinchar en *restablecer*)

(Sigue →)

## Test de Shapiro-Wilk:

$H_0$ : los datos provienen de una distribución normal

$H_1$ : los datos no provienen de una distribución normal

línea: A

Shapiro-Wilk normality test

data: dd[x, ]

W = 0.9708, p-value = 0.1534

-----  
línea: B

Shapiro-Wilk normality test

data: dd[x, ]

W = 0.9746, p-value = 0.2841

Para los datos de la línea A el p-valor es 0.1534 y para los datos de la línea B es 0.2841. En ambos casos suficientemente grande como para no rechazar la hipótesis nula (se puede admitir la normalidad de los datos).

# ¿El consumo medio es menor en la línea A que en la B?

$$H_0 : \mu_A \geq \mu_B$$
$$H_1 : \mu_A < \mu_B$$



$$H_0 : \mu_A - \mu_B \geq 0$$
$$H_1 : \mu_A - \mu_B < 0$$

Estadísticos

↳ Medias

↳ Test t para muestras independientes

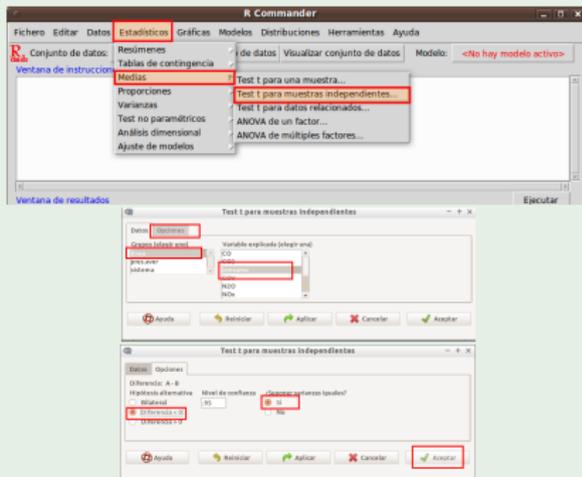
Seleccionar variables **linea** y **consumo**

↳ Seleccionar: **Diferencia < 0**

↳ **Varianzas iguales** (ver ejemplo previo)

vio)

↳ OK



(Sigue →)

$$\begin{array}{|c}
 H_0 : \mu_A \geq \mu_B \\
 H_1 : \mu_A < \mu_B
 \end{array}
 \iff
 \begin{array}{|c}
 H_0 : \mu_A - \mu_B \geq 0 \\
 H_1 : \mu_A - \mu_B < 0
 \end{array}$$

Two Sample t-test

data: consumo by linea

t = -10.1697, df = 115, **p-value < 2.2e-16**

alternative hypothesis: true difference in means is less than 0

**95 percent confidence interval:**

**-Inf -65.32647**

sample estimates:

mean in group A      mean in group B

98.3182

176.3716

Intervalo de confianza



Como el p-valor es prácticamente cero, se rechaza la hipótesis nula. Por lo tanto, el consumo medio en la línea A es menor.

# ¿El consumo promedio es igual en ambas líneas?

$$H_0 : \mu_A = \mu_B$$
$$H_1 : \mu_A \neq \mu_B$$



$$H_0 : \mu_A - \mu_B = 0$$
$$H_1 : \mu_A - \mu_B \neq 0$$

Estadísticos

↳ Medias

↳ Test t para muestras independientes

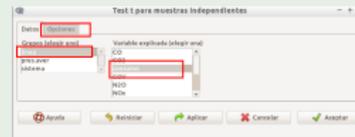


Seleccionar variables **linea** y **consumo**

↳ Seleccionar: **Bilateral**

↳ **Varianzas iguales**

↳ OK



(Sigue →)

¿El consumo promedio es igual en ambas líneas?

$$\begin{array}{l} H_0 : \mu_A = \mu_B \\ H_1 : \mu_A \neq \mu_B \end{array} \iff \begin{array}{l} H_0 : \mu_A - \mu_B = 0 \\ H_1 : \mu_A - \mu_B \neq 0 \end{array}$$

data: consumo by linea

t = -10.1697, df = 115, **p-value < 2.2e-16**

alternative hypothesis: true difference in means is not equal to 0

**95 percent confidence interval:**

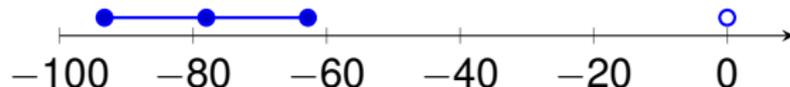
**-93.25631 -62.85051**

sample estimates:

mean in group A mean in group B

98.3182 176.3716

Intervalo de confianza



El consumo es distinto.

# Muestras pareadas

Calcule la diferencia entre la variable  $V1$  y  $V2$ . ¿Sigue esta diferencia una distribución normal?

V1	V2	V1-V2	
14	10	4	
12	12	0	
...		...	
5	7	-2	

Calcule una nueva variable como la diferencia entre *pr.cc* y *pr.pint*. Llame a esta variable *diferencia*.

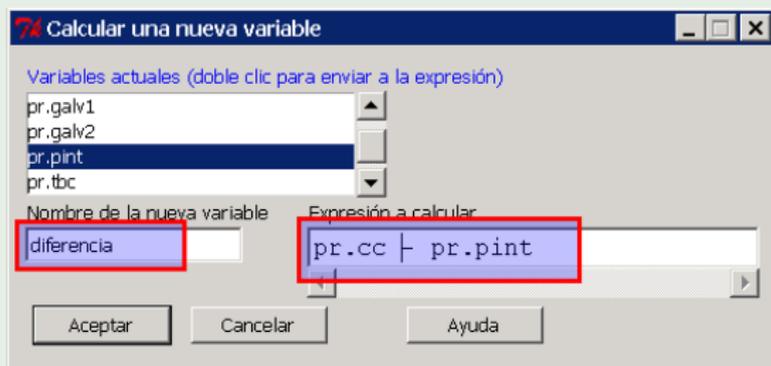
Datos

- ➔ Modificar variables del conjunto de datos activo
  - ➔ Calcular una nueva variable

Nombre de la nueva variable: **diferencia**

Expresión a calcular: **pr.cc - pr.pint**

Aceptar



```
> acero$diferencia <- with(acero, pr.cc - pr.pint)
```

## ¿Sigue la variable *diferencia* una distribución normal?

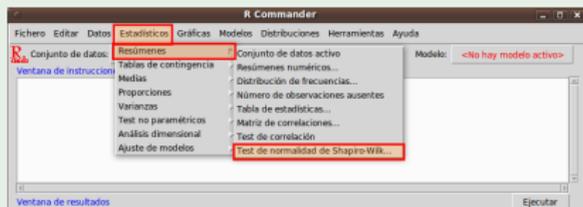
Estadísticos

➔ Resúmenes

➔ Test de normalidad ...

Seleccionar **diferencia**

➔ OK



Shapiro-Wilk normality test

```
data: diferencia
```

```
W = 0.988, p-value = 0.3948
```

Como el p-valor es 0.39, no se rechaza la hipótesis de normalidad.

## Datos pareados

Se ha preguntado a diversos jóvenes sobre su gasto mensual en telefonía y en consumo de alcohol:

Persona	Gasto en (euros)		diferencia
	Telefonía	Alcohol	
Juan	10	23	-13
María	7	12	-5
José	11	27	-16
...	...	...	

¿Existe relación entre lo que gasta Juan en Telefonía (10 euros) y en Alcohol (23 euros)?

- Sí, a Juan le corresponde el par de datos (10, 23).
- Son *datos pareados* (no son independientes).

¿El gasto medio es igual en telefonía y en alcohol?

$$H_0 : \mu_{Telefonía} = \mu_{Alcohol}$$

$$H_1 : \mu_{Telefonía} \neq \mu_{Alcohol}$$

Son datos pareados: hay que utilizar el test t *pareado* o el Wilcoxon *pareado*.

# ¿Son iguales las producciones medias de (*pr.cc*) y de (*pr.pint*)?

$$H_0 : \mu_{pr.cc} = \mu_{pr.pint}$$

$$H_1 : \mu_{pr.cc} \neq \mu_{pr.pint}$$



$$H_0 : \mu_{pr.cc} - \mu_{pr.pint} = 0$$

$$H_1 : \mu_{pr.cc} - \mu_{pr.pint} \neq 0$$

Como la variable *diferencia* (que es la diferencia entre ambas variables) sigue una distribución normal, utilizaremos el test t pareado.

Estadísticos

➔ Medias

➔ Test t para datos relacionados

Primera variable

➔ Seleccionar **pr.cc**

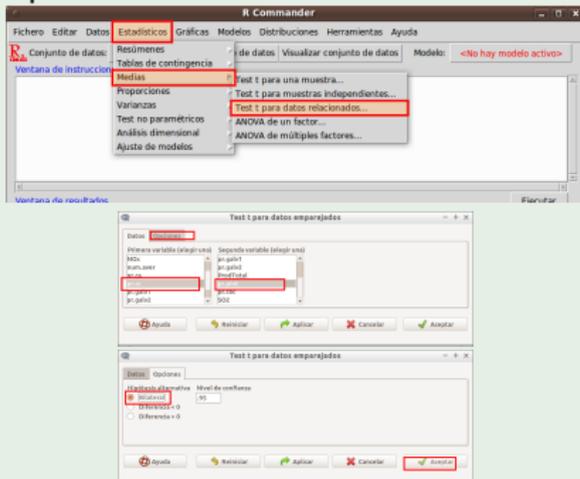
➔ Segunda variable

➔ Seleccionar **pr.pint**

➔ Hipótesis alternativa

➔ **Bilateral**

Aceptar



(Sigue →)

$$\begin{array}{|l}
 H_0 : \mu_{pr.cc} = \mu_{pr.pint} \\
 H_1 : \mu_{pr.cc} \neq \mu_{pr.pint}
 \end{array}
 \iff
 \begin{array}{|l}
 H_0 : \mu_{pr.cc} - \mu_{pr.pint} = 0 \\
 H_1 : \mu_{pr.cc} - \mu_{pr.pint} \neq 0
 \end{array}$$

Paired t-test

data: pr.cc and pr.pint

t = 2.5405, df = 116, **p-value = 0.01239**

alternative hypothesis: true difference in means is not equal to 0

**95 percent confidence interval:**

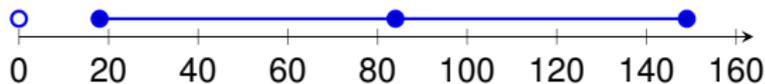
**18.56348 149.91515**

sample estimates:

mean of the differences

84.23932

Intervalo de confianza de la diferencia



El p-valor es 0.012; por lo que las medias de pr.cc y pr.pint son significativamente distintas.

## Muestras independientes

- Si consideramos sólo a los hombres, ¿sigue la variable consumo de alcohol una distribución normal?
- Si consideramos sólo a las mujeres, ¿sigue la variable consumo de alcohol una distribución normal?

Sexo	...	Consumo	...
Hombre		10	
Hombre		12	
...		...	 ?
Hombre		7	
Mujer		9	
Mujer		11	
...		...	 ?
Mujer		8	

¿Sigue la variable *pr.galv2* una distribución normal en cada línea?

Estadísticos

↳ Resúmenes

↳ Test de Normalidad

Seleccionamos: **pr.galv2**

Pinchamos en el botón test por grupos:

↳ Seleccionamos: **línea**

↳ Aceptar

Aceptar

(para eliminar el test por grupo, pinchar en *restablecer*)

(Sigue →)

linea: A

Shapiro-Wilk normality test

data: dd[x, ]

W = 0.8955, p-value = 7.985e-05

---

linea: B

Shapiro-Wilk normality test

data: dd[x, ]

W = 0.9111, p-value = 0.0005496

**No hay condiciones de normalidad.**

# ¿Son iguales las producciones medias de (*pr.galv2*) según la línea)?

$$H_0 : \text{Mediana}_A = \text{Mediana}_B$$
$$H_1 : \text{Mediana}_A \neq \text{Mediana}_B$$

Como la variable *pr.galv2* no sigue una distribución normal, utilizaremos el test de Wilcoxon.

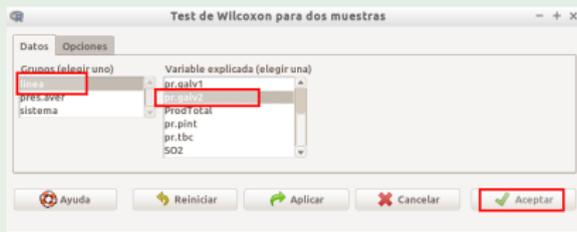
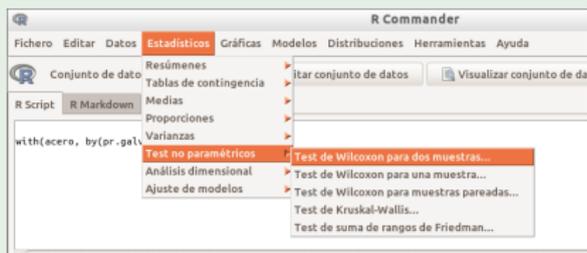
Estadísticos

- ➔ Test no paramétricos
- ➔ Test de Wilcoxon para dos muestras

Primera variable

- ➔ Seleccionar **linea**
- ➔ Segunda variable
- ➔ Seleccionar **pr.galv2**
- ➔ Hipótesis alternativa
- ➔ **Bilateral**

Aceptar



(Sigue →)

Wilcoxon rank sum test with continuity correction

data: pr.galv2 by linea

W = 1431, **p-value = 0.1314**

alternative hypothesis: true location shift is not equal to 0

No se rechaza la hipótesis de igualdad de producción en ambas líneas.

# Muestras pareadas

Calcule la diferencia entre la variable  $V1$  y  $V2$ . ¿Sigue esta diferencia una distribución normal?

V1	V2	V1-V2	
14	10	4	
12	12	0	
...		...	
5	7	-2	

Calcule una nueva variable como la diferencia entre *pr.galv1* y *pr.galv2*. Llame a esta variable *dif*.

Datos

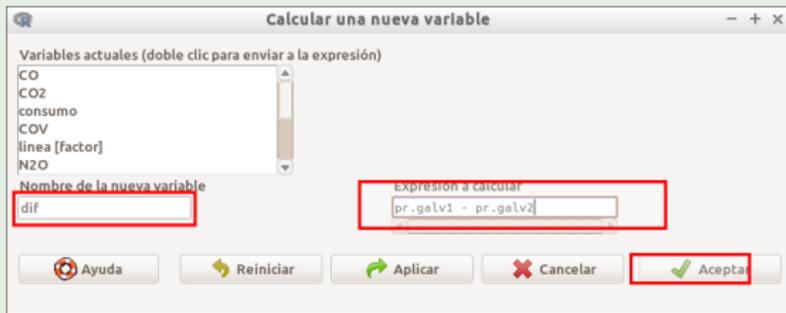
➡ Modificar variables del conjunto de datos activo

➡ Calcular una nueva variable

Nombre de la nueva variable: **dif**

Expresión a calcular: **pr.galv1 - pr.galv2**

Aceptar



```
> acero$dif <- with(acero, pr.galv1 - pr.galv2)
```

## ¿Sigue la variable *dif* una distribución normal?

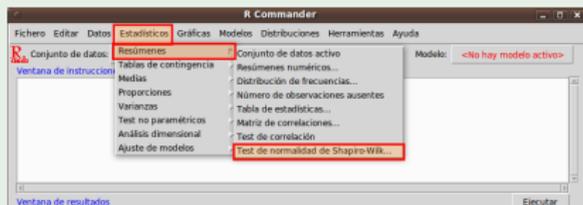
Estadísticos

↳ Resúmenes

↳ Test de normalidad...

Seleccionar **dif**

↳ OK



Shapiro-Wilk normality test

```
data: dif
```

```
W = 0.9671, p-value = 0.005665
```

Como el p-valor es pequeño, se rechaza la hipótesis de normalidad.

# Compárese, en promedio, la producción *pr.galv1* y *pr.galv2*

$$H_0 : \text{Mediana}_{pr.galv1 - pr.galv2} = 0$$

$$H_1 : \text{Mediana}_{pr.galv1 - pr.galv2} \neq 0$$

Como la variable *dif* (que es la diferencia entre ambas variables) no sigue una distribución normal, utilizaremos el test de Wilcoxon pareado.

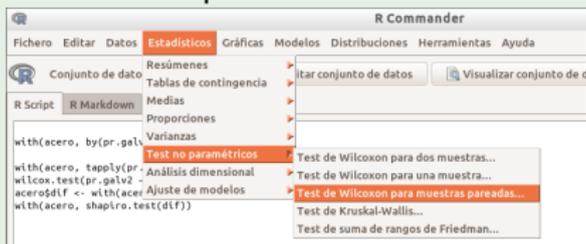
## Estadísticos

- ➔ Test no paramétricos
  - ➔ Test de Wilcoxon para muestras pareadas

## Primera variable

- ➔ Seleccionar **pr.galv1**
  - ➔ Segunda variable
    - ➔ Seleccionar **pr.galv2**
      - ➔ Hipótesis alternativa
        - ➔ **Bilateral**

Aceptar



(Sigue →)

Wilcoxon signed rank test with continuity correction

data: pr.galv1 and pr.galv2

V = 249, p-value < 2.2e-16

alternative hypothesis: true location shift is not equal to 0

Se rechaza la hipótesis de igualdad de producción en ambos tipos de galvanizado.