

***Universidad Nacional de La Plata***  
***Facultad de Ciencias Agrarias y Forestales***



**CÁLCULO ESTADÍSTICO Y  
BIOMETRÍA**



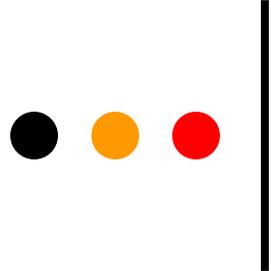
# *Técnicas de Análisis simultaneo de variables*

## ANALISIS DE REGRESION

Determinar como se  
relacionan funcionalmente  
dos o más variables

## ANALISIS DE CORRELACION

Determinar si las  
variables están asociadas  
y como es esa asociación



# Problemáticas

Muchas veces estamos interesados en describir cómo cambia una variable (que llamaremos **dependiente**) en función de una (o varias) llamada/s **independiente/s**.

- ✓ *cuantificar cómo cambia la disponibilidad de agua a distintas profundidades del perfil analizado en un cultivo de soja.*
- ✓ *evaluar la efectividad de un insecticida a distintas concentraciones sobre la sobrevivencia de un insecto.*
- ✓ *estudiar el comportamiento del aumento de peso de animales sobre distintas disponibilidades de una ración.*
- ✓ *estudiar el efecto de distintas disponibilidades de luz y/o la temperatura sobre el poder germinativo de una semilla forrajera.*



# ***ANALISIS DE REGRESION***



# Objetivos

## Identificar

- ... la mejor relación funcional entre una variable aleatoria (llamada variable dependiente y denotada generalmente con  $Y$ ), y una o mas variables no aleatorias (independiente, indicada con  $X_i$ )

## Estimar

- ... los parámetros del modelo

## Probar hipótesis (evaluar la adecuación del modelo)

- ... sobre los parámetros del modelo

## Predecir

- ... el nivel medio de la variable dependiente para valores determinados de las independientes.



# *Regresión lineal simple - MODELO*

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$$

- $y_i$ : variable dependiente o respuesta,
- $x_i$ : variable independiente,
- $\beta_0$  y  $\beta_1$ : parámetros desconocidos que representan la ordenada al origen y la pendiente respectivamente,
- $\varepsilon_i$ : error aleatorio

## Suposiciones del modelo

- Los errores son variables aleatorias no correlacionadas
- Los errores tienen distribución normal con media cero y varianza cte.

# ● ● ● | *Estimación de parámetros*

Modelo Poblacional

$$y_i = \beta_0 + \beta_1 \cdot x_i + \varepsilon_i$$



Modelo Muestral

$$\hat{y}_i = a + b \cdot x_i + \varepsilon_i$$

- ✓ Datos  $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$
- ✓ Se estiman  $\beta_0$  y  $\beta_1$  minimizando la suma de los cuadrados de  $(y_i - \hat{y}_i)$  donde  $\hat{y}_i$  es el valor estimado de  $y_i$ .

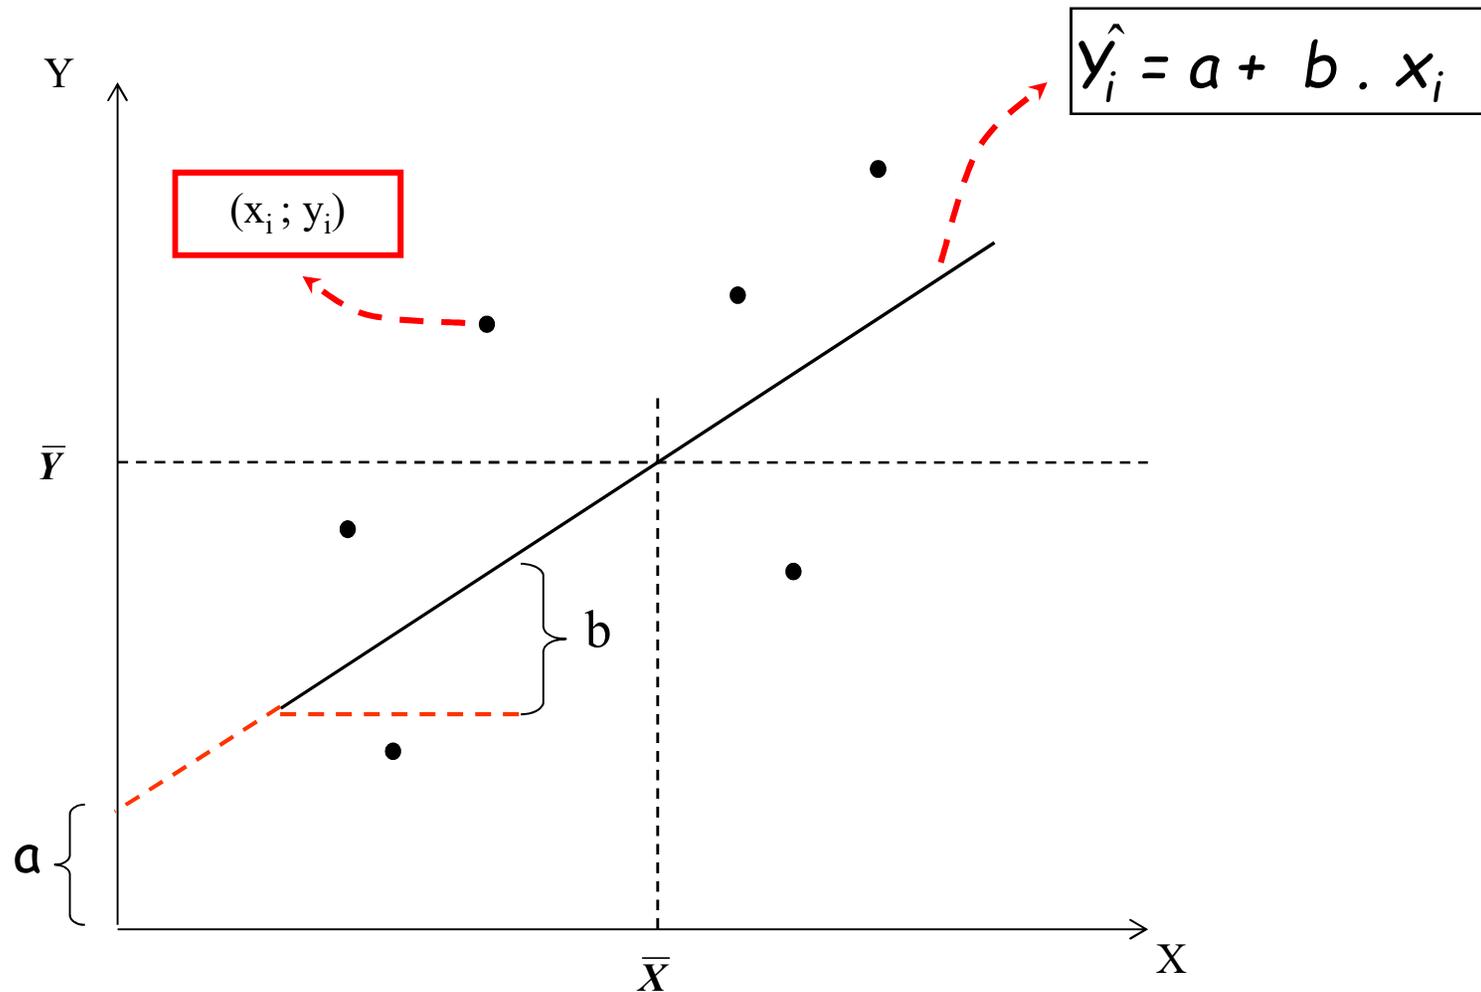
$$a = \frac{\sum_{i=1}^n Y_i}{n} - b \frac{\sum_{i=1}^n X_i}{n} = \bar{Y} - b \bar{X}$$

$$b_{y/x} = \frac{\sum_{i=1}^n X_i Y_i - \frac{\sum_{i=1}^n X_i \sum_{i=1}^n Y_i}{n}}{\sum_{i=1}^n X_i^2 - \frac{\left(\sum_{i=1}^n X_i\right)^2}{n}}$$

- ✓ La diferencia  $(y_i - \hat{y}_i) = \varepsilon_i$  se conoce como el residuo de la  $i$ -ésima observación.



# Gráfico de dispersión





# Pruebas de hipótesis sobre los parámetros

## Ordenada al origen

$$H_0 : \beta_0 = 0$$

$$H_1 : \beta_0 \neq 0$$

$$t_a = \frac{a}{S_a}$$

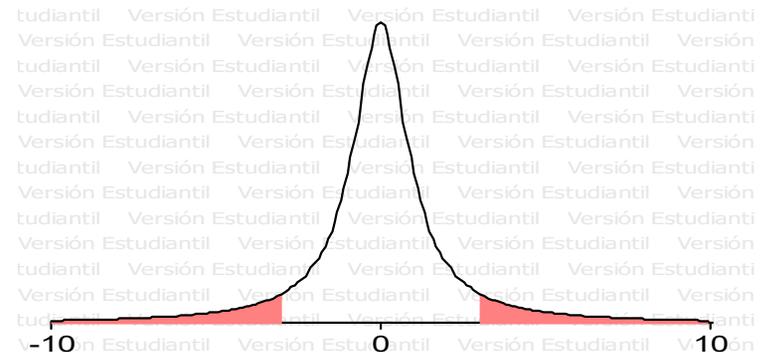
$$t_{\text{tabulado}} \begin{cases} |g| = n - 2 \\ \alpha \end{cases}$$

## Pendiente

$$H_0 : \beta_1 = 0$$

$$H_1 : \beta_1 \neq 0$$

$$t_b = \frac{b}{S_b}$$



# ● ● ● | *Bondad de Ajuste al modelo*

**Coeficiente de determinación ( $R^2$ ):** porcentaje de la variabilidad total de y explicada por la regresión (modelo) o la variable dependiente x.

$$R^2 = \frac{\sum (\hat{Y}_i - \bar{Y})^2}{\sum (Y_i - \bar{Y})^2} = \frac{SCE_{Exp.}}{SCT} \quad \text{siendo} \quad 0 \leq R^2 \leq 1$$

**Objetivo:** descomponer la variabilidad total de la variable Y en:

- la variabilidad explicada por el modelo
- la variabilidad no explicada o variabilidad residual

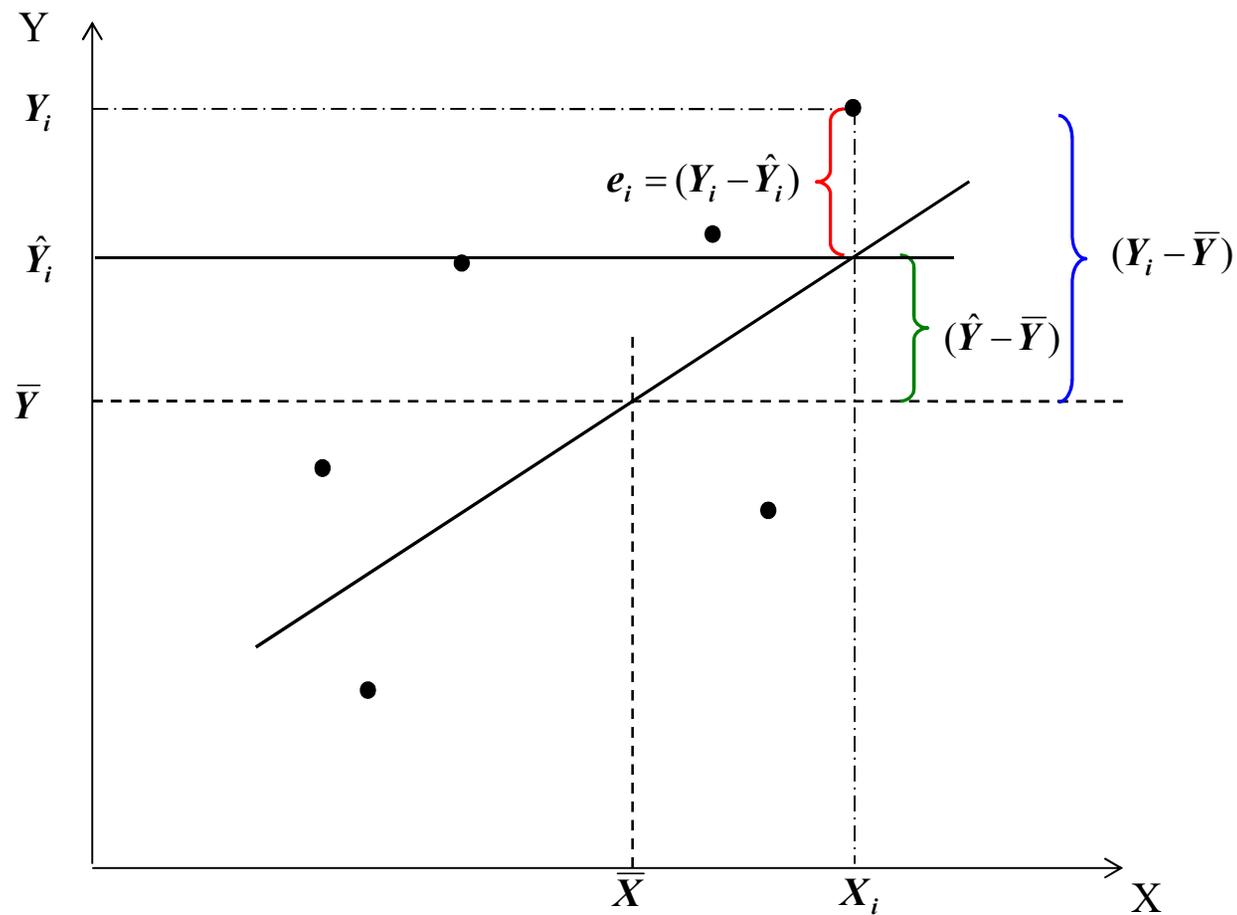
$$SCT = \sum (Y_i - \bar{Y})^2 = SCE_{Exp.} + SCRes.$$

$$SCE_{Exp.} = \sum (\hat{Y}_i - \bar{Y})^2$$

$$SCRes. = \sum (Y_i - \hat{Y}_i)^2$$



# Gráfico de dispersión (Descomposición variabilidad)





# ANOVA: Otra forma de probar la significancia de la regresión

En regresión lineal simple las hipótesis siguientes son EQUIVALENTES

$$H_0 : R^2 = 0$$

$$H_0 : \beta_1 = 0$$

$$H_1 : R^2 \neq 0$$

$$H_1 : \beta_1 \neq 0$$

<b>Fuentes de Variación</b>	<b>Suma de Cuadrados</b>	<b>Grados de Libertad</b>	<b>Cuadrado Medio</b>	<b>F Calculado</b>
<i>Explicada por la regresión</i>	<i>SCExp.</i>	$gl_{Exp.} = k$	$CM_{Exp.} = \frac{SCExp}{gl_{Exp}}$	$F = \frac{CM_{Exp}}{CM_{Res}}$
<i>Error</i>	<i>SCRes.</i>	$gl_{Res.} = n - k - 1$	$CM_{Res.} = \frac{SCRes.}{gl_{Res.}}$	
<b>Total</b>	<i>SCT</i>	$gl_t = n - 1$		

$$F_{\text{tabulado}} \begin{cases} gl_{\text{(numerador)}} = k = 1 \\ gl_{\text{(denominador)}} = n - 2 \\ \alpha \end{cases}$$



## Ejemplo 1 - Regresión

Se determinó el crecimiento de una especie forestal en un suelo pobre en N al cual se le agregaron distintas cantidades de ese elemento.

<i>Nitrógeno agregado (kg/ha)</i>	0	50	100	150	200	250	300	350	400	450
<i>Crecimiento (mg/día)</i>	1.6	20.5	84.8	94.0	143.1	162.5	183.2	218.3	289.0	317.4

Operando con los datos del ejercicio se obtuvieron los siguientes valores:

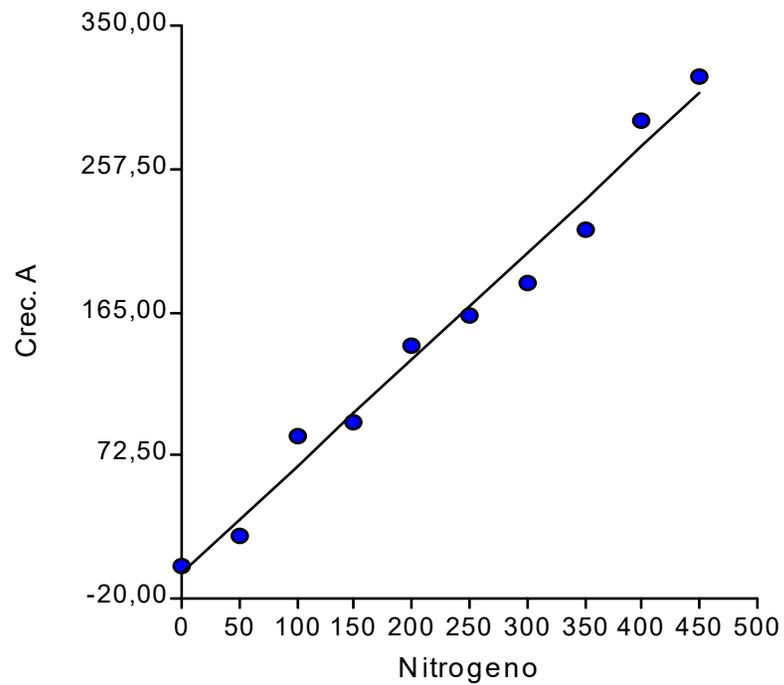
$$a = -3,37 \quad S_a = 8,91 \quad b = 0,69 \quad S_b = 0,03 \quad R^2 = 0,98$$

Responder:

- Realizar el gráfico de dispersión. Explicitar el modelo de regresión e indicar el significado de cada termino.
- Analizar la significancia de los parámetros del modelo, tomar un nivel de significancia del 5 %. Conclusiones
- ¿Que es  $R^2$  y que indica en este problema?



## *Ejemplo 1 - Gráfico*



$$\hat{y}_i = -3,37 + 0,69 x_i$$



# Ejemplo 1 – Salida Infostat

## Análisis de regresión lineal

Variable	N	R <sup>2</sup>	R <sup>2</sup> Aj	ECMP
Crec. A	10	0,98	0,98	357,88

## Coefficientes de regresión y estadísticos asociados

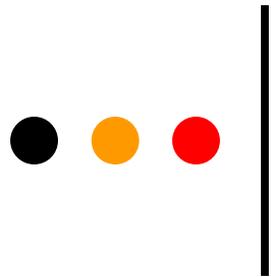
Coef	Est.	EE	LI (95%)	LS (95%)	T	p-valor	CpMallows
const	-3,37	8,91	-23,92	17,19	-0,38	0,7156	
Nitrogeno	0,69	0,03	0,61	0,77	23,00	<0,0001	378,49

## Cuadro de Análisis de la Varianza (SC tipo III)

F.V.	SC	gl	CM	F	p-valor
Modelo	97634,08	1	97634,08	424,55	<0,0001
Nitrogeno	97634,08	1	97634,08	424,55	<0,0001
Error	1839,78	8	229,97		
Total	99473,86	9			



# ***ANALISIS DE CORRELACION***



# *Generalidades*

## Finalidad

- medir el grado de asociación y el sentido del mismo entre variables aleatorias que se supone se relacionan linealmente.

## Objetivos

- **Estimar...**
  - ... el coeficiente de correlación  $\rho$  (rho)
- **Probar hipótesis ...**
  - ... sobre  $\rho$  (rho)

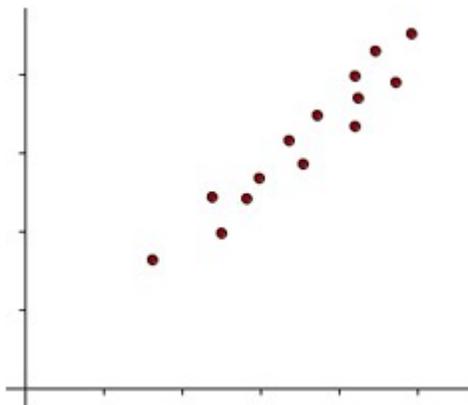


# Estimación de $\rho$ (rho)

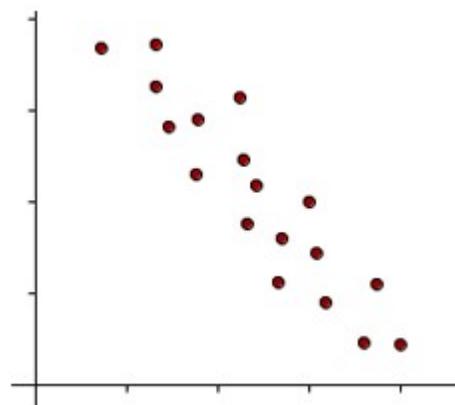
$\rho \longrightarrow r$

$$r = \frac{\sum \delta_x \delta_y}{\sqrt{\delta_x^2 \delta_y^2}}$$

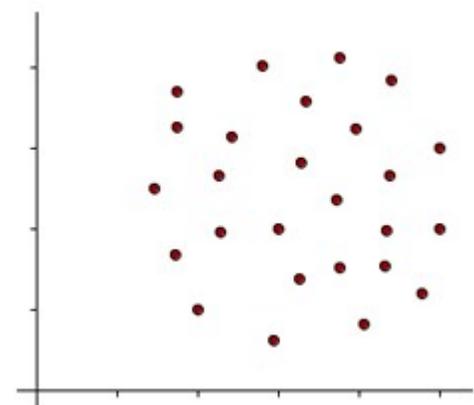
Donde:  $-1 \leq r \leq 1$



$r \longrightarrow 1$



$r \longrightarrow -1$



$r \longrightarrow 0$



# Prueba de Hipótesis

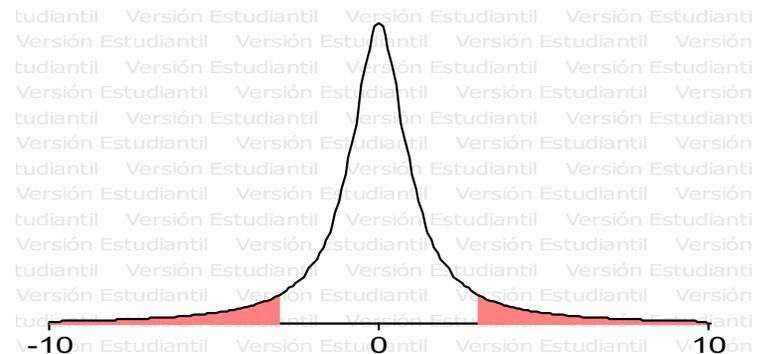
$$H_0 : \rho = 0$$

$$H_1 : \rho \neq 0$$

$$t_r = \frac{r}{S_r}$$

$$S_r = \sqrt{\frac{1-r^2}{n-2}}$$

$$t_{\text{tabulado}} \begin{cases} \text{gl} = n - 2 \\ \alpha \end{cases}$$





## *Ejemplo 2 - Correlación*

Se registro el crecimiento de una especie forestal y la profundidad alcanzada por sus raíces en 10 ejemplares de dicha especie.

<u>Planta</u>	<u>Crecimiento</u>	<u>Prof. Raíces</u>
1	0,10	15,00
2	0,40	20,00
3	0,50	15,00
4	0,60	28,00
5	0,70	25,00
6	0,20	14,00
7	0,40	18,00
8	0,60	22,00
9	0,70	26,00
10	0,20	17,00

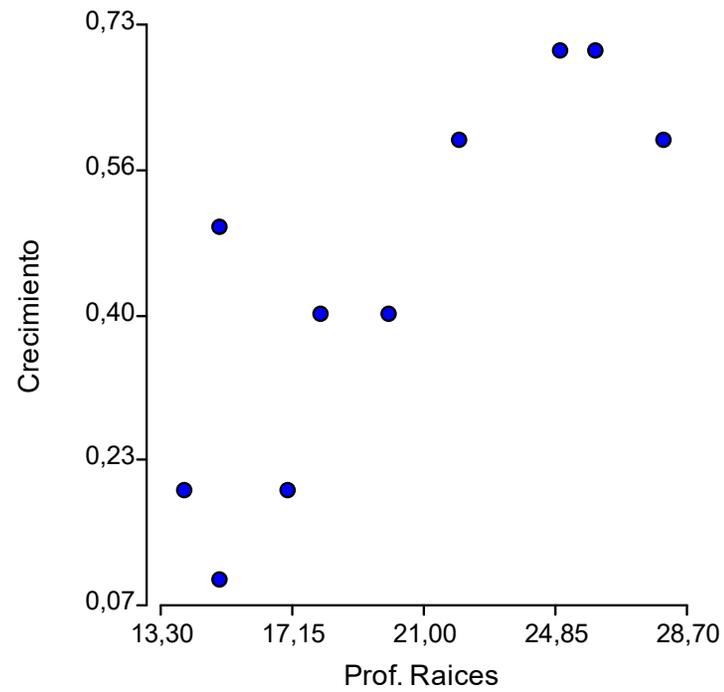
Operando con los datos del ejercicio se obtuvo un  $r = 0,82$

Responder:

- ¿ Que indica el coeficiente de correlación?. Gráficar
- Analizar la significancia del coeficiente de correlación.



## *Ejemplo 2 - Gráfico*



**r** → **1**



## Ejemplo 2 – Salida InfoStat

### Coeficientes de correlación

Correlacion de Pearson: coeficientes\probabilidades

	Crecimiento	Prof. Raices
Crecimiento	1,00	3,4E-03
Prof. Raices	0,82	1,00