


ESTADÍSTICA APLICADA

T2 Distribucions Bidimensionals



- **Distribució bidimensional:** cada observació d'un element de la mostra està representada per un parell de valors (x,y)

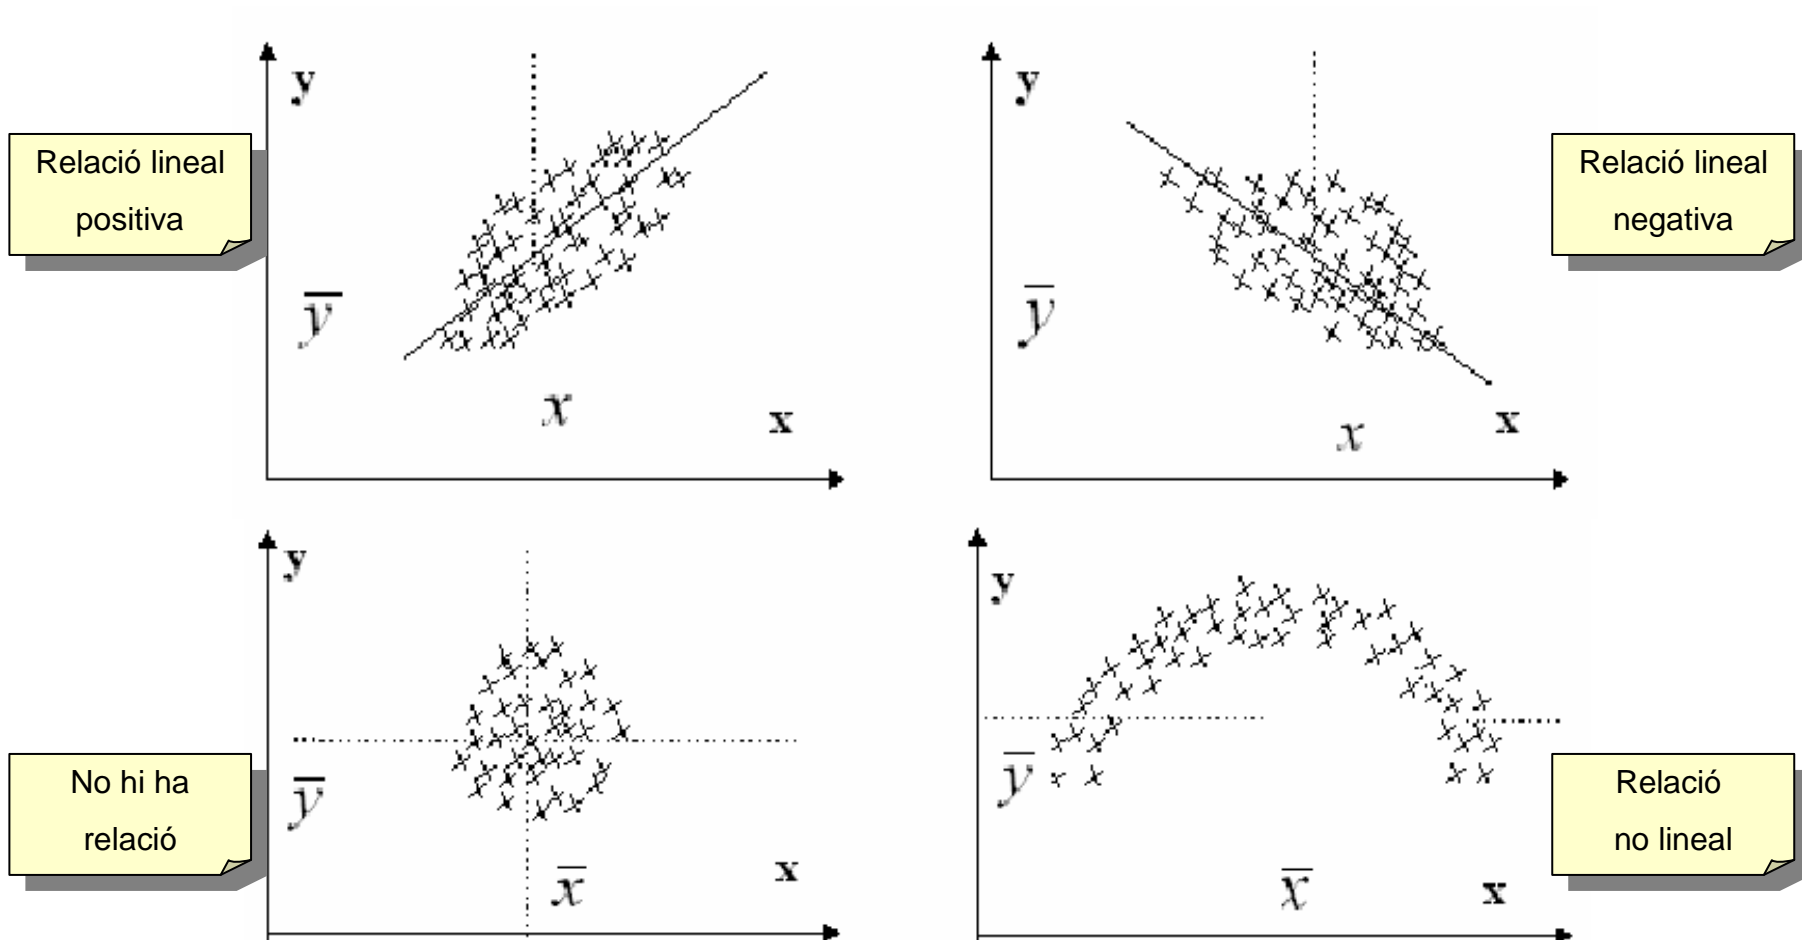
| Variable X | Variable Y |
|------------|------------|
| x1 | y1 |
| x2 | y2 |
| x3 | y3 |
| ... | ... |
| xk | yk |

| Velocidad del ultrasonido Km/seg. | Resistencia del hormigón N/mm2 |
|--------------------------------------|-----------------------------------|
| 2.98 | 5,1 |
| 3.25 | 19,1 |
| 3.26 | 15,4 |
| 3.42 | 12,8 |
| 3.55 | 20,9 |
| 3.59 | 28,0 |
| 3.62 | 19,9 |
| 3.71 | 17,4 |

Exemple 1

T2 – 2.3: Diagrames Bivariants

- La representació gràfica dels parells (x,y) s'anomena **núvol de punts** (*scatterplot*)



- La **covariància** és un indicador del grau d'interdependència lineal entre dues variables X i Y:

$$Cov(X, Y) \equiv S_{xy} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{n} = \frac{1}{n} \sum x_i \cdot y_i - \bar{x} \cdot \bar{y}$$

- Significat de la covariància:


$Cov(X, Y) > 0 \rightarrow$ relació lineal positiva

$Cov(X, Y) < 0 \rightarrow$ relació lineal negativa

$Cov(X, Y) = 0 \rightarrow$ no hi ha relació lineal (n'hi pot haver d'altre tipus)

- Problema: la covariància està en funció de les unitats de mesura de les variables (no està estandarditzada).
- Solució: a partir de la covariància, definirem un altre indicador (estandarditzat), el **coeficient de correlació lineal**

- La **recta de regressió** de Y sobre X és aquella recta (model) de la forma $\hat{y} = a + b \cdot x$ que “millor s’ajusta” al núvol de punts
- Per a determinar els valors òptims dels coeficients a i b , s’empra el **mètode dels mínims quadrats**, el qual minimitza la suma dels quadrats dels **residus** (diferències entre els valors observats, y_i , i els teòrics predits pel model, \hat{y}_i):



(Continua)

- Aplicant mínims quadrats, la **recta de regressió de Y** (variable dependent) **sobre X** (variable independent) és:

$$\hat{y} = a + b \cdot x \quad \begin{array}{l} \rightarrow b = \frac{\text{Cov}(X, Y)}{\text{Var}(X)} = \frac{S_{xy}}{S_x^2} \\ \rightarrow a = \bar{y} - b \cdot \bar{x} \end{array}$$

- Alternativament: $y - \bar{y} = b \cdot (x - \bar{x})$
- El pendent, b , s'anomena **coeficient de regressió de Y sobre X** (no confondre amb el coef. de correlació lineal)
- Observacions:
 - recta X sobre Y \neq recta Y sobre X
 - (\bar{x}, \bar{y}) és sempre un punt de la recta
 - recta Y sobre X permet predir y conegut x (i viceversa)

- **Coeficient de correlació lineal**, r , (indicador estandarditzat del grau d'interdependència lineal):

$$r = \frac{S_{xy}}{S_x \cdot S_y}$$

- Propietats de r :
 - $-1 \leq r \leq +1$
 - $\text{signe}(r) = \text{signe}(S_{xy})$
 - Si $r = +1$ ó $r = -1 \rightarrow$ punts sobre la recta (correlació lineal total)
 - Si $r > 0 \rightarrow$ correlació lineal positiva (recta creixent)
 - Si $r < 0 \rightarrow$ correlació lineal negativa (recta decreixent)
 - Si $r = 0 \rightarrow$ no hi ha correlació lineal



(Continua)

- Variància residual, S_r^2 (variància dels residus):

$$S_r^2 = \frac{1}{n} \sum (y_i - \hat{y}_i)^2 = S_y^2 (1 - r^2)$$

- Variació total de la variable Y, VT:

$$VT = \sum (y_i - \bar{y})^2 = \sum (\hat{y}_i - \bar{y})^2 + \sum (y_i - \hat{y}_i)^2$$



- El coeficient de determinació, R^2 , ens diu quin percentatge de la variació en Y és explicada per la variació en X i el model:

$$R^2 = r^2 = \frac{VE}{VT}$$

- El model seria vàlid per a fer prediccions si aprox $R^2 \geq 80\%$