


Actividade 2

a) CORRELACIÓN

Lamentable, non todos os órganos doados reunen as condicións necesarias para seren trasplantados. Unha pregunta natural, ao respecto diso, é se a idoneidade dun órgano para efectuar un trasplante garda relación coa idade do doante?

Un posible método para responder é o de realizar un estudo no que se presenten, comparativamente, os datos referidos ás dúas cuestións implicadas. No seguinte gráfico as barras indican a idade media dos doantes de fígado, e a poligonal o % que puido ser trasplantado:

Figura 5.9. Porcentaxe de aproveitamento de fígados en relación coa idade media dos doadores



O estudo de **correlación** trata de avaliar ata que punto se poden relacionar mutuamente ambas as dúas casuísticas que, en xeral, denominaremos como **variables** (x e y) - aproveitamento dos órganos e idade media dos doantes, neste caso-.

Para iso construíuse un indicador, **coeficiente de correlación** (ideado polo matemático inglés Pearson) que, centrándose nas respectivas **medias** \bar{x} e \bar{y} de cada variable, primeiro calcula a

variación conxunta –media- das dúas variables (**covarianza**: $s_{xy} = \frac{\sum (x - \bar{x}) \cdot (y - \bar{y})}{N}$;

$\sum \rightarrow$ suma dos produtos das respectivas variacións
 $N \rightarrow n^\circ$ de datos), que tamén poderíamos calculala desta outra

maneira, quizais máis cómoda: $s_{xy} = \frac{\sum xy}{N} - \bar{x}\bar{y}$) e despois compara por cociente coas variacións

de cada unha delas (**desviación típica**: $s_x = \sqrt{\frac{\sum (x - \bar{x})^2}{N}}$. A **varianza** sería $\frac{\sum (x - \bar{x})^2}{N}$, antes de

facerlle a raíz, e tal vez se calcule máis rapidamente así: $V_x = \frac{\sum x^2}{N} - \bar{x}^2$).

Finalmente obteríamos o coeficiente de correlación: $r = \frac{s_{xy}}{s_x \cdot s_y}$ que **toma valores entre -1 e 1**.

Se dá negativo indica que a correlación é **inversa** (como se pode apreciar a simple vista neste exemplo). Se dá próximo a 0 a correlación é débil, e próximo a 1 (ou -1) é forte.

Exercicio: Completa a táboa e calcula as medias, as desviacións típicas, a covarianza e o coeficiente de correlación (na última fila debes poñer as sumas que corresponden á columna respectiva)

ano	x_i	$x_i - \bar{x}$	$(x_i - \bar{x})^2$	y_i	$y_i - \bar{y}$	$(y_i - \bar{y})^2$	$(x_i - \bar{x}) \cdot (y_i - \bar{y})$
2000							
2013							

Aínda que a matemática permite tomar calquera das variables como independente (x), representando a outra en función dela, no caso que nos ocupa o máis natural sería tomarmos como x a idade dos doantes e como y o aproveitamento dos órganos.


(Comproba se obtés : $\bar{x} = 82'27$; $\bar{y} = 54'36$; $s_x = 5'637$; $s_y = 6'918$; $s_{xy} = -22'93$; $r = -0'588$)

A correlación é, como se intuía, inversa, pero non é moi forte, mais bem medianeira. Isto indícanos que si, que a idade do doante é um factor de peso á hora de poder aproveitar os seus órganos, pero que debe haber outros factores que teñan tamén moita repercusión neste asunto.

Exercicio: Busca na *rede* que hábitos ou circunstancias poden deteriorar en exceso o fígado humano.

b) CONSTRUÍNDO FUNCIÓNS

Exercicio: representa nos eixes que se indican, desde a perspectiva das **funcións**, os datos anteriores. (O que obterás coñécese como **nube de puntos**).




Agora o que nos propoñemos é aproximar esa serie de puntos por medio dunha función manexable, encontrar a fórmula desa función e aplicala para obter novos datos.

Vexamos un exemplo: Temos a seguinte táboa de datos, incompleta:

x	14	15	16		18	19		21
y	0'5	13	21'5		31	31'2		35'2

Facemos a gráfica:



A recta é a función máis sinxela: tomamos dous puntos e buscamos a recta que pase por eles (**recta que pasa por dous puntos**). Por exemplo: (15, 10) e (19, 30)

$$\frac{x-19}{19-15} = \frac{y-30}{30-10} \rightarrow y = 5x - 65$$

A través da fórmula podemos completar a información:

$$\text{Para } x = 17, y = 20$$

$$\text{Para } x = 20, y = 35$$

E tamén realizar prospeccións (previsións teóricas): para $x = 22, y = 45$

e, incluso, retrotaernos no tempo: para $x = 13, y = 0$

c) RECTA DE REGRESIÓN

A idea que se nos presenta a continuación é a de escoller a que puidese considerarse "mellor" entre todas as rectas que nos dan unha boa aproximación. Esa será a que denominemos recta de regresión, que debera, entón, facer mínimos os erros a respecto dos puntos coñecidos.

Os ditos erros trátanse xeometricamente como distancias entre os puntos e a recta elixida e, para evitar andar con raíces utilízanse os seus cadrados. Asemade quedan todos positivos, evitando así que os erros puntuais se neutralicen mutuamente¹ -o que tamén se conseguiría usando o valor absoluto-. De aquí procede o nome de "**método dos mínimos cadrados**"².

A recta que buscamos denomínase **recta de regresión** e, como calquera outra recta pódese determinar coñecendo un dos seus puntos (neste caso será aquel que conforman as respectivas medias (\bar{x}, \bar{y}) e a súa pendente (inclinación), e responde ao formato: $y - y_0 = m(x - x_0)$ (**ecuación punto-pendente**).

Definitivamente, a ecuación vén a ser: $y - \bar{y} = \frac{S_{xy}}{S_x^2} (x - \bar{x})$

Exercicio: Calcula a recta de regresión para o aproveitamento de órganos em función da idade do doante.

¹ Por ex: erros de 1'2 por exceso e 0'95 por defecto, daría $1'2 - 0'95 = 0'25$, cando o erro total é de:
 $0'95 + 1'2 = 2'15$.

² Ao tratar os datos como puntos no plano, utilizamos dúas variables para representalos. Constrúese unha función -de dúas variables- coa suma de distancias entre os puntos da táboa inicial e os correspondentes puntos da recta $y=a \cdot x+b$, onde "a" e "b" son incógnitas a determinar.

Buscamos o *mínimo* dunha nova función "función suma de distancias" anulando a súa derivada (neste caso anulando as derivadas parciais respecto de cada variable).