

### TEMA 3. DESCRICION ESTATÍSTICA DE DATOS MULTIDIMENSIONAIS.

#### 3.1. Distribucions Bidimensionais de Frecuências. Representacion Grafica.

No tema anterior nos ocupabamos de describer as variables estatísticas unha por unha, cada individuo da mostra era descrito de acordo con unha única característica independentemente de outras posibles características de interese no mesmo individuo. Sen embargo, as veces, necesitamos estudar nun mesmo individuo varias características simultaneamente, tratando de averiguar as posibles relacións entre características; ou mesmo estudar unha característica dada condicionada a certos valores posibles de outras. Por iso cando observamos varias características simultaneamente nun mesmo individuo estamos a obter os valores dunha variable K-dimensional ( $X_1, X_2, \dots, X_k$ ).

Por exemplo consideremos o estudo simultáneo das cinco características en impresoras laser indicadas no exemplo abaixo. Temos entón unha variable de este tipo con cinco componentes ( $X_1, X_2, \dots, X_5$ ).

Imos comezar o estudo simultáneo de varias características polo caso en que consideremos dúas. Isto é, polo que chamaremos unha variable bidimensional ( $X_1, X_2$ ). Tamén se utiliza a notación ( $X, Y$ ).

O primeiro que imos facer é reducir os datos tabulando a información sobre os valores aparecidos e o número de veces que aparecen no que se chama unha TABOA DE FRECUÊNCIAS.

Exemplo: Características relativas ás impresoras láser:

	$X_1$	$X_2$	$X_3$	$X_4$	$X_5$		$X_1$	$X_2$	$X_3$	$X_4$	$X_5$
<b>1</b>	1180	39	5	25	512	<b>21</b>	14710	42	4	50	5120
<b>2</b>	2550	64	10	25	716	<b>22</b>	46480	43	13	500	1024
<b>3</b>	2672	74	10	25	204	<b>23</b>	30780	29	32	150	1222
<b>4</b>	1038	6	6	15	102	<b>24</b>	10990	22	4	150	1024
<b>5</b>	1279	16	6	15	102	<b>25</b>	14490	27	6	150	1024
<b>6</b>	9878	18	6	15	512	<b>26</b>	19490	54	6	150	2048
<b>7</b>	2500	14	10	25	204	<b>27</b>	34990	35	8	250	2048
<b>8</b>	3410	22	10	25	204	<b>28</b>	23800	45	8	100	2048
<b>9</b>	4890	22	16	25	204	<b>29</b>	22240	29	30	250	6144
<b>10</b>	4700	14	3	10	256	<b>30</b>	28990	29	30	550	6144
<b>11</b>	1550	14	4	10	102	<b>31</b>	28000	23	10	100	2048
<b>12</b>	2400	14	7	25	204	<b>32</b>	14900	23	6	100	1024
<b>13</b>	2690	17	8	25	153	<b>33</b>	11500	23	4	100	1024
<b>14</b>	3150	39	8	25	204	<b>34</b>	26500	87	10	200	2048
<b>15</b>	5990	62	9	25	819	<b>35</b>	28500	87	16	500	4096
<b>16</b>	5310	62	8	25	819	<b>36</b>	10900	26	4	100	1024
<b>17</b>	7990	17	4	10	102	<b>37</b>	27500	45	12	250	2048
<b>18</b>	1122	17	4	10	153	<b>38</b>	80000	35	16	100	1024
<b>19</b>	2539	25	8	25	204	<b>39</b>	48145	14	18	250	2048
<b>20</b>	4913	17	8	40	153	<b>40</b>	21558	50	4	100	1638

Na Tab. anterior podemos ollar 5 variables medidas simultaneamente en 40 impresoras laser:  $X_1$  = Prezo en pts.,  $X_2$  = Número de fontes de escritura,  $X_3$  = Velocidade de Impresión,  $X_4$  = Número de follas que pode conter o cargador de papel,  $X_5$  = Memória en Kbytes.

Para comezar consideramos unha variable bidimensional estudando dúas características nunha mesma poboación.

Sexa  $(x_1, y_1), \dots, (x_n, y_n)$  unha mostra de  $n$  observacións de unha variable estatística bidimensional  $(X, Y)$ . Esta información pode resumir-se nunha taboa de frecuencias onde aparecerán as modalidades respectivas das variables  $(x_i, y_j)$  e o número de veces que aparece o par anterior será a frecuencia absoluta  $n_{ij}$ .

Propiedades das frecuencias:

- a)  $n_{ij} \geq 0$
- b)  $0 \leq f_{ij} \leq 1$
- c)  $\sum_i \sum_j n_{ij} = n$  e  $\sum_i \sum_j f_{ij} = 1$

Sendo  $n_{ij}$  a frecuencia absoluta do par  $(x_i, y_j)$ , e  $f_{ij}$  a frecuencia relativa do mesmo par, que poderá vir expresada en tanto por un ou en tanto por cen.

Esta taboa nomea-se Taboa de Continxencia cando as dúas variables  $X$  e  $Y$  son de tipo cualitativo, en xeral a información que aparece nela recibe o nome de **Distribución Conxunta de X e Y**. A disposición é como segue.

Táboa de Continxencia que resume a Distribución Conxunta duna variable bidimensional  $(X, Y)$

	Y	$y_1$	$y_2$	...	$y_j$	...	$y_m$	
X								
$x_1$	$n_{11}$	$n_{12}$	...	$n_{1j}$	...	$n_{1m}$	$n_{1.}$	
$x_2$	$n_{21}$	$n_{22}$	...	$n_{2j}$	...	$n_{2m}$	$n_{2.}$	
$x_i$	...	...	...	$n_{ij}$	...	...	$n_{i.}$	
.....	...	...	...	...	...	...		
$x_1$	$n_{11}$	$n_{12}$	...	$n_{1j}$	...	$n_{1m}$	$n_{1.}$	
	$n_{.1}$	$n_{.2}$		$n_{.j}$		$n_{.m}$	$n_{..} = n$	

No seguinte exemplo temos unha táboa de continxencia (variables cualitativas) onde temos as frecuencias absolutas e relativas %.

Exemplo: Datos “Encuesta General USA 1991”

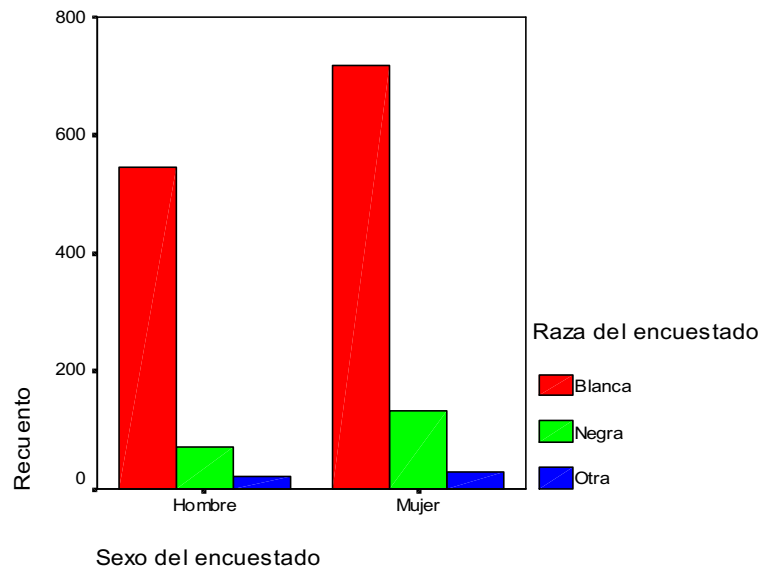
Tabla de contingencia Sexo del encuestado \* Raza del encuestado

		Raza del encuestado			Total	
		Blanca	Negra	Otra		
Sexo del encuestado	Hombre	Recuento	545	71	20	636
		% del total	35,9%	4,7%	1,3%	41,9%
	Mujer	Recuento	719	133	29	881
		% del total	47,4%	8,8%	1,9%	58,1%
Total		Recuento	1264	204	49	1517
		% del total	83,3%	13,4%	3,2%	100,0%

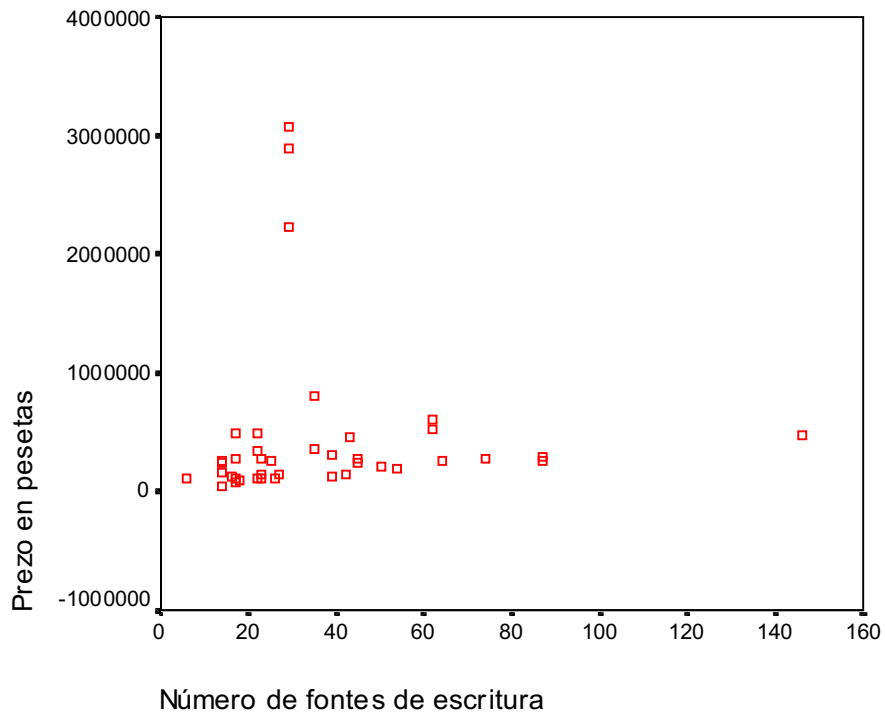
Representacions Gráficas:

A seguir podemos ollar distintas representacions gráficas de variables bidimensionais e mesmo o último gráfico que se utiliza para variables tridimensionais. Más aló de tres variables resulta imposible representar ou interpretar os gráficos

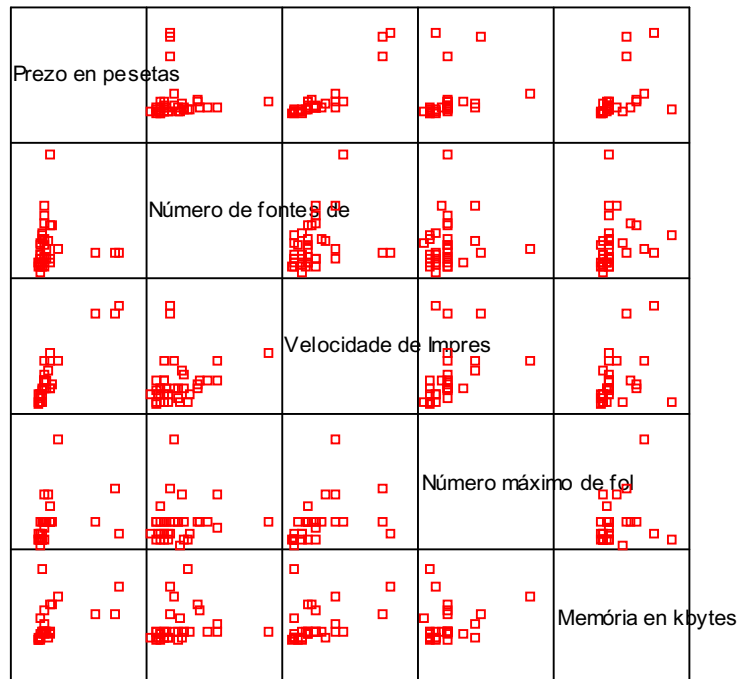
Gráfica 1. Gráfico de Barras



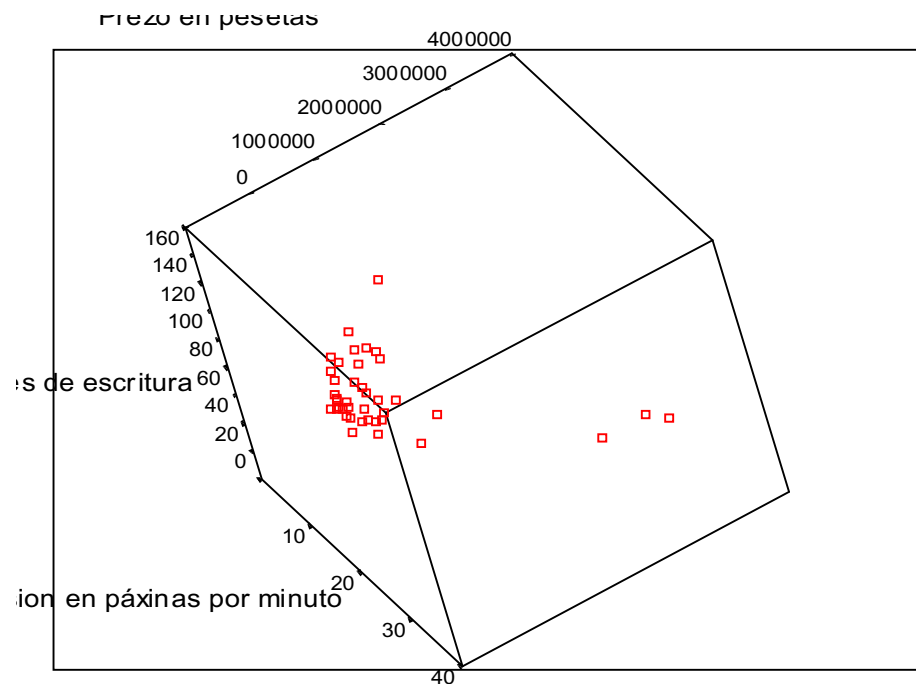
Gráfica 2. Gráfico de dispersión de dúas variables



Gráfica 3. Gráfico de dispersión simultáneo das cinco variables, tomadas de dúas en dúas.



Gráfica 4. Gráfico de dispersión de tres variables.



### 3.2. Distribucións Marxinais e Condicionadas. Independencia.

#### Distribucións Marxinais.

As veces interesa estudar por separado cada variable ou mesmo estudar unha variable condicionada a certo(s) valor(es) da outra.

O estudo individual de cada variable, independentemente da outra constitúe o que chamamos Distribución Marxinal de X ou Distribución Marxinal de Y, segundo sexa o caso. A Distribución Marxinal da variable X está constituída polos valores que toma a variable X xunto con o número de veces que aparece cada valor.  $(X=x_i, n_i=n_{i.}=\sum_j n_{ij})$ . Estas frecuencias

absolutas da variable marxinal X aparecen na última columna da táboa de frecuencias.

Do mesmo xeito a Distribución Marxinal de Y estará constituída polos valores que toma a variable Y xunto con o número de veces que aparece cada valor.  $(Y=y_j, n_j=n_{.j}=\sum_i n_{ij})$ .

Estas frecuencias absolutas da variable marxinal Y aparecen na última fila da táboa de frecuencias.

Podemos observar na taboa do exemplo cos datos da “Encuesta General USA 1991” toda a información das distribucións marxinais de X e de Y na última columna e na última fila respectivamente.

### Distribución condicionadas.

Poderíamos estar interesados en saber como é a distribución das razas dependendo do sexo. Isto significa supeditar o estudo duna variable a certo(s) valor(es) da outra. Na Enquisa Xeral USA 1991, gráficamente aparece na Gráfica 1 unha representación simultánea das dúas distribucións condicionadas: X=Raza condicionada a Y=home ou Y=muller.

Coñecer os valores que toma unha variable dada X condicionada a certo ou certos valores de outra  $Y=y_j$  xunto con o número de veces que aparecen aqueles valores  $n_i/Y=y_j$  chámase distribución de X condicionada a  $Y=y_j$ .

### Independencia de dúas variables X e Y.

Intuitivamente a independencia entre dúas variables se dá cando o coñecemento de certos valores de unha variable non presupón a aparición de determinados valores da outra. Isto na práctica se comproba ollando se a distribución marxinal duna variable coincide con cualquier distribución condicionada, independentemente do valor ou valores aos que condicione mos. Cuando non hai independencia resulta de interese estudar en que modo están relacionadas as variables. Agora deberemos ter en conta que non se pode medir esta relación de igual modo para variables cualitativas ou cuantitativas. Dentro de estas últimas tamén distinguiremos entre variables de intervalo ou variables ordinais.

### **3.3. Momentos dunha Distribución de Frecuencias.**

Os momentos dunha Distribución de Frecuencias son medidas que resumen a información de unha variable estatística, xa temos visto algúns exemplos de este tipo de medidas como son as medidas de centralización, dispersión ou forma. Os momentos xeneralizan estas medidas. Podemos definir momentos de distribución de frecuencias tamén para as variables unidimensionais, bidimensionais, etc., sempre que tratemos con variables numéricas ou cuantitativas.

Lembremos os momentos para unha variable unidimensional.

Momento de orde  $r$  a respecto de un punto  $c$ ,  $c$  ou  $r$  poden ser números reais:

$$\mu_{r,c} = \sum_i (x_i - c)^r f_i$$

Casos particulares:

- a) se  $c = \bar{x}$  o momento chama-se momento central
- b) se  $c = 0$  o momento chama-se momento a respeito da orixe.

Exemplo de momentos son a propia médua, que é o momento respecto da orixe de orde  $r=1$ .

Momentos de unha variable bidimensional.

Para unha variable bidimensional  $(X,Y)$  podemos definir o momento de orde  $(r,s)$  a respecto de dous puntos  $\underline{c}$  e  $\underline{d}$  como:  $\mu_{(r,s),(c,d)} = \sum_{i,j} (x_i - c)^r (y_j - d)^s f_{ij}$  o máis relevante é o

momento de orde  $r=1, s=1$  a respecto das méduas de  $X$  e  $Y$  que se chama Covarianza  $\mu_{(1,1),(\bar{x},\bar{y})} = \sum_{i,j} (x_i - \bar{x})(y_j - \bar{y})f_{ij}$ , a covarianza mide un certo tipo de relacion entre duas variables como veremos a seguir.

### 3.4. Covarianza e Correlación. Recta de Regresión.

Xa temos indicado que cuando non hai independencia entre variables, certo(s) valor(es) de unha das variables condicionarán a frecuencia con que aparecen os valores da outra. En estos casos resulta de interese saber medir a intensidade e forma de relacion entre variables.

A forma de relacionar-se duas variables pode ser diversa, os modelos que se utilizan son modelos matemáticos que expresan unha variable en funcion da outra como poden ser: rectas, funcións exponenciais, funcións logarítmicas, etc.

O xeito mais simple de relacionarmos duas variables é unha recta:  $Y=a + bX$ , entón temos varias incógnitas por abordar como son a estimación dos parámetros  $a$  e  $b$ , saber o grao de axuste dos nosos datos a este modelo ou ecuación. Isto último nos proporcionará o grao de relacion entre as variables. En resumo deberemos averiguar a FORMA e a INTENSIDADE da relacion entre as variables implicadas.

A Covarianza definida anteriormente pode interpretarse como unha medida da Relacion Linear entre as duas variables  $X$  e  $Y$  de tipo cuantitativo. É un valor positivo ou negativo: se a relación é directa a covarianza é un número positivo e se a relación entre as variables é inversa a covarianza é un número negativo. Por exemplo o peso e a altura de unha persoa dá unha covarianza positiva porque a relación é directa *a máis altura mais peso*. E o gasto de unha persoa en certo tipo de produtos pode ser de tipo inverso, como por exemplo o consumo de caramelos e a idade de un individuo.

O problema da covarianza como medida de relacion é que cambiando de unidades cambia a súa magnitude e por tanto non é doada de interpretar. Unha medida alternativa sen

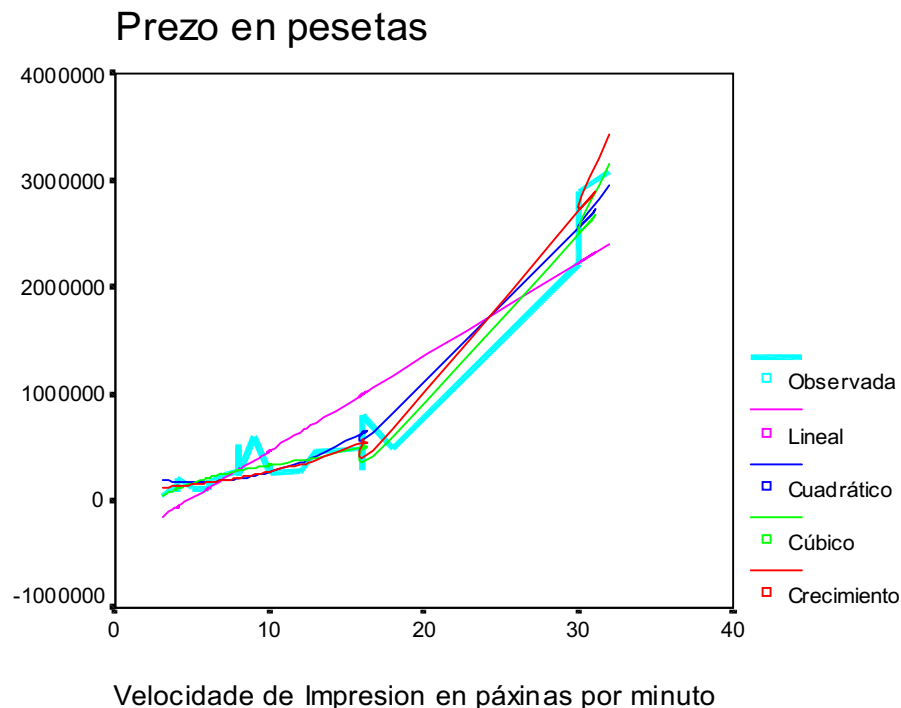
unidades é o coeficiente de correlación linear  $r = \text{COV}(X,Y) / \sigma_x \sigma_y$  o cuadrado do coeficiente de correlación chama-se coeficiente de determinación  $r^2$ .

O coeficiente de correlación só mide unha relación linear entre as variables:  $Y = a + bX$ . O coeficiente de correlación está acoutado entre  $-1$  e  $1$ , cuanto máis perto de  $1$  ou  $-1$  máis intensa será a relación linear entre as variables  $X$  e  $Y$ . Unha aproximación ao valor  $0$  do coeficiente de correlación indica unha falta de relación linear entre as variables, pero isto non presupón que non haxa outro tipo de relación como pode ser: cuadrática, cúbica, logarítmica, exponencial, etc. Para relacións non lineares debemos interpretar o coeficiente de Determinación  $R^2$  correspondente a cada modelo. Este coeficiente de determinación pode definir-se para cualquier tipo de relación funcional.

Abaixo temos os distintos coeficientes para diferentes modelos. No gráfico de abaixo podemos ollar diferentes modelos axustados aos datos sobre as impresoras laser. Podemos ver claramente que a Recta de Regresión en comparación con outros modelos:

Independent: X3

Dependent	Mth	b0	b1	b2	b3
X1	LIN	-411179	88022,3		
X1	QUA	73598	-38804	3837,14	
X1	CUB	-226516	114123	-8338,1	252,363
X1	GRO	11,3559	,1154		





### 3.5. Táboas de Continxencia

Cuando facemos unha análise simultánea de dúas características cualitativas en estudo ou cando tratamos de avaliar conxuntamente a resposta de dúas preguntas nunha enquisa, obtemos o que se chama TÁBOA DE CONTINXENCIA. O número de casos de cada combinación de valores das dúas variables aparece nunha cela da táboa, xunto con varios percentaxes. Estas entradas nas celas proporcionan información acerca das relacións entre as variables. Tentaremos responder a preguntas como: Hai relación entre o sexo e a resposta á pregunta formulada? Hai influencia do sexo na resposta? Son independentes?

Primeiro imos botar unha ollada á táboa de continxencia, ás súas percentaxes e o que nos queren dicir:

Tabla de contingencia ¿POSEE ALGUNA INFORMACIÓN ? \* SEXO

			SEXO		Total
			HOMBRE	MUJER	
¿POSEE ALGUNA INFORMACIÓN ?	SI	Recuento	17	13	30
		% de ¿POSEE ALGUNA INFORMACIÓN ?	56.7%	43.3%	100.0%
		% de SEXO	85.0%	65.0%	75.0%
		% del total	42.5%	32.5%	75.0%
	NON	Recuento	3	7	10
		% de ¿POSEE ALGUNA INFORMACIÓN ?	30.0%	70.0%	100.0%
		% de SEXO	15.0%	35.0%	25.0%
		% del total	7.5%	17.5%	25.0%
Total		Recuento	20	20	40
		% de ¿POSEE ALGUNA INFORMACIÓN ?	50.0%	50.0%	100.0%
		% de SEXO	100.0%	100.0%	100.0%
		% del total	50.0%	50.0%	100.0%

Contido das celas e marxinais

Os números situados á dereita e debaixo da táboa coñecen-se como **marxinais** e manifestan as variables por separado, independentemente unha da outra.

Dentro das celas podemos considerar, por orde de aparición cara abaixo:

- i) o número de casos ou frecuencia absoluta
- ii) a percentaxe de fila, percentaxe calculado sobre o total de esa fila.

- iii) a percentaxe de columna, percentaxe calculado sobre o total de esa columna.
- iv) a percentaxe sobre o total da táboa

Cál das percentaxes nos interesa?

#### Eleición das Percentaxes

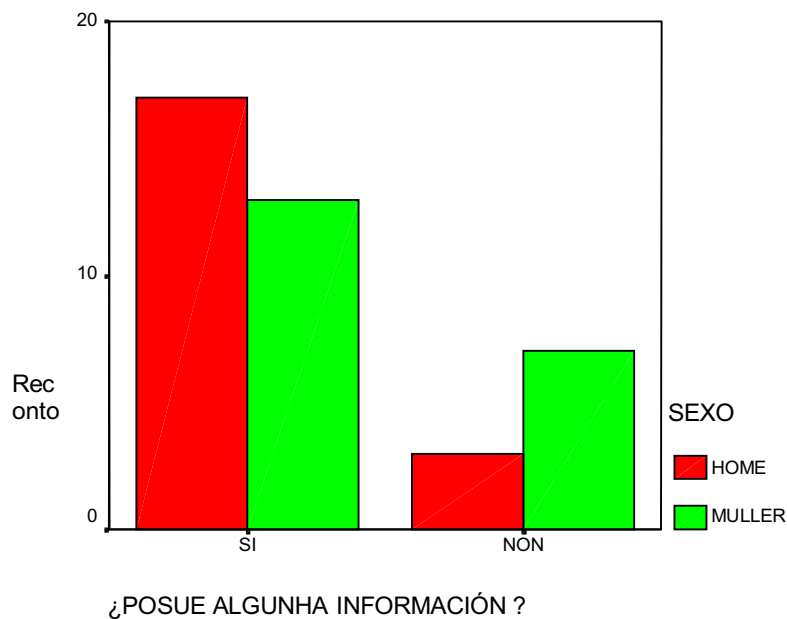
Se unha das variables está baixo control experimental se chamará variable independente. Supon-se que a variable independente afectará á resposta ou variable dependente. No noso caso a Sexo é a variable independente e a resposta á pregunta a variable dependente. Como REGRA XERAL seleccionamos a percentaxe da fila se a variable independente é a variable fila, e a percentaxe columna se a variable independente é a variable columna. No noso caso a información relevante está a percentaxe columna posto que ao facermos a táboa temos situado a variable independente (sexo) nas columnas.

#### Adición dunha variable de control

As veces necesitamos ver se grupos concretos de homes e mulleres difiren, en algunha resposta a outra(s) preguntas(s), teremos entón, que incluir variables adicionais na táboa de continxencia. Por exemplo se desexamos ver se o estado civil afecta ás respostas de homes e mulleres, poderíamos facer unha táboa de continxencia de sexo e a resposta para cada unha das categorías de interese do estado civil.

#### Representación gráfica das táboas de continxencia.

Igual que as táboas de frecuencias, a representación visual de unha táboa de continxencia simplifica, a miúdo, a busca de asociacións. Na gráfica que segue podemos ollar claramente a diferenza de opinión dos homes e das mulleres e a súa relación segundo manifestan que “posúen algunha información”



Utilización da táboa de continxencia para o filtrado de datos

Os erros e valores inusuais da entrada de datos que non poden representar-se con táboas de frecuencias as veces poden identificar-se utilizando unha táboa de continxencia. Por exemplo, un caso identificado como home con un historial de tres embarazos non se identificaría como sospeitoso nas táboas de frecuencias de sexo e número de embarazos. Cuando se consideran por separado, o código home é aceptable para sexo e o valor 3 é aceptable para o número de embarazos. Sen embargo, a combinación é inesperada.

Estatísticos das táboas de continxencia.

Ainda que un exame das distintas percentaxes de fila e columna nunha táboa de continxencia é un primeiro paso útil no estudo das relacións entre dúas variables, as percentaxes de fila e de columna non permiten a cuantificación ou comprobación de dita relación. Para esta finalidade, é útil considerar distintos índices que miden o grao de asociación, así como as probas estatísticas de hipóteses de que non existe asociación. Xa indicamos que cando as variables son de tipo cuantitativo existe unha medida do grao de relación entre as mesmas: o coeficiente de determinación  $R^2$ . Análogamente podemos medir o grao de Asociación entre dúas variables cualitativas polos correspondentes coeficientes. Pero distinguiremos entre datos de tipo ordinal ou datos de tipo nominal.

Cando os datos indican un orde o coeficiente que mide o grao de asociación deriva do coeficiente de correlacion linear e chama-se coeficiente de correlacion por rangos de SPEARMAN ou coeficiente de correlación ordinal:

$$\rho = 1 - \frac{6 \sum d_i^2}{n^3 - n}$$

sendo n o número total de datos,  $d_i = x_i - y_i$ , con  $x_i$  e  $y_i$  os rangos correspondentes a dous criterios de ordenación A e B para cada valor observado:

Exemplo: Rangos de cinco estudantes segundo as Cualificacións en Dereito Administrativo e Dereito Constitucional

Alunos	D. Administrativo (x)	D. Constitucional (y)	$d_i = x_i - y_i$	$d_i^2$
A	1	3	-2	4
B	2	2	0	0
C	3	1	2	4
D	4	5	-1	1
E	5	4	1	1

O coeficiente de correlación ordinal é  $\rho = 0.5$ . A súa interpretación é igual que o coeficiente de correlación linear: -1 significa unha discordancia perfecta, 1 significa unha concordancia perfecta.

Exercicio: calcula o coeficiente de correlación por rangos de Spearman.

Alunos	D. Administrativo (x)	D. Constitucional (y)	$d_i = x_i - y_i$	$d_i^2$
A	1	5		
B	2	4		
C	3	3		
D	4	1		
E	5	2		

### Coeficientes de continxencia.

Agora imos estudar as medidas de asociación para dúas características de tipo cualitativo. O grao de asociación para taboas de continxencia ven medido polo coeficiente de continxencia Xi-cuadrado  $\chi^2$  ou o cuadrado medio da continxencia  $\phi^2$ . Ambos coeficientes son positivos e o seu valor indica o grao de asociación. Canto máis perto de cero indicarán unha independencia entre os dous caracteres. O problema de estes coeficientes é que non están acoutados e por tanto non teñen doada interpretación. Outros coeficientes de continxencia evitan este problema.

$$\chi^2 = \sum_i \sum_j \frac{(n'_{ij} - n_{ij})^2}{n'_{ij}} = \sum_i \sum_j \frac{(\text{Esperadas} - \text{Observadas})^2}{\text{Esperadas}}$$

$$n'_{ij} = \text{frecuencia esperadas} = n_i \cdot n_j / n$$

$$\phi^2 = \frac{\chi^2}{n}$$

Exemplo: De unha poboación de 100 persoas, temos observado a seguinte tab.:

	Parados	Ocupados	Total
Pais parados	11	29	40
Pais ocupados	19	41	60
Total	30	70	100

Calcular o coeficiente Xi-cuadrado

De outra poboación distinta de 150 persoas, temos observado a seguinte tab.:

	Parados	Ocupados	Total
Pais parados	31	29	60
Pais ocupados	19	71	90
Total	50	100	150

Calcular o coeficiente Xi-cuadrado e comparar coa primeira das poboacións indicando a qué conclusión se chega.

### 3.6. Variables Multidimensionais.

O estudo de mais de dúas variables implica máis “complicación” en todos os aspectos. Para tres variables podemos obter gráficos en tres dimensións: gráficos de dispersión. Para máis variables isto resulta imposible, unicamente poderemos obter visions parciais de todo o conxunto utilizando proxeccións tridimensionais. En cuanto a medidas que resumen a información estatística contamos con: Vector de Médias, Matriz de Varianzas e Covarianzas, e Matriz de Correlacións. Por razóns obvias é de utilidade contar con un programa estatístico que nos axude a facer este tipo de cálculos. Estudaremos este tipo de variables utilizando un paquete de software estatístico que nos axude a tratar este tipo de información.

### Exercicios.

**Exercicio 1.** Os seguintes datos son os prezos de venda en miles de pesetas (Y) de un modelo de automóvil usado durante X anos:

X	1	2	2	3	5	5
Y	635	570	575	540	499	490

- Estimar varios modelos que se axusten aos datos anteriores.
- Estimar os parámetros a e b da curva  $y=ab^x$  utilizando a información da mostra anterior. Comentar o coeficiente de determinación.
- Estímese o prezo de venda de un vehículo que ten catro anos de uso.

**Exercicio 2.** Os seguintes proporcionan información sobre a renda mensual familiar (X) e os importes mensuais dos seus recibos de teléfono, en miles de pesetas, (Y) nunha mostra de 10 fogares:

X	160	450	360	320	300	130	410	150	360	400
Y	3.5	7.8	10.2	5.6	7.5	2.6	13.0	4.2	5.9	8.5

- Representar gráficamente os datos nun diagrama de dispersión
- Determinar a ecuación da recta de regresión entre as variables X e Y

**Exercicio 3.** A unha mostra de 200 persoas de ambos sexos deu-se-lles a probar margarina en manteiga e pediu-se-lles que indicasen a súa preferéncia, cos resultados da táboa. Calcula o valor do Xi-cuadrado. (Grao de asociación).

	Margarina	Manteiga
Homes	42	58
Mulleres	65	35

**Exercicio 4.** Nunha enquisa entre estudantes sobre a súa crencia na percepción ultrasensorial encontraron-se os datos da táboa. Indicar o grao de asociación entre as dúas características Xi-cuadrado.

	Cren totalmente	A medias	En absoluto
Enseñaría	30	50	20
Económicas	50	109	11
Humanidades	48	93	9

**Exercicio 5.** Na táboa seguinte presentan-se as cualificacións médias de un grupo de estudantes en dúas materias. Calcula o grao de asociación.

	Cualificación Baixa	Cualificación Média	Cualificación Alta
Matéria A	15	18	7
Matéria B	2	22	23

**Exercicio 6.** Nunha enquisa de presupostos familiares feita a 200 familias de unha cidade ten-se obtido a seguinte taboa de correlacion sobre os seus ingresos e gastos de consumo referidos ao derradeiro mes (os intervalos están expresados en miles de pesetas):

G = Gastos de consumo Ingresos = I	60-80	80-100	100-120	120-140	140-160
60-80	30	2			
80-100	25	10	3		
100-120	15	25	10		
120-140	5	18	30	3	
140-160			8	15	1

- Estudar por separado as variables G e I calculando a distribución de frecuencias média, desviación típica.
- Estudar a distribución de Gastos condicionada aos distintos rangos de valores dos ingresos. Calculando para cada condicionada a distribución de gastos, a média condicionada e a varianza condicionada.
- Calcular a ecuación linear que liga estas dúas variables. (utilizar unha calculadora)
- Cal é o grao de axuste dos puntos á esta recta?

**Exercicio 7.** A partir dos seguintes datos asustar dúas rectas para expresar a variable Y en función das variables  $X_1$  e  $X_2$  respectivamente.

$Y_i$	3	4	8	5	5
$X_{1i}$	1	2	3	4	5
$X_{2i}$	8	9	16	9	8

Onde é maior o grao de axuste ao modelo linear?

**Exercicio 8.** O consumo de enerxía eléctrica en kwh per capita en 1985 e a renda per capita, expresada en dólares, foron os seguintes para os países da enton Comunidade Económica Europea:

País	Alem.	Bel	Din	Esp	Fr	Gr.	It.	Ir.	Lx.	Hol.	Por.	GB.
Consumo de Enerxía eléctrica	5730	4920	4960	2680	4510	2400	3050	2760	10450	4250	1720	4280
Renda	11090	8430	11290	4470	9860	3740	6440	4950	13650	9430	1970	8530

- Estimar os parámetros dun modelo linear que exprese a demanda en función da renda do país, calculando o coeficiente de correlacion.
- Calcular a demanda de enerxía eléctrica para un suposto país con renda de 6000 \$.
- Calcular os valores estimados para cada un dos países xunto cos residuos. Interpretar os resultados.