

Conceitos Básicos

- **População** ou **Universo Estatístico**: conjunto de elementos sobre o qual incide o estudo estatístico;
- **Característica Estatística** ou **Atributo**: a característica que se observa nos elementos da população;
- **Modalidades** (incompatíveis e exaustivas): as diversas formas em que se apresenta a característica estatística;
- **Amostra**: subconjunto finito da população (razões para a recolha de uma amostra: dimensão excessiva da população, estudo de natureza destrutiva, economia e tempo)

Exemplos:

➤ O Gestor de produção de uma fábrica pretende ter uma ideia da percentagem de peças defeituosas que a fábrica produziu em determinado período de tempo.

População - *todas as peças produzidas pela fábrica durante aquele período de tempo.*

Característica estatística *tem apenas duas modalidades: peça defeituosa e peça não defeituosa.*

➤ Num estudo de mercado para construção de um centro comercial, interessa estudar o rendimento familiar mensal dos habitantes de uma determinada cidade.

População - *famílias daquela cidade*

Característica estatística - *rendimento familiar mensal.*

Modalidades *não se podem enumerar; são todos os valores desde, por exemplo, 10 0Euros até 10000 Euros.*

➤ Uma determinada empresa pretende realizar um inquérito aos seus trabalhadores, onde lhes é pedido para classificarem a qualidade do serviço do bar/refeitório segundo a seguinte escala: fraco, razoável, bom ou muito bom.

População - trabalhadores da fábrica

Característica estatística opinião acerca da qualidade do serviço do bar/refeitório. Neste estudo o atributo pode manifestar-se nas seguintes

Modalidades: fraco, razoável, bom ou muito bom.

Tipos de Dados estatísticos.

- **Quantitativos** (e.g., o número diário de nascimentos no hospital de Viseu ou a altura dos alunos da ESTV):
 - **Discretos** (número finito ou infinito numerável de modalidades; e.g., o número diário de nascimentos no hospital de Viseu)
 -
 - **Contínuos** (pode assumir qualquer valor num intervalo de números reais; a distinção entre os dois é por vezes arbitrária; e.g., altura de um aluno da ESTV)
- **Qualitativos** (e.g., cor dos cabelos, estado civil)

Escalas de medida de dados estatísticos

Escala Nominal (dados qualitativos): apresentam-se em diferentes categorias ou classes, não ordenáveis.

Exemplos: - Estado civil dos empregados de uma empresa;

- Religião;

- Cor de cabelos;

- Profissão de um indivíduo;

- Sexo dos indivíduos de uma população (**característica dicotómica ou binária**);

- Numa sondagem de opinião, a resposta à pergunta “É a favor da despenalização do aborto?” (**característica dicotómica ou binária**).

Para lidar com este tipo de dados é frequente atribuir um código numérico a cada categoria da característica em estudo, mas **cuidado! não faz qualquer sentido usar operações aritméticas e calcular médias, desvios padrões, etc..**

Escala Ordinal (dados qualitativos): as diversas categorias possuem uma ordem intrínseca (os códigos numéricos devem ter em conta essa ordem).

Exemplos:

- Habilitações literárias
- Num inquérito de opinião pede-se às pessoas que classifiquem um determinado produto como sendo, muito fraco, fraco, razoável, bom ou muito bom.
- Classificação dos clientes de um banco, segundo o volume de capital que movimentam mensalmente: pouco importantes, importantes ou muito importantes.
- Classificação dos alunos de uma escola segundo a sua altura: baixos (menos de 155 cm), médios (entre 155 e 170 cm) ou altos (mais de 170 cm).

Escala de Intervalo (dados quantitativos):

Os dados podem ser ordenados e a diferença entre dois valores desta escala pode ser calculada e interpretada.

Exemplo:

– Temperatura do ar em graus Fahrenheit ou em graus centígrados $F=9/5C+32$,

Distâncias numericamente iguais implicam as mesmas alterações na característica que está a ser medida (20° C está à mesma distância de 25° C do que 25° C de 30° C).

Não podemos atribuir um significado à razão entre dois valores (se na Guarda se registar uma temperatura de 40° C e em Viseu 20° C, isto não significaria que na Guarda está duas vezes mais calor do que em Viseu)

O valor zero não tem o significado de “nada”. Não se pode dizer que uma cidade onde se registre uma temperatura de 0° C não tem qualquer temperatura.

Escala de Razões ou de Rácios (dados quantitativos)

Tem todas as características de uma escala de intervalo e, além disso, o valor zero representa a ausência total da característica que está a ser medida. Com dados medidos nesta escala, não só é possível atribuir um significado à diferença (distância) entre dois valores como também à razão entre eles.

Alterações nas unidades de medida não afectam os rácios entre dois valores.

Exemplos: peso; altura

A temperatura do ar não está definida numa escala de rácios. Note que

$$10^{\circ}\text{C} = 50^{\circ}\text{F} \qquad \text{e} \qquad 30^{\circ}\text{C} = 86^{\circ}\text{F}$$

mas,

$$\frac{10^{\circ}\text{C}}{30^{\circ}\text{C}} \neq \frac{50^{\circ}\text{F}}{86^{\circ}\text{F}}.$$

Representação de Dados

População ou amostra de n indivíduos.

Atributo A com p modalidades: A_1, A_2, \dots, A_p .

Frequência absoluta ou **efectivo** da modalidade $A_i \rightarrow n_i$, é o nº de indivíduos que apresentam a modalidade A_i .

Frequência relativa da modalidade $A_i \rightarrow f_i$, é a proporção de indivíduos que apresentam a modalidade A_i , $f_i = \frac{n_i}{n}$.

$$\sum_{i=1}^p n_i = n \quad \text{e} \quad \sum_{i=1}^p f_i = 1.$$

Representação Tabular – Quadros de Frequências

Modalidades	Frequências absolutas	Frequências relativas	Frequências absolutas acumuladas	Frequências relativas acumuladas
A_1	n_1	$f_1=n_1/n$	n_1	f_1
A_2	n_2	$f_2=n_2/n$	n_1+n_2	f_1+f_2
\vdots	\vdots	\vdots	\vdots	\vdots
A_p	n_p	$f_p=n_p/n$	$n_1+n_2+\dots+n_p=n$	$f_1+f_2+\dots+f_p=1$
Total	n	1	-	-

Exemplo - Vendas

Os dados que se seguem são relativos às vendas (em contos) de 30 vendedores da ElectroNoLar durante o mês de Outubro passado.

120	130	80	100	110	100	90	70	140	120
140	110	100	100	110	70	90	90	130	150
160	80	70	120	100	110	110	80	100	120

Tabela de frequências - dados não agrupados

x_i	Freq. absolutas n_i	Freq. relativas f_i	Freq. absolutas acumuladas	Freq. relativas acumuladas
70	3	3/30	3	3/30
80	3	3/30	6	6/30
90	3	3/30	9	9/30
100	6	6/30	15	15/30
110	5	5/30	20	20/30
120	4	4/30	24	24/30
130	2	2/30	26	26/30
140	2	2/30	28	28/30
150	1	1/30	29	29/30
160	1	1/30	30	1
Total	30	1	-	-

Tabela de frequências com dados agrupados.

Classes de valores	Freq. absolutas n_i	Freq. relativas f_i	Freq. absolutas acum.	Freq. relativas acum.
[60, 80[3	3/30	3	3/30
[80, 100[6	6/30	9	9/30
[100, 120[11	11/30	20	20/30
[120, 140[6	6/30	26	26/30
[140, 160[3	3/30	29	29/30
[160, 180[1	1/30	30	30/30
Total	30	1	-	-

- Os intervalos de classe podem ter a mesma amplitude ou amplitudes diferentes dependendo da natureza dos fenómenos a estudar.
- Agrupar os dados implica perda de informação.
- Regras práticas para a determinação do nº de classes:


Regra de Sturges – nº de classes $\cong 1 + \log_{10}(n) / \log_{10}(2)$

Outra – nº de classes $\cong \sqrt{n}$ (usualmente empregue quando $n > 25$).


Representação gráfica

Dados Não Agrupados


Diagrama de barras



Polígono de frequências



Representação gráfica das frequências acumuladas



Dados Agrupados

Histograma

No histograma tomamos rectângulos justapostos, cada um com base proporcional à amplitude da classe respectiva e altura h_i dada por:

$$h_i = \begin{cases} \frac{n_i}{a_{i+1} - a_i} & \text{(frequências absolutas)} \\ \frac{f_i}{a_{i+1} - a_i} & \text{(frequências relativas)} \end{cases}$$


A área de cada rectângulo é então proporcional à frequência da classe respectiva:

$$\text{área do } i - \text{ésimo rectângulo} = \begin{cases} n_i & \text{(frequências absolutas)} \\ f_i & \text{(frequências relativas)} \end{cases}$$


A área total do histograma é igual a **n** se foram usadas frequências absolutas e igual a **1** se foram usadas frequências relativas.

Note-se, porém, que quando as classes têm todas a mesma amplitude é costume, para facilitar a representação, tomar para altura de cada rectângulo a frequência absoluta ou relativa da classe a que respeita.


Histograma



Polígono de frequências



Polígono de frequências acumuladas




Exemplo – Calçado Desportivo


Os dados estão registados no ficheiro *Compra Calçado Desportivo.sav*.
Construa-se o histograma para a variável **Semanada** (v5).

SPSS: Graphs – Chart Builder– Ok

The image shows the SPSS Chart Builder and Element Properties dialog boxes. The Chart Builder window displays a histogram for the variable 'Semanada' (v5). The 'Variables' list on the left includes 'ninq', 'idade', 'sexo', 'Habilitações', 'Principal mar...', 'Semanada [v5]', 'Fila [v6.1]', 'Ripcurl [v6.2]', and 'Adidas [v6.3]'. The 'Semanada [v5]' variable is highlighted in the 'Variables' list and also in the 'Semanada' box within the chart preview. The 'Element Properties' dialog box is open, showing the 'Statistics' section with 'Variable: Semanada' and 'Statistic: Histogram'. The 'Element Properties: Set Parameters' dialog box is also open, showing the 'Bin Sizes' section with 'Interval width' set to 10. The 'Histogram' option is selected in the 'Choose from:' list at the bottom left of the Chart Builder window.





Clicando 2x no gráfico podemos editá-lo e, por exemplo, clicar em  (na barra superior) para obter:




Alternativamente,

SPSS: Graphs – Legacy Dialogs – Histogram





Clicando 2x no gráfico podemos editá-lo e, por exemplo, alterar a amplitude das classes para obter um histograma igual ao anterior.





Para as **habilitações** podemos construir vários tipos de gráficos:

Eis alguns exemplos:

Graphs – Legacy Dialogs – Pie – Summaries for groups of cases




Graphs – Legacy Dialogs – Bar – Simple



A tabela de frequências e os gráficos anteriores podem também ser obtidos em:

Analyse – Descriptive Statistics – Frequencies



Habilitações

	Frequency	Percent	Valid Percent	Cumulative Percent
Valid Até ao 9ºano	33	11,0	11,1	11,1
9ºano ao 12ºano	118	39,3	39,6	50,7
+12ºano	147	49,0	49,3	100,0
Total	298	99,3	100,0	
Missing System	2	,7		
Total	300	100,0		




Há muito para explorar no SPSS...

Exemplo - Vendas (atividade proposta para trabalho individual)


Construa um ficheiro em SPSS com os dados deste exemplo.

Obtenha a tabela de frequências e os gráficos abaixo.


		vendas			
		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	70,00	3	10,0	10,0	10,0
	80,00	3	10,0	10,0	20,0
	90,00	3	10,0	10,0	30,0
	100,00	6	20,0	20,0	50,0
	110,00	5	16,7	16,7	66,7
	120,00	4	13,3	13,3	80,0
	130,00	2	6,7	6,7	86,7
	140,00	2	6,7	6,7	93,3
	150,00	1	3,3	3,3	96,7
	160,00	1	3,3	3,3	100,0
	Total	30	100,0	100,0	




Graphs - Legacy Dialogs - Line - Simple



Graphs - Legacy Dialogs - Bar - Simple



Graphs - Legacy Dialogs - Histogram
 (para obter um histograma igual ao anterior, é preciso clicar 2x no gráfico e alterar a amplitude das classes para 20)



Medidas Descritivas

Medidas de Localização e de Tendência Central

As medidas que descrevemos seguidamente dão-nos uma ideia do “centro” ou “localização” da distribuição dos dados.

Média aritmética

Sejam x_1, x_2, \dots, x_p os valores distintos de um conjunto de n dados, cada um deles com frequência absoluta n_i e frequência relativa f_i . Então a média aritmética representa-se por \bar{x} e é dada por:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n n_i x_i = \sum_{i=1}^n f_i x_i.$$

Para **dados agrupados em classes** toma-se para x_i o ponto médio da i -ésima classe; n_i e f_i serão, naturalmente, a frequência absoluta e relativa da i -ésima classe, respectivamente.

Exemplo – Pneus

A tabela de frequências que se segue é relativa ao número de pneus produzidos por dia na fábrica MAVOR, para uma amostra de 30 dias.

x_i	Freq. absoluta n_i	Freq. relativa f_i	Freq. abso. acum.	Freq. relat. acum.s	$n_i x_i$
18	2	0.06667	2	0.06667	36
20	3	0.1	5	0.16667	60
21	5	0.16667	10	0.33334	105
24	7	0.23333	17	0.56667	168
25	6	0.2	23	0.76667	150
28	4	0.13333	27	0.9	112
29	3	0.1	30	1	87
Total	30	1	-	-	718

A média de pneus produzidos diariamente, para os 30 dias considerados é:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n n_i x_i = \frac{718}{30} = 23.9333.$$

Mediana

Trata-se do valor que divide o conjunto de dados, ordenados por ordem crescente, em duas partes iguais. Isto é, a mediana, como o próprio nome indica, é o ponto mediano de um conjunto de dados ordenados em ordem crescente.

Sejam x_1, x_2, \dots, x_n , n observações ordenadas por ordem crescente dos seus valores, e que constituem o conjunto de dados em análise.

$$Me = \begin{cases} x_{(n+1)/2} & \text{se } n \text{ é impar} \\ \frac{x_{n/2} + x_{n/2+1}}{2} & \text{se } n \text{ é par} \end{cases}$$

Exemplo – Pneus: como n é par: $Me = \frac{x_{30/2} + x_{30/2+1}}{2} = \frac{x_{15} + x_{16}}{2} = \frac{24 + 24}{2} = 24$.

Para **dados agrupados em classes**, procuramos a classe mediana, sendo esta tal que a sua frequência absoluta (resp. relativa) acumulada é $\geq n/2$ (resp. $1/2$) e a frequência absoluta (resp. relativa) acumulada da classe anterior é $< n/2$ (resp. $1/2$).

Depois de encontrada a classe mediana, $[a_j, a_{j+1}[$, encontra-se a mediana por interpolação linear:

$$Me = a_j + \frac{n/2 - \sum_{i=1}^{j-1} n_i}{n_j} (a_{j+1} - a_j)$$

Moda

É o valor mais frequente num conjunto de dados.

- {2, 3, 4, 4, 5} → Mo=4 (**distribuição unimodal**);
- {2, 2, 3, 4, 4, 5} → Mo=2 e 4 (**distribuição bimodal**);
- **Exemplo – Pneus** → Mo=24.

Havendo mais de 2 valores modais, a distribuição diz-se **multimodal**.

Quando os **dados estão agrupados em classes**, a classe modal é aquela que tem maior frequência por unidade de amplitude. Nestes casos não podemos determinar o valor exacto da moda pois não sabemos como estão distribuídas as observações dentro de cada classe. Podemos, no entanto, obter uma aproximação da Moda usando uma das seguintes fórmulas:

Fórmula de King:
$$Mo = a_j + \frac{n_{j+1}}{n_{j-1} + n_{j+1}} (a_{j+1} - a_j)$$

Fórmula de Czuber:
$$Mo = a_j + \frac{n_j - n_{j-1}}{(n_j - n_{j-1}) + (n_j - n_{j+1})} (a_{j+1} - a_j)$$

onde, $[a_j, a_{j+1}[$ é a classe modal; n_j é a freq. abso. desta classe; n_{j+1} e n_{j-1} são, resp., a freq. abso. da classe anterior e posterior à modal.

Medidas de Localização não Central – Quantis: Q_p

A mediana divide o conjunto de dados em duas partes iguais.

Quando o conjunto de dados ordenados é dividido em 4 partes iguais, os pontos de divisão são chamados os **quartis**:

- $Q_{1/4}$, 1º quartil – valor que tem cerca de 25% dos dados abaixo dele;
- $Q_{2/4}$, 2º quartil (**Mediana**) – valor que tem cerca de 50% dos dados abaixo;
- $Q_{3/4}$, 3º quartil – valor que tem cerca de 75% dos dados abaixo dele.

Podemos ainda calcular os **quintis**, **decis**, **percentis**,...

Cálculo do quantil de ordem p , Q_p : *Dados não agrupados em classes*

Sejam x_1, x_2, \dots, x_n , n observações ordenadas **por ordem crescente** dos seus valores.

Se np não é um inteiro, então $Q_p = x_k$, onde k é o inteiro imediatamente seguinte a np . Caso contrário, sendo np um inteiro, então $Q_p = (x_{np} + x_{np+1})/2$.

Cálculo do quantil de ordem p , Q_p : *Dados agrupados em classes*


Seja $[a_j, a_{j+1}[$ a classe que contém Q_p , i.e., que contém o valor ao qual corresponde a frequência absoluta (resp. relativa) acumulada de np (resp. p). Por interpolação linear obtém-se Q_p :

$$Q_p = a_j + \frac{np - \sum_{i=1}^{j-1} n_i}{n_j} (a_{j+1} - a_j)$$

Exemplo – Calçado Desportivo

Recorrendo ao SPSS, para a variável **Semanada** (v5) ...

Analyse – Descriptive Statistics – Frequencies



Statistics

Semanada

N	Valid	300
	Missing	0
Mean		28,65
Median		28,50
Mode		22
Percentiles	25	22,00
	50	28,50
	75	35,00

Interprete os valores fornecidos no quadro.

Exemplo - Vendas (atividade proposta para trabalho individual)

Recorrendo ao SPSS obtenha a tabela seguinte.

Statistics

Vendas

N	Valid	30
	Missing	0
Mean		106,6667
Median		105,0000
Mode		100,00
Percentiles	25	90,0000
	50	105,0000
	75	120,0000

Complete as seguintes afirmações:

No mês de Outubro o volume médio de vendas por vendedor foi de _____ .

Cerca de metade dos vendedores venderam menos de _____ .

Cerca de 25% dos vendedores venderam menos de _____ .

Cerca de 25% dos vendedores venderam mais de _____ .


Medidas de Dispersão

Exemplo:

Duas empresas concorrentes com sede em Viseu, obtiveram os seguintes lucros nos 5 últimos anos:

	Lucros em unidades monetárias (u. m.)				
Empresa 1	10	13	12	14	16
Empresa 2	7	5	10	19	24

O lucro médio das duas empresa nos últimos 5 anos é o mesmo, 13 u.m., no entanto a Empresa 2 apresenta uma maior variabilidade nos lucros do que a Empresa 1.



O **intervalo interquartis**, $[Q_{1/4}, Q_{3/4}]$ contém 50% das observações. A amplitude deste intervalo, **amplitude interquartis**, é uma medida de dispersão.

As medidas de dispersão mais utilizadas são o **desvio padrão** e a **variância** que definimos a seguir.

Sejam x_1, x_2, \dots, x_p os valores distintos de um conjunto de n dados, cada um deles com frequência absoluta n_i e frequência relativa f_i .

- Se estes dados constituem observações feitas sobre **toda a população**, a **variância** denota-se por σ^2 e é calculada da seguinte maneira:

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^p n_i (x_i - \bar{x})^2 = \sum_{i=1}^p f_i (x_i - \bar{x})^2, \quad \text{ou} \quad \sigma^2 = \frac{1}{n} \sum_{i=1}^p n_i x_i^2 - \bar{x}^2 = \sum_{i=1}^p f_i x_i^2 - \bar{x}^2.$$

- Se, pelo contrário, o conjunto de dados constitui **uma amostra** da população, então a **variância** denota-se por s^2 e é dada por:

$$s^2 = \frac{1}{n-1} \sum_{i=1}^p n_i (x_i - \bar{x})^2 \quad \text{ou} \quad s^2 = \frac{1}{n-1} \left(\sum_{i=1}^p n_i x_i^2 - n\bar{x}^2 \right).$$

O **desvio padrão** é a raiz quadrada da variância e denota-se por σ ou por s .

Exemplo – Pneus

Como dispomos de uma amostra, temos: $s^2 = \frac{1}{n-1} \left(\sum_{i=1}^p n_i x_i^2 - n\bar{x}^2 \right)$.

x_i	Frequências absolutas n_i	Frequências relativas f_i	$n_i x_i$	$n_i x_i^2$
18	2	0.06667	36	648
20	3	0.1	60	1200
21	5	0.16667	105	2205
24	7	0.23333	168	4032
25	6	0.2	150	3750
28	4	0.13333	112	3136
29	3	0.1	87	2523
Total	30	1	718	17494

Então a variância e o desvio padrão são, respectivamente,

$$s^2 = \frac{1}{29} (17494 - 30 \times 23.9333^2) = 10.6867 \text{ (u.m.)}^2 \quad \text{e} \quad s = \sqrt{106867} = 3.269 \text{ u.m.}$$


As medidas descritivas usadas com maior frequência em cada tipo de dados (escala de medida) são dadas no quadro seguinte:

Escala de medida	Estatísticas descritivas	
	Medidas de localização	Medidas de dispersão
<p>Nominal (sem qualquer relação de ordem).</p> <ul style="list-style-type: none"> ● espécie ou género 	<p>Moda: valor mais frequente da amostra</p>	<p>Não há...</p>
<p>Ordinal (ordenável, mas sem quantificar).</p> <ul style="list-style-type: none"> ● nível hierárquico ● ordem de chegada 	<p>Moda; Quartis: Valor abaixo do qual estão 25%(Q_{1/4}), 50%(Q_{2/4}) ou mediana) ou 75%(Q_{3/4}) dos valores da amostra</p>	<p>Amplitude interquartilica AIQ= Q_{3/4}- Q_{1/4} Intervalo interquartis=[Q_{1/4}, Q_{3/4}]</p>
<p>Quantitativa (ordenável sendo possível quantificar as diferenças).</p> <ul style="list-style-type: none"> ● nº de células ● altura ● temperatura 	<p>Moda Quartis Média</p>	<p>AIQ Desvio padrão</p> $s = \sqrt{\frac{1}{n-1} \sum_{i=1}^p n_i (x_i - \bar{x})^2}$ <p>Erro padrão da média s/\sqrt{n}</p>

Exemplo – Calçado Desportivo

Recorrendo ao SPSS, podemos agora obter, para a variável **Semanada** (v5), as medidas de dispersão abordadas.

Analyse – Descriptive Statistics – Frequencies



Statistics		
Semanada		
N	Valid	300
	Missing	0
Mean		28,65
Std. Error of Mean		,453
Median		28,50
Mode		22
Std. Deviation		7,851
Variance		61,645
Range		44
Minimum		3
Maximum		47
Percentiles	25	22,00
	50	28,50
	75	35,00

Exemplo - Vendas (atividade proposta para trabalho individual)

Recorrendo ao SPSS obtenha a tabela seguinte.

Statistics

Vendas

N	Valid	30
	Missing	0
Mean		106,6667
Std. Error of Mean		4,29738
Median		105,0000
Mode		100,00
Std. Deviation		23,53769
Variance		554,023
Range		90,00
Minimum		70,00
Maximum		160,00
Percentiles	25	90,0000
	50	105,0000
	75	120,0000

Coeficiente de dispersão e de variação

Medidas de dispersão absolutas: expressas na mesma unidade dos dados a que se referem

Medidas de dispersão relativas: independentes da unidade de medida dos dados a que se referem

A variância e o desvio padrão são medidas de dispersão absolutas.

Se pretendermos comparar a dispersão de dois conjuntos de dados que não estejam expressos na mesma unidade de medida, teremos de adoptar uma medida de dispersão relativa, por exemplo:

Coeficiente de dispersão: $cd = \frac{s}{\bar{x}}$ ou $\frac{\sigma}{\bar{x}}$

Coeficiente de variação: $cv = cd \times 100\%$

Estes coeficientes só se empregam quando a variável toma valores de um só sinal.

Exemplos (atividades propostas para trabalho individual)

1. Uma transportadora pretende comparar a variabilidade do peso com a variabilidade do volume das caixas que transporta habitualmente. Sabe-se que as caixas têm um peso médio de 10 quilos com um desvio padrão de 3 kg. O volume médio é de 30 dm^3 com um desvio padrão de 6 dm^3 . Ajude a transportadora neste estudo.
2. Compare a variabilidade do peso dos patos adultos e dos elefantes asiáticos adultos sabendo que os patos de uma determinada espécie de têm um peso medio de 4 kg com desvio padrão de 1,2 e que os elefantes asiáticos pesam em média 4200 kg com um desvio padrão de 400 kg.
3. Qual dos dois conjuntos de dados tem maior dispersão, A (em unidades monetárias) ou B (em metros)?

$$A=\{1, 13, 2, 6, 9\} \quad B=\{10.3, 126.52, 29.76, 5.931, 7.463 \}$$

Coeficientes de assimetria

As distribuições de frequências podem ser simétricas ou não.

Considerando apenas distribuições unimodais, temos, em geral:

Distribuições simétricas $\rightarrow \bar{x} = Me = Mo$


Distribuições assimétricas positivas $\rightarrow Mo < Me < \bar{x}$

A cauda direita é mais longa e menos abrupta do que a esquerda.

Distribuições assimétricas negativas $\rightarrow \bar{x} < Me < Mo$

A cauda esquerda é mais longa e menos abrupta do que a direita

Nas distribuições assimétricas os valores extremos da cauda mais longa puxam a média para o lado direito. A mediana, como divide a área em duas partes iguais, para compensar a redução de área no lado abrupto, afasta-se também da moda, mas menos do que a média.



Há vários coeficientes para medir a assimetria; estes, de um modo geral, interpretam-se da seguinte maneira:

Distribuição simétrica → *coeficiente* $\cong 0$

Distribuição assimétrica positiva → *coeficiente* > 0

Distribuição assimétrica negativa → *coeficiente* < 0

Coeficientes de achatamento


Estes medem o grau de achatamento de uma distribuição, considerado em relação ao da distribuição normal. Para o coeficiente calculado pelo SPSS a interpretação é a seguinte.

Distribuição mesocúrtica → *coeficiente* $\cong 0$ (achatamento igual ao da normal)

Distribuição leptocúrtica → *coeficiente* > 0 (achatamento inferior ao da normal)

Distribuição platicúrtica → *coeficiente* < 0 (achatamento superior ao da normal)

(<http://pt.wikipedia.org>)




A curva normal está representada pela linha preta.


Exemplo – Calçado Desportivo

Recorde o histograma da varável semanada:

A distribuição aparenta ser aproximadamente simétrica...



Analyse - Descriptive Statistics
- Frequencies



Statistics

Semanada

N	Valid	300
	Missing	0
Mean		28,65
Std. Error of Mean		,453
Median		28,50
Mode		22
Std. Deviation		7,851
Variance		61,645
Skewness		-,007
Std. Error of Skewness		,141
Kurtosis		-,778
Std. Error of Kurtosis		,281
Range		44
Minimum		3
Maximum		47
Percentiles	25	22,00
	50	28,50
	75	35,00

Coeficiente de assimetria $\cong 0 \rightarrow$ distribuição simétrica

Coeficiente de achatamento $< 0 \rightarrow$ distribuição platicúrtica

Outras Representações Gráficas

Caixas de bigodes ou diagramas de extremos e quartis (boxplots)

Neste gráfico representam-se a mediana, os quartis, os valores máximo e mínimo e eventuais valores extremos ou outliers.


Os valores **extremos** são assinalados com um **asterisco** e correspondem a valores acima do 3º quartil, ou abaixo do 1º quartil, pelo menos 3 vezes a amplitude interquartis.

Os **outliers** são assinalados com uma **bola** e correspondem a valores acima do 3º quartil, ou abaixo do 1º quartil, de 1.5 a 3 vezes a amplitude interquartis.

Exemplo – Calçado Desportivo


Para a variável **Semanada (v5)**...

Graphs – Legacy Dialogs – Boxplot – Simple



Recorde a tabela seguinte

Statistics		
Semana		
N	Valid	300
	Missing	0
Mean		28,65
Std. Error of Mean		,453
Median		28,50
Mode		22
Std. Deviation		7,851
Variance		61,645
Range		44
Minimum		3
Maximum		47
Percentiles	25	22,00
	50	28,50
	75	35,00



Este gráfico, bem como uma tabela com algumas estatísticas descritivas, pode também ser obtida através de

Analyse - Descriptive Statistics - Explore...


... colocando a variável **Semana** na caixa **Dependent List**;

...no botão `plots` podemos também pedir o histograma



Exemplo - Vendas (atividade proposta para trabalho individual)

Recorrendo ao SPSS obtenha o diagrama de extremos e quartis.






Comparando distribuições...

Exemplo – Vestuário

Para a variável P10 – Quanto gasta em média por mês, comparemos os géneros...

Graphs – Legacy Dialogs – Boxplot – Simple



Também podíamos ter feito:



Analyse – Descriptive Statistics – Explore...

Colocando a variável sexo na caixa Factor List

Comente... (em termos de localização e de dispersão)

Outra forma gráfica para fazer a comparação é:

Graphs – Legacy Dialogs – Population Pyramid



Este gráfico evidencia bastante claramente uma maior dispersão dos valores dos gastos no género masculino do que no feminino.

Quanto à tendência central, o género feminino apresenta valores superiores, apoiando a ideia estereotipada de que as Senhoras, em relação às compras, ...

Exemplo - Vestuário (atividade proposta para trabalho individual)

Compare os dois géneros quanto ao tempo gasto numa sessão de compras (P_13) e comente.

Ainda, comparando distribuições...


Exemplo – Vestuário

Comparando os géneros quanto à frequência de compras (P11) ...



SPSS: Graphs – Chart Builder– Ok
Bar – 3º gráfico da 1ª linha



Arrastar a variável Sexo para o retângulo X-axis
Arrastar a variável Frequência com que vai às compras (P11) para o retângulo Stack: set color



Clicar no botão **Element Properties**
Clicar no botão **Apply**



No género feminino é maior a percentagem de pessoas que vai às compras mais de 4 vezes por mês...



Há muito para explorar no SPSS...