



# Capítulo 1

## Introdução

### 1.1 Revisões

**Convenções e notação:** Seja  $X$  uma v.a. (discreta ou contínua), com função de distribuição  $F_X(x|\theta)$ , onde  $\theta$  designa o parâmetro (uni ou multivariado)

**Funções de v.a.:** Seja  $X$  uma v.a. contínua com f.d.p.  $f_X(x|\theta)$ , onde  $\theta$  é o parâmetro associado, que toma valores em  $\Omega_X$ , e seja  $Y = g(X)$ , onde  $g(\cdot) : \Omega_X \rightarrow \Omega_Y$  é uma função que admite derivada contínua em todo o domínio, anulando-se quando muito num número finito de pontos. Então para cada  $y \in \Omega_Y$  existe um número positivo  $n$  e números reais  $v_1(y), v_2(y), \dots, v_n(y)$  tais que

$$g(v_i(y)) = y, \quad \frac{dg(v_i(y))}{dy} \neq 0, \quad j = 1, 2, \dots, n(y).$$

Então

$$f_Y(y|\theta) = \sum_{j=1}^n f_X(v_j(y)|\theta) \left| \frac{dv_j(y)}{dy} \right|, \quad n > 0, \quad f_Y(y|\theta) = 0, \quad n = 0.$$

Um caso particular ocorre quando  $g(\cdot)$  é uma função monótona (crescente ou decrescente). Nesse caso

$$f_Y(y|\theta) = f_X(g^{-1}(y)|\theta) \left| \frac{d}{dy} g^{-1}(y) \right| I_{\Omega_Y}(y).$$

Uma das transformações mais importantes é a *transformação do integral de probabilidade*.

**Teorema 1** *Seja  $X$  uma v.a. contínua com f.d.  $F_X(\cdot|\theta)$ , e defina-se  $Y = F_X(X|\theta)$ . Então  $Y$  é uniformemente distribuída em  $(0, 1)$ , i.e.,*

$$P(Y \leq y) = yI_{(0,1)}(y).$$

O teorema anterior é particularmente útil na geração de amostras aleatórias. Por exemplo, se for necessário gerar uma observação  $x$  de uma população com f.d.  $F_X(\cdot)$ , então gera-se um número aleatório  $y$ , entre 0 e 1, e resolve-se a equação  $F_X(x) = y$  (o que por si só pode ser uma tarefa hercúlea!).

**Função geradora de momentos:** Seja  $X$  uma v.a. (contínua ou discreta) com f.d.p.  $f_X(x|\theta)$ . Para  $|s| \leq 1$

$$M_X(s) = E[e^{sX}].$$

Quando existe este valor esperado numa vizinhança de  $s = 0$ ,  $M_X(s)$  representa a função geradora de momentos da v.a.  $X$ , uma vez que

$$M_X^{(r)}(s) = E[X^r], \quad r \in \mathbb{N}.$$

Propriedades da f.g.m.:

(a)  $M_{X-\lambda}(s) = e^{-\lambda s} M_X(s)$

(b) Se  $X$  e  $Y$  são v.a. independentes, com f.g.m.  $M_X(\cdot)$  e  $M_Y(\cdot)$  respectivamente, então existe f.g.m. de  $X + Y$  e é dada pela expressão:

$$M_{X+Y}(s) = M_X(s)M_Y(s)$$

(c) A f.g.m., quando existe, determina univocamente a função de distribuição. Reciprocamente, a f.g.m., se existir, é única.

(d) Se a f.g.m. do par aleatório  $(X, Y)$  existir, o par  $(X, Y)$  possui momentos de todas as ordens, os quais podem obter-se da relação

$$\left. \frac{\delta^{r+k} M_{(X,Y)}(s_1, s_2)}{\delta s_1^r \delta s_2^k} \right|_{s_1=s_2=0} = E[X^r Y^k]$$

(e) As v.a.  $X$  e  $Y$  são independentes se e só se  $M_{X+Y}(s_1, s_2) = M_{(X,Y)}(s_1, 0)M_{(0,Y)}(0, s_2)$ .

## 1.2 Variáveis aleatórias

### 1.2.1 Discretas

a) **Uniforme discreta:** diz-se que  $X$  tem distribuição uniforme discreta em  $\Xi = \{x_1, x_2, \dots, x_n\}$  se

$$f_X(x|n) = \frac{1}{n} I_{\Xi}(x).$$

Caso particular:  $\Xi = \{0, 1, \dots, n\}$ . Nesse caso

$$E[X] = \frac{n+1}{2}, \quad Var[X] = \frac{n^2-1}{12}, \quad M_X(s) = e^s \frac{1-e^{s(n+1)}}{1-e^s}.$$

b) **Binomial:**  $X \sim Bin(n, p)$ , descreve os processos em que se realizam repetidas provas independentes de Bernoulli, sendo  $p$  a probabilidade (constante) de sucesso. A f.d.p. é dada por

$$f_X(x|n, p) = \binom{n}{x} p^x (1-p)^{n-x} I_{\{1,2,\dots,n\}}(x)$$

sendo que

$$E[X] = np, \quad Var[X] = np(1-p), \quad M_X(s) = e^{-nsp}(1-p+pe^s)^n.$$

Propriedade relevante:

- Se as v.a.  $X_i, i = 1, \dots, k$  são independentes, então

$$X_i \sim Bin(n_i, p) \Rightarrow \sum_{i=1}^k X_i \sim Bin\left(\sum_{i=1}^k n_i, p\right).$$

d) **Binomial negativa:**  $X \sim BN(r, p)$ , onde  $X$  designa o número de provas de Bernoulli independentes que têm de realizar-se até se obterem  $r$  sucessos, sendo  $p$  a probabilidade de sucesso (constante ao longo das repetições). A f.d.p. é dada por

$$f_X(x|r, p) = \binom{x-1}{x-r} p^r (1-p)^{x-r} I_{\{r, r+1, \dots\}}(x)$$

com

$$E[X] = \frac{r}{p}, \quad Var[X] = r \frac{1-p}{p^2}, \quad M_X(s) = (pe^s)^r (1 - (1-p)e^s)^{-r}.$$

Se em vez de  $X$  se modelar  $Y = X - R$  (nº de insucessos observados até ocorrer o  $r$ -ésimo sucesso), então a f.d.p. é dada por

$$f_Y(y|r, p) = \binom{r+y-1}{y} p^r (1-p)^y I_{\{0, 1, \dots\}}(y)$$

com

$$E[Y] = r \frac{1-p}{p}, \quad Var[Y] = r \frac{1-p}{p^2}, \quad M_X(s) = p^r (1 - (1-p)e^s)^{-r}.$$

Propriedades relevantes:

- Se  $X_i$  são v.a. independentes (para  $i = 1, 2, \dots, k$ ) então

$$X_i \sim BN(r_i, p) \Rightarrow \sum_{i=1}^n X_i \sim BN\left(\sum_{i=1}^n r_i, p\right).$$

- Se  $X \sim BN(1, p)$  então diz-se que  $X$  tem distribuição geométrica de parâmetro  $p$  (simbolicamente:  $X \sim Geo(p)$ )

- Se  $X \sim Geo(p)$  então para  $m, n \in \mathbb{N}$  :  $P(X > m + n | X > m) = P(X \geq n)$  (propriedade da amnésia da geométrica)

- Se  $X$  assume valores da sucessão  $0, 1, \dots$ , e  $\forall m, n \in \mathbb{N}$  :  $P(X > m + n | X > m) = P(X \geq n)$ , então  $X$  tem distribuição Geométrica.

(e) **Poisson:**  $X \sim Poisson(\lambda)$  com f.d.p. dada por

$$f_X(x|\lambda) = \frac{e^{-\lambda} \lambda^x}{x!} I_{\mathbb{N}_0}(x)$$

com

$$E[X] = Var[X] = \lambda, \quad M_X(s) = e^{\lambda(e^s - 1)}.$$

Propriedades mais relevantes:

- Se as v.a.  $X_i, i = 1, \dots, k$  são independentes, então

$$X_i \sim Poisson(\lambda_i) \Leftrightarrow \sum_{i=1}^k X_i \sim Poisson\left(\sum_{i=1}^k \lambda_i\right)$$

- Se  $X \sim Poisson(\lambda)$  e  $Y|X = x \sim Bin(x, p)$  então  $Y \sim Poisson(\lambda, p)$ .
- A distribuição binomial de parâmetros  $(n, p)$  converge para a de Poisson quando  $n \rightarrow \infty$  e  $p \rightarrow 0$ , mantendo-se constante o produto  $np$ .
- A família de distribuições Binomial Negativa inclui a distribuição de Poisson como caso limite, fazendo  $r \rightarrow \infty$  tal que  $r(1 - p) \rightarrow \lambda$ , com  $\lambda \in (0, \infty)$ .

(f) **Hipergeométrica:**  $X \sim HG(N, n, M)$ , onde  $X$  designa o número de sucessos em  $n$  provas de Bernoulli extraídas sem reposição de uma população de dimensão  $N$  onde há  $M$  sucessos.

$$f_X(x|N, n, M) = \frac{\binom{M}{x} \binom{N-M}{n-x}}{\binom{N}{n}} I_{[\max(0, n-M), \min(n, M)]}(x)$$

com

$$E[X] = n \frac{M}{N}, \quad Var[X] = n \frac{M}{N} \frac{N-M}{N} \frac{N-n}{N-1}$$

Propriedades mais relevantes:

- Com  $n$  e  $M$  fixos:

$$\lim_{N \rightarrow \infty} \left[ \frac{\binom{M}{x} \binom{N-M}{n-x}}{\binom{N}{n}} \right] = \binom{n}{x} p^x (1-p)^{n-x}$$

com  $p = \frac{M}{N}$ . Assim sendo a f.d.p. de uma hipergeométrica tende para a f.d.p. de uma binomial quando a dimensão da população aumenta, mantendo-se os outros parâmetros constantes.

- A variância associada à distribuição hipergeométrica é inferior à da binomial correspondente. Esta propriedade pode ser, nalguns casos, uma vantagem da distribuição Hipergeométrica em relação à Binomial. No entanto, e de acordo com a propriedade anterior, à medida que a dimensão da população aumenta, esbate-se a diferença entre extracções com reposição e sem reposição e, conseqüentemente, a diferença entre as duas distribuições.

(g) **Multinomial:**  $X \sim MN(n, \mathbf{p})$ , com  $\mathbf{p} = (p_0, p_1, p_2, \dots, p_k)$ . A Multinomial generaliza a binomial: trata-se de uma sucessão de provas independentes, em que em cada prova realiza-se um e um só dos  $k + 1$  acontecimentos de uma partição do espaço amostral  $\{A_0, A_1, \dots, A_k\}$ . Seja  $p_i = P(A_i)$ , com  $p_0 + p_1 + \dots + p_k = 1$ . À semelhança da binomial, interessa estudar a probabilidade de em  $n$  provas observar  $x_0$  vezes o acontecimento  $A_0$ ,  $x_1$  vezes o acontecimento  $A_1$ , etc.

$$f_X(\mathbf{x}|n, \mathbf{p}) = \frac{n!}{x_0! x_1! \dots x_k!} \prod_{i=0}^k p_i^{x_i}, \quad \mathbf{x} = (x_0, x_1, \dots, x_k)$$

$$E[X_i] = np_i, \quad Var[X_i] = np_i(1 - p_i), \quad Cov(X_i, X_j) = -np_i p_j$$

e, finalmente,

$$M_X(\mathbf{s}) = \left( \sum_{i=0}^k p_i e^{s_i} \right)^n$$

### 1.2.2 Contínuas

(a) Uniforme contínua  $X \sim Unif(a, b)$ , com  $a < b$  e

$$f_X(x|a, b) = \frac{1}{b-a} I_{[a,b]}(x)$$

com

$$E[X] = \frac{a+b}{2}, \quad Var[X] = \frac{(b-a)^2}{12}$$

(b) Gamma  $X \sim Gama(\alpha, \beta)$ , para  $\alpha, \beta \in \mathbb{R}^+$ , onde  $\alpha$  se designa por *parâmetro de forma* e  $\beta$  é o *parâmetro de escala*.

$$f_X(x|\alpha, \beta) = \frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\beta x} I_{\mathbb{R}^+}(x)$$

com  $\Gamma(\alpha) = \int_0^\infty t^{\alpha-1} e^{-t} dt$ .

$$E[X] = \frac{\alpha}{\beta}, \quad Var[X] = \frac{\alpha}{\beta^2}, \quad M_X(s) = \left(1 - \frac{s}{\beta}\right)^{-\alpha} I_{(0,\beta)}(s).$$

Propriedades mais relevantes:

– Se  $X \sim Gama(\alpha, \beta)$  e se  $\alpha \in \mathbb{N}$ , então para qualquer  $x$ :

$$P(X \leq x) = P(Y \geq \alpha)$$

com  $Y \sim Poisson(\beta x)$ . Nesse caso  $X$  diz-se ter distribuição *Erlang*.

– Se  $\alpha = \frac{p}{2}$ , sendo  $p$  um inteiro, e  $\beta = \frac{1}{2}$ , então diz-se que  $X \sim \chi_{(p)}^2$  (qui-quadrado com  $p$  graus de liberdade).

– Se  $\alpha = 1$  então  $X \sim Exp(\beta)$  (exponencial com parâmetro  $\beta$ ).

– A distribuição exponencial tem a propriedade da amnésia, i.e.

$$P(X > s+t | X > t) = P(X > s), \quad \forall s, t \in \mathbb{R}^+$$

– Se  $X \sim Exp(\beta)$  então  $Y = X^{1/\gamma} \sim Weibull(\gamma, \beta)$  (Weibull de parâmetros  $\gamma$  e  $\beta$ ), a que corresponde a f.d.p.

$$f_Y(y|\gamma, \beta) = \frac{\gamma}{\beta} y^{\gamma-1} e^{-y^\gamma/\beta}, \quad y, \gamma, \beta \in \mathbb{R}^+.$$

(c) Normal  $X \sim N(\mu, \sigma)$ ,  $\mu \in \mathbb{R}, \sigma \in \mathbb{R}^+$ , com

$$f_X(x|\mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad x \in \mathbb{R}$$

com

$$E[X] = \mu, \quad Var[X] = \sigma^2, \quad M_X(s) = e^{\mu s + \frac{\sigma^2 s^2}{2}}$$

Propriedades mais relevantes

– Se  $X_i$  forem v.a. independentes então

$$X_i \sim N(\mu_i, \sigma_i) \Rightarrow \sum_{i=1}^k \alpha_i X_i \sim N\left(\sum_{i=1}^k \alpha_i \mu_i, \sqrt{\sum_{i=1}^k \alpha_i^2 \sigma_i^2}\right)$$

- Se  $X$  e  $Y$  forem v.a. independentes e se  $X+Y$  tem distribuição normal, então também  $X$  e  $Y$  possuem distribuição normal.

(d) Beta  $X \sim Beta(\alpha, \beta)$ , com

$$f_X(x|\alpha, \beta) = \frac{1}{B(\alpha, \beta)} x^{\alpha-1} (1-x)^{\beta-1} I_{(0,1)}(x)$$

com  $\alpha, \beta \in \mathbb{R}^+$ , onde

$$B(\alpha, \beta) = \int_0^1 x^{\alpha-1} (1-x)^{\beta-1} dx$$

a chamada *função beta*, a qual se relaciona com a função gama através da seguinte relação:

$$B(\alpha, \beta) = \frac{\Gamma(\alpha)\Gamma(\beta)}{\Gamma(\alpha + \beta)}$$

Tem-se

$$E[X] = \frac{\alpha}{\alpha + \beta}, \quad Var[X] = \frac{\alpha\beta}{(\alpha + \beta)^2(\alpha + \beta + 1)}$$

e

$$M_X(s) = \sum_{k=0}^{\infty} \frac{\Gamma(\alpha + k)\Gamma(\alpha + \beta)}{\Gamma(\alpha + \beta + k)\Gamma(\alpha)\Gamma(k + 1)} s^k$$

a qual se revela pouco importante nas aplicações.

Propriedades mais importantes

- Se  $X$  e  $Y$  são v.a. independentes, com  $X \sim Gama(m, \beta)$  e  $Y \sim Gama(n, \beta)$  então  $\frac{X}{X+Y} \sim Beta(m, n)$ .
- A forma da f.d.p. de uma beta varia muito, consoante os parâmetros. Por exemplo, uma  $Beta(\alpha, \beta)$  com  $\alpha > 1$  e  $\beta = 1$  é estritamente crescente, se  $\alpha = 1$  e  $\beta > 1$  é estritamente decrescente, em forma de U se  $\alpha < 1$  e  $\beta < 1$ , etc.

(e) Cauchy  $X \sim Cauchy(\lambda, \theta)$ , com  $\theta \in \mathbb{R}$  e  $\lambda > 0$ , com

$$f_X(x|\lambda, \theta) = \frac{\lambda}{\pi[\lambda^2 + (x - \theta)^2]}, \quad x \in \mathbb{R}$$

Não tem momentos de ordem alguma, nem f.g.m. O parâmetro  $\theta$  descreve o ponto de simetria da f.d.p. (é a mediana).

Propriedades mais relevantes:

- Se as v.a.  $X_i$  ( $i = 1, 2, \dots$ ) são independentes, então

$$X_i \sim Cauchy(\lambda_i, \theta_i) \Rightarrow \sum_{i=1}^n X_i \sim Cauchy\left(\sum_{i=1}^n \lambda_i, \sum_{i=1}^n \theta_i\right)$$

- Se  $X$  e  $Y$  são v.a. independentes, ambas com distribuição  $N(0, 1)$  então

$$\frac{X}{Y} \sim Cauchy(0, 1)$$

(f) Outras distribuições menos comuns:

- Lognormal: se  $X$  é uma v.a. positiva e se  $\ln X \sim N(0, 1)$ , então diz-se que  $X$  tem distribuição lognormal, com

$$f_X(x|\mu, \sigma) = \frac{1}{x\sigma\sqrt{2\pi}} \exp\left\{-\frac{(\ln x - \mu)^2}{2\sigma^2}\right\}$$

com  $E[X] = e^{\mu+\sigma^2/2}$  e  $Var[X] = e^{2\mu+2\sigma^2}(e^{\sigma^2} - 1)$ .

- Pareto: corresponde à f.d.p.

$$f_X(x|\theta, x_0) = \frac{\theta}{x_0} \left(\frac{x_0}{x}\right)^{\theta+1}, \quad x > x_0 > 0, \theta > 0$$

com  $E[X] = \frac{\theta x_0}{\theta-1}$ , se  $\theta > 1$ , e  $Var[X] = \frac{\theta x_0^2}{\theta-2} - \left(\frac{\theta x_0}{\theta-1}\right)^2$ , se  $\theta > 2$ .

- Laplace: corresponde à f.d.p.

$$f_X(x|\lambda, \theta) = \frac{\lambda}{2} \exp\{-\lambda|x - \theta|\}, \quad x, \theta \in \mathbb{R}, \lambda > 0$$

com  $E[X] = \theta$  e  $Var[X] = \frac{2}{\lambda^2}$ .

- Logística: tem f.d.p.

$$f_X(x|\alpha, \beta) = \frac{e^{-(x-\alpha)/\beta}}{\beta[1 + e^{-(x-\alpha)/\beta}]^2}, \quad x \in \mathbb{R}, \alpha \in \mathbb{R}, \beta > 0$$

com  $E[X] = \alpha$ ,  $Var[X] = \pi^2\beta^2/3$ .

### 1.3 Família Exponencial

Muitas das distribuições dadas até aqui enquadram-se num conjunto de famílias de distribuições designado por **família exponencial**.

Uma família de f.d.p.  $\{f(\cdot|\theta), \theta \in \Theta\}$  pertence à família exponencial se a sua f.d.p. poder ser escrita da seguinte forma:

$$f(x|\theta) = h(x)c(\theta)e^{\sum_{i=1}^k w_i(\theta)t_i(x)}$$

com  $h(x) \geq 0, \forall x$ ,  $t_1, \dots, t_k$  são funções reais da observação  $x$  (e que, em particular, não dependem de  $\theta$ ),  $c(\theta) \geq 0$  e  $w_1(\theta), \dots, w_k(\theta)$  são funções reais de  $\theta$  (e que, em particular, não dependem de  $x$ ).

Por abuso de linguagem, sempre que dissermos *a v.a.  $X$  pertence à família exponencial* significa que *a f.d.p. da v.a.  $X$  pertence à família exponencial*.

Mais tarde veremos a importância da família exponencial. Para além das suas propriedades matemáticas, a sua forma implica propriedades estatísticas que tornam o seu tratamento especialmente simples.

Para já note-se que se tivermos uma série longa de observações de uma v.a.  $X$  cuja f.d.p. pertence à família exponencial, então só necessitamos de calcular  $k$  parcelas, funções de todos os dados da amostra. Isto significa em particular que se tivermos duas amostras  $\underline{x}$  e  $\underline{y}$ , com

$$\underline{x} = (x_1, \dots, x_{n_1}), \quad \underline{y} = (y_1, \dots, y_{n_2})$$



tais que

$$\prod_{i=1}^{n_1} h(x_i) = \prod_{j=1}^{n_2} h(y_j)$$

e

$$\forall r = 1, 2, \dots, k : \sum_{i=1}^{n_1} t_r(x_i) = \sum_{j=1}^{n_2} t_w(y_j), \quad \text{para algum } w = 1, 2, \dots, k$$

então  $f(\underline{x}|\theta) = f(\underline{y}|\theta)$ .

Como veremos mais tarde esta propriedade permitirá a redução dos dados amostrais, levando à consideração de estatísticas suficientes (as quais serão tema do próximo capítulo). Note-se ainda que se o conjunto de valores de  $x$  para os quais  $f_X(x|\theta) > 0$  depender de  $\theta$ , então  $f_X(\cdot|\theta)$  não pertence à família exponencial. Por exemplo, se  $X \sim Unif(a, b)$ , então  $X$  não pertence à família exponencial.

Por vezes a família exponencial é reparametrizada da seguinte forma:

$$f(x|\eta) = h(x)c^*(\eta)e^{\sum_{i=1}^k \eta_i t_i(x)}$$

, tal que  $\eta_i = w_i(\theta)$ . O conjunto  $H = \{\eta = (\eta_1, \dots, \eta_k) : \int_{-\infty}^{\infty} h(x)e^{\sum_{i=1}^k \eta_i t_i(x)} dx < \infty\}$  é designado por *espaço natural paramétrico*. Em particular  $\eta = (w_1(\theta), \dots, w_k(\theta))$  pertence ao espaço paramétrico natural, que pode conter mais elementos para além deste. A vantagem de considerar o espaço paramétrico natural é que se trata de um conjunto convexo; a desvantagem é que a sua interpretação é geralmente mais difícil que a do espaço original.

## 1.4 Famílias de localização e escala

Quando normalizamos a  $N(\mu, \sigma^2)$ , passando-a a  $N(0, 1)$ , dizemos que estamos a fazer uma transformação de localização (ao subtrair  $\mu$ , o valor esperado), seguida de uma transformação de escala (ao dividir por  $\sigma$ ). Este procedimento pode ser alargado a mais f.d.p. A f.d.p. que resulta de uma transformação de localização e escala chama-se, à imagem do caso normal, uma f.d.p. *padrão* ou em standard.

**Teorema 2** *Seja  $f(\cdot)$  uma f.d.p. arbitrária, e  $\mu, \sigma > 0$  duas constantes quaisquer. Então a função*

$$g(x|\mu, \sigma) = \frac{1}{\sigma} f\left(\frac{x - \mu}{\sigma}\right)$$

*é uma f.d.p.*

Este teorema permite-nos então definir uma família de localização e escala.

**Definição 3** *Seja  $f(\cdot)$  uma f.d.p. arbitrária. Então  $\forall \mu \in \mathbb{R}, \sigma \in \mathbb{R}^+$ , a família de f.d.p.  $\{\frac{1}{\sigma} f(\frac{x - \mu}{\sigma}), (\mu, \sigma) \in (\mathbb{R}, \mathbb{R}^+)\}$  é uma família de localização e escala com f.d.p. padrão  $f(\cdot)$ . Neste caso  $\mu$  diz-se ser o parâmetro de localização e  $\sigma$  o parâmetro de escala.*

O efeito da introdução do parâmetro de localização e de escala serve para esticar (se  $\sigma > 1$  ou contrair (se  $\sigma < 1$ ) o gráfico da f.d.p., sendo que a introdução do parâmetro de localização serve para transladar o gráfico.

Os teoremas que se seguem mostram a importância das famílias de localização e escala para determinadas transformações.

**Teorema 4** *Seja  $f(\cdot)$  uma função arbitrária,  $\mu \in \mathbb{R}, \sigma \in \mathbb{R}^+$  também arbitrários. Então existe uma v.a.  $X$  com f.d.p.  $\frac{1}{\sigma}f(\frac{x-\mu}{\sigma})$  sse existe uma v.a.  $Z$  com f.d.p.  $f(\cdot)$  tal que*

$$X = \sigma Z + \mu.$$

**Teorema 5** *Seja  $Z$  uma v.a. com f.d.p.  $f(\cdot)$  tal que  $E[Z]$  e  $Var[Z]$  existem. Se  $X$  for uma v.a. com f.d.p.  $\frac{1}{\sigma}f(\frac{x-\mu}{\sigma})$  então*

$$E[X] = \sigma E[Z] + \mu, \quad Var[Z] = \sigma^2 Var[X].$$

Note-se que se  $\sigma = 1$  então teremos simplesmente uma família de localização, enquanto que se  $\mu = 0$  teremos uma família de escala.

Famílias de localização e escala podem ter aplicações muito concretas. O exemplo que se segue é construído para uma família de escala.

**Exemplo 6** *Seja  $X$  o peso de um peito de frango comercializado por uma empresa Holandesa de produção de aves.*

*Informações da organização europeia de comércio alimentar indicam que uma percentagem desse peso é conseguida pela injeção de água, sendo um valor constante e igual a 35%. Assim o verdadeiro peso é  $0.65X$  (e não  $X$ ), pelo que se  $f_X(x)$  for a f.d.p. de  $X$  no ponto  $x$ , a f.d.p. do verdadeiro peso é  $f_X(0.65x)$ .*