

## 1. CAPÍTULO 7

### Distribuições conjuntas.

Neste capítulo atribuímos a um ponto amostral valores de várias variáveis aleatórias e analisamos a sua distribuição conjunta. Por praticidade desenvolvemos a teoria para vetores de variáveis aleatórias bidimensionais mas os resultados estendem-se para o caso multidimensional de dimensão finita.

**1.1. Distribuições conjuntas discretas.** Começamos com um exemplo:

**Exemplo 1.1.** Um investidor simula uma sequência de sucessos, ou fracassos, anuais de suas aplicações por um período de três anos. Para isso supõe que a probabilidade de sucesso em determinado ano é  $p$ ,  $0 < p < 1$ , independente dos resultados nos outros anos. Considera três variáveis de interesse:

A variável aleatória  $X$ , que indica se houve sucesso ou fracasso no primeiro ano. O sucesso (S) indicado pelo algarismo 1 e o fracasso (F) pelo algarismo 0;

a variável aleatória  $Y$  que indica o número de sucessos nos três anos e a variável aleatória

$Z$ , indicando o número de mudanças ( SF ou FS) que ocorreram durante os três anos.

A configuração dos resultados possíveis com as respectivas probabilidades é a distribuição conjunta tridimensional que apresenta os valores  $(x, y, z)$  do vetor aleatório  $(X, Y, Z)$  com suas respectivas probabilidades

$$P(X = x, Y = y, Z = z) = P(\{X = x\} \cap \{Y = y\} \cap \{Z = z\}),$$

por exemplo  $P(X = 1, Y = 2, Z = 2) = p^2(1 - p)$ .

Tabela 7.1- Distribuição tridimensional de  $(X, Y, Z)$

<i>Realização</i>	$(x, y, z)$	$P(X = x, Y = y, Z = z)$
$(S, S, S)$	$(1, 3, 0)$	$p^3$
$(S, S, F)$	$(1, 2, 1)$	$p^2(1 - p)$
$(S, F, S)$	$(1, 2, 2)$	$p^2(1 - p)$
$(F, S, S)$	$(0, 2, 1)$	$p^2(1 - p)$
$(S, F, F)$	$(1, 1, 1)$	$p(1 - p)^2$
$(F, S, F)$	$(0, 1, 2)$	$p(1 - p)^2$
$(F, F, S)$	$(0, 1, 1)$	$p(1 - p)^2$
$(F, F, F)$	$(0, 0, 0)$	$(1 - p)^3$

As distribuições unidimensionais das variáveis  $X$ ,  $Y$  e  $Z$  são obtidas fixando o valor da variável de interesse e somando sobre os valores das outras variáveis. Analiticamente temos

$$P(X = x) = \sum_y \sum_z P(X = x, Y = y, Z = z).$$

Por exemplo

$$\begin{aligned} P(X = 1) &= P(X = 1, Y = 3, Z = 0) + P(X = 1, Y = 2, Z = 1) + \\ &P(X = 1, Y = 2, Z = 2) + P(X = 1, Y = 1, Z = 1) = \\ p^3 + 2p^2(1 - p) + p(1 - p)^2 &= p[p^2 + 2p(1 - p) + (1 - p)^2] = p[p + (1 - p)]^2 = p. \end{aligned}$$

A probabilidade do evento complementar é  $P(X = 0) = 1 - p$ . O resultado era esperado desde que  $X$  é uma variável aleatória de Bernoulli que tem média  $E[X] = p$  e variância  $Var(X) = p(1 - p)$ .

Obtemos a distribuição da variável  $Y$  de maneira semelhante e a sua função de probabilidade é

$y$	0	1	2	3
$P(Y = y)$	$(1 - p)^3$	$3p(1 - p)^2$	$3p^2(1 - p)$	$p^3$

Resumindo,  $P(Y = k) = \binom{3}{k} p^k (1 - p)^{3-k}$  para  $k \in \{0, 1, 2, 3\}$ . Isto é, o número de sucessos em 3 ensaios de Bernoulli, independentes e identicamente distribuídos, com probabilidade de sucesso igual a  $p$ , tem distribuição binomial com média  $E[Y] = 3p$  e variância  $Var(Y) = 3p(1 - p)$ .

A variável  $Z$  assume os valores 0, 1, 2 com probabilidades

$$P(Z = 0) = p^3 + (1 - p)^3;$$

$$P(z = 1) = 2p^2(1 - p) + 2p(1 - p)^2 = 2p(1 - p);$$

$$P(Z = 2) = p^2(1 - p) + p(1 - p)^2.$$

A sua esperança é

$$E[Z] = 2p(1 - p) + 2p^2(1 - p) + 2p(1 - p)^2 = 4p(1 - p)$$

e sua variância

$$Var(Z) = E[Z^2] - E[Z]^2 = 6p(1-p) - 16p^2(1-p)^2 = 6p - 22p^2 + 32p^3 - 16p^4.$$

A distribuição conjunta de  $(X, Z)$  pode ser representada por uma tabela de dupla entrada

Tabela 7.2- Distribuição bidimensional de  $(X, Z)$

$X, Z$	0	1	2	total
0	$(1-p)^3$	$p(1-p)$	$p(1-p)^2$	$1-p$
1	$p^3$	$p(1-p)$	$p^2(1-p)$	$p$
total	$p^3 + (1-p)^3$	$2p(1-p)$	$pr(1-p) + p(1-p)^2$	1

No seu interior a tabela nos fornece a distribuição conjunta das variáveis  $(X, Z)$ , isto é, os valores

$$P(X = x, Z = z) = P(\{X = x\} \cap \{Z = z\})$$

para todos os valores de  $X$  e de  $Z$  representados por  $x$  e  $z$  respectivamente. As suas margens fornecem as distribuições (marginais) de  $X$  e de  $Z$ .

Em uma primeira simulação o investidor imaginou o menos pior, ou seja, considerou a probabilidade de sucesso igual a  $\frac{1}{2}$ . A tabela torna-se

Tabela 7.3- Distribuição bidimensional de  $(X, Z)$ ,  $p = \frac{1}{2}$

$X, Z$	0	1	2	total
0	$\frac{1}{8}$	$\frac{1}{4}$	$\frac{1}{8}$	$\frac{1}{2}$
1	$\frac{1}{8}$	$\frac{1}{4}$	$\frac{1}{8}$	$\frac{1}{2}$
total	$\frac{1}{4}$	$\frac{1}{2}$	$\frac{1}{4}$	1

Em seguida, para um cenário de sucesso na carreira considerou  $p = \frac{2}{3}$ , projetando

Tabela 7.4- Distribuição bidimensional de  $(X, Z)$ ,  $p = \frac{2}{3}$

$X, Z$	0	1	2	total
0	$\frac{1}{27}$	$\frac{6}{27}$	$\frac{2}{27}$	$\frac{1}{3}$
1	$\frac{2}{27}$	$\frac{27}{6}$	$\frac{27}{4}$	$\frac{3}{3}$
total	$\frac{3}{9}$	$\frac{4}{9}$	$\frac{2}{9}$	1

Quando estudamos a distribuição conjunta de variáveis aleatórias desejamos conhecer se, de alguma maneira, uma variável está associada às outras. Um conceito essencial para uma análise neste sentido é o de distribuição condicional fundamentada no conceito de eventos condicionais: Se  $A$  e  $B$  são eventos com  $P(B) > 0$ , a probabilidade condicional do evento  $A$  dado a ocorrência de  $B$  é  $P(A|B) = \frac{P(A \cap B)}{P(B)}$ .

**Definição 1.2.** Sejam  $X$  e  $Y$  variáveis aleatórias discretas que assumem valores  $x_1, \dots, x_n$  e  $y_1, \dots, y_m$  respectivamente. Se  $P(X = x_i) > 0$ , a probabilidade condicional de  $\{Y = y_j\}$  dado  $\{X = x_i\}$ , denotada por  $P(Y = y_j|X = x_i)$  é definida por

$$P(Y = y_j|X = x_i) = \frac{P(X = x_i, Y = y_j)}{P(X = x_i)}, \quad 1 \leq j \leq m.$$

Podemos observar que para  $x_i$  fixado com  $P(X = x_i) > 0$ , os pares  $(y_j, P(Y = y_j|X = x_i))$   $1 \leq j \leq m$  caracterizam a distribuição de probabilidade da variável aleatória condicional  $(Y|X = x_i)$ . Observe que

$$\begin{aligned} \sum_{j=1}^m P(Y = y_j|X = x_i) &= \sum_{j=1}^m \frac{P(X = x_i, Y = y_j)}{P(X = x_i)} = \\ \frac{1}{P(X = x_i)} \sum_{j=1}^m P(X = x_i, Y = y_j) &= \frac{P(X = x_i)}{P(X = x_i)} = 1. \end{aligned}$$

Na suposição de que  $p = \frac{2}{3}$ , a probabilidade condicional de termos uma única mudança, condicionada que se obteve sucesso no primeiro ano é:

$$P(Z = 1|X = 1) = \frac{P(X=1, Z=1)}{P(X=1)} = \frac{\frac{6}{27}}{\frac{2}{3}} = \frac{6}{18}.$$

A distribuição condicional da variável  $Z$  condicionada ao valor da variável  $X = 1$  tem função de probabilidade:

$Z X = 1$	0	1	2
$P(Z = z X = 1)$	$\frac{8}{18}$	$\frac{6}{18}$	$\frac{4}{18}$

Observe que  $\sum_{k=0}^2 P(Z = k|X = 1) = 1$ . A esperança da variável  $(Z|X = 1)$  é

$$E[Z|X = 1] = \frac{6}{18} + \frac{8}{18} = \frac{14}{18}$$

e a variância da variável  $(Z|X = 1)$  é

$$Var(Z|X = 1) = \frac{22}{18} - \frac{196}{324} = \frac{200}{324},$$

pois  $E[Z^2|X = 1] = \frac{6}{18} + \frac{16}{18} = \frac{22}{18}$ .

Com argumento análogo concluímos que a distribuição condicional da variável  $Z$  condicionada ao valor da variável  $X = 0$  tem função de probabilidade:

$Z X = 0$	0	1	2
$P(Z = z X = 0)$	$\frac{1}{9}$	$\frac{6}{9}$	$\frac{2}{9}$

com

$$E[Z|X = 0] = \frac{10}{9}, E[Z^2|X = 0] = \frac{14}{9} \text{ e } Var(Z|X = 0) = \frac{56}{81}.$$

Observe que uma variável  $Y$  quando condicionada aos valores de uma variável  $X$  é função de tais valores e como função de  $X$  é uma variável aleatória. Esta variável aleatória denotada por  $\varphi(X) = E[Y|X]$  assume valores  $E[Y|X = x]$  com respectivas probabilidades  $P(X=x)$ .

$E[Y X]$	$E[Y X = x_1]$	...	$E[Y X = x_n]$
$P(E[Y X] = E[Y X = x])$	$P(X = x_1)$	...	$P(X = x_n)$

Portanto ao calcular  $E\{E[Y|X]\}$  temos

$$\begin{aligned} E\{E[Y|X]\} &= \sum_{j=1}^m E[Y|X = x_j]P(X = x_j) = \\ &= \sum_{j=1}^m \left[ \sum_{i=1}^n y_i P(Y = y_i|X = x_j) \right] P(X = x_j) + \sum_{j=1}^m \left[ \sum_{i=1}^n y_i \frac{P(Y = y_i, X = x_j)}{P(X = x_j)} \right] P(X = x_j) = \\ &= \sum_{j=1}^m \sum_{i=1}^n y_i P(Y = y_i, X = x_j) = \sum_{i=1}^n y_i P(Y = y_i) = E[Y]. \end{aligned}$$

Pode-se provar também que

$$Var(X) = E[Var(X|Y)] + Var(E[Y|X]).$$

Podemos utilizar os cálculos anteriores para, no caso em que  $p = \frac{2}{3}$ , exemplificarmos:

$$\begin{aligned} E\{E[Z|X]\} &= E[Z|X = 0]P(X = 0) + E[Z|X = 1]P(X = 1) = \\ &= \frac{10}{9} \frac{1}{3} + \frac{14}{18} \frac{2}{3} = \frac{20 + 28}{54} = \frac{8}{9} = E[Z]. \end{aligned}$$

Um tópico importante na análise das distribuições conjuntas de variáveis aleatórias é o estudo da independência das mesmas.

**Definição 1.3.** Duas variáveis aleatórias  $X$  e  $Y$  assumindo valores nos conjuntos  $\{x_1, \dots, x_n\}$  e  $\{y_1, \dots, y_m\}$ , respectivamente, são independentes se, e somente se,

$$P(X = x_i, Y = y_j) = P(X = x_i)P(Y = y_j)$$

para quaisquer possíveis pares de valores  $(x_i, y_j)$ ,  $1 \leq i \leq n$   $1 \leq j \leq m$ .

As variáveis aleatórias  $X$  e  $Z$  acima, quando consideramos  $p = \frac{1}{2}$ , tem distribuição conjunta representada por

Tabela 7.5- Distribuição bidimensional de  $(X, Z)$ ,  $p = \frac{1}{2}$

$X, Z$	0	1	2	total
0	$\frac{1}{8}$	$\frac{1}{4}$	$\frac{1}{8}$	$\frac{1}{2}$
1	$\frac{1}{8}$	$\frac{1}{4}$	$\frac{1}{8}$	$\frac{1}{2}$
total	$\frac{1}{4}$	$\frac{1}{2}$	$\frac{1}{4}$	1

E podemos notar que a probabilidade conjunta é igual ao produto de suas marginais para todos os valores possíveis, por exemplo

$$P(X = 1, Z = 1) = \frac{2}{8} = \frac{1}{2} \frac{1}{2} = P(X = 1)P(Z = 1).$$

Portanto as variáveis  $X$  e  $Z$  são independentes.

Se consideramos  $p = \frac{2}{3}$  temos

$$P(X = 1, Z = 1) = \frac{6}{27} \neq \frac{2}{3} \frac{4}{9} = P(X = 1)P(Z = 1)$$

e podemos afirmar que, neste caso,  $X$  e  $Z$  não são independentes.

Podemos generalizar a definição de independência para um vetor de variáveis aleatórias com dimensões maiores. Vejamos o caso  $n = 3$ .

**Definição 1.4.** As variáveis aleatórias  $X_1, X_2$  e  $X_3$  são independentes se, e somente se

$$P(X_1 = x_1, X_2 = x_2, X_3 = x_3) = P(X_1 = x_1)P(X_2 = x_2)P(X_3 = x_3),$$

$$P(X_1 = x_1, X_2 = x_2) = P(X_1 = x_1)P(X_2 = x_2),$$

$$P(X_1 = x_1, X_3 = x_3) = P(X_1 = x_1)P(X_3 = x_3)$$

e

$$P(X_2 = x_2, X_3 = x_3) = P(X_2 = x_2)P(X_3 = x_3).$$

## Operação entre variáveis aleatórias

Operações com variáveis aleatórias resultam em variáveis aleatórias. Portanto, se  $X$  e  $Y$  são variáveis aleatórias, as operações  $\sqrt{X}$ ,  $\ln Y$ ,  $X + Y$ ,  $X.Y$  são variáveis aleatórias e como tais, cada uma tem sua função de distribuição, sua média, sua variância e outras medidas.

A função de probabilidade induzida pela variável aleatória  $g(X, Y)$  é caracterizada por:

$$P_{g(X,Y)}(k) = P(g(X, Y) = k) = \sum_{\{(x_i, y_j): g(x_i, y_j) = k\}} P(X = x_i, Y = y_j).$$

No que segue estudaremos algumas destas operações:

Se, no exemplo consideramos  $p = \frac{2}{3}$ , a distribuição conjunta de  $(X, Y)$  é dada por

Tabela 7.6- Distribuição bidimensional de  $(X, Y)$ ,  $p = \frac{2}{3}$

$X, Y$	0	1	2	3	total
0	$\frac{1}{27}$	$\frac{4}{27}$	$\frac{4}{27}$	0	$\frac{1}{3}$
1	0	$\frac{2}{27}$	$\frac{8}{27}$	$\frac{8}{27}$	$\frac{2}{3}$
total	$\frac{1}{27}$	$\frac{6}{27}$	$\frac{12}{27}$	$\frac{8}{27}$	1

A distribuição da variável aleatória  $X + Y$  assume os valores  $x + y$ , para todos os valores  $x$  e  $y$  de  $X$  e  $Y$ , respectivamente. A função de probabilidade de  $X + Y$  é:

$X + Y$	0	1	2	3	4
$P(X + Y = x + y)$	$\frac{1}{27}$	$\frac{4}{27}$	$\frac{6}{27}$	$\frac{8}{27}$	$\frac{8}{27}$

de maneira que

$$E[X + Y] = \frac{8}{3} = \frac{2}{3} + 2 = E[X] + E[Y].$$

Este resultado sempre é verdadeiro, isto é, a esperança da soma de variáveis aleatórias é a soma de suas esperanças. O fato é uma consequência do teorema que segue que aceitamos sem prova. Sua prova pode ser encontrada em literatura mais especializada.

**Teorema 1.5.** *Sejam  $X$  e  $Y$  variáveis aleatórias discretas que assumem valores  $x_1, \dots, x_n$  e  $y_1, \dots, y_m$ , respectivamente, com probabilidade conjunta  $P(X = x_i, Y = y_j)$ . Se  $g(x, y)$  é uma função a valores reais, limitada, então*

$$E[g(X, Y)] = \sum_{i=1}^n \sum_{j=1}^m g(x_i, y_j) P(X = x_i, Y = y_j).$$

Utilizando o Teorema 7.5 podemos provar o corolário:

**Corolário 1.6.** *Sejam  $X$  e  $Y$  variáveis aleatórias discretas que assumem valores  $x_1, \dots, x_n$  e  $y_1, \dots, y_m$  respectivamente, com probabilidade conjunta  $P(X = x_i, Y = y_j)$ . Então*

$$E[X + Y] = E[X] + E[Y].$$

*Prova*

Considerando, no Teorema 7.5,  $g(x, y) = x + y$ , obtemos

$$\begin{aligned}
 E[X + Y] &= \sum_{i=1}^n \sum_{j=1}^m (x_i + y_j) P(X = x_i, Y = y_j) = \\
 &= \sum_{i=1}^n \sum_{j=1}^m x_i P(X = x_i, Y = y_j) + \sum_{i=1}^n \sum_{j=1}^m y_j P(X = x_i, Y = y_j) = \\
 &= \sum_{i=1}^n x_i \sum_{j=1}^m P(X = x_i, Y = y_j) + \sum_{j=1}^m y_j \sum_{i=1}^n P(X = x_i, Y = y_j) = \\
 &= \sum_{i=1}^n x_i P(X = x_i) + \sum_{j=1}^m y_j P(Y = y_j) = E[X] + E[Y].
 \end{aligned}$$

Se consideramos a transformação produto, isto é, a variável aleatória  $XY$  que assume valores  $xy$  para todos os pares  $(x, y)$  do vetor aleatório  $(X, Y)$  com função de probabilidade

$XY$	0	1	2	3
$P(XY = xy)$	$\frac{9}{27}$	$\frac{2}{27}$	$\frac{8}{27}$	$\frac{8}{27}$

concluimos que  $E[XY] = \frac{17}{9} \neq \frac{2}{3} \cdot 2 = E[X] \cdot E[Y]$ .

Contudo, se consideramos a distribuição conjunta das variáveis aleatórias independentes  $X$  e  $Z$ , quando  $p = \frac{1}{2}$  obtemos

Tabela 7.7- Distribuição bidimensional de  $(X, Z)$ ,  $p = \frac{1}{2}$

$X, Z$	0	1	2	total
0	$\frac{1}{8}$	$\frac{1}{4}$	$\frac{1}{8}$	$\frac{1}{2}$
1	$\frac{1}{8}$	$\frac{1}{4}$	$\frac{1}{8}$	$\frac{1}{2}$
total	$\frac{1}{4}$	$\frac{1}{2}$	$\frac{1}{4}$	1

e a função de probabilidade de  $XZ$  é

$y$	0	1	2
$P(XZ = xz)$	$\frac{5}{8}$	$\frac{2}{8}$	$\frac{1}{8}$

com  $E[XZ] = \frac{1}{2} = \frac{1}{2} \cdot 1 = E[X] \cdot E[Z]$ .

Utilizando o Teorema 7.5 podemos provar que esta propriedade é verdadeira

**Corolário 1.7.** *Sejam  $X$  e  $Y$  variáveis aleatórias discretas independentes, que assumem valores  $x_1, \dots, x_n$  e  $y_1, \dots, y_m$  respectivamente, com probabilidade conjunta  $P(X = x, Y = y) = P(X = x).P(Y = y)$ . Então*

$$E[X.Y] = E[X].E[Y].$$

*Prova*

*Considerando, no Teorema 7.5,  $g(x, y) = x.y$ , obtemos*

$$\begin{aligned} E[X.Y] &= \sum_{i=1}^n \sum_{j=1}^m x_i.y_j P(X = x_i, Y = y_j) = \\ &= \sum_{i=1}^n \sum_{j=1}^m x_i.y_j P(X = x_i).P(Y = y_j) = \sum_{i=1}^n x_i P(X = x_i). \sum_{j=1}^m y_j P(Y = y_j) = E[X].E[Y]. \end{aligned}$$

Observamos que o corolário prova que a independência de  $X$  e  $Y$  é condição necessária para que  $E[X.Y] = E[X].E[Y]$ . A condição não é suficiente:

**Exemplo 1.8.** Se  $(X, Y)$  tem distribuição de probabilidade conjunta Tabela 7.8- Distribuição conjunta de  $(X, Y)$

$X, Y$	-1	0	1	total
-1	0	$\frac{1}{4}$	0	$\frac{1}{4}$
0	$\frac{1}{4}$	0	$\frac{1}{4}$	$\frac{1}{2}$
1	0	$\frac{1}{4}$	0	$\frac{1}{4}$
total	$\frac{1}{4}$	$\frac{1}{2}$	$\frac{1}{4}$	1

temos  $E[X.Y] = 0 = 0.0 = E[X].E[Y]$  mas  $P(X = 0, Y = 0) \neq \frac{1}{2} \cdot \frac{1}{2} = P(X = 0).P(Y = 0)$ .

As propriedades nos corolários 7.6 e 7.7 se estendem para um número finito de variáveis aleatórias. Se  $(X_1, X_2, \dots, X_n)$  é um vetor de variáveis aleatórias, então

$$E[X_1 + X_2 + \dots + X_n] = E[X_1] + E[X_2] + \dots + E[X_n].$$

Se, em adição as variáveis aleatórias são independentes

$$E[X_1.X_2.\dots.X_n] = E[X_1].E[X_2] \dots E[X_n].$$

Um tipo de dependência entre duas variáveis  $X$  e  $Y$  muito importante nas aplicações é a associação linear entre  $X$  e  $Y$ . Esta medida de

relação linear entre as variáveis é denominada covariância e denotada por  $Cov(X, Y)$ .

**Definição 1.9.** Sejam  $X$  e  $Y$  variáveis aleatórias. A covariância entre  $X$  e  $Y$  é definida pela esperança do produto dos desvios de  $X$  e  $Y$  em relação às suas respectivas médias, isto é

$$Cov(X, Y) = E[(X - E[X]).(Y - E[Y])].$$

*Observação 1.10.* De maneira mais fácil podemos escrever

$$\begin{aligned} Cov(X, Y) &= E[(X - E[X]).(Y - E[Y])] = \\ &E[XY - X.E[Y] - Y.E[X] + E[X].E[Y]] = E[XY] - E[X].E[Y]. \end{aligned}$$

Quando  $X$  e  $Y$  são variáveis aleatórias discretas que assumem valores  $x_1, \dots, x_n$  e  $y_1, \dots, y_n$  respectivamente, podemos escrever utilizando o Teorema 9.5 que

$$Cov(X, Y) = \sum_{i=1}^n \sum_{j=1}^m (x_i - E[X]).(y_j - E[Y])P(X = x_i, Y = y_j).$$

Claramente, usando o Corolário 7.7, se  $X$  e  $Y$  são variáveis aleatórias independentes  $Cov(X, Y) = 0$ . Observamos também que, como no exemplo 7.8, a  $Cov(X, Y)$  pode ser igual a zero quando  $X$  e  $Y$  são variáveis aleatórias dependentes.

Para o vetor aleatório  $(X, Y)$  com distribuição conjunta  
Tabela 7.9- Distribuição conjunta de  $(X, Y)$

$X, Y$	0	1	2	3	total
0	$\frac{1}{27}$	$\frac{4}{27}$	$\frac{4}{27}$	0	$\frac{1}{3}$
1	0	$\frac{2}{27}$	$\frac{8}{27}$	$\frac{8}{27}$	$\frac{2}{3}$
total	$\frac{1}{27}$	$\frac{6}{27}$	$\frac{12}{27}$	$\frac{8}{27}$	1

temos que

$$Cov(X, Y) = E[XY] - E[X].E[Y] = \frac{14}{9} - \frac{2}{3}.2 = \frac{14}{9} - \frac{12}{9} = \frac{2}{9}.$$

No Corolário 7.6 demonstramos que o valor esperado da soma de variáveis aleatórias é a soma dos valores esperados. O que podemos dizer sobre a variância da soma segue do corolário

**Corolário 1.11.** *Sejam  $X$  e  $Y$  variáveis aleatórias, então*

$$\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y) + 2.\text{Cov}(X, Y).$$

*Se, em adição,  $X$  e  $Y$  forem independentes temos  $\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y)$ .*

*Prova*

*A prova é imediata:*

$$\begin{aligned} \text{Var}(X+Y) &= E\{[(X+Y)-E(X+Y)]^2\} = E\{[(X-E[X])+(Y-E[Y])]^2\} = \\ &= E[(X - E[X])^2 + E[(Y - E[Y])^2 + 2.E[(X - E[X]).(Y - E[Y])] = \\ &= \text{Var}(X) + \text{Var}(Y) + 2.\text{Cov}(X, Y). \end{aligned}$$

*Se  $X$  e  $Y$  são independentes,  $\text{Cov}(X, Y) = 0$  e temos*

$$\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y).$$

**Exemplo 1.12.** Para o vetor aleatório  $(X, Y)$  com distribuição conjunta

Tabela 7.10- Distribuição conjunta de  $(X, Y)$

$X, Y$	0	1	2	3	total
0	$\frac{1}{27}$	$\frac{4}{27}$	$\frac{4}{27}$	0	$\frac{1}{3}$
1	0	$\frac{2}{27}$	$\frac{8}{27}$	$\frac{8}{27}$	$\frac{2}{3}$
total	$\frac{1}{27}$	$\frac{6}{27}$	$\frac{12}{27}$	$\frac{8}{27}$	1

temos que

$$\text{Var}(X) = \frac{2}{9}, \text{Var}(Y) = \frac{2}{3} \text{ e } \text{Cov}(X, Y) = \frac{14}{9} - \frac{2}{3}.2 = \frac{2}{9}. \text{ Portanto}$$

$$\text{Var}(X + Y) = \frac{2}{9} + \frac{6}{9} + 2.\frac{2}{9} = \frac{12}{9}.$$

**Exemplo 1.13.** A distribuição Binomial com parâmetros  $n$  e  $p$ ,  $0 < p < 1$  pode ser interpretada como o número de sucessos quando realizamos  $n$  ensaios de Bernoulli com probabilidade de sucesso  $p$ , independentes e identicamente distribuídos. A função de probabilidade da variável aleatória,  $X$ , de Bernoulli é

$X$	0	1
$P(X = x)$	$1 - p$	$p$

Assim a média de  $X$  é  $E[X] = p$  e sua variância  $Var(X) = p(1-p)$ .

Podemos interpretar a variável aleatória Binomial,  $Y$ , como a soma  $Y = \sum_{i=1}^n X_i$  de variáveis aleatórias,  $X_i$ ,  $1 \leq i \leq n$ , de Bernoulli, independentes e identicamente distribuídas a  $X$ .

Portanto

$$E[Y] = E\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n E[X_i] = \sum_{i=1}^n p = np$$

e

$$Var(Y) = Var\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n Var(X_i) = \sum_{i=1}^n p(1-p) = np(1-p).$$

Em relação à distribuição de transformações de variáveis aleatórias independentes, a função geradora de momentos torna-se uma ferramenta importante:

**Teorema 1.14.** *Se  $X$  e  $Y$  são variáveis aleatórias independentes com funções geradoras de Momentos  $M_X(t)$  e  $M_Y(t)$  respectivamente, then*

$$M_{X+Y}(t) = M_X(t) \cdot M_Y(t).$$

*Prova*

$$\begin{aligned} M_{X+Y}(t) &= E[\exp[t(X+Y)]] = E[\exp[tX] \cdot \exp[tY]] = \\ &= E[\exp[tX]] \cdot E[\exp[tY]] = M_X(t) \cdot M_Y(t). \end{aligned}$$

*Observação 1.15.* Utilizando o teorema acima podemos afirmar que a distribuição da soma de  $n$  variáveis aleatórias, de Bernoulli, digamos  $X_1, X_2, \dots, X_n$ , independentes e identicamente distribuídas com probabilidade de sucesso  $p$ ,  $0 < p < 1$  é a distribuição binomial de parâmetros  $n$  e  $p$ . A distribuição de Bernoulli tem função geradora de momentos

$$M_{X_1}(t) = E[e^{tX_1}] = pe^{1 \cdot t} + (1-p)e^{0 \cdot t} = (1-p) + pe^t.$$

Portanto

$$\begin{aligned} M_{X_1+\dots+X_n}(t) &= M_{X_1}(t) \cdot \dots \cdot M_{X_n}(t) = \\ &= [(1-p) + pe^t] \cdot \dots \cdot [(1-p) + pe^t] = [(1-p) + pe^t]^n. \end{aligned}$$

que é a função geradora de momentos da distribuição binomial.

Um outro exemplo seria o da soma de distribuições de Poisson independentes. Se  $X$  e  $Y$  são variáveis aleatórias independentes com parâmetros  $\lambda_1$  e  $\lambda_2$ , respectivamente, então as suas funções geradoras

de momentos so  $M_X(t) = \exp[\lambda_1(e^t - 1)]$  e  $M_Y(t) = \exp[\lambda_2(e^t - 1)]$ , de maneira que

$$M_X(t).M_Y(t) = \exp[(\lambda_1 + \lambda_2)(e^t - 1)]$$

que é a função geradora de momentos de uma distribuição de Poisson com par ametro  $\lambda_1 + \lambda_2$ .

Observe que a função geradora de momentos da distribuição de Poisson é:

$$\begin{aligned} M_X(t) = E[e^{tX}] &= \sum_{k=0}^{\infty} e^{tk} \frac{e^{-\lambda_1} (\lambda_1)^k}{k!} = e^{-\lambda_1} \sum_{k=0}^{\infty} \frac{(\lambda_1 e^t)^k}{k!} = \\ &= e^{-\lambda_1} e^{\lambda_1 e^t} = e^{\lambda_1(e^t - 1)}. \end{aligned}$$

Uma medida da relação linear entre duas variáveis aleatórias  $X$  e  $Y$  que não depende da unidade de medida é o coeficiente de correlação linear, denotado por  $\rho = \rho(X, Y)$ , que é a covariância padronizada pelos desvios padrões de  $X$  e de  $Y$ :

**Definição 1.16.** O coeficiente de correlação linear entre as variáveis aleatórias  $X$  e  $Y$  é definido por

$$\rho = \rho(X, Y) = \frac{Cov(X, Y)}{DP(X).DP(Y)}.$$

**Exemplo 1.17.** O coeficiente de correlação linear entre as variáveis aleatórias  $X$  e  $Y$  do exemplo é

$$\rho = \frac{Cov(X, Y)}{DP(X).DP(Y)} = \frac{\frac{2}{9}}{\sqrt{\frac{2}{9} \cdot \frac{6}{9}}} = \frac{2}{\sqrt{8}} = 0,71.$$

**Proposição 1.18.** Se existem números reais  $a$  e  $b$  tais que  $Y = aX + b$ , isto é,  $Y$  é uma função linear de  $X$ , então  $|\rho| = 1$ .

*Prova:*

Se  $Y = aX + b$  temos  $E[Y] = a.E[X] + b$ ,  $Var(Y) = a^2.Var(X)$  e  $E[XY] = E[X.(aX + b)] = a.E[X^2] + b.E[X] = a.Var(X) + a.E[X]^2 + b.E[X]$ .

Portanto

$$\begin{aligned} Cov(X, Y) &= a.Var(X) + a.E[X]^2 + b.E[X] - a.E[X]^2 - b.E[X] = \\ &= aVar(X) \end{aligned}$$

e

$$\rho(X, Y) = \frac{a \cdot \text{Var}(X)}{\sqrt{a^2 \text{Var}(X)^2}} = \frac{a}{|a|}.$$

**Teorema 1.19.** *Se  $X$  e  $Y$  são variáveis aleatórias com variâncias finitas, então  $|\rho| \leq 1$ . Em adição, se vale a igualdade, existem núemros reais  $a$  e  $b$  tais que, com probabilidade 1,  $Y = a.X + b$ . Prova:*

Consideramos a função  $f$  de  $\mathfrak{R}$  em  $\mathfrak{R}$  definida por

$$f(t) = E\{[(Y - E[Y]) + t.(X - E[X])]^2\}$$

que é maior ou igual a zero. Desenvolvendo o quadrado perfeito temos

$$f(t) = \text{Var}(X).t^2 + 2.t.\text{Cov}(X, Y) + \text{Var}(Y) \geq 0.$$

A função  $f(t)$  é uma equação quadrática que é positiva se, e somente se, o seu discriminante  $\Delta = 4.\text{Cov}(X, Y)^2 - 4.\text{Var}(X).\text{Var}(Y)$  é menor ou igual a zero. Portanto

$$\frac{\text{Cov}(X, Y)^2}{\text{Var}(X).\text{Var}(Y)} \leq 1 \Leftrightarrow \rho^2 \leq 1 \Leftrightarrow |\rho| \leq 1.$$

$|\rho| = 1$  se, e somente se,  $E\{[(Y - E[Y]) + t.(X - E[X])]\} = 0$ , o que implica, com probabilidade 1,  $(Y - E[Y]) + t.(X - E[X]) = 0$ , isto é,  $Y = t.X + (1 - t).E[X]$ . Definindo  $a = t$  e  $b = (1 - t).E[X]$  temos  $Y = a.X + b$ .

**1.2. Distribuições conjuntas contínuas.** Como no caso das distribuições contínuas unidimensionais para definirmos a probabilidade induzida pelo vetor aleatório  $(X, Y) : \Omega \rightarrow \mathfrak{R}^2$  devemos considerar  $\beta^2 = \beta X \beta$ , a classe de subconjuntos de  $\mathfrak{R}^2$  obtida através das operações de reunião, interseccão, complementar, em número finito ou infinito de subconjuntos na forma  $(-\infty, s] \cap (-\infty, t], \forall s, t \in \mathfrak{R}$ .

**Definição 1.20.** Seja  $(\Omega, \mathfrak{S}, P)$  um espaço de probabilidade e  $(X, Y)$  uma aplicação de  $\Omega$  em  $\mathfrak{R}^2$ .  $(X, Y)$  é um vetor aleatório contínuo se  $X^{-1}((0, s]) \cap Y^{-1}((0, t]) \in \mathfrak{S}, \forall s, t \in \mathfrak{R}$ . Denominamos  $(\mathfrak{R}^2, \beta^2, P_{(X, Y)})$  como o espaço de probabilidade induzido por  $(X, Y)$ .

A medida de probabilidade induzida pelo vetor aleatório

$$(X, Y) : \Omega \rightarrow \mathfrak{R}^2.$$

é definida por

$$P_{(X,Y)}(B_1 \times B_2) = P(X^{-1}(B_1) \cap Y^{-1}(B_2)), \quad \forall B_1 \times B_2 \in \beta^2.$$

Observe que  $P_{(X,Y)}$  esta bem definida e

$$\begin{aligned} P_{(X,Y)}((-\infty, s] \cap (-\infty, t]) &= P(X^{-1}((-\infty, s]) \cap Y^{-1}((-\infty, \{t\}))) = \\ &P(\{w : X(w) \in (-\infty, t]\} \cap \{w : X(w) \in (-\infty, t]\}) = \\ &P(X \leq s, Y \leq t) = F_{(X,Y)}(s, t) \end{aligned}$$

é a função de distribuição do vetor aleatório  $(X, Y)$  que, neste caso, é uma função contínua.

Se a função de distribuição de  $(X, Y)$ , for diferenciável em cada variável com  $\frac{\delta^2 F_{(X,Y)}(s,t)}{\delta_s \delta_t} = f_{(X,Y)}(s, t)$ , definimos

**Definição 1.21.** Se  $(X, Y)$  é uma vetor aleatório contínuo com função de distribuição

$$F_{(X,Y)}(s, t) = \int_{-\infty}^s \int_{-\infty}^t f_{(X,Y)}(x, y) dy dx,$$

dizemos que  $f_{(X,Y)}(s, t)$  é a função densidade de probabilidade de  $(X, Y)$  e que é (absolutamente) contínua.

*Observação 1.22.* É evidente que a função densidade de probabilidade é positiva, isto é,  $f_{(X,Y)}(s, t) \geq 0, \forall s, t$  em seu domínio de definição e que

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f_{(X,Y)}(x, y) dy dx = 1.$$

Tambem calculamos

$$P(a < X \leq b, c < Y \leq d) = \int_a^b \int_c^d f_{(X,Y)}(x, y) dy dx$$

**Exemplo 1.23.** Considere que o tempo entre acidentes e o custo do sinistro correspondente são modelados pelo vetor aleatório  $(X, Y)$  com função densidade de probabilidade conjunta

$$f(x, y) = \begin{cases} 0 & : & x < 0 \\ c \cdot \exp[-(x + y)] & : & 0 \leq x < y < \infty \end{cases}.$$

onde  $c$  é um número real positivo. Qual o valor da constante  $c$ ?

Para que  $f(x, y)$  seja uma função densidade de probabilidade conjunta devemos ter:

a)  $f(x, y) \geq 0$  e

b)  $\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f_{(X,Y)}(x, y) dy dx = 1$ .

Como  $\exp[-(x + y)] > 0$  o item a) é obvio se  $c > 0$ .

Contudo, para que o item b seja verdadeiro devemos ter

$$c. \int_0^{\infty} \int_x^{\infty} \exp[-(x + y)] dy dx = c. \int_0^{\infty} \exp[-x] \int_x^{\infty} \exp[-y] dy dx =$$

$$\int_0^{\infty} \exp[-2x] dx = \frac{c}{2} = 1$$

e concluímos que  $c = 2$ . Para calcular  $P(-\infty < X \leq 3, 2 < Y \leq 5)$

procedemos com

$$P(-\infty < X \leq 3, 2 < Y \leq 5) = 2. \int_0^3 \int_{\max\{x, 2\}}^5 \exp[-(x + y)] dy dx =$$

$$2. \int_0^2 \exp[-x] \int_2^5 \exp[-y] dy dx + 2. \int_2^3 \exp[-x] \int_x^5 \exp[-y] dy dx =$$

$$2. (\exp[-2] - \exp[-5]) \int_0^2 \exp[-x] dx + 2. \int_2^3 \exp[-x] (\exp[-x] - \exp[-5]) dx =$$

$$2. (\exp[-2] - \exp[-5]) \cdot (1 - \exp[-2]) + 2. (\exp[-4] - \exp[-6]) - 2. \exp[-5] \cdot (\exp[-2] - \exp[-3]).$$

Como no caso discreto podemos definir as função densidades de probabilidades marginais de  $X$  e de  $Y$ :

**Definição 1.24.** Se  $(X, Y)$  é um vetor aleatório, as funções densidades de probabilidades marginais de  $X$ ,  $f_X(x)$ , e de  $Y$ ,  $f_Y(y)$  são definidas, para  $x$  e  $y$  fixados, por

$$f_X(x) = \int_{-\infty}^{\infty} f_{(X,Y)}(x, y) dy$$

e

$$f_Y(y) = \int_{-\infty}^{\infty} f_{(X,Y)}(x, y) dx,$$

respectivamente.

Em continuação ao exemplo acima temos

**Exemplo 1.25.** Se

$$f(x, y) = \begin{cases} 0 & : & x < 0 \\ 2 \cdot \exp[-(x + y)] & : & 0 \leq x < y < \infty \end{cases}$$

temos que, para  $x$  fixado

$$f_X(x) = \int_x^\infty 2 \cdot \exp[-(x + y)] dy = 2 \cdot \exp[-2x], \quad 0 \leq x < \infty,$$

a função densidade de probabilidade de uma variável aleatória exponencial de parâmetro 2.

Para  $y$  fixado

$$f_Y(y) = 2 \cdot \int_0^y \exp[-(x + y)] dx = 2 \cdot \exp[-y] \cdot (1 - \exp[-y]), \quad 0 \leq y < \infty.$$

Para o cálculo da esperança de uma transformação do vetor aleatório  $(X, Y)$  utilizamos um teorema análogo ao Teorema para o caso bivariado discreto.

**Teorema 1.26.** Se  $(X, Y)$  é um vetor aleatório e com função densidade de probabilidade  $f_{(X,Y)}(x, y)$  e se  $g(x, y)$  é uma função a valores reais, limitada, então

$$E[g(X, Y)] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y) dy dx.$$

Em continuação ao exemplo acima temos

**Exemplo 1.27.** Se

$$f(x, y) = \begin{cases} 0 & : & x < 0 \\ 2 \cdot \exp[-(x + y)] & : & 0 \leq x < y < \infty \end{cases}$$

A transformação  $X \cdot Y$  tem média

$$\begin{aligned} E[X \cdot Y] &= \int_0^\infty \int_x^\infty x \cdot y \cdot 2 \cdot \exp[-(x + y)] dy dx = \int_0^\infty 2 \cdot x \exp[-x] \int_x^\infty y \cdot \exp[-y] dy dx = \\ &= \int_0^\infty 2 \cdot x \exp[-x] (x + 1) \exp[-x] dx = 1. \end{aligned}$$

Como  $X$  é uma variável aleatória exponencial de parâmetro 2,  $E[X] = \frac{1}{2}$  e  $Var(X) = \frac{1}{4}$ .

Com respeito à variável  $Y$  temos

$$E[Y] = \int_0^\infty 2 \cdot y \cdot \exp[-y] (1 - \exp[-y]) dy = \frac{3}{2}$$

$$E[Y^2] = \int_0^{\infty} 2 \cdot y^2 \cdot \exp[-y](1 - \exp[-y])dy = \frac{7}{2}$$

$$\text{e } Var(Y) = \frac{5}{4}.$$

$$\text{Portanto } Cov(X, Y) = 1 - \frac{3}{4} = \frac{1}{4} \text{ e } \rho(X, Y) = \frac{\frac{1}{4}}{\sqrt{\frac{1}{4} \cdot \frac{5}{4}}} = 0,45.$$

Como no caso discreto podemos definir as probabilidades condicionais de um evento do espaço amostral induzido por  $X$ , condicionado a um valor particular  $y$  de  $Y$ . Devemos ser cuidadosos pois sabemos que, como a variável  $Y$  é contínua,  $P(Y = y) = 0$ . Tais probabilidades são calculadas através das densidades de probabilidades condicionais:

**Definição 1.28.** Se  $(X, Y)$  é um vetor aleatório com função densidade de probabilidade conjunta  $f_{(X,Y)}(x, y)$ , a densidade condicional de  $X$ , dado que  $Y = y$  é definida por

$$f_{X|Y}(x|y) = \frac{f_{(X,Y)}(x, y)}{f_Y(y)}, \quad f_Y(y) > 0,$$

e densidade condicional de  $Y$ , dado que  $X = x$  é definida por

$$f_{Y|X}(y|x) = \frac{f_{(X,Y)}(x, y)}{f_X(x)}, \quad f_X(x) > 0.$$

Em continuação ao exemplo acima temos

**Exemplo 1.29.** Se

$$f(x, y) = \begin{cases} 0 & : & x < 0 \\ 2 \cdot \exp[-(x + y)] & : & 0 \leq x < y < \infty \end{cases}$$

temos

$$f_X(x) = 2 \cdot \exp[-2x], \quad 0 \leq x < \infty \text{ e}$$

$$f_Y(y) = 2 \cdot \exp[-y] \cdot (1 - \exp[-y]), \quad 0 \leq y < \infty.$$

Portanto

$$f_{X|Y}(x|y) = \frac{2 \cdot \exp[-(x + y)]}{2 \cdot \exp[-y] \cdot (1 - \exp[-y])} = \frac{\exp[-x]}{1 - \exp[-y]}, \quad 0 \leq x < y.$$

$$f_{Y|X}(y|x) = \frac{2 \cdot \exp[-(x + y)]}{2 \cdot \exp[-2x]} = \frac{\exp[-y]}{\exp[-x]}, \quad x \leq y < \infty.$$

e podemos calcular

$$E[X|Y = y] = \int_0^y x \cdot \frac{\exp[-x]}{1 - \exp[-y]} = \frac{1}{1 - \exp[-y]} [1 - \exp[-y] - y \exp[-y]] = \varphi(y).$$

Assim  $\varphi(Y)$  é uma variável aleatória, com média

$$\begin{aligned} E[\varphi(Y)] &= E\{E[X|Y]\} = \\ &= \int_0^\infty \frac{1}{1 - \exp[-y]} [1 - \exp[-y] - y \exp[-y]] \cdot 2 \cdot \exp[-y] \cdot (1 - \exp[-y]) dy = \\ &= \int_0^\infty (2 \cdot \exp[-y] - 2 \cdot \exp[-2y] - 2 \cdot y \cdot \exp[-2y]) dy = \frac{1}{2} = E[X]. \end{aligned}$$

Fato é que, como no caso discreto, as propriedades

$$E[X] = E\{E[X|Y]\}$$

$$Var(X) = E[Var(X|Y)] + Var(E[Y|X])$$

são verdadeiras.

Quando a função de densidade condicional é igual à densidade marginal dizemos que as variáveis são independentes.

**Definição 1.30.** As variáveis aleatórias  $X$  e  $Y$  do vetor aleatório  $(X, Y)$  são independentes se, e somente se,

$$f_{(X,Y)}(x,y) = f_X(x) \cdot f_Y(y)$$

para todo par  $(x, y)$  de  $(X, Y)$ .

**Exemplo 1.31.** Se

$$f(x, y) = \begin{cases} 0 & : & x < 0 \\ \exp[-(x + y)] & : & 0 \leq x < \infty, 0 \leq y < \infty \end{cases}$$

temos

$$f_X(x) = \int_0^\infty \exp[-(x + y)] dy = \exp[-x],$$

$$f_Y(y) = \int_0^\infty \exp[-(x + y)] dx = \exp[-y]$$

de maneira que

$$f_{(X,Y)}(x, y) = \exp[-(x + y)] = \exp[-x] \cdot \exp[-y] = f_X(x) \cdot f_Y(y)$$

e concluímos que  $X$  e  $Y$  são independentes.

**Observação 1.32. Distribuição normal bivariada** Um vetor aleatório bidimensional  $(X, Y)$ , representando duas características de uma população, tem distribuição normal bivariada,  $N(\mu_X, \mu_Y, \sigma_X^2, \sigma_Y^2, \rho_{XY})$ , com  $E[X] = \mu_X$ ,  $E[Y] = \mu_Y$ ,  $Var(X) = \sigma_X^2$ ,  $Var(Y) = \sigma_Y^2$  e  $CORR(X, Y) = \rho_{XY} = \rho$  se, e somente se,

$(X, Y)$  tem função densidade de probabilidade

$$f_{XY}(x, y) = \left[ \frac{1}{2\pi\sigma_X\sigma_Y\sqrt{1-\rho^2}} \exp\{-K(x, y)\} \right].$$

onde

$$K(x, y) = \frac{1}{2(1-\rho^2)} \left[ \left( \frac{x-\mu_X}{\sigma_X} \right)^2 + \left( \frac{y-\mu_Y}{\sigma_Y} \right)^2 - \frac{2\rho(x-\mu_X)(y-\mu_Y)}{\sigma_X\sigma_Y} \right].$$

O vetor aleatório bidimensional normal tem algumas propriedades ímpares, tais como:

As marginais  $X$  e  $Y$  são independentes se, e somente se,  $COV(X, Y) = 0$ , pois neste caso a densidade conjunta é o produto de suas marginais as quais também tem distribuições normais.

$$f_{XY}(x, y) = \frac{1}{\sqrt{2\pi}\sigma_X} \exp\left[-\left(\frac{x-\mu_X}{\sigma_X}\right)^2\right] \cdot \frac{1}{\sqrt{2\pi}\sigma_Y} \exp\left[-\left(\frac{y-\mu_Y}{\sigma_Y}\right)^2\right] = f_X(x) \cdot f_Y(y),$$

A distribuição condicional de  $Y$  dado  $X$ , ( $Y|X = x$ ) ( de  $X$  dado  $Y$ , ( $X|Y = y$ )) também tem distribuição normal, em particular

$$(Y|X = x) \sim N\left(\mu_Y + \frac{\rho\sigma_Y}{\sigma_X}(x - \mu_X); \sigma_Y^2(1 - \rho^2)\right)$$

Portanto

$$E[Y|X = x] = \mu_Y + \frac{\rho\sigma_Y}{\sigma_X}(x - \mu_X) = \left(\mu_Y - \frac{\rho\sigma_Y}{\sigma_X}\right) + \frac{\rho\sigma_Y}{\sigma_X}x$$

é uma função linear de  $x$  de parâmetros  $\mu_Y - \frac{\rho\sigma_Y}{\sigma_X}$  e  $\frac{\rho\sigma_Y}{\sigma_X}$ .

## Transformações de variáveis aleatórias

Suponha que desejamos obter a função densidade de probabilidade conjunta de um vetor aleatório  $(Y_1, Y_2)$ ,  $f_{(Y_1, Y_2)}(y_1, y_2)$  obtido através de transformações do vetor aleatório  $(X_1, X_2)$ , com função densidade de probabilidade conjunta  $f_{(X_1, X_2)}(x_1, x_2)$ , onde  $Y_1 = g_1(X_1, X_2)$  e  $Y_2 = g_2(X_1, X_2)$  definem transformações bijetivas de  $\mathfrak{R}_{(X_1, X_2)} = \{(x_1, x_2) : f_{(X_1, X_2)}(x_1, x_2) > 0\}$  em  $\mathfrak{R}_{(Y_1, Y_2)} = \{(y_1, y_2) : f_{(Y_1, Y_2)}(y_1, y_2) > 0\}$ . A solução está no teorema seguinte que admitiremos sem prova a qual é encontrada em literatura específica.

**Teorema 1.33.** *Seja  $(X_1, X_2)$  um vetor aleatório com função densidade de probabilidade conjunta  $f_{(X_1, X_2)}(x_1, x_2)$ . Se*

*a)  $Y_1 = g_1(X_1, X_2)$  e  $Y_2 = g_2(X_1, X_2)$  definem transformações bijetivas e contínuas de  $\mathfrak{R}_{(X_1, X_2)}$  em  $\mathfrak{R}_{(Y_1, Y_2)}$ ;*

*b) as derivadas parciais de  $x_1 = g_1^{-1}(y_1, y_2)$  e  $x_2 = g_2^{-1}(y_1, y_2)$  são contínuas em  $\mathfrak{R}_{(Y_1, Y_2)}$ ;*

*c) O Jacobiano  $J = \frac{\delta x_1}{\delta y_1} \cdot \frac{\delta x_2}{\delta y_2} - \frac{\delta x_1}{\delta y_2} \cdot \frac{\delta x_2}{\delta y_1}$  é diferente de zero, 0, em  $\mathfrak{R}_{(Y_1, Y_2)}$ ,*

*então a função densidade de probabilidade conjunta de  $(Y_1, Y_2)$  é*

$$f_{(Y_1, Y_2)}(y_1, y_2) = |J| \cdot f_{(X_1, X_2)}(g_1^{-1}(y_1, y_2), g_2^{-1}(y_1, y_2)), \quad (y_1, y_2) \in \mathfrak{R}_{(Y_1, Y_2)}.$$

**Exemplo 1.34.** Suponha que  $X_1$  e  $X_2$  são variáveis aleatórias independentes e identicamente distribuídas com distribuição uniforme no intervalo  $[0, 1]$ . Então  $\mathfrak{R}_{(X_1, X_2)} = \{(x_1, x_2) : 0 \leq x_1 \leq 1, 0 \leq x_2 \leq 1\}$ .

Sejam  $Y_1 = g_1(X_1, X_2) = X_1 + X_2$  e  $Y_2 = g_2(X_1, X_2) = X_2 - X_1$ . Então  $x_1 = g_1^{-1}(y_1, y_2) = \frac{y_1 - y_2}{2}$  e  $x_2 = g_2^{-1}(y_1, y_2) = \frac{y_1 + y_2}{2}$  e

$$J = \frac{\delta x_1}{\delta y_1} \cdot \frac{\delta x_2}{\delta y_2} - \frac{\delta x_1}{\delta y_2} \cdot \frac{\delta x_2}{\delta y_1} =$$

$$\frac{1}{2} \cdot \frac{1}{2} + \frac{1}{2} \cdot \frac{1}{2} = \frac{1}{2}.$$

Os domínios  $\mathfrak{R}_{(X_1, X_2)}$  e  $\mathfrak{R}_{(Y_1, Y_2)}$  estão na Figura 8.1.

Figura 8.1 -  $\mathfrak{R}_{(X_1, X_2)}$  e  $\mathfrak{R}_{(Y_1, Y_2)}$

A fronteira  $\{(x_1, x_2) : x_1 = 0, 0 \leq x_2 \leq 1\}$  de  $\mathfrak{R}_{(X_1, X_2)}$  é transformada na fronteira  $\{(y_1, y_2) : 0 \leq y_1 \leq 1, y_2 = y_1\}$  de  $\mathfrak{R}_{(Y_1, Y_2)}$ ;

A fronteira  $\{(x_1, x_2) : 0 \leq x_1 \leq 1, x_2 = 0\}$  de  $\mathfrak{R}_{(X_1, X_2)}$  é transformada na fronteira  $\{(y_1, y_2) : 0 \leq y_1 \leq 1, y_2 = -y_1\}$  de  $\mathfrak{R}_{(Y_1, Y_2)}$ ;

A fronteira  $\{(x_1, x_2) : 0 \leq x_1 \leq 1, x_2 = 1\}$  de  $\mathfrak{R}_{(X_1, X_2)}$  é transformada na fronteira  $\{(y_1, y_2) : 1 \leq y_1 \leq 2, y_2 = 2 - y_1\}$  de  $\mathfrak{R}_{(Y_1, Y_2)}$ ;

A fronteira  $\{(x_1, x_2) : x_1 = 1, 0 \leq x_2 \leq 1\}$  de  $\mathfrak{R}_{(X_1, X_2)}$  é transformada na fronteira  $\{(y_1, y_2) : 1 \leq y_1 \leq 2, y_2 = y_1 - 2\}$  de  $\mathfrak{R}_{(Y_1, Y_2)}$ ;

A função densidade de probabilidade conjunta de  $(Y_1, Y_2)$  é

$$f_{(Y_1, Y_2)}(y_1, y_2) = \frac{1}{2} \cdot 1_{[0,1]}\left(\frac{y_1 - y_2}{2}\right) \cdot 1_{[0,1]}\left(\frac{y_1 + y_2}{2}\right) = \frac{1}{2}, \quad (y_1, y_2) \in \mathfrak{R}_{(Y_1, Y_2)}.$$

As condições a, b e c do Teorema são de certa forma restritivas. As transformações  $(Y_1, Y_2)$  de  $\mathfrak{R}_{(X_1, X_2)}$  podem não ser injetoras, mas o domínio  $\mathfrak{R}_{(X_1, X_2)}$  pode ser particionado em várias partes, digamos  $\mathfrak{R}_{(X_1, X_2)}^1, \mathfrak{R}_{(X_1, X_2)}^2, \dots, \mathfrak{R}_{(X_1, X_2)}^m$ , de maneira que a restrição da transformação  $(Y_1, Y_2)$  de  $\mathfrak{R}_{(X_1, X_2)}^i$  em  $\mathfrak{R}_{(Y_1, Y_2)}$ ,  $1 \leq i \leq m$ , seja injetora. Neste caso, definindo  $x_1^i = g_1^{i-1}(y_1, y_2)$  e  $x_2^i = g_2^{i-1}(y_1, y_2)$  em  $\mathfrak{R}_{(X_1, X_2)}^i$  e  $J^i = \frac{\delta x_1^i}{\delta y_1} \cdot \frac{\delta x_2^i}{\delta y_2} - \frac{\delta x_1^i}{\delta y_2} \cdot \frac{\delta x_2^i}{\delta y_1}$  podemos aplicar o Teorema em cada domínio da partição e temos:

**Corolário 1.35.** *Seja  $(X_1, X_2)$  um vetor aleatório com função densidade de probabilidade conjunta  $f_{(X_1, X_2)}(x_1, x_2)$ . Se*

a)  $Y_1 = g_1^i(X_1, X_2)$  e  $Y_2 = g_2^i(X_1, X_2)$  definem transformações bijetivas e contínuas de  $\mathfrak{R}_{(X_1, X_2)}^i$  em  $\mathfrak{R}_{(Y_1, Y_2)}$ ;

b) as derivadas parciais de  $x_1^i = g_1^{i-1}(y_1, y_2)$  e  $x_2^i = g_2^{i-1}(y_1, y_2)$  são contínuas em  $\mathfrak{R}_{(Y_1, Y_2)}$ ;

c) O Jacobiano  $J^i$  é diferente de zero, 0, em  $\mathfrak{R}_{(Y_1, Y_2)}$ ,

então a função densidade de probabilidade conjunta de  $(Y_1, Y_2)$  é

$$f_{(Y_1, Y_2)}(y_1, y_2) = |J^i| \cdot f_{(X_1, X_2)}(g_1^{i-1}(y_1, y_2), g_2^{i-1}(y_1, y_2)), \quad (y_1, y_2) \in \mathfrak{R}_{(Y_1, Y_2)}.$$

**Teorema 1.36.** *Sejam  $Z \sim N(0, 1)$  uma variável aleatória com distribuição normal padrão e  $Y \sim \chi_n^2$  uma variável aleatória com distribuição Qui-quadrado com  $n$  graus de liberdade, independentes. Então a variável aleatória*

$$T = \frac{Z}{\sqrt{\frac{Y}{n}}},$$

tem função densidade de probabilidade

$$f(t) = \frac{\Gamma(\frac{n+1}{2})}{\Gamma(\frac{n}{2})\sqrt{n\pi}} \left(1 + \frac{t^2}{n}\right)^{-\frac{n+1}{2}}, \quad -\infty < t < \infty.$$

A variável aleatória obtida no teorema anterior tem distribuição de Student com  $n$  graus de liberdade e é denota por  $T_n$ .  $n$  é o parâmetro da distribuição e pode-se provar que

$$E[T_n] = 0, \quad Var(T_n) = \frac{n}{n-2}, \quad n > 2.$$

Uma tabela da distribuição de Student esta disponível no fim do livro. É importante notar que a distribuição de  $T_n$  aproxima-se de uma distribuição normal padrão para  $n$  suficientemente grande ( $n \geq 120$ ).

**Teorema 1.37.** *Sejam  $X$  e  $Y$  duas variáveis aleatórias independentes com distribuições qui-quadrado com  $n$  e  $m$  graus de liberdades, respectivamente. Então a variável aleatória*

$$F = \frac{\frac{X}{n}}{\frac{Y}{m}}$$

tem função densidade de probabilidade

$$f(x) = \frac{\Gamma(\frac{n+m}{2})}{\Gamma(\frac{n}{2})\Gamma(\frac{m}{2})} \left(\frac{n}{m}\right)^{\frac{n}{2}} \frac{x^{\frac{n-2}{2}}}{\left(1 + \frac{nx}{m}\right)^{\frac{n+m}{2}}}, \quad x > 0.$$

Diremos que a variável aleatória  $F$ , do teorema anterior tem distribuição  $F$  com  $n$  e  $m$  graus de liberdade, nessa ordem, o que denotamos por  $F \sim F_{n,m}$ .  $n$  e  $m$  são os parâmetros da distribuição e que  $F_{n,m}$  é diferente de  $F_{m,n}$ . Pode-se provar que

$$E[F_{n,m}] = \frac{m}{m-2}, \quad Var(F_{n,m}) = \frac{2m^2(n+m-2)}{n(m-2)^2(m-4)}.$$

Uma tabela da distribuição  $F_{n,m}$  esta disponível no fim do livro.

Como no caso univariado a função geradora de momentos bivariada caracteriza completamente o modelo probabilístico.

**Definição 1.38.** A função geradora de momentos de um vetor aleatório  $(X, Y)$  é definida por

$$M_{(X,Y)}(t_1, t_2) = E[\exp[t_1 \cdot X + t_2 \cdot Y]].$$

*Observação 1.39.* Segue da definição e da caracterização da distribuição da variável aleatória pela função geradora de momentos que, se  $X$  e  $Y$  são variáveis aleatórias independentes se, e somente se,

$$M_{(X,Y)}(t_1, t_2) = E[\exp[t_1 \cdot X + t_2 \cdot Y]] = E[\exp[t_1 \cdot X]]E[\exp[t_2 \cdot Y]] = M_X(t_1)M_Y(t_2).$$

Se  $(X, Y)$  tem função densidade de probabilidade  $f_{(X,Y)}(x, y)$ ,

$$M_{(X,Y)}(t_1, t_2) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \exp[t_1 \cdot x + t_2 \cdot y] \cdot f_{(X,Y)}(x, y) dy dx.$$

**Exemplo 1.40.** Se  $(X, Y)$  tem distribuição normal bivariada,  $N(\mu_X, \mu_Y, \sigma_X^2, \sigma_Y^2, \rho_{XY})$ , então, pode-se provar que a função geradora de momentos bivariada é

$$M_{(X,Y)}(t_1, t_2) = \exp[t_1 \cdot \mu_X + t_2 \cdot \mu_Y + \frac{1}{2}(t_1^2 \sigma_X^2 + 2 \cdot \rho \cdot \sigma_X \cdot \sigma_Y + t_2^2 \sigma_Y^2)].$$

No caso em que  $\rho = 0$  temos

$$\begin{aligned} M_{(X,Y)}(t_1, t_2) &= \exp[t_1 \cdot \mu_X + t_2 \cdot \mu_Y + \frac{1}{2}(t_1^2 \sigma_X^2 + t_2^2 \sigma_Y^2)] = \\ &= \exp[t_1 \cdot \mu_X + \frac{1}{2} t_1^2 \sigma_X^2] \exp[t_2 \cdot \mu_Y + \frac{1}{2} t_2^2 \sigma_Y^2] = M_X(t_1)M_Y(t_2), \end{aligned}$$

e as variáveis aleatórias  $X$  e  $Y$  são independentes.