

## Resumo – Elementos de Probabilidades e Estatística

### Capítulo 1 – Dados Estatísticos

#### 1.2 Amostra, População

- **Colecção de Dados** : conjunto de observações de certo(s) atributo(s), qualquer que seja a forma como foram recolhidas
- **Categorias Básicas de Dados** :
  - a) **Dados temporais** : dados cujas observações se referem a uma mesma entidade, para vários momentos ou periodos de tempo ; caracterizados essencialmente pela sua ordem cronológica ; a frequência temporal das observações é outro aspecto importante ; descrição da evolução no tempo → série temporal / cronograma ;
  - b) **Dados seccionais** : dados cujas observações se referem a determinadas entidades (unidades estatísticas) em certo momento ou periodo de tempo ; a característica fundamental é que a ordem das observações é irrelevante ;
  - c) **Dados seccionais combinados** : dados com aspectos seccionais e temporais ; conjunto de dados seccionais, cada um referente a certa data ; comparação de comportamentos entre as datas ;
  - d) **Dados de painel** : conjunto fixo de entidades observadas em várias datas ; característica essencial → o conjunto de entidades a observar é sempre o mesmo para todas as observações temporais (dificulta a obtenção) / várias observações temporais para a mesma entidade
- **População** : conjunto dos elementos cujos atributos são objecto de um determinado estudo → conjuntos fundamentais para efectuar análises estatísticas
- **Unidade Estatística** : facto ou entidade elementar que é objecto de observação, qualquer que seja a sua natureza
- **Censo / Indagação Completa** : análise de todos os elementos de uma população
- **Amostra** : subconjunto finito de uma população sobre o qual incide o estudo dos atributos da população (conjunto de unidades estatísticas)
- **Processo de Amostragem** : forma de selecção de uma amostra a partir da população ; determinante para a qualidade das inferências ; geralmente aleatório
- **Tipos de Atributos** :
  - 1) **Atributos Quantitativos** : os seus valores determinam as suas intensidades
  - 2) **Atributos Qualitativos** :
    - a) **Representação em Escalas Nominais** : atribuição dos valores não tem qualquer significado (ex: “mulher” = 0 ; “homem” = 1)
    - b) **Representação em Escalas Ordinais** : numeração deve respeitar a ordem das várias modalidades (ex: graus de especialização de 1 a 5)
- **Variável e Dimensão** : O valor numérico de um atributo é representado por uma variável  $x$ . Se a amostra observada tem dimensão  $n$  (ou seja,  $n$  elementos), tem-se  $x_1, x_2, \dots, x_n$  onde  $x_i$  ( $i = 1, 2, \dots, n$ ) é o valor do atributo da  $i$ -ésima observação.
- **Tipos de Variáveis** :
  - a) **Variáveis Discretas** : variáveis que podem tomar somente um número finito ou uma infinidade numerável de valores (ex: contagens, escalas nominais/ordinais, etc)
  - b) **Variáveis Contínuas** : variáveis que podem tomar qualquer valor dentro de um intervalo de números reais (ex: altura, peso, taxas de juro, etc)

### 1.3 Gráfico caule-e-folhas


- **Gráfico caule-e-folhas** : método semigráfico usado quando a amostra é pequena ; permite que o observador se torne mais sensível ao aspecto global dos dados e comece a explorar a existência de padrões
- **Construção/Elementos dos gráficos caule-e-folhas** :
  - **Número de folhas** : número de dígitos dominados de cada dígito dominante
  - **Caule** : dígitos dominantes
  - **Folhas** : dígitos dominados
  - **$n$**  : número total de folhas (dimensão da amostra)
  - **unidade** : primeiro dígito dominado
- **Exceções** :
  - **Caules com demasiadas folhas** :  $12 +$  e  $12 -$  / **dígito dominado** :  $0^*$ ,  $t$ ,  $f$ ,  $s$ ,  $0$  ;  $1^*$ , ...
  - **Valores anormalmente pequenos/grandes** : novas linhas rotuladas com “Pe” e “Gr”
- **Número de linhas de um gráfico caule-e-folhas** : parte inteira de  $2\sqrt{n}$
- **Propriedades que se podem identificar graças à construção de gráficos caule-e-folhas** :
  - Existência de valores em torno dos quais se concentram os restantes
  - Maior ou menor dispersão dos valores
  - Simetrias ou assimetrias
  - Presença de valores extremos (“pequenos” e “grandes”)

N.º de folhas	Caule	Folhas
2	5	47
10	6	2356668889
14	7	00123334457899
8	8	11346789
7	9	0134479
2	10	59

$n = 43$ ; unidade = 0.1.

### 1.4 Distribuições de Frequências, Histogramas

- **Frequência Absoluta** : número de vezes que um valor de  $x$  é observado ; notação:  $F_j$  ; propriedade :  $\sum_j F_j = n$
- **Frequência Relativa** :  $f_j = \frac{F_j}{n}$  ; propriedade :  $\sum_j f_j = 1$
- **Variável  $x$  contínua → classes de valores** :
  - os intervalos de classe não têm pontos em comum :  $I_j \cap I_k = \emptyset, j \neq k$
  - o domínio  $A$  da variável deve ser igual à união de todos os intervalos :  $A = \bigcup_{i=1}^m I_i$
  - os intervalos devem ser abertos à esquerda e fechados à direita :  $I_j = ]l_{j-1}, l_j]$
  - a amplitude deve ser constante :  $h_j = l_j - l_{j-1} (j = 1, 2, \dots, m)$
- **Representação gráfica de distribuições de frequências de variáveis discretas** : diagramas de barras
- **Representação gráfica de distribuições de frequências de variáveis contínuas** :
  - diagrama de áreas / histograma, formado por uma sucessão de rectângulos adjacentes
  - áreas dos rectângulos = resp. frequências relativas
  - **Intervalos de classe com amplitude constante** :
    - base do rectângulo :  $h = 1$
    - altura do rectângulo :  $f_1$  ou  $F_j$
  - **Intervalos de classe com amplitudes diferentes** :
    - base do rectângulo :  $h_j = l_j - l_{j-1}$
    - altura do rectângulo :  $\frac{f_1}{h_j}$  ou  $\frac{F_j}{h_j}$



### 1.5 Características Numéricas : Média e Desvio-Padrão

- **Média** :  $\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{1}{n} \sum_{i=1}^n x_i$  (medida de localização)
- **Ponto médio de uma classe** :  $x'_j = l_{j-1} + \frac{1}{2} h_j = \frac{l_{j-1} + l_j}{2}$
- **Média (de dados agrupados em classes)** :  $\bar{x} = \frac{1}{n} \sum_{j=1}^m F_j x'_j = \sum_{j=1}^m f_j x'_j$
- **Propriedade da Média** : A soma dos desvios em relação à média é nula.  $\sum_{i=1}^n (x_i - \bar{x}) = 0$

- **Moda ( $M_*$ )** : valor com maior frequência
- **Classe modal** : classe com maior frequência
- **Variância** :  $s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$  (medida de dispersão)
- **Variância corrigida** (quando a amostra tem dimensão pequena) :  $s'^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$
- **Desvio-Padrão** :  $s = \sqrt{s^2} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$  ou  $s' = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$
- **Variância (para dados classificados)** :  $s^2 = \frac{1}{n} \sum_{j=1}^m F_j (x'_j - \bar{x})^2 = \sum_{j=1}^m f_j (x'_j - \bar{x})^2$
- **Variância corrigida (para dad. class.)** :  $s'^2 = \frac{1}{n-1} \sum_{j=1}^m F_j (x'_j - \bar{x})^2 = \sum_{j=1}^m \frac{n}{n-1} f_j (x'_j - \bar{x})^2$
- **Variância (forma simplificada)** :  $s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^n (x_i^2) - \bar{x}^2$
- **Desvio-absoluto médio** :  $d = \frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}|$  ou  $d = \frac{1}{n} \sum_{j=1}^m F_j |x'_j - \bar{x}|$
- **Coefficiente de Variação** :  $CV = \frac{s}{\bar{x}}$  ; observações com sinal positivo / independente da unidade em que se exprime a variável / permite comparação entre distribuições

### 1.6 Características Numéricas : Estatísticas da Ordem

- **Extremos** :  $x_{(1)} = \min(x_i)$  ;  $x_{(n)} = \max(x_i)$
- **Mediana** : valor da coleção que tem 50% de observações inferiores e 50% de observações superiores ;  

$$M = \begin{cases} x_{(k+1)} & \text{se } n = 2k + 1 \\ \frac{x_{(k)} + x_{(k+1)}}{2} & \text{se } n = 2k \end{cases}$$
- **Quantil de ordem  $\alpha$**  : valor da coleção que tem  $\alpha n$  observações inferiores e  $(1 - \alpha)n$  observações superiores ; calcula-se a ordem:  $r = 1 + (n - 1)\alpha$  ;  
 → se  $r \in \mathbb{Z}$ ,  $q_\alpha = x_{(r)}$   
 → se  $r \notin \mathbb{Z}$ ,  $q_\alpha = x_{(r)} + \varepsilon(x_{(r+1)} - x_{(r)}) = (1 - \varepsilon)x_{(r)} + \varepsilon x_{(r+1)}$ , onde  $0 \leq \varepsilon < 1$

#### • Quartis :

Quartil	Ordem aproximada
1º quartil : $Q_1$	$\frac{n + 3}{4}$
Mediana : $M$	$\frac{n + 1}{2}$
3º quartil : $Q_3$	$\frac{3n + 1}{4}$

$r$  é a parte inteira  
 $\varepsilon$  é a parte fracionária

- **Amplitude do Intervalo de Variação** :  $AIV = x_{(n)} - x_{(1)}$  (medida de dispersão absoluta)
- **Amplitude do Intervalo de Interquartis** :  $AIQ = Q_3 - Q_1$  (medida de dispersão absoluta)
- Uma medida de dispersão relativa (qdo todas as obs. têm o mesmo sinal) :  $\frac{AIQ}{M}$
- **Resumo dos 5 números** : mínimo, 1º quartil, mediana, 3º quartil, máximo

#### ➤ Gráfico : caixa-de-bigodes

- caixa formada por 1º e 3º quartis
- mediana atravessa a caixa
- “bigodes” → mínimo e máximo
- caixa contém 50% das observações




- **Estimativa da estatística de ordem  $x_{(i)} \in I_j$**  :  $\hat{x}_{(i)} = l_{j-1} + \left[ (i - F_{j-1}^*) - \frac{1}{2} \right] \frac{h_j}{F_j}$ , onde:
  - $l_{j-1}$  : limite inferior da classe  $I_j$  ;
  - $F_{j-1}^*$  : frequência absoluta acumulada até à classe  $I_{j-1}$  :  $F_1 + F_2 + \dots + F_{j-1}$  ;
  - $h_j$  : amplitude da classe  $I_j$  ;
  - $F_j$  : frequência absoluta da classe  $I_j$  ;

- **Estimativa do quantil  $q_\alpha \in I_j$** :  $q_\alpha = l_{j-1} + \frac{\alpha - f_{j-1}^*}{f_j} h_j$
- **Amplitude dos intervalos de classe**:  $h = \frac{2 \times AIQ}{\sqrt[3]{n}}$
- **Principais medidas de localização e de dispersão**:

Medidas	$\bar{x}$	$s$	CV	m.	M	AIQ	AIQ/M
Localização	×			×	×		
Dispersão absoluta		×				×	
Dispersão relativa			×				×
Atributo quantitativo	×	×	×	×	×	×	×
Atributo qualitativo nominal				×			
Atributo qualitativo ordinal				×	×	×	×

### 1.7 Outliers

- **Outlier Severo**:  $x_i$  é um outlier severo quando  $x_i < Q_1 - 3(Q_3 - Q_1)$  ou  $x_i > Q_3 + 3(Q_3 - Q_1)$
- **Outlier Moderado**:  $x_i$  é um outlier moderado quando  $Q_1 - 3(Q_3 - Q_1) < x_i < Q_1 - 1,5(Q_3 - Q_1)$  ou  $Q_3 + 1,5(Q_3 - Q_1) < x_i < Q_3 + 3(Q_3 - Q_1)$
- **Barreira externa inferior**:  $Q_1 - 3(Q_3 - Q_1)$
- **Barreira externa superior**:  $Q_3 + 3(Q_3 - Q_1)$
- **Barreira interna inferior**:  $Q_1 - 1,5(Q_3 - Q_1)$
- **Barreira interna exterior**:  $Q_3 + 1,5(Q_3 - Q_1)$
- **Caixa-de-bigodes (modificada)**:
  - bigodes: barreiras internas superior e inferior
  - outliers moderados/severos → representados por símbolos gráficos diferentes (◦, ■)



### 1.8 Correlação

- **Covariância**:  $s_{xy} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$  ou  $s_{xy} = \frac{1}{n} \sum_{i=1}^n (x_i y_i) - \bar{x} \bar{y}$
- **Coefficiente de correlação de Pearson**:  $r = \frac{s_{xy}}{s_x s_y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$ 
  - $-1 \leq r \leq 1$
  - CC mede o grau de associação linear
  - sinal → correlação positiva ou negativa
  - valor absoluto → intensidade da associação linear
  - CC próximo de 1 → dados dispostos essencialmente nos 1º e 3º quadrantes (linear)
  - CC próximo de -1 → dados dispostos essencialmente nos 2º e 4º quadrantes (linear)
- **Coefficiente de correlação de Spearman**: Substitui-se cada par  $(x_i, y_i)$  é substituído pelo par  $[ord(x_i), ord(y_i)]$ , onde  $ord(x_i)$  representa a ordem de  $x_i$  na coleção. Calcula-se o coeficiente de correlação com a fórmula habitual.
  - mesmos valores → média das ordens
  - outliers podem influenciar CC → retirar outliers

## Capítulo 2 – Probabilidades

### 2.1 Introdução

- **Experiência aleatória** : Diz-se que uma experiência é aleatória se apresentar as seguintes características:
  - a) O conjunto dos resultados possíveis é fixado antecipadamente;
  - b) O resultado da experiência nunca pode ser previsto de forma exacta, mesmo que se desenvolvam todos os esforços para manter sob controlo as circunstâncias relevantes para o resultado.

### 2.2 Espaço de resultados / Acontecimentos

- **Espaço de resultados ou Espaço-amostra ( $\Omega$ )** : conjunto fundamental (não vazio) formado por todos os resultados que hipoteticamente é possível obter quando se efectua uma determinada experiência aleatória
- **Acontecimento** : subconjunto do espaço  $\Omega$   
→ **Acontecimentos elementares** : subconjuntos  $\{\omega\} \subset \Omega$  formados por um só elemento
- **Realização de um acontecimento** : Ao efectuar a experiência aleatória associada com  $\Omega$ , diz-se que o acontecimento  $A \subset \Omega$  se realiza, se o resultado da experiência é um ponto que pertence a  $A$ :  $\omega \in A$
- **Álgebra dos acontecimentos** :
  - **Implicação de acontecimentos** :  $(A \subset B) \Leftrightarrow (x \in A \Rightarrow x \in B)$
  - **Identidade de acontecimentos** :  $(A = B) \Leftrightarrow (x \in A \Leftrightarrow x \in B)$
  - **União de acontecimentos** :  $A \cup B = \{x: x \in A \vee x \in B\}$  ( $A \cup \emptyset = A$ ;  $A \cup \Omega = \Omega$ )
  - **Intersecção de acontecimentos** :  $A \cap B = \{x: x \in A \wedge x \in B\}$  ( $A \cap \emptyset = \emptyset$ ;  $A \cap \Omega = A$ )
  - **Acontecimentos incompatíveis / mutuamente exclusivos** :  $A$  e  $B$  são incompatíveis sse a realização de um implica a não realização do outro (acontecimentos disjuntos)
  - **Acontecimento impossível** :  $\emptyset$  (exemplo :  $A$  e  $B$  são incompatíveis sse  $A \cap B = \emptyset$ )
  - **Acontecimento certo** :  $\Omega$  (para qualquer  $\omega$  da experiência aleatória têm-se  $\omega \in \Omega$ )
  - **Diferença de acontecimentos** :  $A - B = A \cap \bar{B} = \{x: x \in A \wedge x \notin B\}$
  - **Acontecimento contrário/complementar** :  $\bar{A} = \{x: x \notin A\}$  ( $A \cup \bar{A} = \Omega$ ;  $A \cap \bar{A} = \emptyset$ ;  $\bar{\bar{A}} = A$ )
- **Propriedades das operações definidas sobre acontecimentos** :
  - 1) **Associatividade** :  $A \cup (B \cup C) = (A \cup B) \cup C$  ;  $A \cap (B \cap C) = (A \cap B) \cap C$
  - 2) **Comutatividade** :  $A \cup B = B \cup A$  ;  $A \cap B = B \cap A$
  - 3) **Distributividade** :  $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$  ;  $A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$
  - 4) **Leis de Morgan** :  $\overline{A \cup B} = \bar{A} \cap \bar{B}$  ;  $\overline{A \cap B} = \bar{A} \cup \bar{B}$
- **Operações sobre infinitades numeráveis de acontecimentos** :
  - 1) **União numerável** :  $\bigcup_{j=1}^{+\infty} A_j$
  - 2) **Intersecção numerável** :  $\bigcap_{j=1}^{+\infty} A_j$

### 2.3 Medida de Probabilidade. Axiomática de Kolmogorov

- **Medida de probabilidade** : função  $P$  que a cada acontecimento  $A, A \subset \Omega$ , faz corresponder um número real,  $P(A)$ , probabilidade do acontecimento  $A$ , que verifica os 3 axiomas seguintes :
  - P1)  $P(A) \geq 0$
  - P2)  $P(\Omega) = 1$
  - P3) Se  $A$  e  $B$  forem acontec. incompatíveis,  $A \cap B = \emptyset$ , então  $P(A \cup B) = P(A) + P(B)$   
→ P3\*) Se  $A_1, A_2, A_3, \dots, A_n, \dots$  forem acontecimentos em número finito numerável, dois a dois incompatíveis,  $A_i \cap A_j = \emptyset$  ( $i \neq j$ ), então  $P(\bigcup_{j=1}^{+\infty} A_j) = \sum_{j=1}^{+\infty} P(A_j)$

- **Propriedades da medida de probabilidade :**

- 1)  $P(A) = 1 - P(\bar{A})$
- 2)  $P(\emptyset) = 0$
- 3)  $P(B - A) = P(B) - P(A \cap B)$
- 4)  $P(A \cup B) = P(A) + P(B) - P(A \cap B)$
- 5)  $A \subset B \Rightarrow P(A) \leq P(B)$
- 6)  $P(A) \leq 1$

## 2.4 Interpretações do conceito de probabilidade

- **Regra de Laplace :** Sejam os acontecimentos elementares equiprováveis, então temos

$$P(A) = \frac{m}{n} = \frac{\#(A)}{\#(\Omega)} = \frac{n^\circ \text{ de casos favoráveis a } A}{n^\circ \text{ de casos possíveis}}$$

- **Como reconhecer que os casos são igualmente possíveis?**

- 1) O **princípio da indiferença** faz apelo às propriedades de simetria ou de homogeneidade da situação experimental (se o dado é perfeito, porque seriam umas faces preferidas em detrimento de outras?);
- 2) O **princípio da razão insuficiente** diz que se não há razão para crer em que qualquer dos casos é mais provável do que os outros, pode actuar-se como se todos os casos fossem igualmente prováveis.

- **Lei dos grandes números :**  $\lim_{n \rightarrow +\infty} P(|f_n(A) - P(A)| < \varepsilon) = 1$

- **As propriedades das frequências relativas verificam a axiomática de Kolmogorov :**

E1)  $f_n(A) \geq 0$

E2)  $f_n(\Omega) = 1$

E3) Se  $A$  e  $B$  forem acontec. incompatíveis, então  $f_n(A \cup B) = f_n(A) + f_n(B)$

- **Probabilidade subjectiva** (grau de credibilidade) : aproximação quantitativa à credibilidade que se atribui a um determinado acontecimento. (deve respeitar o princípio da coerência)

## 2.5 Métodos de contagem

- **Regra fundamental da contagem :** Suponha-se que uma experiência aleatória é composta por  $k$  etapas. Se na primeira etapa há  $m_1$  casos possíveis, na segunda etapa há  $m_2$  casos possíveis, ..., na  $k$ -ésima etapa há  $m_k$  casos possíveis, então o número total de resultados da experiência aleatória, combinando as  $k$  etapas é  $m_1 \times m_2 \times \dots \times m_k$ .

- **Amostra ordenada :** Se  $k$  elementos são seleccionados de um conjunto de  $n$  elementos e se a ordem da selecção é registada, o conjunto de  $k$  elementos forma uma amostra ordenada de dimensão  $k$ .

- **Amostragem sem reposição :** Quando se selecciona um elemento e o mesmo não é repostado no conjunto, diz-se que se seguiu um processo de amostragem sem reposição.

- **Amostragem com reposição :** Um processo de amostragem com reposição ocorre quando se selecciona um elemento e o mesmo é repostado no conjunto antes de se seleccionar o elemento seguinte.

- **Conceitos fundamentais de Análise Combinatória :**

➤ **Arranjos (sem repetição) :**  $A_k^n = \frac{n!}{(n-k)!}$

➤ **Arranjos completos (com repetição) :**  $\alpha_k^n = n^k$

➤ **Permutações :**  $P_n = A_n^n = n!$

➤ **Combinações :**  $C_k^n = \binom{n}{k} = \frac{A_k^n}{P_k} = \frac{n!}{k!(n-k)!}$  (coeficiente binomial)

➤ **Permutações de elementos não todos distintos :**  $\frac{n!}{k_1!k_2!\dots k_r!}$  (coeficiente multinomial)

## 2.6 Probabilidade Condicionada. Teorema de Bayes

- **Probabilidade Condicionada** :  $P(A|B) = \frac{P(A \cap B)}{P(B)}$  se  $P(B) > 0$
- **Regra da multiplicação de probabilidades** :  $P(A \cap B) = P(B) \times P(A|B) = P(A) \times P(B|A)$   
→ Generalizável para 3 ou + aconte. (Ex:  $P(A \cap B \cap C) = P(A) \times P(B|A) \times P(C|A \cap B)$ )
- **Partição do espaço de resultados** : Diz-se que a classe de acontecimentos  $\{A_1, A_2, A_3, \dots, A_m, \dots\}$  é uma partição de  $\Omega$  quando  $A_i \cap A_j = \emptyset$  ( $i \neq j$ ) e  $\cup_j A_j = \Omega$   
→ Consequência :  $P(\cup_j A_j) = \sum_j P(A_j) = 1$
- **Regra da Probabilidade Total** : Se  $\{A_1, A_2, A_3, \dots, A_m, \dots\}$  é uma partição de  $\Omega$  e se  $P(A_j) > 0$  ( $j = 1, 2, \dots, m, \dots$ ), vem, para qualquer acontecimento  $B$ ,

$$P(B) = \sum_j P(A_j) \times P(B|A_j)$$

- **Teorema de Bayes** : Se  $\{A_1, A_2, A_3, \dots, A_m, \dots\}$  é uma partição de  $\Omega$  e se  $P(A_j) > 0$  ( $j = 1, 2, \dots, m, \dots$ ), vem, para qualquer acontecimento  $B$ , a verificar  $P(B) > 0$ ,

$$P(A_j|B) = \frac{P(A_j) \times P(B|A_j)}{\sum_{i=1}^m P(A_i) \times P(B|A_i)} \quad (j = 1, 2, \dots, m, \dots)$$

Nota 1 :  $\sum_j P(A_j|B) = 1$

Nota 2 :  $\sum_{i=1}^m P(A_i) \times P(B|A_i) = P(B)$

- **Interpretação do Teorema de Bayes** :
  - Probabilidade *a priori* :  $P(A_j)$
  - Probabilidade *a posteriori* :  $P(A_j|B)$
  - Verossimilhanças de  $B$  para cada  $A_j$  :  $P(B|A_j)$
  - [probabilidade *a priori*]  $\propto$  [probabilidade *a posteriori*]  $\times$  [verossimilhança]  
 $\propto$  → “proporcional a”

## 2.7 Acontecimentos Independentes

- **Acontecimentos independentes** : Dois acontecimentos,  $A$  e  $B$ , do mesmo espaço de resultados, dizem-se independentes, se e só se  $P(A \cap B) = P(A) \times P(B)$

- **Teorema** : Se  $A$  e  $B$  forem acontecimentos independentes, então

$$P(A|B) = P(A) \text{ se } P(B) > 0 ; P(B|A) = P(B) \text{ se } P(A) > 0$$

- **Nota sobre o Exemplo 2.38 (Lançamento de uma moeda regular/viciada)** : A igualdade  $P(A \cap B) = P(A) \times P(B)$  verifica-se apenas nos casos triviais,  $p = 0$  e  $p = 1$ , e no caso simétrico,  $p = \frac{1}{2}$  (moeda “regular”). Assim,  $A$  e  $B$  podem ser ou não independentes, consoante a natureza da moeda.

- **Casos com 3 (ou mais) acontecimentos** : Os acontecimentos  $A$ ,  $B$  e  $C$  podem ser independentes dois a dois e não se verificar  $P(A \cap B \cap C) = P(A) \times P(B) \times P(C)$  ou vice-versa.

- **Independência completa ou mútua** : Os acontecimentos  $A$ ,  $B$  e  $C$  do mesmo espaço de resultados dizem-se completamente independentes ou mutuamente independentes se e só se:  
$$P(A \cap B) = P(A) \times P(B), \quad P(A \cap C) = P(A) \times P(C),$$
$$P(B \cap C) = P(B) \times P(C), \quad P(A \cap B \cap C) = P(A) \times P(B) \times P(C)$$

Nota : Definição extensível a quatro ou mais acontecimentos.

- **Independência condicional** : Dois acontecimentos,  $A$  e  $B$ , são independentes condicionalmente em relação a um acontecimento  $C$  se e só se

$$P[(A \cap B)|C] = P(A|C) \times P(B|C)$$

Nota : A independência condicional não implica independência no sentido corrente a não ser, obviamente, quando  $C = \Omega$ .

## Capítulo 3 – Variável Aleatória / Função de Distribuição

### 3.1 Variável Aleatória

- **Variável Aleatória** : Uma variável aleatória  $X$ , é uma função com domínio  $\Omega$  e com contradomínio  $\mathbb{R}$ . Assim:  $X : \omega \in \Omega \rightarrow X(\omega) \in \mathbb{R}$

### 3.2 Função de Distribuição

- **Função de Distribuição** : A função real de variável real,  $F_X$ , com domínio  $\mathbb{R}$ , definida por
$$F_X(x) = P(X \leq x)$$
designa-se por função de distribuição da variável aleatória  $X$ .
- **Propriedades da Função de Distribuição** :
  - 1)  $0 \leq F(x) \leq 1$
  - 2)  $F$  é não decrescente:  $\Delta x > 0 \Rightarrow F(x) \leq F(x + \Delta x)$
  - 3)  $F(-\infty) = \lim_{x \rightarrow -\infty} F(x) = 0$  e  $F(+\infty) = \lim_{x \rightarrow +\infty} F(x) = 1$
  - 4)  $P(a < X \leq b) = F(b) - F(a)$ ,  $\forall a, b: b > a$
  - 5)  $F$  é contínua à direita:  $F(a + 0) = \lim_{x \rightarrow a+0} F(x) = F(a)$
  - 6)  $P(X = a) = F(a) - F(a - 0)$ ,  $\forall a \in \mathbb{R}$
- **Acontecimentos com probabilidade zero** : Estes acontecimentos têm probabilidade zero, mas não são impossíveis. Exemplo: “Obter  $\pi$  na escolha de um número real qualquer no intervalo  $[3,4]$ ”. Voltar a calhar  $\pi$  é praticamente impossível, daí ser um acontecimento com probabilidade zero.
- **Mais Propriedades da Função de Distribuição** :
  - a)  $P(X < b) = F(b - 0)$
  - b)  $P(X > a) = 1 - F(a)$
  - c)  $P(X \geq a) = 1 - F(a - 0)$
  - d)  $P(a < X < b) = F(b - 0) - F(a)$
  - e)  $P(a \leq X < b) = F(b - 0) - F(a - 0)$
  - f)  $P(a \leq X \leq b) = F(b) - F(a - 0)$
- **Teorema** : A função real de variável real,  $F$ , é uma função de distribuição se e só se verifica as propriedades 2, 3 e 5.

### 3.3 Classificação das Variáveis Aleatórias

- **Conjunto dos Pontos de Descontinuidade** :  $D = \{x : P(X = x) = F(X) - F(X - 0) > 0\}$
- **Classificação das Variáveis Aleatórias** :
  - $X$  é uma **variável aleatória discreta** se e só se  $P(X \in D) = 1$ , ou seja, se e só se a soma dos saltos da função de distribuição for igual a 1. Assim:
$$P(X \in D) = \sum_{x \in D} P(X = x) = 1$$
  - $X$  é uma **variável aleatória contínua** se e só se  $D = \emptyset$  e se existe uma função real de variável real  $f_X$ , não negativa, tal que
$$F_X(x) = \int_{-\infty}^x f_X(u) du, \quad \forall x \in \mathbb{R}$$
  - Seja  $F_{X_1}$  uma função de distribuição associada a uma variável aleatória discreta,  $X_1$ , e  $F_{X_2}$  outra função de distribuição carterizadora de uma variável aleatória contínua,  $X_2$ . Diz-se que  $X$  é uma **variável aleatória mista** se e só se a respectiva função de distribuição puder ser escrita do seguinte modo:
$$F_X(x) = \lambda F_{X_1}(x) + (1 - \lambda) F_{X_2}(x), \quad \text{onde } 0 < \lambda < 1$$
  - Existem variáveis aleatórias que não são nem discretas, nem contínuas nem mistas.

#### A) Variáveis Aleatórias Discretas

- **Nota** : Uma variável aleatória é discreta quando toda a massa de probabilidade está concentrada nos pontos de descontinuidade da função de distribuição.



- **Função Probabilidade** : A função  $f_X$  chama-se função probabilidade da variável aleatória discreta  $X$  se e só se:

$$f_X(x) = \begin{cases} P(X = x) > 0 & \text{se } x \in D \\ P(X = x) = 0 & \text{se } x \notin D \end{cases}$$

→ **Suporte da Distribuição** : Subdomínio de  $f_X$  ; valores de  $x$  que pertencem a  $D$  ; habitualmente, refere-se a função probabilidade apenas para os valores do suporte

→  $P(X \in B) = P(B) = \sum_{x \in B \cap D} f(x)$

→  $F(x) = P(X \leq x) = \sum_{x_i \leq x} f(x_i)$ ,  $\forall x \in \mathbb{R}$  com  $D = \{x_1, x_2, \dots\}$

→ É indiferente representar-se uma v.a. discreta por  $F(x)$  ou  $f(x)$ .

## B) Variáveis Aleatórias Contínuas

- **Função Densidade de Probabilidade** : A função  $f_X$ , tal que  $F_X(x) = \int_{-\infty}^x f_X(u)du$ , chama-se função densidade de probabilidade ou simplesmente função densidade.

→  $f(x) = \begin{cases} F'(x) & \text{(nos pontos onde existe derivada)} \\ 0 & \text{(nos outros pontos)} \end{cases}$

→  $\int_{-\infty}^{+\infty} f(x)dx = F(+\infty) - F(-\infty) = 1$

→  $P(B) = P(X \in B) = \int_B f(x)dx$

→ Se  $B = ]a, b]$ , com  $a < b$ , tem-se  $P(B) = P(a < X \leq b) = \int_a^b f(x)dx = F(b) - F(a)$

→ Devido à continuidade da função de distribuição,  $P(X = a) = P(X = b) = 0$ , e pode escrever-se:

$$P(a < X \leq b) = P(a \leq X < b) = P(a < X < b) = P(a \leq X \leq b), \text{ com } a < b$$

→ É indiferente representar-se uma v.a. discreta por  $F(x)$  ou  $f(x)$ .

## C) Variáveis Aleatórias Mistas

- **Variável Aleatória Mista** : Seja  $F_{X_1}$  uma função de distribuição associada a uma variável aleatória discreta,  $X_1$ , e  $F_{X_2}$  outra função de distribuição carterizadora de uma variável aleatória contínua,  $X_2$ . Diz-se que  $X$  é uma variável aleatória mista se e só se a respectiva função de distribuição puder ser escrita do seguinte modo:

$$F_X(x) = \lambda F_{X_1}(x) + (1 - \lambda)F_{X_2}(x), \text{ onde } 0 < \lambda < 1$$

## 3.4 Funções de uma variável aleatória

- **Mudança de Variável** : Seja  $X$  uma variável aleatória, e considere-se uma função  $Y = \psi(X)$  é também uma variável aleatória que assume o valor  $y = \psi(x)$  quando  $X = x$ . Conhecida a função de distribuição de  $X$ ,  $F_X$ , pretende-se determinar a função de distribuição de  $Y$ ,  $F_Y$ . Ao substituir a variável aleatória  $X$  pela variável aleatória  $Y$ , está a efectuar-se uma **mudança de variável**.
  - **Utilidade** : facilita a interpretação e o tratamento quando da variável aleatória original
- **Caso 1 : Variável Aleatória Discreta** :
  - **Conjunto dos pontos que  $Y$  assume com probabilidade positiva** :  $D_Y = \psi(D_X)$  ;  
 $A_y = \{x : \psi(x) = y, x \in D_X\}$
  - **Função Probabilidade de  $Y$**  :  $f_Y(y) = P(Y = y) = P(X \in A_y) = \sum_{x \in A_y} f_X(x)$ , para  $y \in D_Y$
- **Caso 2 : Variável Aleatória Qualquer** :
  - **Função de Distribuição de  $Y$**  :  $F_Y(y) = P(Y \leq y) = P(A_y^*)$  onde  $A_y^* = \{x : \psi(x) \leq y\}$
- **Condição suficiente para que uma variável aleatória  $Y = \psi(X)$  seja também contínua** :  
 Seja  $Y = \psi(X)$ , onde  $X$  é uma variável aleatória contínua e  $\psi$  é uma função real de variável real com domínio em  $A$ ; supõe-se que este domínio contém o conjunto dos valores assumidos por  $X$  com densidade positiva. Se  $\psi$  tem derivada não nula em todos os pontos do seu domínio e é estritamente monótona em  $A$ , então  $Y$  é uma variável aleatória contínua.

### 3.5 Variáveis Aleatórias Bidimensionais

- **Variável Aleatória Bidimensional** : Uma variável aleatória bidimensional,  $(X, Y)$ , é uma função com domínio  $\Omega$  e com contradomínio  $\mathbb{R}^2$ . Assim,

$$(X, Y) : \omega \in \Omega \rightarrow (X(\omega), Y(\omega)) \in \mathbb{R}^2$$

- **Função de Distribuição Conjunta** : Seja  $(X, Y)$  uma variável aleatória bidimensional. A função real de duas variáveis reais,  $F_{X,Y}$ , com domínio  $\mathbb{R}^2$ , definida por

$$F_{X,Y}(x, y) = P(X \leq x, Y \leq y),$$

é a função de distribuição de  $(X, Y)$ , ou função de distribuição conjunta das variáveis  $X$  e  $Y$ .

- **Propriedades da Função de Distribuição Conjunta** :

1)  $0 \leq F(x, y) \leq 1$

- 2)  $F$  é não decrescente, separadamente, em relação a  $x$  e em relação a  $y$  :

$$\Delta x > 0 \Rightarrow F(x, y) \leq F(x + \Delta x, y) \quad \text{e} \quad \Delta y > 0 \Rightarrow F(x, y) \leq F(x, y + \Delta y)$$

3)  $F(-\infty, y) = F(x, -\infty) = 0$  e  $F(+\infty, +\infty) = 1$

4)  $P(I) = P(x_1 < x \leq x_2, y_1 < y \leq y_2) = F(x_2, y_2) - F(x_1, y_2) - F(x_2, y_1) + F(x_1, y_1)$

- 5)  $F$  é contínua à direita, separadamente, em relação a  $x$  e em relação a  $y$  :

$$F(x + 0, y) = F(x, y), \quad F(x, y + 0) = F(x, y)$$

- **Função de Distribuição Marginal** : A função  $F_X$  definida por  $F_X(x) = F_{X,Y}(x, +\infty)$  designa-se por função de distribuição marginal da variável aleatória  $X$ . A função  $F_Y$  dada por  $F_Y(y) = F_{X,Y}(+\infty, y)$  é a função de distribuição marginal da variável aleatória  $Y$ .

- **Variáveis Aleatórias Independentes** : Considere-se uma variável aleatória bidimensional  $(X, Y)$ . Sejam  $B_1$  e  $B_2$  dois acontecimentos quaisquer tais que  $B_1$  envolve apenas  $X$ , e  $B_2$  refere-se apenas a  $Y$ . As variáveis aleatórias  $X$  e  $Y$  são independentes se e só se

$$P(X \in B_1, Y \in B_2) = P(X \in B_1)P(Y \in B_2)$$

$$\text{ou então } F_{X,Y}(x, y) = F_X(x)F_Y(y)$$

- **Teorema** : Se  $X$  e  $Y$  são variáveis aleatórias independentes, e se  $\psi$  e  $\varphi$  são duas funções, então as variáveis aleatórias  $U = \psi(X)$  e  $V = \varphi(Y)$  são também independentes.

### 3.6 Variáveis Bidimensionais Discretas

- **Variável Aleatória Bidimensional Discreta** :  $(X, Y)$  é variável aleatória bidimensional discreta se e só se  $X$  e  $Y$  são variáveis aleatórias discretas.

- **Conjunto dos Pontos de Descontinuidade** :  $D = \{(x, y) : P(X = x, Y = y) > 0\}$

- **Função Probabilidade Conjunta** : Seja  $(X, Y)$  é variável aleatória bidimensional discreta. A função real de duas variáveis reais,  $f_{X,Y}$ , com domínio  $\mathbb{R}^2$ , definida por

$$f_{X,Y}(x, y) = P(X = x, Y = y)$$

é a função probabilidade de  $(X, Y)$ , ou função probabilidade conjunta das variáveis  $X$  e  $Y$ .

$$\rightarrow f(x, y) = \begin{cases} P(X = x, Y = y) > 0 & \text{se } (x, y) \in D \\ P(X = x, Y = y) = 0 & \text{se } (x, y) \notin D \end{cases}$$

$$\rightarrow \sum_{(x,y) \in D} f(x, y) = 1 \quad ; \quad P[(X, Y) \in B] = \sum_{(x,y) \in B \cap D} f(x, y)$$

$$\rightarrow F(x, y) = P(X \leq x, Y \leq y) = \sum_{x_i \leq x} \sum_{y_i \leq y} f(x_i, y_i)$$

- **Função Probabilidade Marginal** : Considere-se uma variável bidimensional discreta,  $(X, Y)$ . Seja  $F_X$  a função de distribuição marginal de  $X$ , e

$$D_X = \{x : P(X = x) = F_X(x) - F_X(x - 0) > 0\}$$

o conjunto dos pontos de descontinuidade de  $F_X$ .

A função probabilidade marginal de  $X$ ,  $f_X$ , é definida da seguinte maneira:

$$f_X(x) = \begin{cases} P(X = x) > 0 & \text{se } x \in D_X \\ P(X = x) = 0 & \text{se } x \notin D_X \end{cases}$$

Do mesmo modo se define a função probabilidade marginal de  $Y$ ,  $f_Y$ ,

$$f_Y(y) = \begin{cases} P(Y = y) > 0 & \text{se } y \in D_Y \\ P(Y = y) = 0 & \text{se } y \notin D_Y \end{cases}$$

onde  $D_Y = \{y : P(Y = y) = F_Y(y) - F_Y(y - 0) > 0\}$

→ A função probabilidade marginal de X obtém-se somando, para cada  $x$ , a função probabilidade conjunta para todos os  $y$  :

$$f_X(x) = P(X = x) = \sum_{y \in D_Y} P(X = x, Y = y) = \sum_{y \in D_Y} f_{X,Y}(x, y)$$

→ idem para  $Y$

- **Teorema** : As variáveis aleatórias discretas,  $X$  e  $Y$ , são independentes se e só se

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

isto é, se e só se a função probabilidade conjunta for igual ao produto das funções probabilidade marginais.

- **Função Probabilidade Condicionada** : Seja  $f_{X,Y}$  a função probabilidade conjunta de  $X$  e  $Y$ . A função probabilidade de  $X$  condicionada pela realização do acontecimento  $\{Y = y\}$ , com  $P(Y = y) > 0$ , é dada por:

$$f_{X|Y=y}(x) = P(X = x|Y = y) = \frac{P(X=x, Y=y)}{P(Y=y)} = \frac{f_{X,Y}(x,y)}{f_Y(y)} \quad (y \text{ fixo})$$

De modo análogo, a função probabilidade de  $Y$  condicionada pela realização do acontecimento  $\{X = x\}$ , com  $P(X = x) > 0$ , é dada por:

$$f_{Y|X=x}(y) = P(Y = y|X = x) = \frac{P(X=x, Y=y)}{P(X=x)} = \frac{f_{X,Y}(x,y)}{f_X(x)} \quad (x \text{ fixo})$$

→  $\sum_{x \in D_X} f_{X|Y=y}(x) = 1$  e  $\sum_{y \in D_Y} f_{Y|X=x}(y) = 1$

→ Se  $X$  e  $Y$  são **independentes**, então

$$f_{X|Y=y}(x) = f_X(x), \text{ se } f_Y(y) > 0 \quad ; \quad f_{Y|X=x}(y) = f_Y(y), \text{ se } f_X(x) > 0$$

### 3.7 Variáveis Bidimensionais Contínuas

- **Variável Aleatória Bidimensional Contínua** : A variável aleatória  $(X, Y)$ , com função de distribuição  $F_{X,Y}$ , é uma variável aleatória bidimensional contínua se e só se existe uma função real de duas variáveis reais, não negativa,  $f_{X,Y}$ , tal que

$$F_{X,Y}(x, y) = \int_{-\infty}^y \int_{-\infty}^x f_{X,Y}(u, v) du dv, \quad \forall (x, y) \in \mathbb{R}^2$$

- **Função Densidade Conjunta** : A função  $f_{X,Y}$  (introduzida na definição anterior) chama-se função densidade de  $(X, Y)$  ou função densidade conjunta de  $X$  e  $Y$

→  $F_{X,Y}(+\infty, +\infty) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y) dx dy = 1$

→ Se a função densidade  $f(x, y)$  for contínua no ponto  $(x, y)$ , então  $f(x, y) = \frac{\partial^2 F(x, y)}{\partial x \partial y}$

- **Funções Densidade Marginais** : A função densidade marginal de  $X$ ,  $f_X$ , é dada por

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

De forma análoga,

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

é a função densidade marginal de  $Y$ ,  $f_Y$ .

- **Teorema** : As variáveis aleatórias  $X$  e  $Y$  dizem-se independentes se e só se

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

isto é, se e só se a função densidade conjunta for igual ao produto das funções densidade marginais.

- **Função Densidade Condicionada** : Seja  $f_{X,Y}(x, y)$  a função densidade conjunta de  $X$  e  $Y$ . A função densidade de  $X$  condicionada por  $Y = y$ , com  $f_Y(y) > 0$ , é definida da seguinte maneira:

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

A função densidade de  $Y$  condicionada por  $X = x$ , com  $f_X(x) > 0$ , é dada por:

$$f_{Y|X=x}(y) = \frac{f_{X,Y}(x,y)}{f_X(x)} \quad (x \text{ fixo})$$

→  $\int_{-\infty}^{+\infty} f_{X|Y=y}(x) dx = 1$

→  $P(a < X < b | Y = c) = \int_a^b f_{X|Y=c}(x) dx = \frac{\int_a^b f_{X,Y}(x, c) dx}{f_Y(c)}$

→ **Factorização da Funç. de Dens. Conj.** :  $f_{X,Y}(x, y) = f_X(x)f_{Y|X=x}(y) = f_Y(y)f_{X|Y=y}(x)$

→ **Fórmula de Bayes para Densidades** :

$$f_{X|Y=y}(x) = \frac{f_X(x)f_{Y|X=x}(y)}{f_Y(y)} = \frac{f_X(x)f_{Y|X=x}(y)}{\int_{-\infty}^{+\infty} f_X(x)f_{Y|X=x}(y)dx}, \text{ com } f_Y(y) > 0$$

### 3.8 Distribuições Multidimensionais

- **Vectores Aleatórios** : Variáveis Aleatórias  $k$ -dimensionais (com  $k \geq 2$ )
- **Função de Distribuição** : A função de distribuição de  $X = (X_1, \dots, X_k)$ ,  $F_X$ , é a função real de  $k$  variáveis reais definida por

$$F_X(x_1, \dots, x_k) = P(X_1 \leq x_1, \dots, X_k \leq x_k)$$

→  $F_X$  é não decrescente e contínua à direita em relação a cada variável

→  $F_X(-\infty, x_2, \dots, x_k) = \dots = F_X(x_1, x_2, \dots, -\infty) = 0$  ;  $F_X(+\infty, +\infty, \dots, +\infty) = 1$

→ A noção de **função de distribuição marginal** abrange agora não só as situações unidimensionais mas também todos os possíveis subconjuntos das  $k$  variáveis.

– Exemplo 1 : Seja  $U = (X_1, \dots, X_k)$ , com  $m < k$ , então

$$F_U(u) = F_X(x_1, \dots, x_m, +\infty, \dots, +\infty)$$

– Exemplo 2 :  $F_X(x_1, +\infty, \dots, +\infty) = P(X_1 \leq x_1) = F_{X_1}(x_1)$

- **Vectores Aleatórios Independentes** : Os vectors aleatórios  $U$  e  $V$  dizem-se independentes se e só se

$$F_X(x_1, \dots, x_k) = F_{U,V}(u, v) = F_U(u)F_V(v)$$

ou seja, se e só se a função de distribuição conjunta é igual ao produto das funções de distribuição marginais.

- **Variáveis Aleatórias Independentes** : As variáveis aleatórias  $X_1, \dots, X_k$  dizem-se independentes se e só se

$$F_X(x_1, \dots, x_k) = F_{X_1}(x_1) \dots F_{X_k}(x_k)$$

- **Variável Aleatória  $k$ -dimensional Discreta** :  $X = (X_1, \dots, X_k)$  é variável aleatória  $k$ -dimensional discreta se e só se as variáveis aleatórias  $X_j$ , com  $j = 1, \dots, k$ , são discretas.

→ As restantes propriedades das variáveis aleatórias discretas são generalizáveis.

- **Variável Aleatória  $k$ -dimensional Contínua** : A variável aleatória  $k$ -dimensional  $X = (X_1, \dots, X_k)$ , onde  $F_X$  é a respectiva função de distribuição, é contínua se e só se existe uma função real de  $k$  variáveis reais, não negativa,  $f_X$ , a verificar

$$F_X(x_1, \dots, x_k) = \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_k} f_X(u_1, \dots, u_k) du_1 \dots du_k$$

→ As restantes propriedades das variáveis aleatórias discretas são generalizáveis.

## Capítulo 4 – Distribuições Discretas

### 4.2 Valor Esperado

- **Valor Esperado de uma Variável Aleatória Discreta** : Se  $X$  é uma variável aleatória discreta com função probabilidade  $f_X$ , a expressão

$$\mu = E(X) = \sum_{x \in D} x f_X(x)$$

quando

$$\sum_{x \in D} |x| f_X(x) < +\infty \quad \text{(4.2)}$$

define o valor esperado, média ou esperança matemática de  $X$ .

→ centro de gravidade da distribuição

→ parâmetro de localização

- **Valor Esperado de uma Função de uma Variável Aleatória Discreta** : Se  $X$  é uma variável aleatória discreta com função probabilidade  $f_X$ , a expressão

$$E(\psi(X)) = \sum_{x \in D} \psi(x) f_X(x)$$

é o valor esperado de  $\psi(x)$ , impondo-lhe uma condição semelhante a (4.2)

→  $\sum_{y \in D_Y} y f_Y(y) = \sum_{x \in D_X} \psi(x) f_X(x) < \Rightarrow E(Y) = E(\psi(X))$

- **Propriedades do Valor Esperado :**
  - 1) Se  $c$  é uma constante, então  $E(c) = c$
  - 2) Se  $c$  é uma constante e se existe  $E[\psi(X)]$ , então  $E[c\psi(X)] = cE[\psi(X)]$
  - 3) Se existirem  $E[\psi_1(X)]$  e  $E[\psi_2(X)]$ , então  $E[\psi_1(X) + \psi_2(X)] = E[\psi_1(X)] + E[\psi_2(X)]$
- **Outra Propriedade :** O valor esperado de uma combinação linear de funções de variável aleatória  $X$  é a respectiva combinação linear dos valores esperados:
$$E\left[\sum_{j=1}^n c_j \psi_j(X)\right] = \sum_{j=1}^n c_j E[\psi_j(X)]$$
- **Resultados Importantes :**
  - Se  $X$  e  $Y$  são duas variáveis aleatórias discretas, então  $E(X + Y) = E(X) + E(Y)$
  - Se  $X$  e  $Y$  são duas variáveis aleatórias discretas independentes, então  $E(XY) = E(X)E(Y)$

#### 4.3 Momentos

- **Momento de Ordem  $k$  em Relação à Origem :** O valor esperado,
$$\mu'_k = E(X^k) = \sum_{x \in D} x^k f_X(x)$$
se existir, é o momento de ordem  $k$  em relação à origem, ou momento ordinário de ordem  $k$  da variável aleatória  $X$ .
  - Nota :  $\mu'_1 = E(X) = \sum_{x \in D} x f_X(x) \rightarrow$  valor esperado
- **Teorema :** Se existe o momento ordinário de ordem  $k$  de uma variável aleatória, então também existe o momento ordinário de ordem  $s$ , com  $s < k$ , da mesma variável aleatória.
- **Momento de Ordem  $k$  em Relação à Média :** O valor esperado,
$$\mu_k = E[(X - \mu)^k] = \sum_{x \in D} (x - \mu)^k f_X(x)$$
se existir, é o momento de ordem  $k$  em relação à média, ou momento central de ordem  $k$  da variável aleatória  $X$ .
- **Variância :** Designa-se por variância de  $X$  o valor esperado, se existir, de  $(X - \mu)^2$ ,
$$Var(X) = \sigma_X^2 = E[(X - \mu)^2] = \sum_{x \in D} (x - \mu)^2 f_X(x)$$
  - $Var(X) \geq 0$  ;  $Var(X) = 0 \Leftrightarrow P(X = c) = 1$
  - parâmetro de dispersão da distribuição de  $X$  em torno da média
- **Propriedades da Variância :**
  - 1) Se  $c$  é uma constante,  $Var(c) = 0$
  - 2) Se  $c$  é uma constante,  $Var(cX) = c^2 Var(X)$
  - 3) Se  $c$  e  $d$  são constantes,  $Var(cX + d) = c^2 Var(X)$
- **Fórmula mais operacional para o cálculo da variância :**  $Var(X) = E(X^2) - \mu^2$
- **Desvio Padrão :** Ao valor positivo da raiz quadrada da variância,  $\sigma_X = +\sqrt{Var(X)}$ , chama-se desvio padrão da variável aleatória  $X$ .
  - medida de dispersão absoluta
- **Coefficiente de Variação :** Considere-se uma variável aleatória  $X$  com suporte contido no conjunto dos números reais positivos. O coeficiente de variação de  $X$  é igual, se existir, ao quociente entre o desvio padrão e a média,  $CV = \frac{\sigma}{\mu}$ 
  - medida de dispersão relativa
- **Coefficiente de Assimetria :** O quociente  $\gamma_1 = \frac{E(X - \mu)^3}{\sigma^3} = \frac{\mu_3}{\sigma^3}$ , se existir, é designado por coeficiente de assimetria da variável aleatória  $X$ .
  - $\gamma_1 = 0$  sse a distribuição é simétrica
  - $\gamma_1 > 0$  sse os desvios positivos dominam
  - $\gamma_1 < 0$  sse os desvios negativos dominam
- **Variância de Variáveis Aleatórias Independentes :** Se  $X$  e  $Y$  são duas variáveis aleatórias discretas independentes, então
$$Var(X + Y) = Var(X) + Var(Y)$$

#### 4.4 Funções Geradoras

- **Sucessões Importantes :**

- Sucessão das probabilidades :  $p_0, p_1, p_2, \dots$
- Sucessão dos momentos em relação à origem :  $\mu'_1 = \mu, \mu'_2, \dots, \mu'_k, \dots$
- Sucessão dos momentos em relação à média :  $\mu_1 = 0, \mu_2, \dots, \mu_k, \dots$

- **Função Geradora das Probabilidades :** Seja  $X$  uma variável aleatória discreta assumindo, com probabilidade positiva, os valores do conjunto  $D = \{0, 1, 2, \dots\}$ . Seja

$$p_x = P(X = x) \text{ com } x = 0, 1, 2, \dots \text{ a verificar } \sum_{x=0}^{+\infty} p_x = 1$$

A função geradora das probabilidades de  $X$  é a função real de variável real,  $\Pi_X$ , definida por

$$\Pi_X(z) = E(z^X) = \sum_{x=0}^{+\infty} p_x z^x$$

$$\rightarrow p_x = P(X = x) = \frac{\Pi^{(x)}(0)}{x!}$$

$$\rightarrow E(X) = \Pi'(1) = \sum_{x=1}^{+\infty} x p_x$$

$$\rightarrow \text{Var}(X) = \Pi''(1) + \Pi'(1) - [\Pi'(1)]^2$$

- **Função Geradora dos Momentos :** Seja  $X$  uma variável aleatória discreta com função probabilidade  $f_X$ . Se existir um número real  $s_0 > 0$ , tal que

$$E(e^{sX}) = \sum_{x \in D} e^{sx} f_X(x)$$

existe para  $-s_0 < s < s_0$ , então

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

define a função geradora dos momentos de  $X$ ,  $M_X$ .

$$\rightarrow M'(0) = \sum_{x \in D} x f_X(x) = E(X)$$

- **Teorema :** A função geradora dos momentos, se existir numa vizinhança de 0, determina univocamente a função de distribuição ; inversamente, se existir, a função geradora dos momentos é única.

Formalizando: Se para cada uma das variáveis aleatórias  $X$  e  $Y$ , existe função geradora dos momentos, e se  $M_X(s) = M_Y(s)$  para algum intervalo  $-s_0 < s < s_0$ , então  $X$  e  $Y$  possuem a mesma função de distribuição (e a mesma probabilidade, no caso de as variáveis aleatórias serem discretas).

- **Relação entre a Função Geradora dos Momentos com a Função Geradora das Probabilidades :**

$$M(s) = E(e^{sX}) = \Pi(e^s) \Leftrightarrow \Pi(z) = M[\ln(z)]$$

- **Teorema :** Se  $X$  e  $Y$  são variáveis aleatórias discretas independentes, com funções geradoras dos momentos  $M_X(s)$  e  $M_Y(s)$ , então a função geradora dos momentos  $X + Y$  existe, e é dada pela expressão:

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

#### 4.5 Distribuição Uniforme

- **Distribuição Uniforme :** Seja  $X$  uma variável aleatória discreta com  $D = \{x_1, x_2, \dots, x_n\}$ . Diz-se que  $X$  segue uma distribuição uniforme nos  $n$  pontos  $x_j$ , com  $j = 1, 2, \dots, n$ , se e só se a função probabilidade é dada por

$$f_X(x) = \begin{cases} \frac{1}{n} & \text{se } x \in D \\ 0 & \text{se } x \notin D \end{cases}$$

→ a função probabilidade é constante para um número finito de pontos

→ a distribuição é simétrica

- **Principais características da Distribuição Uniforme :**

- Valor Esperado :  $E(X) = \mu = \frac{1}{n} \sum_{j=1}^n x_j$
- Momento de Ordem  $k$  em relação à Origem :  $E(X^k) = \frac{1}{n} \sum_{j=1}^n x_j^k$
- Variância :  $\text{Var}(X) = \frac{1}{n} \sum_{j=1}^n (x_j - \mu)^2$
- Função Geradora dos Momentos :  $M(s) = \frac{1}{n} \sum_{j=1}^n e^{sx}$

- **Casos Particulares Importantes :**

- 1) Ex: Lançamento de um dado perfeito :  $D = \{1, 2, \dots, n\}$
- 2) Ex: Obtenção de um dos 10 dígitos :  $D = \{0, 1, 2, \dots, m\}$

#### 4.6 Distribuição de Bernoulli / Distribuição Binomial

- **Prova de Bernoulli :** Experiência aleatória em que se observa a realização (sucesso;  $x = 1$ ) ou a não realização (insucesso;  $x = 0$ ) de determinado acontecimento  $A$  com probabilidade  $P(A) = \theta$ .

$$f_X(x|\theta) = \begin{cases} 1 - \theta & \text{se } x = 1 \\ \theta & \text{se } x = 0 \\ 0 & \text{para outros } x \end{cases}$$

- **Distribuição de Bernoulli :** Se a variável aleatória  $X$  tem função probabilidade dada por

$$f_X(x|\theta) = \theta^x(1 - \theta)^{1-x} \text{ com } x = \{0, 1\} \text{ para } 0 < \theta < 1,$$

diz-se que  $X$  tem distribuição de Bernoulli. Simbolicamente,  $X \sim B(1; \theta)$

- **Principais características da Distribuição de Bernoulli :**

- Valor Esperado :  $E(X) = \mu = \theta$
- Momento de Ordem 2 em relação à Origem :  $E(X^2) = \theta$
- Variância :  $Var(X) = \theta(1 - \theta)$
- Desvio Padrão :  $\sigma = \sqrt{\theta(1 - \theta)}$
- Coeficiente de Assimetria :  $\gamma_1 = \frac{1-2\theta}{\sigma}$
- Função Geradora dos Momentos :  $M(s) = E(e^{sX}) = (1 - \theta) + \theta e^s$

- **Sucessão de Provas de Bernoulli Independentes :** Sucessão de experiências aleatórias independentes em cada uma das quais se observa a realização (sucesso;  $x = 1$ ) ou a não realização (insucesso;  $x = 0$ ) de determinado acontecimento  $A$  com probabilidade  $P(A) = \theta$ , constante de prova para prova.

- **Distribuição Binomial :** Se a variável aleatória  $X$  tem função probabilidade dada por

$$f_X(x|\theta) = \begin{cases} \binom{n}{x} \theta^x (1 - \theta)^{n-x} & \text{se } x = 0, 1, 2, \dots, n, \\ 0 & \text{para outros } x \end{cases}, \text{ para } 0 < \theta < 1,$$

diz-se que  $X$  tem distribuição binomial. Simbolicamente,  $X \sim B(n; \theta)$

- **Principais características da Distribuição Binomial :**

- Valor Esperado :  $E(X) = \mu = n\theta$
- Momento de Ordem 2 em relação à Origem :  $E(X^2) = n(n - 1)\theta^2 + n\theta$
- Variância :  $Var(X) = n\theta(1 - \theta)$
- Desvio Padrão :  $\sigma = \sqrt{n\theta(1 - \theta)}$
- Coeficiente de Assimetria :  $\gamma_1 = \frac{1-2\theta}{\sigma}$
- Função Geradora dos Momentos :  $M(s) = E(e^{sX}) = [(1 - \theta) + \theta e^s]^n$

- **Teorema :** Sejam  $Y_1$  e  $Y_2$  duas variáveis aleatórias independentes. Então

$$Y_1 \sim B(n_1; \theta), Y_2 \sim B(n_2; \theta) \Rightarrow Y = Y_1 + Y_2 \sim B(n; \theta)$$

onde  $n = n_1 + n_2$ .

#### 4.7 Distribuição Geométrica / Distribuição Binomial Negativa

- **Nova perspectiva :** Realizar provas de Bernoulli até que se dê um sucesso. O número de provas é que passa a ser aleatório.

- **Distribuição Geométrica :** Quando a variável aleatória  $X$  tem função probabilidade dada por

$$f_X(x) = \begin{cases} (1 - \theta)^{x-1} \theta & \text{se } x = 1, 2, \dots \\ 0 & \text{para outros } x \end{cases}$$

diz-se que tem distribuição geométrica ou distribuição de Pascal.

→ A sucessão das probabilidades forma uma progressão geométrica de razão  $1 - \theta$ .

- **Propriedades da Série Geométrica de razão  $z$  :**

a)  $S(z) = \sum_{k=0}^{\infty} z^k = \frac{1}{1-z}$  (série absolutamente convergente para  $|z| < 1$ )

b)  $S'(z) = \sum_{k=1}^{\infty} kz^{k-1} = \frac{1}{(1-z)^2}$

c)  $S''(z) = \sum_{k=2}^{\infty} k(k-1)z^{k-2} = \frac{1}{(1-z)^3}$

- **Principais características da Distribuição Geométrica :**

➤  $\sum_{k=1}^{\infty} f_X(x|\theta) = 1$

➤ Valor Esperado :  $E(X) = \mu = \frac{1}{\theta}$

➤ Variância :  $Var(X) = \sigma^2 = \frac{1-\theta}{\theta^2}$

➤ Desvio Padrão :  $\sigma = \frac{\sqrt{1-\theta}}{\theta}$

➤ Coeficiente de Assimetria :  $\gamma_1 = \frac{2-\theta}{\sqrt{1-\theta}} > 0$  (enviesamento positivo)

➤ Função Geradora dos Momentos :  $M(s) = E(e^{sX}) = \frac{\theta e^s}{1-(1-\theta)e^s}$ , com  $(1-\theta)e^s < 1$

- **Algumas Propriedades :**

→  $P(a \leq X \leq b) = (1-\theta)^{a-1} - (1-\theta)^b$

→ Se  $b \rightarrow +\infty$ ,  $P(X \geq a) = (1-\theta)^{a-1}$

→ Se  $a = 1$ ,  $P(X \leq b) = 1 - (1-\theta)^b$

- **Função de Distribuição de uma Variável Aleatória com Distribuição Geométrica :**

$$F_X(x) = \begin{cases} 0 & \text{se } x < 1 \\ 1 - (1-\theta)^k & \text{se } k \leq x \leq k+1 \end{cases}$$

para  $k = 1, 2, \dots$

- **Propriedade da "Falta de Memória" :**  $P(X > s | X > t) = P(X > s - t)$

- **Nova perspectiva :** Realizar provas de Bernoulli independentes até obter  $r$  sucessos.

- **Distribuição Binomial Negativa :** Uma variável aleatória  $X$  com função probabilidade dada por

$$f_X(x|\theta) = \begin{cases} \binom{x-1}{r-1} \theta^r (1-\theta)^{x-r} & \text{se } x = r, r+1, r+2, \dots \\ 0 & \text{para outros } x \end{cases}, \text{ para } 0 < \theta < 1$$

diz-se que tem distribuição binomial negativa. Simbolicamente,  $X \sim BN(r; \theta)$ .

- **Principais características da Distribuição Binomial Negativa :**

➤ Valor Esperado :  $E(X) = \mu = \frac{r}{\theta}$

➤ Variância :  $Var(X) = \sigma^2 = \frac{r(1-\theta)}{\theta^2}$

➤ Desvio Padrão :  $\sigma = \frac{\sqrt{r(1-\theta)}}{\theta}$

➤ Coeficiente de Assimetria :  $\gamma_1 = \frac{r\theta}{\sqrt{1-\theta}} > 0$

➤ Função Geradora dos Momentos :  $M(s) = E(e^{sX}) = \left( \frac{\theta e^s}{1-(1-\theta)e^s} \right)^r$ , com  $(1-\theta)e^s < 1$

- **Teorema :** Sejam  $Y_1$  e  $Y_2$  duas variáveis aleatórias independentes. Então

$$Y_1 \sim BN(n_1; \theta), Y_2 \sim BN(n_2; \theta) \Rightarrow Y = Y_1 + Y_2 \sim BN(n; \theta)$$

onde  $n = n_1 + n_2$ .

- **Corolário :**  $X_i \sim BN(1; \theta)$  se  $i = 1, 2, \dots, r$ , independentes  $\Rightarrow \sum_{i=1}^r X_i \sim BN(r; \theta)$

→ **Interpretação do Corolário :** Realizar provas até aparecerem  $r$  sucessos é o mesmo que realizar provas até aparecer o primeiro sucesso, continuar até aparecer o segundo, e assim sucessivamente, até aparecer o  $r$ -ésimo sucesso.



#### 4.8 Distribuição Hipergeométrica

- **Distribuição Hipergeométrica** : Se a variável aleatória  $X$  tem função probabilidade dada por

$$f_X(x|N, M, n) = \begin{cases} \frac{\binom{M}{x} \binom{N-M}{n-x}}{\binom{N}{n}} & \text{se } x \in D \\ 0 & \text{se } x \notin D \end{cases}$$

com  $D = \{x : \max\{0, n - (N - M)\} \leq x \leq \min\{n, M\}, x \text{ inteiro}\}$

diz-se que tem distribuição hipergeométrica. Simbolicamente  $X \sim H(N, M, n)$

- **Principais características da Distribuição Hipergeométrica** :  $\left(\theta = \frac{M}{N}\right)$

- $\sum_{x=0}^n f_X(x|N, M, n) = 1$
- Valor Esperado :  $E(X) = n \frac{M}{N} = n\theta$
- Variância :  $Var(X) = n \cdot \frac{M}{N} \cdot \frac{N-M}{N} \cdot \frac{N-n}{N-1} = n\theta(1-\theta) \frac{N-n}{N-1}$

#### 4.9 Distribuição de Poisson

- **Processo de Poisson** : Suponha-se que se procede à contagem do número de acontecimentos (chegada de doentes, “chegada” de avarias, chegada de navios, etc) ocorridos ao longo do tempo. Tem-se um processo de Poisson com parâmetro  $\lambda > 0$  quando se verificam as seguintes condições:

- O número de acontecimentos que ocorrem em dois intervalos disjuntos são independentes;
- A probabilidade de ocorrer exactamente um acontecimento em qualquer intervalo de amplitude  $\Delta t$  arbitrariamente pequena é aproximadamente  $\lambda \Delta t$ ;
- A probabilidade de ocorrerem dois ou mais acontecimentos em qualquer intervalo de amplitude  $\Delta t$  arbitrariamente pequena é aproximadamente igual a zero.

- **Distribuição de Poisson** : Uma variável aleatória  $X$  com função probabilidade dada por

$$f_X(x|\lambda) = \begin{cases} \frac{e^{-\lambda} \lambda^x}{x!} & \text{se } x = 0, 1, 2, \dots, \text{ com } \lambda > 0, \\ 0 & \text{para outros } x \end{cases}$$

diz-se que tem distribuição de Poisson. Simbolicamente,  $X \sim Po(\lambda)$

- **Principais características da Distribuição de Poisson** :

- $\sum_{x=0}^{+\infty} \frac{e^{-\lambda} \lambda^x}{x!} = 1$
- Função Geradora dos Momentos :  $M(s) = E(e^{sX}) = \exp[\lambda(e^s - 1)]$
- Valor Esperado :  $E(X) = \lambda$
- Variância :  $Var(X) = \lambda$
- Desvio Padrão :  $\sigma = \sqrt{\lambda}$
- Coeficiente de Assimetria :  $\gamma_1 = \lambda^{-1/2}$

- **Distribuição de Poisson e Intervalos de Tempo** :

$$f_X(x|\lambda t) = P[X(t) = x|\lambda t] = \frac{e^{-\lambda t} (\lambda t)^x}{x!}, \text{ se } x = 0, 1, 2, \dots, \text{ para } \lambda > 0$$

- **Teorema** : Sejam  $X_1$  e  $X_2$  duas variáveis aleatórias independentes. Então

$$X_1 \sim Po(\lambda_1), X_2 \sim Po(\lambda_2) \Rightarrow X = X_1 + X_2 \sim Po(\lambda)$$

onde  $\lambda = \lambda_1 + \lambda_2$ .

- **Lei dos Acontecimentos Raros** : A génese da distribuição de Poisson, a partir do processo de Poisson, mostra que, quando  $\theta = \frac{\lambda}{n} \rightarrow 0$  mantendo-se fixo  $n\theta = \lambda$ , a binomial tende para Poisson,

$$\lim_{n \rightarrow +\infty} \binom{n}{x} \left(\frac{\lambda}{n}\right)^x \left(1 - \frac{\lambda}{n}\right)^{n-x} = \frac{e^{-\lambda} \lambda^x}{x!}$$

#### 4.10 Valor Esperado e Momentos de Variáveis Aleatórias Bidimensionais Discretas

- **Valor Esperado de Função de Variável Aleatória Bidimensional** : Se  $(X, Y)$  é uma variável aleatória bidimensional discreta com função probabilidade  $f_{X,Y}$ , e se  $\psi$  é uma função de  $(X, Y)$ , a expressão

$$E[\psi(X, Y)] = \sum_{(x,y) \in D} \psi(x, y) f_{X,Y}(x, y)$$

é o valor esperado de  $\psi(x, y)$ . Tal como no caso unidimensional, tem de se verificar

$$\sum_{(x,y) \in D} |\psi(x, y)| f_{X,Y}(x, y) < +\infty$$

- **Teorema** : Se  $(X, Y)$  for uma variável aleatória bidimensional discreta com função probabilidade  $f_{X,Y}$ , e se existirem  $E(X)$  e  $E(Y)$ , então

$$E(X + Y) = E(X) + E(Y)$$

- **Teorema** : Se  $X$  e  $Y$  forem variáveis aleatórias discretas e independentes, com função probabilidade conjunta  $f_{X,Y}$ , e se existirem  $E(X)$  e  $E(Y)$ , então

$$E(XY) = E(X)E(Y)$$

- **Momentos de Ordem  $r + s$  em Relação à Origem** : Seja  $(X, Y)$  uma variável aleatória bidimensional discreta. O valor esperado,

$$\mu'_{rs} = E(X^r Y^s) = \sum_{(x,y) \in D} x^r y^s f_{X,Y}(x, y)$$

define, se existir, um momento de ordem  $r + s$  em relação à origem (ordinário) de variável aleatória  $(X, Y)$ .

→ Momentos de primeira ordem :

- $r = 1, s = 0 \Rightarrow \mu'_{10} = E(X) = \mu_X$
- $r = 0, s = 1 \Rightarrow \mu'_{01} = E(Y) = \mu_Y$

→ Momentos de segunda ordem :

- $r = 2, s = 0 \Rightarrow \mu'_{20} = E(X^2)$
- $r = 1, s = 1 \Rightarrow \mu'_{11} = E(XY)$
- $r = 0, s = 2 \Rightarrow \mu'_{02} = E(Y^2)$

- **Momentos de Ordem  $r + s$  em Relação à Média** : Seja  $(X, Y)$  uma variável aleatória bidimensional discreta. O valor esperado,

$$\mu_{rs} = E[(X - \mu)^r (Y - \mu)^s] = \sum_{(x,y) \in D} (x - \mu_X)^r (y - \mu_Y)^s f_{X,Y}(x, y)$$

define, se existir, um momento de ordem  $r + s$  em relação à média (central) de variável aleatória  $(X, Y)$ .

→ Momentos de primeira ordem (são nulos) :

- $r = 1, s = 0 \Rightarrow \mu_{10} = 0$
- $r = 0, s = 1 \Rightarrow \mu_{01} = 0$

→ Momentos de segunda ordem :

- $r = 2, s = 0 \Rightarrow \mu_{20} = E[(X - \mu)^2] = Var(X) = \sigma_X^2$
- $r = 1, s = 1 \Rightarrow \mu_{11} = E[(X - \mu)(Y - \mu)]$
- $r = 0, s = 2 \Rightarrow \mu_{02} = E[(Y - \mu)^2] = Var(Y) = \sigma_Y^2$

- **Covariância** : A covariância das variáveis aleatórias  $X$  e  $Y$  é

$$Cov(X, Y) = \sigma_{X,Y} = E[(X - \mu_X)(Y - \mu_Y)],$$

se este valor esperado existir.

→  $Cov(X, Y) = E(XY) - E(X)E(Y)$

→  $Cov(c, X) = E(cX) - cE(X) = 0$

- **Interpretação do Sinal e da Grandeza da Covariância** :

→ Centro de gravidade da distribuição conjunta :  $(\mu_X, \mu_Y)$

→  $(X - \mu_X)(Y - \mu_Y) > 0 \rightarrow 1^\circ$  e  $3^\circ$  quadrantes

→  $(X - \mu_X)(Y - \mu_Y) < 0 \rightarrow 2^\circ$  e  $4^\circ$  quadrantes

- **Coefficiente de Correlação** : O coeficiente de correlação entre as variáveis aleatórias  $X$  e  $Y$  é dado por

$$\rho_{X,Y} = \frac{Cov(X,Y)}{\sqrt{Var(X)Var(Y)}} = \frac{\sigma_{X,Y}}{\sigma_X \sigma_Y}$$

- **Teorema** : Se duas variáveis aleatórias,  $X$  e  $Y$ , são independentes, então a respectiva covariância é igual a zero.

→ A independência implica não correlação, mas a recíproca não é verdadeira.

- **Teorema** : Se existem segundos momentos para as variáveis aleatórias  $X$  e  $Y$ , então

$$Var(X \pm Y) = Var(X) \pm Cov(X, Y) + Var(Y)$$

Em particular, se as variáveis são independentes,

$$Var(X \pm Y) = Var(X) + Var(Y)$$

- **Valor Esperado Condicionado** : Seja a variável aleatória  $Z = \psi(X, Y)$ , função das variáveis aleatórias discretas  $X$  e  $Y$ . O valor esperado de  $Z = \psi(X, Y)$  condicionado por  $X = x$ , é definido por

$$E(Z|X = x) = E[\psi(X, Y)|X = x] = \sum_{y \in D_Y} \psi(x, y) f_{Y|X=x}(y)$$

se se verificar a condição habitual de existência do valor esperado.

De modo análogo se define

$$E(Z|Y = y) = E[\psi(X, Y)|Y = y] = \sum_{x \in D_X} \psi(x, y) f_{X|Y=y}(x)$$

→ Se  $\psi(x, y) = Y$ ,  $E(Y|X = x) = \sum_{y \in D_Y} y f_{Y|X=x}(y)$

→ Se  $\psi(x, y) = X$ ,  $E(X|Y = y) = \sum_{x \in D_X} x f_{X|Y=y}(x)$

- **Teorema** : O valor esperado de  $Z = \psi(X, Y)$ , se existir, é igual ao valor esperado do seu valor esperado condicionado por  $X$ ,

$$E(Z) = E[E(Z|X)]$$

→ Se  $Z = Y$ ,  $E(Y) = E[E(Y|X)]$  → regra do valor esperado iterado (→ v.e. marginal)

- **Variância Condicionada** : A variância de  $Y$  condicionada por  $X = x$  é definida por

$$Var(Y|X = x) = E[\{Y - E(Y|X = x)\}^2|X = x] = \sum_{y \in D_Y} \{y - E(Y|X = x)\}^2 f_{Y|X=x}(y)$$

Do mesmo modo se define a variância de  $X$  condicionada por  $Y = y$ ,

$$Var(X|Y = y) = E[\{X - E(X|Y = y)\}^2|Y = y] = \sum_{x \in D_X} \{x - E(X|Y = y)\}^2 f_{X|Y=y}(x)$$

→  $Var(Y|X = x) = E(Y^2|X = x) - E(Y|X = x)^2$

→  $Var(X|Y = y) = E(X^2|Y = y) - E(X|Y = y)^2$

- **Teorema** : Se existe  $E(Y^2)$ , então

$$Var(Y) = Var[E(Y|X)] + E[Var(Y|X)] \quad (\text{Variância Marginal})$$

- **Teorema** : A covariância entre  $X$  e  $Y$  é igual à covariância entre  $X$  e o valor esperado de  $Y$  condicionado por  $X$ ,

$$Cov(X, Y) = Cov[X, E(Y|X)]$$

- **Independência em Média** : A variável aleatória  $Y$  é independente em média da variável aleatória  $X$  se e só se

$$E(Y|X = x) = E(Y), \text{ qualquer que seja } x$$

A variável aleatória  $X$  é independente em média da variável aleatória  $Y$  se e só se

$$E(X|Y = y) = E(X), \text{ qualquer que seja } y$$

#### 4.11 Valor Esperado de Momentos de Variáveis Aleatórias $k$ -Dimensionais Discretas

- **Momento de Ordem  $r_1 + r_2 + \dots + r_k$  em Relação à Média** :

$$E[(X_1 - \mu_1)^{r_1} (X_2 - \mu_2)^{r_2} \dots (X_k - \mu_k)^{r_k}]$$

- **Momentos Centrais de 2ª Ordem** :

➤ Variância :  $Var(X_i) = \sigma_{ii} = \sigma_i^2$

➤ Covariância :  $Cov(X_i, X_j) = \sigma_{ij} \quad (i \neq j)$

- **Matriz das Covariâncias** :  $Cov(\mathbf{X}) = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1k} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2k} \\ \vdots & \vdots & & \vdots \\ \sigma_{k1} & \sigma_{k2} & \dots & \sigma_{kk} \end{bmatrix}$

- **Coefficiente de Correlação entre  $X_i$  e  $X_j$**  :  $\rho_{ij} = \frac{\sigma_{ij}}{\sqrt{\sigma_{ii}\sigma_{jj}}} = \frac{\sigma_{ij}}{\sigma_i\sigma_j}$

- **Matriz das Correlações do Vector Aleatório  $X$**  :  $Corr(X) = \begin{bmatrix} 1 & \rho_{12} & \cdots & \rho_{1k} \\ \rho_{21} & 1 & \cdots & \rho_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{k1} & \rho_{k2} & \cdots & 1 \end{bmatrix}$
  - **Relação entre a Variância e a Matriz das Covariâncias** :  

$$Var(Y) = Var(\mathbf{a}^T X) = \mathbf{a}^T Cov(X) \mathbf{a}$$
  - **Relação entre a Matriz das Covariâncias e a Matriz das Correlações** :  

$$Cov(Y) = Cov(AX) = ACov(X)A^T$$
- Nota:  $\mathbf{a}$  e  $A$  são matrizes de coeficientes

#### 4.12 Distribuição Multinomial

- **Distribuição Multinomial** : Se uma variável aleatória  $k$ -dimensional tem função probabilidade dada por

$$f_X(x_1, x_2, \dots, x_k) = \frac{n!}{x_1! x_2! \dots x_k! (n - x_1 - x_2 - \dots - x_k)!} \times \theta_1^{x_1} \theta_2^{x_2} \dots \theta_k^{x_k} (1 - \theta_1 - \theta_2 - \dots - \theta_k)^{n - x_1 - x_2 - \dots - x_k},$$

para as probabilidades positivas, diz-se que tem distribuição multinomial.

- **Principais características da Distribuição Multinomial** :
  - Valor Esperado :  $E(X_i) = n\theta_i$
  - Variância :  $Var(X_i) = n\theta_i(1 - \theta_i)$
  - Desvio Padrão :  $\sigma = \sqrt{n\theta_i(1 - \theta_i)}$
  - Covariância :  $Cov(X_i, X_j) = \sigma_{ij} = -n\theta_i\theta_j$
  - Coeficiente Correlação :  $\rho_{ij} = -\sqrt{\frac{\theta_i\theta_j}{(1-\theta_i)(1-\theta_j)}}$  ( $i \neq j$ )

## Capítulo 5 – Distribuições Contínuas

### 5.2 Valor Esperado

- **Valor Esperado de uma Variável Aleatória Discreta** : Se  $X$  é variável aleatória contínua com função densidade  $f_X$ , a expressão

$$E(X) = \int_{-\infty}^{+\infty} x f_X(x) dx$$

quando

$$\int_{-\infty}^{+\infty} |x| f_X(x) dx < +\infty \quad \text{(5.2)}$$

define o valor esperado, média ou esperança matemática de  $X$ .

→ centro de gravidade da distribuição

→ parâmetro de localização

- **Valor Esperado de uma Função de uma Variável Aleatória Discreta** : Se  $X$  é uma variável aleatória contínua com função densidade  $f_X$ , e  $\psi$  é uma função real de variável real. A expressão

$$E(\psi(X)) = \int_{-\infty}^{+\infty} \psi(x) f_X(x) dx$$

é o valor esperado de  $\psi(x)$ , impondo-lhe uma condição semelhante a (5.2)

- **Propriedades do Valor Esperado** : As propriedades do valor esperado para variáveis aleatórias contínuas são as mesmas do que as propriedades para variáveis aleatórias discretas. Apenas é necessário substituir as somas por integrais.

### 5.3 Momentos

- **Momento de Ordem  $k$  em Relação à Origem** : O valor esperado,

$$\mu'_k = E(X^k) = \int_{-\infty}^{+\infty} x^k f_X(x) dx$$

se existir, define o momento de ordem  $k$  em relação à origem, ou momento ordinário de ordem  $k$  da variável aleatória  $X$ .

Nota :  $\mu'_1 = E(X) = \int_{-\infty}^{+\infty} x f_X(x) dx \rightarrow$  valor esperado

- **Teorema** : Se existe o momento ordinário de ordem  $k$  de uma variável aleatória, então também existe o momento ordinário de ordem  $s$ , com  $s < k$ , da mesma variável aleatória.
- **Momento de Ordem  $k$  em Relação à Média** : O valor esperado,

$$\mu_k = E[(X - \mu)^k] = \int_{-\infty}^{+\infty} (X - \mu)^k f_X(x) dx$$

se existir, é o momento de ordem  $k$  em relação à média, ou momento central de ordem  $k$  da variável aleatória  $X$ .

- **Variância** : A variância de uma variável aleatória contínua  $X$  é dada por

$$Var(X) = \sigma_X^2 = E[(X - \mu)^2] = \int_{-\infty}^{+\infty} (X - \mu)^2 f_X(x) dx$$

$\rightarrow$  parâmetro de dispersão da distribuição de  $X$  em torno da média

- **Propriedades da Variância** :

$\rightarrow Var(cX) = c^2 Var(X)$

$\rightarrow Var(X) = E(X^2) - \mu^2 \rightarrow$  fórmula mais operacional para o cálculo da variância

$\rightarrow Var(X + Y) = Var(X) + Var(Y)$ , se  $X$  e  $Y$  são independentes

- **Desvio Padrão** :  $\sigma_X = +\sqrt{Var(X)}$   $\rightarrow$  medida de dispersão absoluta

- **Coefficiente de Variação** :  $CV = \frac{\sigma}{\mu}$   $\rightarrow$  medida de dispersão relativa

- **Coefficiente de Assimetria** :  $\gamma_1 = \frac{E(X-\mu)^3}{\sigma^3} = \frac{\mu_3}{\sigma^3}$

- **Coefficiente de Kurtosis** : O coeficiente de *kurtosis* de uma variável aleatória  $X$ , se existir, é definido por  $\gamma_1 = \frac{\mu_4}{\sigma^4} \rightarrow$  excesso de kurtosis :  $\gamma_1 - 3$

### 5.4 Parâmetros da Ordem

- **Quantil** : Seja  $X$  uma variável aleatória contínua, e  $\alpha$ , um número real a verificar  $0 < \alpha < 1$ . Quantil de ordem  $\alpha$ ,  $\mathcal{E}_\alpha$ , é um valor de  $X$  que satisfaz a condição

$$\int_{-\infty}^{\mathcal{E}_\alpha} f_X(x) dx = \alpha \iff F_X(\mathcal{E}_\alpha) = \alpha$$

$\rightarrow$  medida de localização

$\rightarrow$  Mediana :  $\alpha = 0,5 \rightarrow \mathcal{E}_{0,5} = \mu_c = med(X) \rightarrow \int_{-\infty}^{\mathcal{E}_{0,5}} f_X(x) dx = 0,5$

$\rightarrow$  1º Quartil :  $\alpha = 0,25 \rightarrow \mathcal{E}_{0,25} \rightarrow \int_{-\infty}^{\mathcal{E}_{0,25}} f_X(x) dx = 0,25$

$\rightarrow$  3º Quartil :  $\alpha = 0,75 \rightarrow \mathcal{E}_{0,75} \rightarrow \int_{-\infty}^{\mathcal{E}_{0,75}} f_X(x) dx = 0,75$

- **Moda** : Seja  $X$  uma variável aleatória contínua. Moda,  $\mu_*$ , é um valor de  $X$  que verifica a condição

$$f_X(x) \leq f_X(\mu_*), \forall x \in \mathbb{R}$$

Nota: A moda não é um parâmetro da ordem, contudo trata-se de uma importante medida de localização.

- **Amplitude Interquartis** :  $AIQ = \mathcal{E}_{0,75} - \mathcal{E}_{0,25}$  (medida de dispersão absoluta)

- **Uma medida de dispersão relativa** :  $\frac{AIQ}{\mu_c}$

- **Principais medidas de localização e de dispersão** :

Medidas	$\mu$	$\sigma$	CV	$\mu_*$	$\mu_c$	AIQ	AIQ/ $\mu_c$
Localização	×			×	×		
Dispersão absoluta		×				×	
Dispersão relativa			×				×

### 5.5. Função Geradora dos Momentos

- **Função Geradora dos Momentos** : Seja  $X$  uma variável aleatória contínua com função densidade  $f_X$ . Se existir um número real  $s_0 > 0$ , tal que

$$E(e^{sX}) = \int_{-\infty}^{+\infty} e^{sx} f_X(x) dx$$

existe e é finito para  $-s_0 < s < s_0$ , então

$$M(s) = E(e^{sX})$$

define a função geradora dos momentos de  $X$ .

- Existe uma correspondência biunívoca entre função geradora dos momentos (quando existe) e função densidade
- $M_{X+Y}(s) = M_X(s)M_Y(s)$

### 5.6 Distribuição Uniforme

- **Distribuição Uniforme** : Diz-se que uma variável aleatória contínua,  $X$ , tem distribuição uniforme no intervalo  $(\alpha, \beta)$ , com  $\alpha < \beta$ , quando a função densidade é dada por

$$f_X(x|\alpha, \beta) = \begin{cases} \frac{1}{\beta-\alpha} & \text{se } \alpha < x < \beta \\ 0 & \text{para outros } x \end{cases}$$

Simbolicamente,  $X \sim U(\alpha, \beta)$ .

- **Principais características da Distribuição Uniforme** :

➤ Função de Distribuição :  $F_X(x|\alpha, \beta) = \begin{cases} 0 & \text{se } x < \alpha \\ \frac{x-\alpha}{\beta-\alpha} & \text{se } \alpha < x < \beta \\ 1 & \text{se } x \geq \beta \end{cases}$

➤ Função Geradora dos Momentos :  $M(s) = E(e^{sX}) = \int_{\alpha}^{\beta} \frac{e^{sx}}{\beta-\alpha} dx = \begin{cases} \frac{e^{s\beta}-e^{s\alpha}}{s(\beta-\alpha)} & \text{se } s \neq 0 \\ 1 & \text{se } s = 0 \end{cases}$

➤ Expressão Geral dos Momentos em Relação à Origem :

$$E(X^k) = \int_{\alpha}^{\beta} \frac{x^k}{\beta-\alpha} dx = \frac{1}{\beta-\alpha} \left[ \frac{x^{k+1}}{k+1} \right]_{\alpha}^{\beta} = \frac{\beta^{k+1}-\alpha^{k+1}}{(k+1)(\beta-\alpha)}$$

➤ Média :  $E(X) = \frac{\alpha+\beta}{2}$

➤ Variância :  $Var(X) = \frac{(\beta-\alpha)^2}{12}$

➤ Coeficiente de Assimetria é nulo :  $\gamma_1 = 0$

- **Transformação Uniformizante** :

a) Seja  $X$  uma variável aleatória contínua com função de distribuição  $F_X$  estritamente crescente no intervalo aberto  $]a, b[$  onde  $X$  tem densidade positiva (este intervalo pode ser ilimitado, isto é, pode acontecer  $a = -\infty$  ou  $b = +\infty$  ; tem-se  $F_X(a) = 0$  e  $F_X(b) = 1$ ). Então a variável aleatória  $Y = F_X(X)$  tem distribuição  $U(0,1)$ .

b) Seja  $Y$  uma variável aleatória contínua com distribuição  $U(0,1)$ , e  $F_X$  a função de distribuição de uma variável aleatória contínua. Supõe-se que  $F_X$  é estritamente crescente no intervalo aberto  $]a, b[$  onde esta variável aleatória tem densidade positiva (o intervalo pode ser ilimitado, isto é, pode acontecer  $a = -\infty$  ou  $b = +\infty$  ; tem-se  $F_X(a) = 0$  e  $F_X(b) = 1$ ). Então a variável aleatória  $X = F_X^{-1}(Y)$  é contínua com função de distribuição  $F_X$ .

## 5.7 Distribuição Normal

- **Distribuição Normal** : Diz-se que a variável aleatória  $X$  tem distribuição normal com parâmetros  $\mu$  e  $\sigma^2$  quando a função densidade é da forma

$$f(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2}(x - \mu)^2\right) \quad \text{com } -\infty < x < +\infty$$

onde  $\mu \in \mathbb{R}$  e  $\sigma^2 > 0$ . Simbolicamente  $X \sim N(\mu, \sigma^2)$ .

- **Função de Distribuição de  $X \sim N(\mu, \sigma^2)$**  :  $F(x|\mu, \sigma^2) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2}(t - \mu)^2\right) dt$

- **Caso Particular Importante** :  $\mu = 0$  e  $\sigma^2 = 1$

➤ Função Densidade :  $\phi(z) = \frac{1}{\sqrt{2\pi}} e^{-z^2/2}$

➤ Função de Distribuição :  $\Phi(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-t^2/2} dt$

- **Distribuição Normal Estandardizada** : A distribuição  $N(0,1)$  é uma distribuição normal estandardizada se  $X \sim N(\mu, \sigma^2)$  e  $Z = \frac{X - \mu}{\sigma}$ .

- **Simetria** :

→  $N(\mu, \sigma^2)$  é simétrica em relação à recta  $x = \mu$

→  $N(0,1) \rightarrow \phi(x) = \phi(-x)$  ;  $\Phi(x) = 1 - \Phi(-x)$

- **Função Geradora dos Momentos de  $Z \sim N(0, 1)$**  :  $M_Z(s) = e^{-s^2/2}$

- **Função Geradora dos Momentos de  $X \sim N(\mu, \sigma^2)$**  :  $M_X(s) = \exp\left(\mu s + \frac{\sigma^2 s^2}{2}\right)$

- **Valor Esperado e Variância** :  $E(X) = \mu$  ;  $Var(X) = \sigma^2$

- **Expressão Geral dos Momentos Centrais de Ordem Par** :  $\mu_{2r} = \frac{(2r)! \sigma^{2r}}{2^r r!}$

- **Coefficiente de Kurtosis** :  $\gamma_2 = \frac{\mu_4}{\sigma^4} = 3$

- **Interpretação do excesso de kurtosis** :

a) Distribuição leptokurtica :  $\gamma_2 > 3 \rightarrow$  caudas mais “espessas”

b) Distribuição platilurtica :  $\gamma_2 < 3 \rightarrow$  caudas mais “finas”

c) Distribuição mesokurtica :  $\gamma_2 = 3 \rightarrow$  distribuição normal

- **Intervalos e Probabilidades da Distribuição Normal** :

Intervalos	Probabilidades
$\mu \pm \sigma$	0,6826
$\mu \pm 2\sigma$	0,9544
$\mu \pm 3\sigma$	0,9973
$\mu \pm 0,6745\sigma$	0,5000
$\mu \pm 1,6450\sigma$	0,9000
$\mu \pm 1,9600\sigma$	0,9500
$\mu \pm 2,5758\sigma$	0,9900

- **Teorema** : Se as variáveis aleatórias  $X_i$  ( $i = 1, 2, \dots, k$ ) são independentes, então

$$X_i \sim N(\mu_i, \sigma_i^2) \Rightarrow Y = \sum_{i=1}^k \alpha_i X_i \sim N(\mu_Y, \sigma_Y^2)$$

onde

$$\mu_Y = \sum_{i=1}^k \alpha_i \mu_i \quad \text{e} \quad \sigma_Y^2 = \sum_{i=1}^k \alpha_i^2 \sigma_i^2$$

→ Qualquer combinação linear de variáveis aleatórias independentes com distribuição normal tem ainda distribuição normal.

- **Corolário** : Se as variáveis aleatórias  $X_i$  ( $i = 1, 2, \dots, k$ ) são independentes e identicamente distribuídas, então

$$X_i \sim N(\mu, \sigma^2) \Rightarrow Y = \sum_{i=1}^k X_i \sim N(k\mu, k\sigma^2)$$

- **Corolário** : Se as variáveis aleatórias  $X_i$  ( $i = 1, 2, \dots, k$ ) são independentes e identicamente distribuídas, então

$$X_i \sim N(\mu, \sigma^2) \Rightarrow \bar{X} = \frac{1}{k} \sum_{i=1}^k X_i \sim N\left(\mu, \frac{\sigma^2}{k}\right)$$

- **Teorema** : Se as variáveis aleatórias  $X_i$  ( $i = 1, 2, \dots, k$ ) são normais tais que  
 $E(X_i) = \mu_i$ ,  $Var(X_i) = \sigma_i^2 = \sigma_{ii}$ ,  $Cov(X_i, X_j) = \sigma_{ij}$  ( $i \neq j$ )  
então

$$Y = \sum_{i=1}^k \alpha_i X_i \sim N(\mu_Y, \sigma_Y^2)$$

onde

$$\mu_Y = \sum_{i=1}^k \alpha_i \mu_i$$

e

$$\begin{aligned} \sigma_Y^2 = & \alpha_1^2 \sigma_{11} + 2\alpha_1 \alpha_2 \sigma_{12} + 2\alpha_1 \alpha_3 \sigma_{13} + \dots + 2\alpha_1 \alpha_k \sigma_{1k} \\ & + \alpha_2^2 \sigma_{22} + 2\alpha_2 \alpha_3 \sigma_{23} + \dots + 2\alpha_2 \alpha_k \sigma_{2k} \\ & \dots \\ & + \alpha_k^2 \sigma_{kk} \end{aligned}$$

## 5.8 Distribuição Exponencial

- **Distribuição Exponencial** : A variável aleatória  $X$  com função densidade definida por

$$f(x|\lambda) = \begin{cases} 0 & \text{se } x \leq 0 \\ \lambda e^{-\lambda x} & \text{se } x > 0 \end{cases}$$

diz-se que tem distribuição exponencial (ou exp. negativa). Simbolicamente,  $X \sim Ex(\lambda)$ .

- **Principais Características da Distribuição Exponencial** :

- Função de Distribuição :  $F(x|\lambda) = \begin{cases} 0 & \text{se } x \leq 0 \\ 1 - e^{-\lambda x} & \text{se } x > 0 \end{cases}$
- Função Geradora dos Momentos :  $M(s) = \left(1 - \frac{s}{\lambda}\right)^{-1} = \frac{\lambda}{\lambda - s}$ , ( $s < \lambda$ )
- Valor Esperado :  $E(X) = \frac{1}{\lambda}$
- Variância :  $Var(X) = \frac{1}{\lambda^2}$
- Coeficiente de Variação :  $CV = 1$
- Coeficiente de Assimetria :  $\gamma_1 = 2$
- Coeficiente de Kurtosis :  $\gamma_2 = 9$
- Não tem Moda porque  $f(x|\lambda)$  é decrescente com  $x$  e o domínio é aberto.
- Mediana :  $\mu_c = \frac{\ln 2}{\lambda} \rightarrow$  enviesamento positivo  $\rightarrow \mu_c < \mu$

- **Propriedade da "Falta de Memória"** :

$$X \sim Ex(\lambda) \Rightarrow P(X > x + h | X > x) = P(X > x)$$

- **Teorema** : Se  $X_1, X_2, \dots, X_k$  são variáveis aleatórias independentes, então

$$X_i \sim Ex(\lambda) \Rightarrow \min_i X_i \sim Ex(k\lambda)$$

## 5.9 Distribuição Gama ; Distribuição do Qui-Quadrado

- **Função Gama (factorial generalizado)** : Função real de variável real que faz corresponder a cada número real positivo,  $\alpha > 0$ , o número real definido por

$$\Gamma(\alpha) = \int_0^{+\infty} e^{-x} x^{\alpha-1} dx \quad (\alpha > 0)$$

- **Propriedades da Função Gama** :

- Substituindo  $x$  por  $\lambda x$ , obtém-se  $\Gamma(\alpha) = \lambda^\alpha \int_0^{+\infty} e^{-\lambda x} x^{\alpha-1} dx$
- Com  $\alpha > 1$ , integrando por partes, obtém-se  $\Gamma(\alpha) = (\alpha - 1) \cdot \Gamma(\alpha - 1)$
- Se  $\alpha = n$  (inteiro positivo), tem-se  $\Gamma(n) = (n - 1)!$   
mas  $\Gamma(1) = \int_0^{+\infty} e^{-x} dx = 1$
- $\Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}$

- **Distribuição Gama** : Uma variável aleatória  $X$  com função densidade dada por

$$f(x|\alpha, \lambda) = \begin{cases} 0 & \text{se } x \leq 0 \\ \frac{\lambda^\alpha e^{-\lambda x} x^{\alpha-1}}{\Gamma(\alpha)} & \text{se } x > 0 \end{cases}, \text{ com } \alpha > 0 \text{ e } \lambda > 0$$

diz-se ter distribuição gama de parâmetros  $\alpha$  e  $\lambda$ . Simbolicamente,  $X \sim G(\alpha, \lambda)$ .

$\rightarrow$  Nota : Quando  $\alpha = 1$  cai-se no caso particular da [distribuição exponencial](#).



- **Principais Características da Distribuição Exponencial :**

- Função Geradora dos Momentos :  $M(s) = \left(1 - \frac{s}{\lambda}\right)^{-n} = \left(\frac{\lambda}{\lambda-s}\right)^n$ , ( $s < \lambda$ )
- Momentos em Relação à Origem :  $E(X^k) = \frac{\alpha(\alpha+1)\dots(\alpha+k-1)}{\lambda^k}$
- Valor Esperado :  $E(X) = \mu = \frac{\alpha}{\lambda}$
- Variância :  $Var(X) = \sigma^2 = \frac{\alpha}{\lambda^2}$
- Coeficiente de Variação :  $CV = \frac{1}{\sqrt{\alpha}}$
- Coeficiente de Assimetria :  $\gamma_1 = \frac{2}{\sqrt{\alpha}}$
- Coeficiente de Kurtosis :  $\gamma_2 = 3 + \frac{6}{\alpha}$
- Se  $\alpha \leq 1$ , não tem Moda ; Se  $\alpha > 1$ , Moda :  $moda(X) = \mu_* = \frac{\alpha-1}{\lambda}$
- Se  $\alpha > 1$ , verifica-se sempre  $\mu_* < \mu_c < \mu$

- **Teorema :** Sejam  $X_1$  e  $X_2$  duas variáveis aleatórias independentes. Então

$$X_1 \sim G(\alpha_1; \lambda), X_2 \sim G(\alpha_2; \lambda) \Rightarrow X = X_1 + X_2 \sim G(\alpha; \lambda), \alpha = \alpha_1 + \alpha_2$$

Generalizando para  $k$  variáveis aleatórias independentes, tem-se

$$X_i \sim G(\alpha_i; \lambda), i = 1, 2, \dots, k \Rightarrow X = \sum_{i=1}^k X_i \sim G(\alpha; \lambda), \alpha = \sum_{i=1}^k \alpha_i$$

→ Quando, em particular,  $\alpha_i = 1$  ( $i = 1, 2, \dots, k$ ), tem-se

$$X_i \sim Ex(\lambda), i = 1, 2, \dots, k \Rightarrow X = \sum_{i=1}^k X_i \sim G(k; \lambda)$$

ou seja, a soma de  $k$  variáveis aleatórias independentes com distribuição exponencial, com o mesmo  $\lambda$ , tem distribuição gama com parâmetros  $k$  e  $\lambda$ .

- **Tempo de Espera pelo  $n$ -ésimo acontecimento (Poisson) :**  $f(x|n, \lambda) = \frac{\lambda^n e^{-\lambda x} x^{n-1}}{(n-1)!}$

- **Distribuição do Qui-Quadrado :** Diz-se que a variável aleatória  $X$  tem distribuição do qui-quadrado com  $n$  graus de liberdade ( $n$  inteiro positivo), simbolicamente  $X \sim \chi^2(n)$ , quando a respectiva função densidade é dada por

$$f(x|n) = \begin{cases} 0 & \text{se } x \leq 0 \\ \frac{e^{-\frac{x}{2}} x^{\frac{n}{2}-1}}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} & \text{se } x > 0 \end{cases}, \text{ para } n = 1, 2, \dots$$

Nota : A distribuição do qui-quadrado é uma **distribuição gama** com  $\alpha = \frac{n}{2}$  e  $\lambda = \frac{1}{2}$ ,

$$X \sim \chi^2(n) \Leftrightarrow X \sim G\left(\frac{n}{2}; \frac{1}{2}\right)$$

- **Métodos de Cálculo :**

$$\rightarrow X \sim \chi^2(n) \Rightarrow \sqrt{2X} - \sqrt{2n-1} \sim N(0,1)$$

$$\rightarrow X \sim G(n; \lambda) \Leftrightarrow 2\lambda X \sim \chi^2(2n)$$

- **Principais Características da Distribuição do Qui-Quadrado :**

- Valor Esperado :  $E(X) = n$
- Variância :  $Var(X) = 2n$
- Coeficiente de Variação :  $CV = \sqrt{\frac{2}{n}}$
- Coeficiente de Assimetria :  $\gamma_1 = \sqrt{\frac{8}{n}}$
- Coeficiente de Kurtosis :  $\gamma_2 = 3 + \frac{12}{n}$
- Função Geradora dos Momentos :  $M(s) = (1 - 2s)^{-\frac{n}{2}}$  com  $s < \frac{1}{2}$

- **Teorema :** Sejam  $X_1$  e  $X_2$  duas variáveis aleatórias independentes. Então

$$X_1 \sim \chi^2(n_1), X_2 \sim \chi^2(n_2) \Rightarrow X = X_1 + X_2 \sim \chi^2(n), n = n_1 + n_2$$

Generalizando para  $k$  variáveis aleatórias independentes, tem-se

$$X_i \sim \chi^2(n_i), i = 1, 2, \dots, k \Rightarrow X = \sum_{i=1}^k X_i \sim \chi^2(n), \alpha = \sum_{i=1}^k n_i$$

- **Teorema** : Seja  $X$  uma variável aleatória. Então

$$X \sim N(0,1) \Rightarrow Y = X^2 \sim \chi^2(1)$$

ou

$$X_i \sim N(\mu_i, \sigma_i^2) \Rightarrow \sum_{i=1}^n \left( \frac{X_i - \mu_i}{\sigma_i} \right)^2 \sim \chi^2(n)$$

### 5.10 Distribuição Beta

- **Função Beta** : Função real de duas variáveis reais, fazendo corresponder a cada par de números reais positivos  $(\alpha, \beta)$ , um número real definido por

$$B(\alpha, \beta) = \int_0^1 u^{\alpha-1} (1-u)^{\beta-1} du \quad \text{com } \alpha > 0 \text{ e } \beta > 0$$

- **Propriedades da Função Beta**

a)  $B(\alpha, \beta) = B(\beta, \alpha)$

b)  $B(1,1) = 1$

c) As funções gama e beta estão relacionadas do seguinte modo :  $B(\alpha, \beta) = \frac{\Gamma(\alpha)\Gamma(\beta)}{\Gamma(\alpha+\beta)}$

d)  $B\left(\frac{1}{2}, \frac{1}{2}\right) = \pi$

- **Distribuição Beta** : A variável aleatória  $X$  com função densidade dada por

$$f_X(x|\alpha, \beta) = \begin{cases} \frac{1}{B(\alpha, \beta)} x^{\alpha-1} (1-x)^{\beta-1} & \text{se } 0 < x < 1 \\ 0 & \text{para outros } x \end{cases}, \quad \text{para } \alpha > 0 \text{ e } \beta > 0,$$

diz-se que tem distribuição beta. Simbolicamente  $X \sim Be(\alpha, \beta)$ .

- **Principais Características da Distribuição Beta** :

➤ Momentos em Relação à Origem :  $E(X^k) = \frac{\alpha(\alpha+1)\dots(\alpha+k-1)}{(\alpha+\beta)(\alpha+\beta+1)\dots(\alpha+\beta+k-1)}$

➤ Valor Esperado :  $E(X) = \frac{\alpha}{\alpha+\beta}$

➤ Variância :  $Var(X) = \frac{\alpha\beta}{(\alpha+\beta)^2(\alpha+\beta+1)}$

➤ Coeficiente de Variação :  $CV = \sqrt{\frac{\beta}{\alpha(\alpha+\beta+1)}}$

➤ Coeficiente de Assimetria :  $\gamma_1 = \frac{2(\beta-\alpha)\sqrt{\alpha+\beta+1}}{(\alpha+\beta+2)\sqrt{\alpha\beta}}$

➤ Coeficiente de Kurtosis :  $\gamma_2 = \frac{3(\alpha+\beta+1)[2(\alpha+\beta)^2 + \alpha\beta(\alpha+\beta-6)]}{\alpha\beta(\alpha+\beta+2)(\alpha+\beta+3)}$

- **Forma/Simetria** :

→  $\alpha = \beta$  → distribuição simétrica

→  $\alpha < \beta$  → distribuição assimétrica positiva → cauda longa à direita

→  $\alpha > \beta$  → distribuição assimétrica negativa → cauda longa à esquerda

→  $\alpha > 0$  e  $\beta > 0$  → distribuição unimodal →  $moda(X) = \mu_c = \frac{\alpha-1}{\alpha+\beta-2}$

→  $\alpha = 1$  e  $\beta = 1$  → distribuição uniforme

→ outros valores de  $\alpha$  e  $\beta$  → não tem moda

### 5.11 Teorema do Limite Central

- **Interpretação do Teorema do Limite Central** : O Teorema do Limite Central garante que a soma de  $n$  variáveis aleatórias independentes, todas com a mesma média e a mesma variância, tem, depois de estandardizada e para valores de  $n$  suficientemente grandes, distribuição aproximada,  $N(0,1)$ .

- **Teorema da Continuidade** : Considere-se a sucessão de variáveis aleatórias,

$$X_1, X_1 + X_2, \dots, X_1 + X_2 + \dots + X_n, \dots, \text{ ou } \sum_{i=1}^n X_i \quad \text{com } n = 1, 2, \dots$$

Sejam  $\{F_n\}$  e  $\{M_n\}$ , com  $n = 1, 2, \dots$ , as respectivas sucessões de funções de distribuição e de funções geradoras dos momentos [supõe-se que existem para  $|s| < s_0$  ( $s_0 > 0$ )]. Então, se  $M_n(s) \rightarrow M(s)$  ( $s > 0$ ) e  $M_n(0) \rightarrow 1$ , a sucessão  $\{F_n\}$  tende para a função de distribuição  $F$  que tem  $M$  como função geradora dos momentos.

- **Teorema do Limite Central** : Dada a sucessão de variáveis aleatórias independentes e identicamente distribuídas (*iid*),  $X_1, X_2, \dots, X_n, \dots$ , com média  $\mu$  e variância  $\sigma^2$ , então, quando  $n \rightarrow +\infty$ , a função de distribuição da variável aleatória,

$$Z_n = \frac{\sum_{i=1}^n (X_i) - n\mu}{\sqrt{n}\sigma}$$

tende para uma função de distribuição  $N(0,1)$ , ou seja, a distribuição assintótica ou aproximada de  $Z_n$  é  $N(0,1)$ . Simbolicamente,  $Z_n \sim N(0,1)$ .

➤ Outras formulações :

$$\rightarrow \lim_{n \rightarrow \infty} P(Z_n \leq x) = \lim_{n \rightarrow \infty} P\left(\frac{\sum_{i=1}^n (X_i) - n\mu}{\sqrt{n}\sigma} \leq x\right) = \Phi(x)$$

$$\rightarrow P(Z_n \leq x) = P\left(\frac{\sum_{i=1}^n (X_i) - n\mu}{\sqrt{n}\sigma} \leq x\right) \approx \Phi(x) \quad (n \text{ grande})$$

- **Corolário** : Dada uma sucessão de variáveis aleatórias *iid*,  $X_1, X_2, \dots, X_n, \dots$ , com distribuição de Bernoulli de média  $E(X_i) = \theta$  e  $Var(X_i) = \theta(1 - \theta)$ , vem

$$\frac{\sum_{i=1}^n (X_i) - n\theta}{\sqrt{n\theta(1-\theta)}} \sim N(0,1)$$

$$\rightarrow P(a \leq X \leq b) = \Phi\left(\frac{b-n\theta}{\sqrt{n\theta(1-\theta)}}\right) - \Phi\left(\frac{a-n\theta}{\sqrt{n\theta(1-\theta)}}\right)$$

- **Correcção de Continuidade** : para  $n > 20$ ,

$$P(a \leq X \leq b) \approx \Phi\left(\frac{b+\frac{1}{2}-n\theta}{\sqrt{n\theta(1-\theta)}}\right) - \Phi\left(\frac{a-\frac{1}{2}-n\theta}{\sqrt{n\theta(1-\theta)}}\right)$$

Caso particular ( $c = a = b$ ) :

$$P(X = c) = P\left(c - \frac{1}{2} \leq X \leq c + \frac{1}{2}\right) = \Phi\left(\frac{c+\frac{1}{2}-n\theta}{\sqrt{n\theta(1-\theta)}}\right) - \Phi\left(\frac{c-\frac{1}{2}-n\theta}{\sqrt{n\theta(1-\theta)}}\right)$$

- **Regras práticas orientadoras do cálculo de probabilidades que envolvem a distribuição binomial** :

→ Sempre que possível, deve utilizar-se directamente a distribuição binomial, o que permite o cálculo exacto das probabilidades recorrendo a meios computacionais.

→ Quando necessário (sempre para  $n > 20$ ), o cálculo aproximado das probabilidades deve atender aos seguintes casos:

- Se  $\theta \leq 0,1$ , deve utilizar-se a aproximação da binomial pela Poisson;
- Se  $\theta \geq 0,9$ , deve usar-se a Poisson considerando o acontecimento complementar
- Se  $0,1 < \theta < 0,9$ , deve recorrer-se à fórmula da correcção da continuidade

➤ Nota importante : À medida que  $\theta$  se afasta de 0,5, são necessárias amostras com dimensão cada vez maior, uma vez que a distribuição binomial se torna mais assimétrica.

- **Corolário** : Se  $X$  é uma variável com distribuição de Poisson,  $X \sim Po(\lambda)$ , então

$$\lim_{n \rightarrow \infty} P\left(\frac{X-\lambda}{\sqrt{\lambda}} \leq x\right) = \Phi(x)$$

➤ Outra formulação : ...  $\frac{X-\lambda}{\sqrt{\lambda}} \sim N(0,1)$  quando  $\lambda \rightarrow +\infty$

- **Correcção de Continuidade** : para  $\lambda > 20$ ,

$$P(a \leq X \leq b) \approx \Phi\left(\frac{b+\frac{1}{2}-\lambda}{\sqrt{\lambda}}\right) - \Phi\left(\frac{a-\frac{1}{2}-\lambda}{\sqrt{\lambda}}\right)$$

## 5.12 Valor Esperado e Momentos de Variáveis Aleatórias Contínuas

- **Valor Esperado de Função de Variável Aleatória Bidimensional** : Se  $(X, Y)$  for uma variável aleatória bidimensional contínua, com função densidade  $f_{X,Y}$ , e se  $\psi$  é uma função de  $(X, Y)$ , a expressão

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

define o valor esperado de  $\psi(x, y)$ , desde que se verifique a já referida condição de existência do valor esperado.

- **Teorema** : ...  $E(X + Y) = E(X) + E(Y)$
- **Teorema** : ...  $E(XY) = E(X)E(Y)$
- **Momentos de Ordem  $r + s$  em Relação à Origem** : Seja  $(X, Y)$  uma variável aleatória bidimensional contínua. O valor esperado,

$$\mu'_{rs} = E(X^r Y^s) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x^r y^s f_{X,Y}(x, y) dx dy$$

define um momento de ordem  $r + s$  em relação à origem de  $(X, Y)$ .

→ Momentos de primeira ordem :

- $r = 1, s = 0 \Rightarrow \mu'_{10} = E(X) = \mu_X$
- $r = 0, s = 1 \Rightarrow \mu'_{01} = E(Y) = \mu_Y$

→ Momentos de segunda ordem :

- $r = 2, s = 0 \Rightarrow \mu'_{20} = E(X^2)$
- $r = 1, s = 1 \Rightarrow \mu'_{11} = E(XY)$
- $r = 0, s = 2 \Rightarrow \mu'_{02} = E(Y^2)$

- **Momentos de Ordem  $r + s$  em Relação à Média** : Seja  $(X, Y)$  uma variável aleatória bidimensional contínua. O valor esperado,

$$\mu_{rs} = E[(X - \mu)^r (Y - \mu)^s] = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (x - \mu_X)^r (y - \mu_Y)^s f_{X,Y}(x, y) dx dy$$

define um momento de ordem  $r + s$  em relação à média de  $(X, Y)$ .

→ Momentos de primeira ordem (são nulos) :

- $r = 1, s = 0 \Rightarrow \mu_{10} = 0$
- $r = 0, s = 1 \Rightarrow \mu_{01} = 0$

→ Momentos de segunda ordem :

- $r = 2, s = 0 \Rightarrow \mu_{20} = E[(X - \mu)^2] = Var(X) = \sigma_X^2$
- $r = 1, s = 1 \Rightarrow \mu_{11} = E[(X - \mu)(Y - \mu)]$
- $r = 0, s = 2 \Rightarrow \mu_{02} = E[(Y - \mu)^2] = Var(Y) = \sigma_Y^2$

- **Covariância** : A covariância das variáveis aleatórias  $X$  e  $Y$  é

$$Cov(X, Y) = \sigma_{X,Y} = E[(X - \mu_X)(Y - \mu_Y)],$$

se este valor esperado existir.

→  $Cov(X, Y) = E(XY) - E(X)E(Y)$

→  $Cov(c, X) = E(cX) - cE(X) = 0$

- **Coefficiente de Correlação** : O coeficiente de correlação entre as variáveis aleatórias  $X$  e  $Y$  é dado por

$$\rho_{X,Y} = \frac{Cov(X,Y)}{\sqrt{Var(X)Var(Y)}} = \frac{\sigma_{X,Y}}{\sigma_X \sigma_Y}$$

- **Teorema** : Se duas variáveis aleatórias,  $X$  e  $Y$ , são independentes, então a respectiva covariância é igual a zero.

→ A independência implica não correlação, mas a recíproca não é verdadeira.

- **Teorema** : Se existem segundos momentos para as variáveis aleatórias  $X$  e  $Y$ , então

$$Var(X \pm Y) = Var(X) \pm Cov(X, Y) + Var(Y)$$

Em particular, se as variáveis são independentes,

$$Var(X \pm Y) = Var(X) + Var(Y)$$

- **Valor Esperado Condicionado** : Seja a variável aleatória  $Z = \psi(X, Y)$ , função das variáveis aleatórias contínuas  $X$  e  $Y$ . O valor esperado de  $Z = \psi(X, Y)$  condicionado por  $X = x$ , é definido por

$$E(Z|X = x) = E[\psi(X, Y)|X = x] = \int_{-\infty}^{+\infty} \psi(x, y) f_{Y|X=x}(y) dy$$

se se verificar a condição habitual de existência do valor esperado.

De modo análogo se define

$$E(Z|Y = y) = E[\psi(X, Y)|Y = y] = \int_{-\infty}^{+\infty} \psi(x, y) f_{X|Y=y}(x) dx$$

→ Se  $\psi(x, y) = Y$ ,  $E(Y|X = x) = \int_{-\infty}^{+\infty} y f_{Y|X=x}(y) dy$

→ Se  $\psi(x, y) = X$ ,  $E(X|Y = y) = \int_{-\infty}^{+\infty} x f_{X|Y=y}(x) dx$

- **Teorema** : O valor esperado de  $Z = \psi(X, Y)$ , se existir, é igual ao valor esperado do seu valor esperado condicionado por  $X$ ,

$$E(Z) = E[E(Z|X)]$$

→ Se  $Z = Y$ ,  $E(Y) = E[E(Y|X)]$  → regra do valor esperado iterado (→ v.e. marginal)

- **Variância Condicionada** : A variância de  $Y$  condicionada por  $X = x$  é definida por

$$\begin{aligned} \text{Var}(Y|X = x) &= E\{[Y - E(Y|X = x)]^2|X = x\} \\ &= \int_{-\infty}^{+\infty} \{y - E(Y|X = x)\}^2 f_{Y|X=x}(y) dy \end{aligned}$$

Do mesmo modo se define a variância de  $X$  condicionada por  $Y = y$ ,

$$\begin{aligned} \text{Var}(X|Y = y) &= E\{[X - E(X|Y = y)]^2|Y = y\} \\ &= \int_{-\infty}^{+\infty} \{x - E(X|Y = y)\}^2 f_{X|Y=y}(x) dx \end{aligned}$$

→  $\text{Var}(Y|X = x) = E(Y^2|X = x) - E(Y|X = x)^2$

→  $\text{Var}(X|Y = y) = E(X^2|Y = y) - E(X|Y = y)^2$

- Os resultados da secção 4.11 ainda são válidos para variáveis aleatórias  $k$ -dimensionais contínuas (matrizes das covariâncias e das correlações, etc).

### 5.13 Distribuição Normal Bidimensional

- **Distribuição Normal Bidimensional** : Se a variável aleatória bidimensional  $(X, Y)$  tem função densidade é da forma

$$\begin{aligned} f_{X,Y}(x, y|\mu_X, \mu_Y, \sigma_X^2, \sigma_Y^2, \rho_{X,Y}) &= \frac{1}{2\pi\sigma_X\sigma_Y\sqrt{1-\rho_{X,Y}^2}} \\ &\times \exp\left\{-\frac{1}{2(1-\rho_{X,Y}^2)}\left(\frac{x-\mu_X}{\sigma_X}\right)^2 - 2\rho_{X,Y}\left(\frac{x-\mu_X}{\sigma_X}\right)\left(\frac{y-\mu_Y}{\sigma_Y}\right) + \left(\frac{y-\mu_Y}{\sigma_Y}\right)^2\right\} \end{aligned}$$

com  $(x, y) \in \mathbb{R}^2$ ,  $\mu_X \in \mathbb{R}$ ,  $\mu_Y \in \mathbb{R}$ ,  $\sigma_X^2 > 0$ ,  $\sigma_Y^2 > 0$  e  $-1 \leq \rho_{X,Y} \leq 1$ , diz-se que tem distribuição normal bidimensional.

- **Principais Características da Distribuição Normal Bidimensional** :

- $\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f_{X,Y}(x, y) dx dy = 1$
- Valor Esperado (marginal) :  $E(X) = \mu_X$  ;  $E(Y) = \mu_Y$
- Variância (marginal) :  $\text{Var}(X) = \sigma_X^2$  ;  $\text{Var}(Y) = \sigma_Y^2$
- Coeficiente de Correlação :  $\rho_{X,Y}$
- Covariância :  $\text{Cov}(X, Y) = \rho_{X,Y}\sigma_X\sigma_Y$

- **Distribuição Normal Bidimensional Estandarizada** : Se  $\mu_X = \mu_Y = 0$  e  $\sigma_X^2 = \sigma_Y^2 = 1$ ,

$$f_{X,Y}(x, y) = \frac{1}{2\pi\sqrt{1-\rho^2}} \exp\left\{-\frac{1}{2(1-\rho^2)}(x^2 - 2\rho xy + y^2)\right\}$$

- **Função Densidade Marginal** :

$$f_X(x) = \frac{1}{\sqrt{2\pi\sigma_X^2}} \exp\left\{-\frac{1}{2\sigma_X^2}(x - \mu_X)^2\right\} ; f_Y(y) = \frac{1}{\sqrt{2\pi\sigma_Y^2}} \exp\left\{-\frac{1}{2\sigma_Y^2}(y - \mu_Y)^2\right\}$$

- **Teorema** : Se  $(X, Y)$  é uma variável aleatória normal bidimensional, então  $X$  e  $Y$  são independentes se e so se  $X$  e  $Y$  forem não correlacionados ( $\rho = 0$ ).

- **Função Densidade de  $X$  condicionada por  $Y = y$  :**

$$f_{X|Y=y}(x, y) = \frac{f_{X,Y}(x, y)}{f_Y(y)} = \frac{1}{\sqrt{2\pi\sigma_X^2(1-\rho^2)}} \times \exp\left\{-\frac{1}{2\sigma_X^2(1-\rho^2)}\left[x - \left(\mu_X + \rho\frac{\sigma_X}{\sigma_Y}(y - \mu_Y)\right)\right]^2\right\}$$

- **Valor Esperado de  $X$  condicionado por  $Y = y$  :**  $E(X|Y = y) = \mu_X + \rho\frac{\sigma_X}{\sigma_Y}(y - \mu_Y)$
- **Variância de  $X$  condicionada por  $Y = y$  :**  $Var(X|Y = y) = \sigma_X^2(1 - \rho^2)$

#### 5.14 Distribuição Normal $k$ -Dimensional

- Os resultados obtidos na secção 5.13 são generalizáveis.

...