

## Amostras Aleatórias e Distribuições Amostrais

### Probabilidade e Estatística: afinal, qual é a diferença?

Até agora o que fizemos foi desenvolver **modelos probabilísticos** que se adequavam a situações reais. Por exemplo, indicamos quando os modelos Binomial, Poisson, Exponencial, Normal, Uniforme, etc ... eram adequados. Todos estes modelos referem-se a distribuições de probabilidade que envolvem **parâmetros**, que **até agora** foram **supostos conhecidos**. Para que as probabilidades associadas a eventos sejam calculadas é necessário conhecer o valor destes parâmetros.

No estudo das probabilidades, o nosso objetivo é calcular a probabilidade de eventos pré-especificados. **De agora em diante** teremos um novo objetivo. A partir de uma **amostra** de uma distribuição de probabilidade especificada pretendemos aprender alguma coisa sobre os parâmetros da distribuição, isto é, estaremos interessados em **estimar os parâmetros** da distribuição de probabilidade.

Esta é a grande diferença entre Probabilidade e Estatística. No estudo de Probabilidade estamos interessados em definir modelos que possam ser aplicados a situações reais. Estes modelos envolvem distribuições de probabilidade totalmente conhecidas, isto é, não apenas a forma da densidade, mas também os seus parâmetros são conhecidos. No estudo da Estatística supõe-se que o modelo probabilístico é conhecido, isto é, sabe-se qual a distribuição de probabilidade que modela a situação real, mas os parâmetros desta distribuição são desconhecidos, e devem ser estimados a partir dos dados.

O nosso objetivo em Estatística é descobrir alguma coisa sobre os parâmetros desconhecidos de uma distribuição de probabilidade. Os mecanismos mais usuais para "inferir" alguma coisa sobre estes parâmetros são:

- 1) *Estimação pontual* - o objetivo é "chutar" os valores do parâmetro desconhecido.
- 2) *Estimação por intervalos* - o objetivo é encontrar um intervalo que contenha o parâmetro de interesse com uma probabilidade especificada.
- 3) *Testes de hipóteses* - o objetivo é criar conjecturas sobre os valores possíveis do parâmetro e verificar se estas conjecturas são muito ou pouco prováveis (isto é, testar as hipóteses).

Todos estes procedimentos são baseados na noção de **amostra aleatória**.

### **Definição (amostra, ou amostra aleatória)**

Uma amostra aleatória é um conjunto de variáveis aleatórias **independentes e identicamente distribuídas** (iid).

**Notação : a.a. = amostra aleatória**

### ***O que se faz na prática?***

Para ganhar informação sobre os parâmetros desconhecidos de uma distribuição de probabilidade usamos um conjunto de variáveis aleatórias independentes e identicamente distribuídas. Isto equivale a repetir a experiência aleatória que está sendo descrita pelo modelo em questão  $n$  vezes, em condições idênticas e de maneira independente. A partir dos valores observados das variáveis  $X_1, X_2, \dots, X_n$  calcularemos funções que nos permitirão aprender sobre os parâmetros desconhecidos do modelo. Estas funções serão chamadas de "estatísticas".

### **Definição (estatística)**

Seja  $X_1, X_2, \dots, X_n$  uma a.a. de uma variável aleatória  $X$ . Sejam  $x_1, x_2, \dots, x_n$  os valores observados de  $X_1, X_2, \dots, X_n$ .

Seja  $Y = h(X_1, X_2, \dots, X_n)$  uma função apenas das variáveis  $X_1, X_2, \dots, X_n$ .  $Y$  é chamado de "**estatística**".

Note que *uma estatística não é função de parâmetros desconhecidos*, ela só envolve as variáveis na amostra aleatória, ou seja, pode ser diretamente computada a partir dos valores observados numa amostra.

Por definição, qualquer estatística  $Y$  é uma variável aleatória, e tem uma distribuição de probabilidade que depende da distribuição de  $X_1, X_2, \dots, X_n$ .

O nosso problema então é encontrar estatísticas que sirvam como bons estimadores pontuais de parâmetros desconhecidos. Também é importante definir critérios que nos permitam dizer que uma estatística é "melhor" que outra para estimar um dado parâmetro.

De uma maneira geral, as estatísticas devem conter "toda" a informação presente numa amostra. Se não fosse assim, não valeria a pena calcular uma estatística, a gente simplesmente usaria uma única observação da amostra. Este acréscimo de informação representado pelo uso de uma estatística (*ao invés de uma única observação*) geralmente se traduz por uma considerável redução na variância. Por exemplo, a variância da média amostral é igual à variância de cada observação dividida pelo tamanho da amostra. Quanto maior o tamanho da amostra, menor é a variância da média amostral, isto é, mais "precisa" é a média amostral.

### **As estatísticas mais famosas**

Sejam  $X_1, X_2, \dots, X_n$  uma amostra aleatória de uma distribuição qualquer. As estatísticas mais comuns, calculadas a partir desta amostra são:

1) Média amostral

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

2) Variância amostral

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

3) Desvio padrão amostral

$$S = \sqrt{S^2} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}$$

4) Mínimo da amostra

$$X_{(1)} = \min(X_1, X_2, \dots, X_n)$$

5) Máximo da amostra

$$X_{(n)} = \max(X_1, X_2, \dots, X_n)$$

6) Amplitude da amostra

$$A = X_{(n)} - X_{(1)}$$

7) k-ésima estatística de ordem

É o k-ésimo elemento da amostra ordenada. Por exemplo,  $X_{(2)}$  é o segundo menor elemento da amostra  $X_1, X_2, \dots, X_n$ .

Um dos nossos objetivos aqui é desenvolver as distribuições de estatísticas obtidas a partir de uma amostra aleatória da distribuição Normal.

O próximo teorema refere-se à média amostral de uma amostra aleatória da densidade Normal.

### **Teorema**

Sejam  $X_1, X_2, \dots, X_n$  uma amostra aleatória da distribuição  $N(\mu, \sigma^2)$ . Seja  $\bar{X}$  a média amostral. Então:

$$\bar{X} \approx N\left(\mu, \frac{\sigma^2}{n}\right)$$

A demonstração do teorema é trivial, e segue das propriedades da função geradora de momentos.

Este teorema pode ser generalizado para uma amostra aleatória de uma distribuição qualquer.

### **Teorema**

Sejam  $X_1, X_2, \dots, X_n$  uma amostra aleatória de uma distribuição qualquer tal que  $E(X_i) = \mu$  e  $\text{VAR}(X_i) = \sigma^2$ . Seja  $\bar{X}$  a média amostral. Então:

1)  $E(\bar{X}) = \mu$

2)  $\text{VAR}(\bar{X}) = \sigma^2 / n$

3) Se  $n$  é grande, pelo teorema central do limite podemos concluir que:

$$\frac{\sqrt{n}(\bar{X} - \mu)}{\sigma}$$

é aproximadamente  $N(0,1)$ .

Note que, neste caso, nada é dito a respeito da distribuição de  $X$ . Apenas a sua média e variância são conhecidas, e são funções da média e variância de cada  $X_i$ .

A princípio a distribuição de  $\bar{X}$  poderia ser uma coisa estranha, que não tem nada a ver com a distribuição original de cada  $X_i$ . No entanto, se o tamanho da amostra é grande podemos concluir que a distribuição de  $\bar{X}$ , devidamente escalonada, é aproximadamente  $N(0,1)$ .

O próximo teorema refere-se à distribuição do máximo e do mínimo de uma amostra.

### Teorema

Sejam  $X_1, X_2, \dots, X_n$  uma amostra aleatória de uma distribuição **contínua** qualquer com densidade  $f(\cdot)$  e função de distribuição  $F(\cdot)$ . Sejam  $X_{(1)}$  e  $X_{(n)}$  respectivamente, o mínimo e o máximo da amostra. Então as densidades de  $X_{(1)}$  e  $X_{(n)}$  são dadas por:

1) Densidade do mínimo

$$g_1(x) = n \cdot f(x) \cdot (1 - F(x))^{n-1}$$

2) Densidade do máximo

$$g_n(x) = n \cdot f(x) \cdot (F(x))^{n-1}$$

### Demonstração

Só faremos a demonstração do segundo item (máximo da amostra). A demonstração do outro item é semelhante.

Note que se  $X_{(n)}$  é o máximo da amostra, então  $X_{(n)} < k$  equivale a : todo  $X_i < k$ , para qualquer número  $k$ . Logo, a função de distribuição do máximo pode ser facilmente encontrada, e é dada por:

$$G_n(k) = \Pr(X_{(n)} \leq k) = \Pr(X_1 \leq k, X_2 \leq k, \dots, X_n \leq k)$$

Também, os  $X_i$  's são independentes, e esta última probabilidade pode ser escrita como o produto das probabilidades para cada  $X_i$  . Então:

$$G_n(k) = \Pr(X_1 \leq k, X_2 \leq k, \dots, X_n \leq k) = \Pr(X_1 \leq k) \cdot \Pr(X_2 \leq k) \dots \Pr(X_n \leq k)$$

Como os  $X_i$  são identicamente distribuídos, estas probabilidades são as mesmas para todo  $X_i$  e correspondem à função de distribuição  $F(\cdot)$  com argumento  $k$ .

$$G_n(k) = (\Pr(X_1 \leq k))^n = (F(k))^n$$

A densidade de  $X_{(n)}$  é encontrada derivando-se a função de distribuição com relação ao argumento  $k$ , e lembrando que a derivada de  $F(\cdot)$  é  $f(\cdot)$ , a densidade de cada  $X_i$ . Então :

$$g_n(k) = \frac{dG_n(k)}{dk} = n \cdot (F(k))^{n-1} \cdot \frac{dF(k)}{dk} = n \cdot f(k) \cdot (F(k))^{n-1}$$

### Exemplo

Sejam  $X_1, X_2, \dots, X_n$  uma amostra aleatória da densidade Exponencial com parâmetro  $\lambda$ . Encontre a densidade de  $X_{(1)}$ , o mínimo da amostra.

### Solução

A densidade de cada  $X_i$  é:

$$f(x) = \lambda \cdot e^{-\lambda x}$$

A função de distribuição é:

$$F(x) = \Pr(X \leq x) = \int_0^x \lambda \cdot e^{-\lambda t} dt = 1 - e^{-\lambda x}$$

A densidade do mínimo é, pelo teorema anterior:

$$\begin{aligned} g_1(y) &= n \cdot (1 - F(y))^{n-1} \cdot f(y) = n \cdot (1 - 1 + e^{-\lambda y})^{n-1} \cdot (\lambda \cdot e^{-\lambda y}) = \\ &= n \cdot \lambda \cdot (e^{-\lambda y})^{n-1+1} = n \cdot \lambda \cdot e^{-n \cdot \lambda \cdot y} \end{aligned}$$

Ou seja,  $X_{(1)}$  tem densidade Exponencial com parâmetro  $n \cdot \lambda$ .

### Exemplo

A duração de um componente eletrônico é uma variável aleatória  $T$  com distribuição Exponencial com parâmetro  $\lambda = 0.001$ .

Testou-se 100 componentes e observou-se a duração de cada um deles, gerando uma amostra aleatória  $T_1, T_2, \dots, T_{100}$ .

Calcule as seguintes probabilidades:

a)  $\Pr(950 < T < 1100)$

b)  $\Pr ( W > 7200 )$  onde  $W = \text{máx}( T_1, T_2 , \dots, T_{100} )$

c)  $\Pr ( V < 10 )$  onde  $V = \text{mín}( T_1, T_2 , \dots, T_{100} )$

### Solução

a) Note que, se  $T_i \sim \text{Expo}( 0.001 )$  para  $i = 1 , 2, \dots, 100$  então :

$$E(T_i) = 1/ 0.001 = 1000 \text{ e}$$

$$\text{VAR}(T_i) = 1/(0.001)^2 = 10^6$$

Assim:

$$E(T) = E(T_i) = 1000 \text{ e } \text{VAR}(T) = \text{VAR}(T_i)/100 = 10^4$$

Pelo teorema central do limite:

$$Z = \frac{\bar{T} - 1000}{\sqrt{10^4}} = \frac{\bar{T} - 1000}{100}$$

tem aproximadamente a distribuição  $N(0,1)$  .

Assim:

$$\Pr(950 \leq \bar{T} \leq 1100) = \Pr\left(\frac{950 - 1000}{100} \leq \frac{\bar{T} - 1000}{100} \leq \frac{1100 - 1000}{100}\right) =$$

$$= \Pr(-0.5 \leq Z \leq 1) = \Phi(1) - \Phi(-0.5) = 0.532$$

Onde estas últimas probabilidades foram obtidas da tabela  $N(0,1)$ .

$$\begin{aligned} \text{b) } \Pr ( W > 7200 ) &= \Pr\{ \text{máx}( T_1, T_2 , \dots, T_{100} ) > 7200 \} = \\ &= 1 - \Pr\{ \text{máx}( T_1, T_2 , \dots, T_{100} ) \leq 7200 \} \end{aligned}$$

Mas, se  $W = \text{máx}( T_1, T_2 , \dots, T_{100} ) \leq 7200$  então todos os  $T_i$  são  $\leq 7200$ .

$$\Pr( W \leq 7200 ) = \Pr( T_1 \leq 7200, T_2 \leq 7200, \dots, T_{100} \leq 7200 ) =$$

$$= (\Pr(T_1 \leq 7200))^{100} = (1 - e^{-0.001(7200)})^{100} = (1 - e^{-7.2})^{100} = (0.99925)^{100} = 0.928$$

c)  $\Pr ( V < 10 )$  onde  $V = \text{mín}( T_1, T_2 , \dots, T_{100} )$

$$\Pr ( V < 10 ) = 1 - \Pr( V \geq 10 ) = 1 - \Pr(\text{mín}( T_1, T_2 , \dots, T_{100} ) \geq 10)$$

Mas, se  $\text{mín}( T_1, T_2 , \dots, T_{100} ) \geq 10$  então todos os  $T_i$  também são  $\geq 10$ .

$$\text{Logo, } \Pr( V < 10 ) = 1 - \Pr(T_1 \geq 10, T_2 \geq 10, \dots, T_{100} \geq 10) =$$

$$= 1 - [\Pr(T_1 \geq 10)]^{100} = 1 - [e^{-0.001(10)}]^{100} = 1 - [e^{-0.01}]^{100} = 1 - e^{-1} = 0.632$$

## A distribuição Qui-Quadrado

### Definição (densidade Qui-Quadrado com k graus de liberdade)

Seja X uma variável aleatória contínua e positiva com densidade dada por:

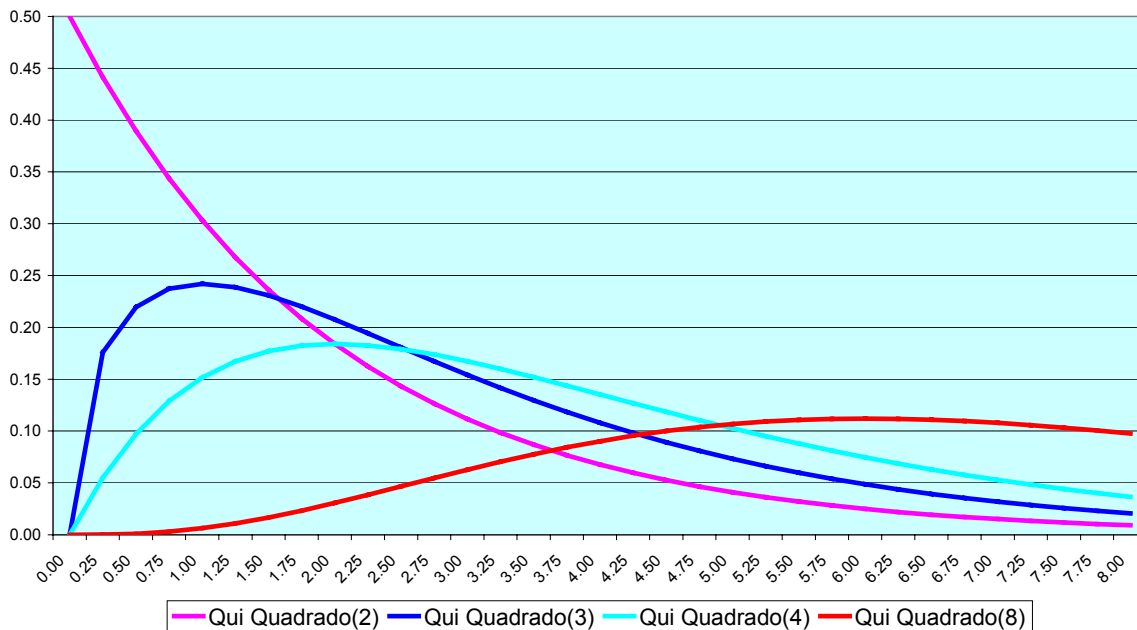
$$f(x) = \frac{1}{2^{k/2} \Gamma\left(\frac{k}{2}\right)} x^{\frac{k}{2}-1} e^{-x/2} \text{ onde } x > 0$$

Então X tem densidade Qui-Quadrado com k graus de liberdade, e escrevemos :  $X \sim \chi^2_k$

**A densidade Qui-Quadrado com k graus de liberdade é apenas um caso particular da densidade Gama. Na verdade:**

$$\chi_k^2 = \text{Gama}(\alpha = k/2, \beta = 1/2)$$

Densidades Qui-Quadrado com 2, 3, 4 e 8 Graus de Liberdade



### Teorema

Se X tem densidade Qui-Quadrado com k graus de liberdade então sua média, variância e função geradora de momentos são dadas por:

$$E(X) = k$$

$$\text{VAR}(X) = 2.k$$

$$M(t) = \frac{1}{(1-2t)^{r/2}}$$

### Demonstração

Segue direto dos resultados correspondentes para a densidade Gama.

A densidade Qui-Quadrado é tabelada. As tabelas desta densidade fornecem os pontos tais que a probabilidade da variável estar acima deles é especificada. Uma pequena porção de uma tabela da densidade Qui-Quadrado é mostrada a seguir.

graus de liberdade ↓	0.990	0.950	0.050	0.01
2	0.020	0.100	5.99	9.21
6	0.870	1.640	12.59	16.81
12	3.570	5.23	21.03	26.22

Por exemplo:

Supondo que  $X$  seja uma variável aleatória com densidade Qui-Quadrado com 6 graus de liberdade, a probabilidade de  $X$  exceder 0.87 é 99%. Analogamente, a probabilidade de  $X$  exceder 12.59 é 5% e a probabilidade de  $X$  estar acima de 16.81 é apenas 1%.

Uma propriedade muito importante da densidade Qui-Quadrado é a preservação da mesma família de densidades quando somamos variáveis independentes. Ou seja, se  $X_1, X_2, \dots, X_n$  são variáveis **independentes**, cada uma com distribuição Qui-Quadrado, a soma de  $X_1, X_2, \dots, X_n$  também é uma variável aleatória Qui-Quadrado.

### Teorema (aditividade da densidade Qui-Quadrado)

Sejam  $X_1, X_2, \dots, X_n$  variáveis aleatórias independentes, e suponha que  $X_i$  tem densidade Qui-Quadrado com  $k_i$  graus de liberdade. Seja  $Y = X_1 + X_2 + \dots + X_n$ . Então  $Y$  tem também uma densidade Qui-Quadrado, mas com  $k = k_1 + k_2 + \dots + k_n$  graus de liberdade.

O próximo teorema exhibe a relação existente entre as densidades Normal padrão e Qui-Quadrado.

### Teorema

Seja  $Z \sim N(0, 1)$ . Então  $V = Z^2$  tem densidade Qui-Quadrado com 1 grau de liberdade.

### Demonstração

A demonstração é feita usando-se o método da função de distribuição, já que a função  $V = Z^2$  não é injetora, o que nos impede de usar o método do jacobiano :

$$G(v) = \Pr( V \leq v) = \Pr( Z^2 \leq v) = \Pr( -\sqrt{v} \leq Z \leq +\sqrt{v} ) = \Phi(+\sqrt{v}) - \Phi(-\sqrt{v})$$

onde  $\Phi(\cdot)$  indica a função de distribuição de uma variável aleatória  $N(0,1)$ .

Derivando esta expressão em relação a  $v$  resulta na densidade de  $V$ , que é :

$$\begin{aligned} g(v) &= \left( \frac{1}{\sqrt{2\pi}} \cdot \exp\left(-\frac{(\sqrt{v})^2}{2}\right) \right) \cdot \left(\frac{1}{2} \cdot v^{-1/2}\right) - \left( \frac{1}{\sqrt{2\pi}} \cdot \exp\left(-\frac{(-\sqrt{v})^2}{2}\right) \right) \cdot \left(\frac{-1}{2} \cdot v^{-1/2}\right) = \\ &= \left(\frac{1}{2} \cdot v^{-1/2}\right) \cdot \left(\frac{2}{\sqrt{2\pi}} \exp\left(-\frac{v}{2}\right)\right) = \frac{1}{\sqrt{2\pi}} v^{-1/2} \cdot e^{-v/2} \end{aligned}$$

Isto é :

$$g(v) = \frac{1}{2^{1/2} \sqrt{\pi}} v^{\frac{1}{2}-1} \cdot e^{-v/2} = \frac{1}{2^{1/2} \Gamma\left(\frac{1}{2}\right)} v^{\frac{1}{2}-1} \cdot e^{-v/2}$$

Substituindo  $k = 1$  na definição da densidade Qui-Quadrado resulta na expressão acima, o que prova o teorema.

A combinação dos 2 últimos teoremas leva a um resultado importante.

### Teorema

Sejam  $Z_1, Z_2, \dots, Z_n$  variáveis aleatórias independentes e identicamente distribuídas com densidade  $N(0,1)$ . Então:

$$V = \sum_{i=1}^n Z_i^2 = Z_1^2 + Z_2^2 + \dots + Z_n^2$$

tem densidade Qui-Quadrado com  $n$  graus de liberdade.

Este resultado segue trivialmente dos dois últimos teoremas, se lembrarmos que cada  $Z_i^2$  tem densidade Qui-Quadrado com 1 grau de liberdade ( e são todos independentes).

**Por que a densidade Qui-Quadrado é importante?  
Esta densidade está relacionada com a distribuição da variância amostral obtida a partir de uma amostra aleatória Normal, como indicado no próximo teorema.**

### Teorema

Sejam  $X_1, X_2, \dots, X_n$  uma amostra aleatória da distribuição  $N(\mu, \sigma^2)$ . Seja  $S^2$  a variância amostral, dada por:

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

Então:

$$\frac{(n-1)S^2}{\sigma^2} = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\sigma^2}$$

tem distribuição Qui-Quadrado com  $(n-1)$  graus de liberdade.

A partir deste teorema podemos deduzir facilmente a média e variância de  $S^2$ .

### Teorema

Sejam  $X_1, X_2, \dots, X_n$  uma amostra aleatória da distribuição  $N(\mu, \sigma^2)$ . Seja  $S^2$  a variância amostral. Então :

$$E(S^2) = \sigma^2$$

$$VAR(S^2) = \frac{2\sigma^4}{n-1}$$

### Demonstração

Pelo teorema anterior e sabendo a média e variância de uma variável aleatória Qui-Quadrado temos:

$$E\left(\frac{(n-1)S^2}{\sigma^2}\right) = n-1 \Rightarrow E(S^2) = \frac{(n-1)\sigma^2}{(n-1)} = \sigma^2$$

$$VAR\left(\frac{(n-1)S^2}{\sigma^2}\right) = 2 \cdot (n-1) \Rightarrow VAR(S^2) = \frac{2 \cdot (n-1) \cdot (\sigma^2)^2}{(n-1)^2} = \frac{2 \cdot \sigma^4}{n-1}$$