

# Teorema do Limite Central

Bacharelado em Economia - FEA - Noturno

1º Semestre 2016

Prof. Fábio P. Machado e Gilberto A. Paula

# Sumário

- 1 Objetivos da Aula
- 2 Distribuição Binomial
- 3 Distribuição de Poisson
- 4 Distribuição Uniforme
- 5 Distribuição Exponencial
- 6 Teorema do Limite Central
- 7 Tabela Normal
- 8 Exemplos

## Objetivos da Aula

### Soma de Variáveis Aleatórias

O objetivo principal desta aula é estudar empiricamente a distribuição da soma de variáveis aleatórias quantitativas e enunciar o principal teorema da Estatística **Teorema do Limite Central** (Laplace, 1810).

## Notação

### Soma de Variáveis Aleatórias

Vamos supor  $X_1, \dots, X_n$  variáveis aleatórias independentes com mesma distribuição de média  $\mu$  e variância  $\sigma^2$  finitas. Vamos estudar a distribuição da soma

## Notação

### Soma de Variáveis Aleatórias

Vamos supor  $X_1, \dots, X_n$  variáveis aleatórias independentes com mesma distribuição de média  $\mu$  e variância  $\sigma^2$  finitas. Vamos estudar a distribuição da soma

$$X = X_1 + \dots + X_n$$

## Notação

### Soma de Variáveis Aleatórias

Vamos supor  $X_1, \dots, X_n$  variáveis aleatórias independentes com mesma distribuição de média  $\mu$  e variância  $\sigma^2$  finitas. Vamos estudar a distribuição da soma

$$X = X_1 + \dots + X_n$$

à medida que  $n$  cresce. Ou seja, vamos construir histogramas para a distribuição de  $X$  para diferentes valores de  $n$ .

# Sumário

- 1 Objetivos da Aula
- 2 Distribuição Binomial**
- 3 Distribuição de Poisson
- 4 Distribuição Uniforme
- 5 Distribuição Exponencial
- 6 Teorema do Limite Central
- 7 Tabela Normal
- 8 Exemplos

# Distribuição Binomial

## Distribuição Binomial

A distribuição binomial pode ser obtida através de  $n$  ensaios independentes de Bernoulli. Isto é, se  $X_i \sim \text{Be}(p)$  ( $i = 1, \dots, n$ ), então



# Distribuição Binomial

## Distribuição Binomial

A distribuição binomial pode ser obtida através de  $n$  ensaios independentes de Bernoulli. Isto é, se  $X_i \sim \text{Be}(p)$  ( $i = 1, \dots, n$ ), então

$$X = X_1 + \dots + X_n \sim B(n, p).$$

# Distribuição Binomial

## Distribuição Binomial

A distribuição binomial pode ser obtida através de  $n$  ensaios independentes de Bernoulli. Isto é, se  $X_i \sim \text{Be}(p)$  ( $i = 1, \dots, n$ ), então





$$X = X_1 + \dots + X_n \sim \text{B}(n, p).$$





Temos ainda que  $E(X) = np$  e  $\text{Var}(X) = np(1 - p)$ .





# Histogramas Distribuição Binomial





## Descrição

A seguir serão construídos histogramas para a distribuição de  $X \sim B(n, p)$  variando-se o número de ensaios  $n$  e também a probabilidade de sucesso  $p$ .

Histogramas  $B(n, p)$  para  $n = 10$ 

Histogramas  $B(n, p)$  para  $n = 30$ 

Histogramas  $B(n, p)$  para  $n = 50$ 

Histogramas  $B(n, p)$  para  $n = 100$ 

## Conclusões

### Conclusões

Nota-se pelos gráficos que à medida que  $n$  cresce a distribuição de  $X \sim B(n, p)$  se aproxima da distribuição de  $Y \sim N(\mu_X, \sigma_X^2)$  em que  $\mu_X = np$  e  $\sigma_X^2 = np(1 - p)$ .



# Sumário

- 1 Objetivos da Aula
- 2 Distribuição Binomial
- 3 Distribuição de Poisson**
- 4 Distribuição Uniforme
- 5 Distribuição Exponencial
- 6 Teorema do Limite Central
- 7 Tabela Normal
- 8 Exemplos

# Distribuição de Poisson

## Definição

Se  $X$  segue distribuição de Poisson de parâmetro  $\lambda$ . Isto é, se  $X \sim P(\lambda)$ , então a função de probabilidade de  $X$  fica dada por

# Distribuição de Poisson

## Definição

Se  $X$  segue distribuição de Poisson de parâmetro  $\lambda$ . Isto é, se  $X \sim P(\lambda)$ , então a função de probabilidade de  $X$  fica dada por

$$P(X = x) = \frac{e^{-\lambda} \lambda^x}{x!},$$

# Distribuição de Poisson

## Definição

Se  $X$  segue distribuição de Poisson de parâmetro  $\lambda$ . Isto é, se  $X \sim P(\lambda)$ , então a função de probabilidade de  $X$  fica dada por

$$P(X = x) = \frac{e^{-\lambda} \lambda^x}{x!},$$

em que  $x = 0, 1, \dots$ . Temos ainda que  $E(X) = \lambda$  e  $\text{Var}(X) = \lambda$ .

# Histogramas Distribuição de Poisson

## Descrição

A seguir serão construídos histogramas para a distribuição de

# Histogramas Distribuição de Poisson

## Descrição

A seguir serão construídos histogramas para a distribuição de

$$X = X_1 + \cdots + X_n \sim P(n\lambda),$$





# Histogramas Distribuição de Poisson

## Descrição





A seguir serão construídos histogramas para a distribuição de

$$X = X_1 + \cdots + X_n \sim P(n\lambda),$$

variando-se  $m = n\lambda$ , em que  $X_i \sim P(\lambda)$  independentes ( $i = 1, \dots, n$ ).

Histogramas  $P(m)$ 



Histogramas  $P(m)$ 

## Conclusões

### Conclusões

Nota-se pelos gráficos que à medida que  $m$  cresce a distribuição de  $X \sim P(m)$  se aproxima da distribuição de  $Y \sim N(\mu_X, \sigma_X^2)$  em que  $\mu_X = m$  e  $\sigma_X^2 = m$ .

# Sumário

- 1 Objetivos da Aula
- 2 Distribuição Binomial
- 3 Distribuição de Poisson
- 4 Distribuição Uniforme**
- 5 Distribuição Exponencial
- 6 Teorema do Limite Central
- 7 Tabela Normal
- 8 Exemplos

# Distribuição Uniforme

## Definição

Vamos supor que  $X$  é uma variável aleatória com distribuição uniforme no intervalo  $[a, b]$  ( $X \sim U[a, b]$ ), então

# Distribuição Uniforme

## Definição

Vamos supor que  $X$  é uma variável aleatória com distribuição uniforme no intervalo  $[a,b]$  ( $X \sim U[a, b]$ ), então

$$f(x) = \frac{1}{(b-a)}, \quad a \leq x \leq b,$$

## Distribuição Uniforme

### Definição

Vamos supor que  $X$  é uma variável aleatória com distribuição uniforme no intervalo  $[a,b]$  ( $X \sim U[a, b]$ ), então

$$f(x) = \frac{1}{(b-a)}, \quad a \leq x \leq b,$$

e  $f(x) = 0$  em caso contrário.

## Distribuição Uniforme

### Definição

Vamos supor que  $X$  é uma variável aleatória com distribuição uniforme no intervalo  $[a,b]$  ( $X \sim U[a, b]$ ), então

$$f(x) = \frac{1}{(b-a)}, \quad a \leq x \leq b,$$

e  $f(x) = 0$  em caso contrário.

### Esperança e Variância

Temos que

# Distribuição Uniforme

## Definição

Vamos supor que  $X$  é uma variável aleatória com distribuição uniforme no intervalo  $[a, b]$  ( $X \sim U[a, b]$ ), então

$$f(x) = \frac{1}{(b-a)}, \quad a \leq x \leq b,$$

e  $f(x) = 0$  em caso contrário.

## Esperança e Variância

Temos que

- $E(X) = \frac{a+b}{2}$



# Distribuição Uniforme

## Definição

Vamos supor que  $X$  é uma variável aleatória com distribuição uniforme no intervalo  $[a, b]$  ( $X \sim U[a, b]$ ), então


$$f(x) = \frac{1}{(b-a)}, \quad a \leq x \leq b,$$

e  $f(x) = 0$  em caso contrário.

## Esperança e Variância

Temos que

- $E(X) = \frac{a+b}{2}$
- $\text{Var}(X) = \frac{(b-a)^2}{12}$





Distribuição Uniforme  $U[1, 5]$ 

# Histogramas Distribuição Uniforme

## Descrição

Vamos supor que  $X_i \sim U[1, 5]$  independentes ( $i = 1, \dots, n$ ). A seguir serão construídos histogramas para a distribuição de  $X = X_1 + \dots + X_n$  variando-se o tamanho amostral  $n$ .

# Histogramas Soma de Uniformes



## Conclusões

### Conclusões

Nota-se pelos gráficos que à medida que  $n$  cresce a distribuição de

## Conclusões

### Conclusões

Nota-se pelos gráficos que à medida que  $n$  cresce a distribuição de

$$X = X_1 + \cdots + X_n,$$

## Conclusões

### Conclusões

Nota-se pelos gráficos que à medida que  $n$  cresce a distribuição de

$$X = X_1 + \cdots + X_n,$$

se aproxima da distribuição de  $Y \sim N(\mu_X, \sigma_X^2)$  em que

## Conclusões

### Conclusões

Nota-se pelos gráficos que à medida que  $n$  cresce a distribuição de

$$X = X_1 + \cdots + X_n,$$

se aproxima da distribuição de  $Y \sim N(\mu_X, \sigma_X^2)$  em que

- $\mu_X = \frac{n(1+5)}{2} = 3n$



## Conclusões

### Conclusões

Nota-se pelos gráficos que à medida que  $n$  cresce a distribuição de

$$X = X_1 + \cdots + X_n,$$

se aproxima da distribuição de  $Y \sim N(\mu_X, \sigma_X^2)$  em que

- $\mu_X = \frac{n(1+5)}{2} = 3n$
- $\sigma_X^2 = \frac{n(5-1)^2}{12} = \frac{4n}{3}$

# Sumário

- 1 Objetivos da Aula
- 2 Distribuição Binomial
- 3 Distribuição de Poisson
- 4 Distribuição Uniforme
- 5 Distribuição Exponencial**
- 6 Teorema do Limite Central
- 7 Tabela Normal
- 8 Exemplos

# Distribuição Exponencial

## Definição

Se  $X$  é uma variável aleatória com distribuição exponencial de parâmetro  $\lambda > 0$ , a função densidade de probabilidade de  $X$  é definida por

# Distribuição Exponencial

## Definição

Se  $X$  é uma variável aleatória com distribuição exponencial de parâmetro  $\lambda > 0$ , a função densidade de probabilidade de  $X$  é definida por

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

# Distribuição Exponencial

## Definição

Se  $X$  é uma variável aleatória com distribuição exponencial de parâmetro  $\lambda > 0$ , a função densidade de probabilidade de  $X$  é definida por

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

em que  $x > 0$ . Notação  $X \sim \text{Exp}(\lambda)$ .

# Distribuição Exponencial

## Definição

Se  $X$  é uma variável aleatória com distribuição exponencial de parâmetro  $\lambda > 0$ , a função densidade de probabilidade de  $X$  é definida por

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

em que  $x > 0$ . Notação  $X \sim \text{Exp}(\lambda)$ .

## Esperança e Variância

Temos que

# Distribuição Exponencial

## Definição

Se  $X$  é uma variável aleatória com distribuição exponencial de parâmetro  $\lambda > 0$ , a função densidade de probabilidade de  $X$  é definida por

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

em que  $x > 0$ . Notação  $X \sim \text{Exp}(\lambda)$ .

## Esperança e Variância

Temos que

- $E(X) = \frac{1}{\lambda}$

# Distribuição Exponencial

## Definição

Se  $X$  é uma variável aleatória com distribuição exponencial de parâmetro  $\lambda > 0$ , a função densidade de probabilidade de  $X$  é definida por

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

em que  $x > 0$ . Notação  $X \sim \text{Exp}(\lambda)$ .

## Esperança e Variância

Temos que


- $E(X) = \frac{1}{\lambda}$
- $\text{Var}(X) = \frac{1}{\lambda^2}$








# Histogramas Distribuição Exponencial





## Definição

Vamos supor que  $X_i \sim \text{Exp}(\lambda)$  independentes ( $i = 1, \dots, n$ ). A seguir serão construídos histogramas para a distribuição de  $X = X_1 + \dots + X_n$  variando-se  $\lambda$  e o tamanho amostral  $n$ .

Distribuição Exponencial  $\lambda = 1$ 

Histogramas Soma de Exponenciais com  $\lambda = 1$ 

Distribuição Exponencial  $\lambda = 3$ 

Histogramas Soma de Exponenciais com  $\lambda = 3$ 

## Conclusões

### Conclusões

Nota-se pelos gráficos que à medida que  $n$  cresce a distribuição de

## Conclusões

### Conclusões

Nota-se pelos gráficos que à medida que  $n$  cresce a distribuição de

$$X = X_1 + \cdots + X_n,$$

## Conclusões

### Conclusões

Nota-se pelos gráficos que à medida que  $n$  cresce a distribuição de

$$X = X_1 + \cdots + X_n,$$

se aproxima da distribuição de  $Y \sim N(\mu_X, \sigma_X^2)$  em que



## Conclusões

### Conclusões

Nota-se pelos gráficos que à medida que  $n$  cresce a distribuição de

$$X = X_1 + \cdots + X_n,$$

se aproxima da distribuição de  $Y \sim N(\mu_X, \sigma_X^2)$  em que

- $\mu_X = n \frac{1}{\lambda} = \frac{n}{\lambda}$

## Conclusões

### Conclusões

Nota-se pelos gráficos que à medida que  $n$  cresce a distribuição de

$$X = X_1 + \cdots + X_n,$$

se aproxima da distribuição de  $Y \sim N(\mu_X, \sigma_X^2)$  em que

- $\mu_X = n \frac{1}{\lambda} = \frac{n}{\lambda}$
- $\sigma_X^2 = n \frac{1}{\lambda^2} = \frac{n}{\lambda^2}$

# Sumário

- 1 Objetivos da Aula
- 2 Distribuição Binomial
- 3 Distribuição de Poisson
- 4 Distribuição Uniforme
- 5 Distribuição Exponencial
- 6 Teorema do Limite Central**
- 7 Tabela Normal
- 8 Exemplos

## Teorema do Limite Central

### Enunciado para a Soma Amostral

Para variáveis aleatórias  $X_1, \dots, X_n$  independentes e com mesma distribuição de média  $\mu$  e variância  $\sigma^2$  finitas, a distribuição da soma

# Teorema do Limite Central

## Enunciado para a Soma Amostral

Para variáveis aleatórias  $X_1, \dots, X_n$  independentes e com mesma distribuição de média  $\mu$  e variância  $\sigma^2$  finitas, a distribuição da soma

$$X = X_1 + \dots + X_n$$

## Teorema do Limite Central

### Enunciado para a Soma Amostral

Para variáveis aleatórias  $X_1, \dots, X_n$  independentes e com mesma distribuição de média  $\mu$  e variância  $\sigma^2$  finitas, a distribuição da soma

$$X = X_1 + \dots + X_n$$

se aproxima à medida que  $n$  cresce da distribuição de  $Y \sim N(\mu_X, \sigma_X^2)$ , em que  $\mu_X = n\mu$  e  $\sigma_X^2 = n\sigma^2$ .

# Teorema do Limite Central

Aproximação para  $n$  Grande

$$\begin{aligned} P(a \leq X \leq b) &\cong P(a \leq Y \leq b) \\ &= P\left(\frac{a - n\mu}{\sigma\sqrt{n}} \leq Z \leq \frac{b - n\mu}{\sigma\sqrt{n}}\right), \end{aligned}$$

# Teorema do Limite Central

Aproximação para  $n$  Grande

$$\begin{aligned} P(a \leq X \leq b) &\cong P(a \leq Y \leq b) \\ &= P\left(\frac{a - n\mu}{\sigma\sqrt{n}} \leq Z \leq \frac{b - n\mu}{\sigma\sqrt{n}}\right), \end{aligned}$$

em que  $Z \sim N(0, 1)$ .



## Teorema do Limite Central

Aproximação para  $n$  Grande

$$\begin{aligned} P(a \leq X \leq b) &\cong P(a \leq Y \leq b) \\ &= P\left(\frac{a - n\mu}{\sigma\sqrt{n}} \leq Z \leq \frac{b - n\mu}{\sigma\sqrt{n}}\right), \end{aligned}$$

em que  $Z \sim N(0, 1)$ .

Observação: correção de continuidade pode ser aplicada apenas para variáveis aleatórias discretas, tais como binomial e Poisson.

# Teorema do Limite Central

## Média Amostral

Para a média amostral

# Teorema do Limite Central

## Média Amostral

Para a média amostral  $\bar{X} = \frac{X_1 + \dots + X_n}{n}$  temos que

# Teorema do Limite Central

## Média Amostral

Para a média amostral  $\bar{X} = \frac{X_1 + \dots + X_n}{n}$  temos que

$$\begin{aligned} E(\bar{X}) &= \frac{E(X_1) + \dots + E(X_n)}{n} \\ &= \frac{n\mu}{n} = \mu \text{ e} \\ \text{Var}(\bar{X}) &= \frac{\text{Var}(X_1) + \dots + \text{Var}(X_n)}{n^2} \\ &= \frac{n\sigma^2}{n^2} = \frac{\sigma^2}{n}. \end{aligned}$$

## Teorema do Limite Central

### Enunciado para a Média Amostral

Para variáveis aleatórias  $X_1, \dots, X_n$  independentes e com mesma distribuição de média  $\mu$  e variância  $\sigma^2$  finitas, a distribuição da média amostral

## Teorema do Limite Central

### Enunciado para a Média Amostral

Para variáveis aleatórias  $X_1, \dots, X_n$  independentes e com mesma distribuição de média  $\mu$  e variância  $\sigma^2$  finitas, a distribuição da média amostral

$$\bar{X} = \frac{X_1 + \dots + X_n}{n}$$

## Teorema do Limite Central

### Enunciado para a Média Amostral

Para variáveis aleatórias  $X_1, \dots, X_n$  independentes e com mesma distribuição de média  $\mu$  e variância  $\sigma^2$  finitas, a distribuição da média amostral

$$\bar{X} = \frac{X_1 + \dots + X_n}{n}$$

se aproxima à medida que  $n$  cresce da distribuição de  $Y \sim N(\mu_{\bar{X}}, \sigma_{\bar{X}}^2)$ , em que  $\mu_{\bar{X}} = \mu$  e  $\sigma_{\bar{X}}^2 = \frac{\sigma^2}{n}$ .

# Teorema do Limite Central

Aproximação para  $n$  Grande

$$\begin{aligned} P(a \leq \bar{X} \leq b) &\cong P(a \leq Y \leq b) \\ &= P\left(\frac{a - \mu}{\sigma/\sqrt{n}} \leq Z \leq \frac{b - \mu}{\sigma/\sqrt{n}}\right), \end{aligned}$$



# Teorema do Limite Central

Aproximação para  $n$  Grande

$$\begin{aligned} P(a \leq \bar{X} \leq b) &\cong P(a \leq Y \leq b) \\ &= P\left(\frac{a - \mu}{\sigma/\sqrt{n}} \leq Z \leq \frac{b - \mu}{\sigma/\sqrt{n}}\right), \end{aligned}$$


em que  $Z \sim N(0, 1)$ .

# Sumário

- 1 Objetivos da Aula
- 2 Distribuição Binomial
- 3 Distribuição de Poisson
- 4 Distribuição Uniforme
- 5 Distribuição Exponencial
- 6 Teorema do Limite Central
- 7 Tabela Normal**
- 8 Exemplos

# Cálculo de Probabilidades

Descrição de  $A(z) = P(Z \leq z)$ ,  $z \geq 0$



Distribuição Normal Padrão: Valores de  $A(z) = P(Z \leq z)$ 

z	Segunda Decimal de z									
	0	1	2	3	4	5	6	7	8	9
0.0	0.5000	0.5040	0.5080	0.5120	0.5160	0.5199	0.5239	0.5279	0.5319	0.5359
0.1	0.5398	0.5438	0.5478	0.5517	0.5557	0.5596	0.5636	0.5675	0.5714	0.5753
0.2	0.5793	0.5832	0.5871	0.5910	0.5948	0.5987	0.6026	0.6064	0.6103	0.6141
0.3	0.6179	0.6217	0.6255	0.6293	0.6331	0.6368	0.6406	0.6443	0.6480	0.6517
0.4	0.6554	0.6591	0.6628	0.6664	0.6700	0.6736	0.6772	0.6808	0.6844	0.6879
0.5	0.6915	0.6950	0.6985	0.7019	0.7054	0.7088	0.7123	0.7157	0.7190	0.7224
0.6	0.7257	0.7291	0.7324	0.7357	0.7389	0.7422	0.7454	0.7486	0.7517	0.7549
0.7	0.7580	0.7611	0.7642	0.7673	0.7704	0.7734	0.7764	0.7794	0.7823	0.7852
0.8	0.7881	0.7910	0.7939	0.7967	0.7995	0.8023	0.8051	0.8078	0.8106	0.8133
0.9	0.8159	0.8186	0.8212	0.8238	0.8264	0.8289	0.8315	0.8340	0.8365	0.8389
1.0	0.8413	0.8438	0.8461	0.8485	0.8508	0.8531	0.8554	0.8577	0.8599	0.8621
1.1	0.8643	0.8665	0.8686	0.8708	0.8729	0.8749	0.8770	0.8790	0.8810	0.8830
1.2	0.8849	0.8869	0.8888	0.8907	0.8925	0.8944	0.8962	0.8980	0.8997	0.9015
1.3	0.9032	0.9049	0.9066	0.9082	0.9099	0.9115	0.9131	0.9147	0.9162	0.9177
1.4	0.9192	0.9207	0.9222	0.9236	0.9251	0.9265	0.9279	0.9292	0.9306	0.9319
1.5	0.9332	0.9345	0.9357	0.9370	0.9382	0.9394	0.9406	0.9418	0.9429	0.9441
1.6	0.9452	0.9463	0.9474	0.9484	0.9495	0.9505	0.9515	0.9525	0.9535	0.9545
1.7	0.9554	0.9564	0.9573	0.9582	0.9591	0.9599	0.9608	0.9616	0.9625	0.9633
1.8	0.9641	0.9649	0.9656	0.9664	0.9671	0.9678	0.9686	0.9693	0.9699	0.9706
1.9	0.9713	0.9719	0.9726	0.9732	0.9738	0.9744	0.9750	0.9756	0.9761	0.9767
2.0	0.9772	0.9778	0.9783	0.9788	0.9793	0.9798	0.9803	0.9808	0.9812	0.9817

Distribuição Normal Padrão: Valores de  $A(z) = P(Z \leq z)$ 

z	Segunda Decimal de z									
	0	1	2	3	4	5	6	7	8	9
2.1	0.9821	0.9826	0.9830	0.9834	0.9838	0.9842	0.9846	0.9850	0.9854	0.9857
2.2	0.9861	0.9864	0.9868	0.9871	0.9875	0.9878	0.9881	0.9884	0.9887	0.9890
2.3	0.9893	0.9896	0.9898	0.9901	0.9904	0.9906	0.9909	0.9911	0.9913	0.9916
2.4	0.9918	0.9920	0.9922	0.9925	0.9927	0.9929	0.9931	0.9932	0.9934	0.9936
2.5	0.9938	0.9940	0.9941	0.9943	0.9945	0.9946	0.9948	0.9949	0.9951	0.9952
2.6	0.9953	0.9955	0.9956	0.9957	0.9959	0.9960	0.9961	0.9962	0.9963	0.9964
2.7	0.9965	0.9966	0.9967	0.9968	0.9969	0.9970	0.9971	0.9972	0.9973	0.9974
2.8	0.9974	0.9975	0.9976	0.9977	0.9977	0.9978	0.9979	0.9979	0.9980	0.9981
2.9	0.9981	0.9982	0.9982	0.9983	0.9984	0.9984	0.9985	0.9985	0.9986	0.9986
3.0	0.9987	0.9987	0.9987	0.9988	0.9988	0.9989	0.9989	0.9989	0.9990	0.9990
3.1	0.9990	0.9991	0.9991	0.9991	0.9992	0.9992	0.9992	0.9992	0.9993	0.9993
3.2	0.9993	0.9993	0.9994	0.9994	0.9994	0.9994	0.9994	0.9995	0.9995	0.9995
3.3	0.9995	0.9995	0.9995	0.9996	0.9996	0.9996	0.9996	0.9996	0.9996	0.9997
3.4	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9998
3.5	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998
3.6	0.9998	0.9998	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999
3.7	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999
3.8	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999
3.9	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000

# Sumário

- 1 Objetivos da Aula
- 2 Distribuição Binomial
- 3 Distribuição de Poisson
- 4 Distribuição Uniforme
- 5 Distribuição Exponencial
- 6 Teorema do Limite Central
- 7 Tabela Normal
- 8 Exemplos**

## Exemplo 1

### Exemplo 1

Uma loja recebe em média 16 clientes por dia com desvio padrão de 4 clientes. Calcule aproximadamente a probabilidade de num período de 30 dias a loja receber mais do que 500 clientes. Calcule também a probabilidade aproximada de nesse mesmo período a média de clientes ultrapassar a 18 clientes.

## Exemplo 1

Dados do Problema

Seja  $U$ : número de clientes que a loja recebe num dia. Temos que



## Exemplo 1

### Dados do Problema

Seja  $U$ : número de clientes que a loja recebe num dia. Temos que

- $E(U) = \mu = 16$

## Exemplo 1

### Dados do Problema

Seja  $U$ : número de clientes que a loja recebe num dia. Temos que

- $E(U) = \mu = 16$
- $\text{Var}(U) = \sigma^2 = 4^2 = 16$

## Exemplo 1

### Dados do Problema

Seja  $U$ : número de clientes que a loja recebe num dia. Temos que

- $E(U) = \mu = 16$
- $\text{Var}(U) = \sigma^2 = 4^2 = 16$

### Soma Amostral

Seja  $X$ : número de clientes que a loja recebe em 30 dias. Temos que

## Exemplo 1

### Dados do Problema

Seja  $U$ : número de clientes que a loja recebe num dia. Temos que

- $E(U) = \mu = 16$
- $\text{Var}(U) = \sigma^2 = 4^2 = 16$

### Soma Amostral

Seja  $X$ : número de clientes que a loja recebe em 30 dias. Temos que

- $\mu_X = n \times \mu = 30 \times 16 = 480$

## Exemplo 1

### Dados do Problema

Seja  $U$ : número de clientes que a loja recebe num dia. Temos que

- $E(U) = \mu = 16$
- $\text{Var}(U) = \sigma^2 = 4^2 = 16$

### Soma Amostral

Seja  $X$ : número de clientes que a loja recebe em 30 dias. Temos que

- $\mu_X = n \times \mu = 30 \times 16 = 480$
- $\sigma_X^2 = n \times \sigma^2 = 30 \times 16 = 480$

## Exemplo 1

### Dados do Problema

Seja  $U$ : número de clientes que a loja recebe num dia. Temos que

- $E(U) = \mu = 16$
- $\text{Var}(U) = \sigma^2 = 4^2 = 16$

### Soma Amostral

Seja  $X$ : número de clientes que a loja recebe em 30 dias. Temos que

- $\mu_X = n \times \mu = 30 \times 16 = 480$
- $\sigma_X^2 = n \times \sigma^2 = 30 \times 16 = 480$
- $\sigma_X = \sqrt{480} \cong 21,91$

## Exemplo 1

### Média Amostral

Seja  $\bar{X}$ : número médio de clientes que a loja recebe em 30 dias.  
Temos que

## Exemplo 1

### Média Amostral

Seja  $\bar{X}$ : número médio de clientes que a loja recebe em 30 dias.  
Temos que

- $\mu_{\bar{X}} = \mu = 16$



## Exemplo 1

### Média Amostral

Seja  $\bar{X}$ : número médio de clientes que a loja recebe em 30 dias.

Temos que

- $\mu_{\bar{X}} = \mu = 16$
- $\sigma_{\bar{X}}^2 = \frac{\sigma^2}{n} = \frac{16}{30} \cong 0,533$

## Exemplo 1

### Média Amostral

Seja  $\bar{X}$ : número médio de clientes que a loja recebe em 30 dias.

Temos que

- $\mu_{\bar{X}} = \mu = 16$
- $\sigma_{\bar{X}}^2 = \frac{\sigma^2}{n} = \frac{16}{30} \cong 0,533$
- $\sigma_{\bar{X}} = \sqrt{0,533} \cong 0,73$

## Exemplo 1

### Cálculo da Probabilidade

A probabilidade da loja receber mais do que 500 clientes em 30 dias fica dada por

## Exemplo 1

### Cálculo da Probabilidade

A probabilidade da loja receber mais do que 500 clientes em 30 dias fica dada por

$$\begin{aligned}P(X \geq 501) &\cong P\left(Z \geq \frac{501 - \mu_X}{\sigma_X}\right) \\&= P\left(Z \geq \frac{501 - 480}{21,91}\right) \\&= P(Z \geq 0,96) \\&= 1 - P(Z \leq 0,96) \\&= 1 - A(0,96) \\&= 1 - 0,8315 \\&= 0,1685(16,85\%).\end{aligned}$$

## Exemplo 1

### Cálculo da Probabilidade

A probabilidade da média de clientes ultrapassar 18 clientes em 30 dias fica dada por

## Exemplo 1

### Cálculo da Probabilidade

A probabilidade da média de clientes ultrapassar 18 clientes em 30 dias fica dada por

$$\begin{aligned}P(\bar{X} > 18) &\cong P\left(Z > \frac{18 - \mu_{\bar{X}}}{\sigma_{\bar{X}}}\right) \\&= P\left(Z > \frac{18 - 16}{0,73}\right) \\&= P(Z > 2,74) \\&= 1 - P(Z \leq 2,74) \\&= 1 - A(2,74) \\&= 1 - 0.9969 \\&= 0,0031(0,31\%).\end{aligned}$$

## Exemplo 2

### Exemplo 2

Sabe-se que numa corrida de revezamento de 42 km com 8 atletas (cada um correndo 5,25 km) o tempo que cada atleta demora para completar o percurso tem distribuição aproximadamente normal de média 30 minutos e desvio padrão de 8 minutos. Se 8 atletas são escolhidos ao acaso para um prova, qual a probabilidade da equipe completar o percurso em menos de 3 horas? E em mais de 4 horas? Qual é tempo que apenas 5% das equipes farão abaixo dele?

## Exemplo 2

Dados do Problema

Seja  $T$ : tempo que um atleta demora para completar o percurso.  
Temos que



## Exemplo 2

### Dados do Problema

Seja  $T$ : tempo que um atleta demora para completar o percurso.

Temos que

- $E(T) = \mu = 30$

## Exemplo 2

### Dados do Problema

Seja  $T$ : tempo que um atleta demora para completar o percurso.

Temos que

- $E(T) = \mu = 30$
- $\text{Var}(T) = \sigma^2 = 8^2 = 64$

## Exemplo 2

### Dados do Problema

Seja  $T$ :tempo que um atleta demora para completar o percurso.  
Temos que

- $E(T) = \mu = 30$
- $\text{Var}(T) = \sigma^2 = 8^2 = 64$

### Soma Amostral

Seja  $X$ :tempo que a equipe (de 8 atletas) demora para completar o percurso. Temos que

## Exemplo 2

### Dados do Problema

Seja  $T$ :tempo que um atleta demora para completar o percurso.  
Temos que

- $E(T) = \mu = 30$
- $\text{Var}(T) = \sigma^2 = 8^2 = 64$

### Soma Amostral

Seja  $X$ :tempo que a equipe (de 8 atletas) demora para completar o percurso. Temos que

- $\mu_X = n \times \mu = 8 \times 30 = 240$

## Exemplo 2

### Dados do Problema

Seja  $T$ :tempo que um atleta demora para completar o percurso.  
Temos que

- $E(T) = \mu = 30$
- $\text{Var}(T) = \sigma^2 = 8^2 = 64$

### Soma Amostral

Seja  $X$ :tempo que a equipe (de 8 atletas) demora para completar o percurso. Temos que

- $\mu_X = n \times \mu = 8 \times 30 = 240$
- $\sigma_X^2 = n \times \sigma^2 = 8 \times 64 = 512$

## Exemplo 2

### Dados do Problema

Seja  $T$ :tempo que um atleta demora para completar o percurso.  
Temos que

- $E(T) = \mu = 30$
- $\text{Var}(T) = \sigma^2 = 8^2 = 64$

### Soma Amostral

Seja  $X$ :tempo que a equipe (de 8 atletas) demora para completar o percurso. Temos que

- $\mu_X = n \times \mu = 8 \times 30 = 240$
- $\sigma_X^2 = n \times \sigma^2 = 8 \times 64 = 512$
- $\sigma_X = \sqrt{512} \cong 22,63$

## Exemplo 2

### Cálculo da Probabilidade

A probabilidade da equipe completar o percurso em menos de 3 horas (180 minutos) fica dada por

## Exemplo 2

### Cálculo da Probabilidade

A probabilidade da equipe completar o percurso em menos de 3 horas (180 minutos) fica dada por

$$\begin{aligned}P(X < 180) &= P\left(Z < \frac{180 - \mu_X}{\sigma_X}\right) \\&= P\left(Z < \frac{180 - 240}{22,63}\right) \\&= P(Z < -2,65) \\&= P(Z > 2,65) \\&= 1 - P(z \leq 2,65) \\&= 1 - 0,996 \\&= 0,004(0,4\%).\end{aligned}$$



## Exemplo 2

### Cálculo da Probabilidade

A probabilidade da equipe completar o percurso em mais de 4 horas (240 minutos) fica dada por

## Exemplo 2

### Cálculo da Probabilidade

A probabilidade da equipe completar o percurso em mais de 4 horas (240 minutos) fica dada por

$$\begin{aligned}P(X > 240) &= P\left(Z > \frac{240 - \mu_X}{\sigma_X}\right) \\&= P\left(Z > \frac{240 - 240}{22,63}\right) \\&= P(Z > 0) \\&= 0,5(50\%).\end{aligned}$$

## Exemplo 2

### Cálculo do Tempo

Seja  $t_0$  o tempo superado por 95% das equipes (apenas 5% das equipes fazem abaixo desse tempo). Temos que

## Exemplo 2

### Cálculo do Tempo

Seja  $t_0$  o tempo superado por 95% das equipes (apenas 5% das equipes fazem abaixo desse tempo). Temos que

$$\begin{aligned}P(X < t_0) &= P\left(Z < \frac{t_0 - \mu_X}{\sigma_X}\right) \\&= P\left(Z < \frac{t_0 - 240}{22,63}\right) \\&= P(Z < a) = 0,05,\end{aligned}$$

## Exemplo 2

### Cálculo do Tempo

Seja  $t_0$  o tempo superado por 95% das equipes (apenas 5% das equipes fazem abaixo desse tempo). Temos que

$$\begin{aligned}P(X < t_0) &= P\left(Z < \frac{t_0 - \mu_X}{\sigma_X}\right) \\&= P\left(Z < \frac{t_0 - 240}{22,63}\right) \\&= P(Z < a) = 0,05,\end{aligned}$$

em que  $a = (t_0 - 240)/22,63$ . Pela tabela normal  $a = -1,64$ . Assim, obtemos  $t_0 = 240 - 1,64 \times 22,63 \cong 203$  minutos.