

Teorema do Limite Central

Bacharelado em Economia - FEA - Noturno

1^o Semestre 2017

Profs. Gilberto A. Paula e Vanderlei C. Bueno

Sumário

- 1 Objetivos da Aula
- 2 Distribuição Binomial
- 3 Distribuição de Poisson
- 4 Distribuição Uniforme
- 5 Distribuição Triangular
- 6 Distribuição Exponencial
- 7 Teorema do Limite Central
- 8 Tabela Normal
- 9 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 μ e variância σ^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 μ e variância σ^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 μ e variância σ^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 Triangular
- 6 Distribuição Exponencial
- 7 Teorema do Limite Central
- 8 Tabela Normal
- 9 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





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





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 Triangular
- 6 Distribuição Exponencial
- 7 Teorema do Limite Central
- 8 Tabela Normal
- 9 Exemplos

Distribuição de Poisson

Definição

Se X segue distribuição de Poisson de parâmetro λ . 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 λ . 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 λ . 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 Triangular
- 6 Distribuição Exponencial
- 7 Teorema do Limite Central
- 8 Tabela Normal
- 9 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

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 Triangular**
- 6 Distribuição Exponencial
- 7 Teorema do Limite Central
- 8 Tabela Normal
- 9 Exemplos

Distribuição Triangular

Definição

Vamos supor que X é uma variável aleatória com distribuição triangular no intervalo $[a,c,b]$, notação $X \sim T[a, c, b]$.

Distribuição Triangular

Definição

Vamos supor que X é uma variável aleatória com distribuição triangular no intervalo $[a,c,b]$, notação $X \sim T[a, c, b]$. Então

Distribuição Triangular

Definição

Vamos supor que X é uma variável aleatória com distribuição triangular no intervalo $[a,c,b]$, notação $X \sim T[a, c, b]$. Então

$$f(x) = \begin{cases} \frac{2(x-a)}{(b-a)(c-a)} & a \leq x \leq c, \\ \frac{2(b-x)}{(b-a)(b-c)} & c < x \leq b, \\ 0 & \text{c.c.} \end{cases}$$

Distribuição Triangular

Definição

Vamos supor que X é uma variável aleatória com distribuição triangular no intervalo $[a,c,b]$, notação $X \sim T[a, c, b]$. Então

$$f(x) = \begin{cases} \frac{2(x-a)}{(b-a)(c-a)} & a \leq x \leq c, \\ \frac{2(b-x)}{(b-a)(b-c)} & c < x \leq b, \\ 0 & \text{c.c.} \end{cases}$$

Esperança e Variância

Distribuição Triangular

Definição

Vamos supor que X é uma variável aleatória com distribuição triangular no intervalo $[a,c,b]$, notação $X \sim T[a, c, b]$. Então

$$f(x) = \begin{cases} \frac{2(x-a)}{(b-a)(c-a)} & a \leq x \leq c, \\ \frac{2(b-x)}{(b-a)(b-c)} & c < x \leq b, \\ 0 & \text{c.c.} \end{cases}$$

Esperança e Variância

Temos que

Distribuição Triangular

Definição

Vamos supor que X é uma variável aleatória com distribuição triangular no intervalo $[a,c,b]$, notação $X \sim T[a, c, b]$. Então

$$f(x) = \begin{cases} \frac{2(x-a)}{(b-a)(c-a)} & a \leq x \leq c, \\ \frac{2(b-x)}{(b-a)(b-c)} & c < x \leq b, \\ 0 & \text{c.c.} \end{cases}$$

Esperança e Variância

Temos que

- $E(X) = \frac{a+b+c}{3}$

Distribuição Triangular

Definição

Vamos supor que X é uma variável aleatória com distribuição triangular no intervalo $[a,c,b]$, notação $X \sim T[a, c, b]$. Então

$$f(x) = \begin{cases} \frac{2(x-a)}{(b-a)(c-a)} & a \leq x \leq c, \\ \frac{2(b-x)}{(b-a)(b-c)} & c < x \leq b, \\ 0 & \text{c.c.} \end{cases}$$

Esperança e Variância

Temos que

- $E(X) = \frac{a+b+c}{3}$
- $\text{Var}(X) = \frac{a^2+b^2+c^2-ab-ac-bc}{18}$


Histogramas Distribuição Triangular





Descrição


Vamos supor que $X_i \sim T[a, b, c]$ 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 .





Distribuição Triangular $T[0, 1, 0.5]$ 

Histogramas Soma de $T[0, 1, 0.5]$ 

Distribuição Triangular $T[0, 1, 0.7]$ 

Histogramas Soma de $T[0, 1, 0.7]$ 

Distribuição Triangular $T[0, 1, 0.2]$ 

Histogramas Soma de $T[0, 1, 0.2]$ 

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

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

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

Sumário

- 1 Objetivos da Aula
- 2 Distribuição Binomial
- 3 Distribuição de Poisson
- 4 Distribuição Uniforme
- 5 Distribuição Triangular
- 6 Distribuição Exponencial**
- 7 Teorema do Limite Central
- 8 Tabela Normal
- 9 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

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 λ 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

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

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

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

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 Triangular
- 6 Distribuição Exponencial
- 7 Teorema do Limite Central**
- 8 Tabela Normal
- 9 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 μ e variância σ^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 μ e variância σ^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 μ e variância σ^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

$$P(a \leq X \leq b) \cong P(a \leq Y \leq b)$$

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

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

Teorema do Limite Central

Média Amostral

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

$$\begin{aligned} E(\bar{X}) &= \frac{E(X_1) + \dots + E(X_n)}{n} \\ &= \frac{n\mu}{n} = \mu \end{aligned}$$

Teorema do Limite Central

Média Amostral

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

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

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 μ e variância σ^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 μ e variância σ^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 μ e variância σ^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

$$P(a \leq \bar{X} \leq b) \cong P(a \leq Y \leq b)$$

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 Triangular
- 6 Distribuição Exponencial
- 7 Teorema do Limite Central
- 8 Tabela Normal**
- 9 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 Triangular
- 6 Distribuição Exponencial
- 7 Teorema do Limite Central
- 8 Tabela Normal
- 9 Exemplos**

Exemplo 1

Exemplo 1

Uma loja recebe em média 16 clientes por dia com desvio padrão de 4 clientes. Calcule aproximadamente a probabilidade

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

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
- de nesse mesmo período de 30 dias a média de clientes ultrapassar 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.

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.

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

$$\begin{aligned}P(X \geq 501) &\cong P\left(Z \geq \frac{501 - \mu_X}{\sigma_X}\right) \\&= P\left(Z \geq \frac{501 - 480}{21,91}\right) \\&= P(Z \geq 0,96)\end{aligned}$$

Exemplo 1

Cálculo da Probabilidade

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

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

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

$$\begin{aligned} P(\bar{X} > 18) &\cong P\left(Z > \frac{18 - \mu_{\bar{X}}}{\sigma_{\bar{X}}}\right) \\ &= P\left(Z > \frac{18 - 16}{0,73}\right) \\ &= P(Z > 2,74) \end{aligned}$$

Exemplo 1

Cálculo da Probabilidade

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

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

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

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.

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 uma prova:

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 uma prova:

- qual a probabilidade da equipe completar o percurso em menos de 3 horas?

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 uma prova:

- qual a probabilidade da equipe completar o percurso em menos de 3 horas?
- E em mais de 4 horas?

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 uma 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.

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.

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

$$\begin{aligned}P(X < 180) &= P\left(Z < \frac{180 - \mu_X}{\sigma_X}\right) \\&= P\left(Z < \frac{180 - 240}{22,63}\right) \\&= P(Z < -2,65)\end{aligned}$$

Exemplo 2

Cálculo da Probabilidade

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

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

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

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

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).

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 $a = -1,64$.

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.