

Amostragem aleatória simples com reposição (parte 1)

Prof. Caio Azevedo

Estrutura geral

- Temos uma população de interesse de tamanho N e desejamos realizar inferências sobre algum parâmetro (média, total, proporção, variância) dessa população, com base em uma amostra de tamanho n .
- Com algumas adaptações, os resultados a serem vistos poderão ser utilizados mesmo se N for infinito.
- População: observações univariadas - y_1, \dots, y_N (variáveis não aleatórias), em que y_i é a observação relativa ao indivíduo i (podemos também considerar observações multivariadas $\mathbf{y}_i = (y_{i1}, \dots, y_{ip})^t$). Exemplos: peso, altura, intenção de voto, conhecimento em alguma área.

Estrutura geral

- Objetivo: estimar $\mu = \frac{1}{N} \sum_{i=1}^N y_i$ (média, ou proporção se os y_i 's forem variáveis binárias), $\tau = \sum_{i=1}^N y_i = N\mu$ (total), variância ($\sigma^2 = \frac{1}{N} \sum_{i=1}^N (y_i - \mu)^2$) (esta, às vezes, tem de ser estimada para se poder fazer inferência para parâmetros de interesse como a média, total, proporção etc), com base na amostra de tamanho n , com reposição.
- Amostragem aleatória simples com reposição ($AAS_c \equiv A_1$).
- Amostra $\{y_{k_1}, y_{k_2}, \dots, y_{k_n}\}$, em que $k_i \in \{1, 2, \dots, N\}$. Por exemplo, Se $N = 5$ e $n = 3$, podemos ter $\{y_2, y_3, y_3\}$.

Mecanismo de sorteio da amostra

- 1 Dado que os elementos da população estão numerados de 1 a N, sorteia-se um elemento, segundo algum procedimento de geração de números aleatórios ([link 1](#), [link 2](#)).
- 2 Repõe-se esse elemento na população.
- 3 Repete-se os procedimentos 1 e 2, $n - 1$ vezes.
- 4 No R:
 - Função “[sample](#)”.
 - Pacote “[sampling](#)”.
 - Pacote “[survey](#)”.

Notações/exemplo (univariado)

- População:

- “Labels” - $\mathcal{U} = \{1, \dots, N\}$.
- Variável (não aleatória) - $\mathbf{y} = (y_1, \dots, y_N)^t$ (valores da característica de interesse para cada elemento na população).

- Amostra

- “Labels” - $\{1, \dots, n\}$.
- Índices dos elementos a serem selecionados: $\mathbf{s} = (K_1, \dots, K_n)$ (variável aleatória) e $\mathbf{s} = (k_1, \dots, k_n)$ (os respectivos valores observados, índices sorteados).
- Variável (aleatória) - $\mathbf{Y} = (Y_1, \dots, Y_n)^t$ (valores da característica de interesse para cada elemento sorteado).
- Exemplo: Suponha $N=3$, $\mathbf{y} = (y_1, y_2, y_3)^t$, $n = 2$ e que $\mathbf{s} = (2, 3)$. Assim, $k_1 = 2$, $k_2 = 3$, $Y_1 = y_2$ e $Y_2 = y_3$.

Estimação da média

- Estimador natural (replicar na amostra a fórmula do parâmetro de interesse) (sob duas formas diferentes):

$$\hat{\mu} = \bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i = \frac{1}{n} \sum_{i \in S} y_i \quad (1)$$

$$\hat{\mu} = \bar{Y} = \frac{1}{n} \sum_{i=1}^N F_i y_i, \quad (2)$$

em que, na Equação (1) $Y_i, i = 1, \dots, n$ e $S = (K_1, \dots, K_n)$ são variáveis (vetores) aleatórios, enquanto que na Equação (2) F_i é uma v.a. que representa o número de vezes que o i -ésimo elemento da população apareceu na amostra.

Estimação da média

- Utilizar a forma (1) e considerar a distribuição das variáveis $\mathbf{Y} = (Y_1, \dots, Y_n)^t$ (esses desenvolvimentos dependem da distribuição considerada para a amostra).
- Neste caso, $Y_i, i = 1, \dots, n$ são variáveis aleatórias. Esta abordagem é vista nos cursos (usuais) de Inferência Estatística e pode, eventualmente, levar a inferências exatas, desde que as suposições sobre a distribuição de \mathbf{Y} sejam válidas.
- Note que, neste caso, como há reposição $Y_i \stackrel{i.i.d}{\sim} D(\theta)$.
- Utilizar a distribuição de \mathbf{S} pode ser bem complicado.

Estimação da média

- Utilizar a forma (2) e considerar a distribuição das variáveis $\mathbf{F} = (F_1, \dots, F_N)^t$ (mais geral, ou seja, em princípio, os resultados se aplicam, independentemente da distribuição de \mathbf{Y}).
- Neste caso, F_i , $i = 1, \dots, N$ são variáveis aleatórias (y_i , $i = 1, 2, \dots, N$ são variáveis não aleatórias). Esta abordagem leva a inferências aproximadas (“ n ” e “ $N - n$ ” suficientemente grandes).
- Uma vantagem é que ela se aplica, em princípio, independentemente da forma da distribuição de \mathbf{Y} .

Estimação da média

- Resultados ([link 1](#), [link 2](#), [link 3](#)) (i.d. - identicamente distribuídas):

- 1 $F_i \stackrel{i.d.}{\sim} \text{binomial}(n, 1/N)$. Ou seja,

$$P(F_i = f_i) = \binom{n}{f_i} p^{f_i} (1-p)^{n-f_i} \mathbb{1}_{\{0,1,2,\dots,n\}}(f_i)$$

- 2 $(F_i, F_j) \stackrel{i.d.}{\sim} \text{trinomial}(n, 1/N, 1/N)$ ($i \neq j$), ou seja, os F_i 's são dependentes e:

$$\begin{aligned} P(F_i = f_i, F_j = f_j) &= \frac{n!}{f_i! f_j! (n - f_i - f_j)!} p_1^{f_i} p_2^{f_j} (1 - p_1 - p_2)^{n - f_i - f_j} \\ &\times \mathbb{1}_{\{0,1,2,\dots,n-f_j\}}(f_i) \mathbb{1}_{\{0,1,2,\dots,n\}}(f_j) \end{aligned}$$

- Exercício: obtenha a distribuição de $(F_{k_1}, F_{k_2}, \dots, F_{k_r})^t$, em que $\{k_1, k_2, \dots, k_r\}$ é um subconjunto de $\{1, 2, \dots, n\}$.
- Exercício: obtenha a distribuição de $(F_1, F_2, \dots, F_N)^t$.

Estimação da média

- Prova (1): para um número n de repetições, repetimos um procedimento cuja probabilidade de sucesso (selecionar o elemento i) é constante ($1/N$) e contabilizamos o número de sucessos.
- Prova (2): para um número n de repetições, repetimos um procedimento cujas probabilidades de interesse (selecionar os elementos i e j , $i \neq j$) são constantes ($1/N, 1/N$) e contabilizamos o número de ocorrências de cada categoria.

Propriedades dos F_i

1 $\mathcal{E}_{A_1}(F_i) = \frac{n}{N}$, $\mathcal{V}_{A_1}(F_i) = n \frac{1}{N} \left(\frac{N-1}{N} \right) = n \frac{N-1}{N^2}$.

2 $Cov_{A_1}(F_i, F_j) = -n \frac{1}{N} \frac{1}{N} = -\frac{n}{N^2}$.

3 $\pi_i = 1 - \left(1 - \frac{1}{N}\right)^n$ (probabilidade do i-ésimo elemento aparecer na amostra). Prova

$$\pi_i = 1 - P(F_i = 0) = 1 - \left(1 - \frac{1}{N}\right)^n.$$

4 $\pi_{ij} = \left(1 - \frac{2}{N}\right)^n$ (probabilidade do i-ésimo e j-ésimo elementos aparecerem na amostra). Exercício: provar esta propriedade.

As provas dos resultados 1, 2 e 3 decorrem das respectivas distribuições de F_i e $(F_i, F_j)^t$.

Estimação da média : Propriedades do estimador sob AAS_c

- Valor esperado

$$\begin{aligned}\mathcal{E}_{A_1}(\hat{\mu}) &= \frac{1}{n} \mathcal{E}_{A_1} \left(\sum_{i=1}^N F_i y_i \right) = \frac{1}{n} \sum_{i=1}^N \mathcal{E}_{A_1}(F_i) y_i = \frac{1}{n} \sum_{i=1}^N \frac{ny_i}{N} \\ &= \sum_{i=1}^N \frac{y_i}{N} = \mu\end{aligned}$$

- Portanto $\hat{\mu}$ é uma estimador não viciado (env)

Estimação da média : Propriedades do estimador sob AAS_c

■ Variância do estimador

$$\begin{aligned}\mathcal{V}_{A_1}(\hat{\mu}) &= \frac{1}{n^2} \mathcal{V} \left(\sum_{i=1}^N F_i y_i \right) \\ &= \frac{1}{n^2} \left(\sum_{i=1}^N y_i^2 \mathcal{V}_{A_1}(F_i) + \sum_{\substack{i \neq j, \\ i,j=1,2,\dots,N}} \text{Cov}_{A_1}(F_i y_i, F_j y_j) \right) \\ &= \frac{1}{n^2} \left(\sum_{i=1}^N y_i^2 \left(\frac{n(N-1)}{N^2} \right) - \sum_{\substack{i \neq j, \\ i,j=1,2,\dots,N}} y_i y_j \frac{n}{N^2} \right) \\ &= \frac{1}{N^2 n} (N-1) \left(\sum_{i=1}^N y_i^2 - \frac{1}{N-1} \sum_{\substack{i \neq j, \\ i,j=1,2,\dots,N}} y_i y_j \right)\end{aligned}$$

Estimação da média : Propriedades do estimador sob AAS_c

■ Cont.

Lembrando que (Exercício) $\sum_{i \neq j} y_i y_j = -\sum_{i=1}^N y_i^2 + N^2 \mu^2$ e

$\sum_{i=1}^N (y_i - \mu)^2 = \sum_{i=1}^N y_i^2 - N\mu^2$, vem que

$$\begin{aligned}\mathcal{V}_{A_1}(\hat{\mu}) &= \frac{1}{N^2 n} (N-1) \left(\sum_{i=1}^N y_i^2 - \frac{1}{N-1} \left(N^2 \mu^2 - \sum_{i=1}^N y_i^2 \right) \right) \\ &= \frac{N-1}{(N-1)N^2 n} \left(N \sum_{i=1}^N y_i^2 - \sum_{i=1}^n y_i^2 - N^2 \mu^2 + \sum_{i=1}^N y_i^2 \right) \\ &= \frac{1}{N^2 n} \left(N \sum_{i=1}^N y_i^2 - N^2 \mu^2 \right) = \frac{1}{n} \left(\frac{1}{N} \sum_{i=1}^N y_i^2 - \mu^2 \right) = \frac{\sigma^2}{n}\end{aligned}$$

Estimação da média : Propriedades do estimador sob AAS_c

- Resumidamente, $\mathcal{E}_{A_1}(\hat{\mu}) = \mu$ e $\mathcal{V}_{A_1}(\hat{\mu}) = \frac{\sigma^2}{n}$. Podemos provar, sob AAS_c , que $\hat{\mu}$ é **consistente**.
- A distribuição exata de $\hat{\mu}$ (sob A_1) é bastante complicada de ser obtida (média de uma combinação linear de um vetor aleatório com distribuição multinomial).
- Distribuição assintótica: note que em $\{F_i\}_{i \geq 1}$ os F_i 's são identicamente distribuídos mas não independentes. O TCL padrão não se aplica.
- Estimativa: $\tilde{\mu} = \frac{1}{n} \sum_{i \in s} y_i = \frac{1}{n} \sum_{i=1}^N f_i y_i$.

Estimação da média : Propriedades do estimador sob AAS_c

- Discutiremos, com mais detalhes (mais a frente), como se obter os resultados assintóticos mas, por enquanto, sob certas condições, entre elas n e $N - n$ suficientemente grandes, temos que

$$\frac{\hat{\mu} - \mu}{\sqrt{\sigma^2/n}} \xrightarrow[N-n \rightarrow \infty]{n \rightarrow \infty} N(0, 1) \quad (4)$$

ou

$$\hat{\mu} \approx N(\mu, \sigma^2/n), \text{ para } n \text{ e } N - n \text{ suficientemente grandes.}$$

Problema: σ^2 , quase sempre, é desconhecido. Faz-se necessário, portanto, considerar um estimador consistente (de preferência não viciado), para se poder usar o [Teorema de Slutsky](#).

Estimação da média : Propriedades do estimador sob AAS_c

- Vamos considerar o seguinte estimador para σ^2

$$\hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (Y_i - \hat{\mu})^2 = \frac{1}{n-1} \sum_{i=1}^N F_i (y_i - \hat{\mu})^2.$$

Note que (lembrando que $\sum_{i=1}^N y_i^2 = N\sigma^2 + N\mu^2$)

$$\begin{aligned}\mathcal{E}_{A_1}(\hat{\sigma}^2) &= \frac{1}{n-1} \mathcal{E}_{A_1} \left(\sum_{i=1}^n Y_i^2 - n\hat{\mu}^2 \right) = \frac{1}{n-1} \left[\mathcal{E}_{A_1} \left(\sum_{i=1}^N y_i^2 F_i \right) - n \mathcal{E}_{A_1}(\hat{\mu}^2) \right] \\ &= \frac{1}{n-1} \left[\sum_{i=1}^N y_i^2 \mathcal{E}_{A_1}(F_i) - n \mathcal{E}_{A_1}(\hat{\mu}^2) \right] \\ &= \frac{1}{n-1} \left[N(\sigma^2 + \mu^2) \frac{n}{N} - n \left(\mu^2 + \frac{\sigma^2}{n} \right) \right] \\ &= \frac{1}{n-1} [n\sigma^2 + n\mu^2 - n\mu^2 - \sigma^2] = \sigma^2\end{aligned}$$

Estimação da média : Propriedades do estimador sob AAS_c

- A prova de sua consistência, i.e.,

$$\widehat{\sigma}^2 \xrightarrow[n \rightarrow \infty, N - n \rightarrow \infty]{P} \sigma^2 \quad (5)$$

também será discutida mais à frente.

- Portanto, dos resultados (4) e (5), temos que

$$\frac{\widehat{\mu} - \mu}{\sqrt{\widehat{\sigma}^2/n}} = \frac{\widehat{\mu} - \mu}{\sqrt{\sigma^2/n}} \frac{\sigma}{\widehat{\sigma}} \xrightarrow[n \rightarrow \infty, N - n \rightarrow \infty]{D} N(0, 1)$$

por Slutsky.

Intervalo de Confiança

- Estimativa da variância:

$$\tilde{\sigma}^2 = \frac{1}{n-1} \sum_{i \in s} (y_i - \tilde{\mu})^2 = \frac{1}{n-1} \sum_{i=1}^N f_i (y_i - \tilde{\mu})^2.$$

- Assim, um intervalo de confiança (assintótico) com coeficiente de confiança de aproximadamente γ é dado por

$$IC(\mu, \gamma) \approx \left[\hat{\mu} - z_\gamma \sqrt{\frac{\hat{\sigma}^2}{n}}; \hat{\mu} + z_\gamma \sqrt{\frac{\hat{\sigma}^2}{n}} \right]$$

em que $P(Z \leq z_\gamma) = \frac{1+\gamma}{2}$ e $Z \sim N(0, 1)$.

- Erro da estimativa: $z_\gamma \sqrt{\frac{\hat{\sigma}^2}{n}}$.

Testes de Hipótese

- Hipóteses usuais (μ_0 conhecido)
 - 1 $H_0 : \mu = \mu_0$ vs $H_1 : \mu < \mu_0$.
 - 2 $H_0 : \mu = \mu_0$ vs $H_1 : \mu > \mu_0$.
 - 3 $H_0 : \mu = \mu_0$ vs $H_1 : \mu \neq \mu_0$.
- Estatística do teste $Z_t = \frac{\hat{\mu} - \mu_0}{\hat{\sigma}/\sqrt{n}}$, em que $\hat{\sigma} = \sqrt{\hat{\sigma}^2}$.
- Sob H_0 , vimos que $Z_t \approx N(0, 1)$, para n e N -n suficientemente grandes.
- Defina $z_t = \frac{\tilde{\mu} - \mu_0}{\tilde{\sigma}/\sqrt{n}}$ o valor calculado da estatística do teste e z_c o(s) valor(es) crítico(s).
- Defina ainda $Z \sim N(0, 1)$.

Testes de Hipótese

- Procedimento para testar o conjunto de hipóteses [1]
- Valor crítico
 - $P(Z \leq z_c | H_0) = \alpha.$
 - Se $z_t \leq z_c$ rejeita-se H_0 , caso contrário, não se rejeita.
- p-valor (nível descritivo)
 - $p - valor = P(Z \leq z_t | H_0)$

Testes de Hipótese

- Procedimento para testar o conjunto de hipóteses [2]
- Valor crítico
 - $P(Z \geq z_c | H_0) = \alpha.$
 - Se $z_t \geq z_c$ rejeita-se H_0 , caso contrário, não se rejeita.
- p-valor (nível descritivo)
 - $p - valor = P(Z \geq z_t | H_0)$

Testes de Hipótese

- Procedimento para testar o conjunto de hipóteses [3]
- Valor crítico
 - $P(Z \leq z_c | H_0) = \frac{1+\alpha}{2}$.
 - Se $|z_t| \geq z_c$ rejeita-se H_0 , caso contrário, não se rejeita.
- p-valor (nível descritivo)
 - $p\text{-valor} = 2[1 - P(Z \leq |z_t| | H_0)]$.

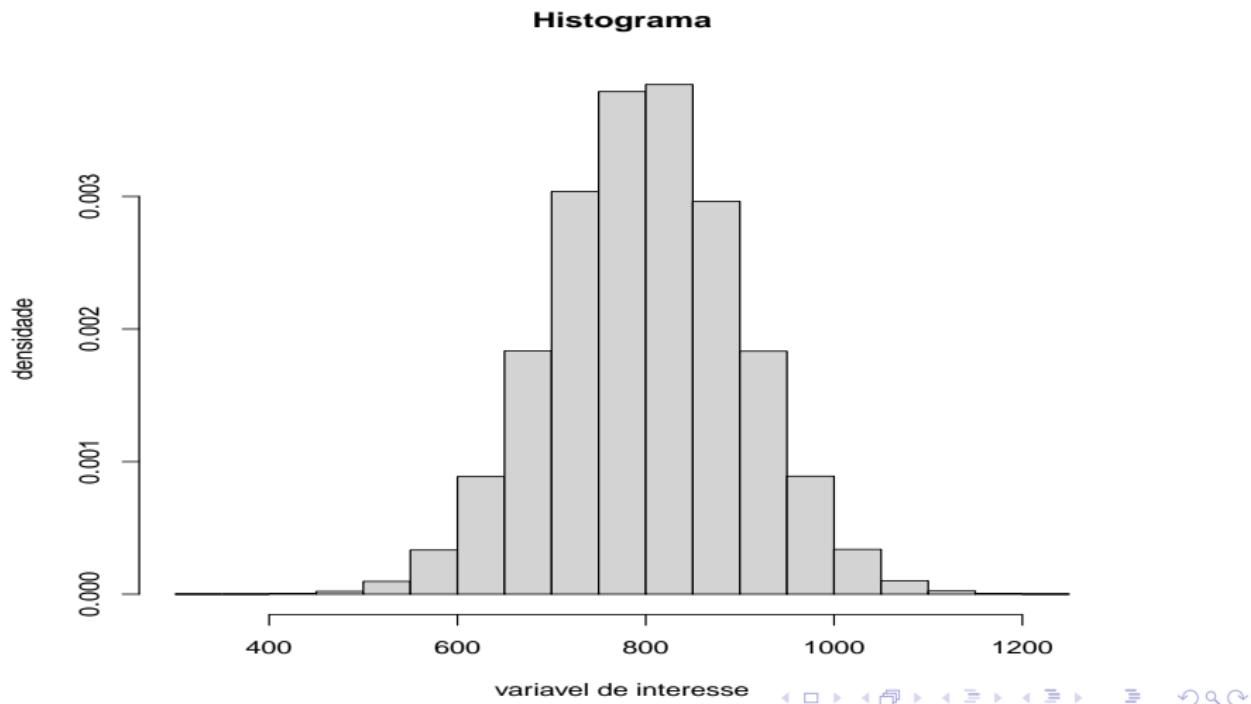
Estudos de simulação

- Distribuição assintótica do estimador para a média. Tamanho da população $N = 100.000$.
- Cinco cenários, variando em função da variável de interesse na população (X).
 - $X \sim N(800, 10.000)$
 - $X \sim \text{gama}(5; 0, 00625)$, $E(X) = 800, V(X) = 128.000$.
 - $X \sim t_{(7)}(800, 5.000)$, $E(X) = 800, V(X) = 7.000$.
 - $X \sim U[400; 1.200]$.
 - $X \sim 0,5N(200, 5.000) + 0,5N(600, 5.000)$

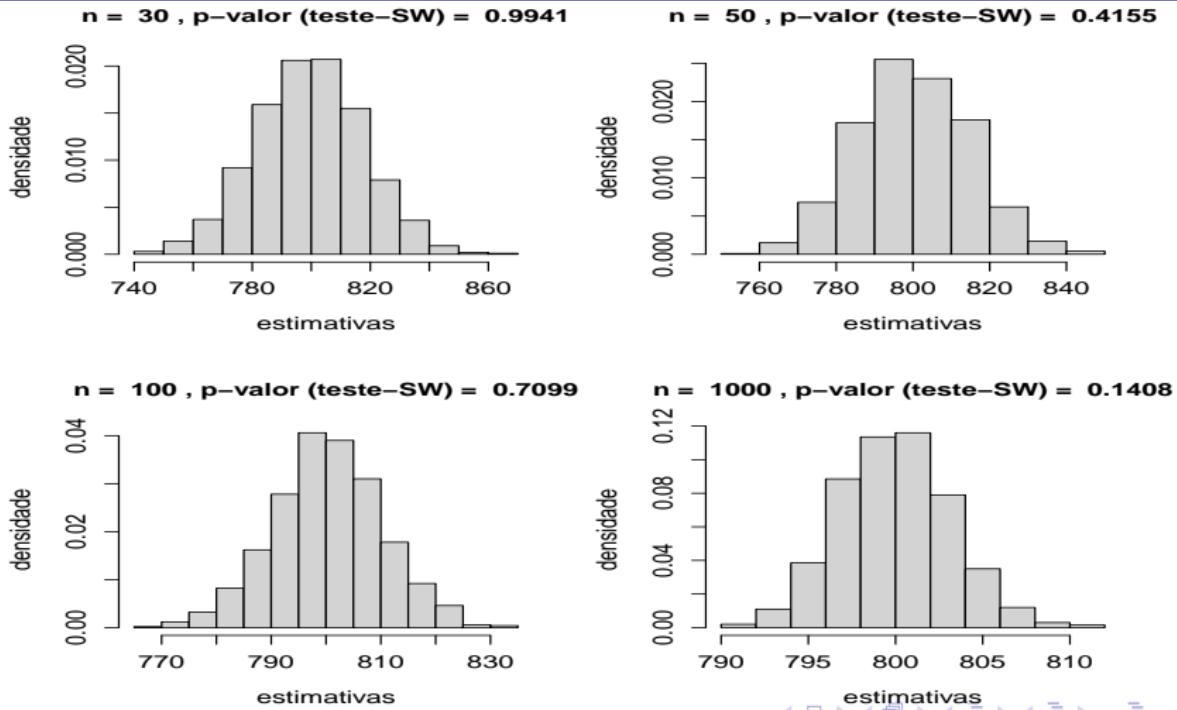
Estudos de simulação

- Quatro tamanhos amostrais (30, 50, 100, 1.000), em termos percentuais, com relação ao tamanho da população (0,03%, 0,05%, 0,1%, 1%).
- Estudar a distribuição amostral (empírica) com base em $R = 1.000$ réplicas (amostras selecionadas da população de interesse).

normal

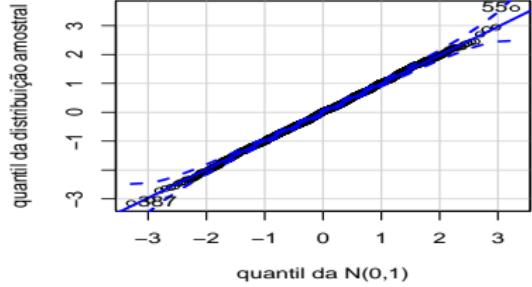


normal

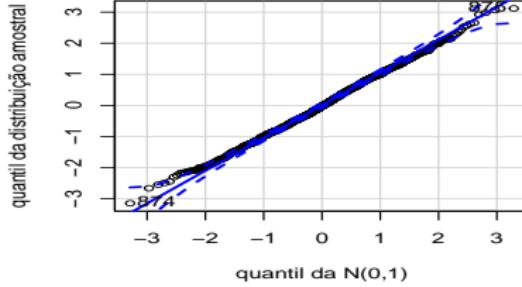


normal

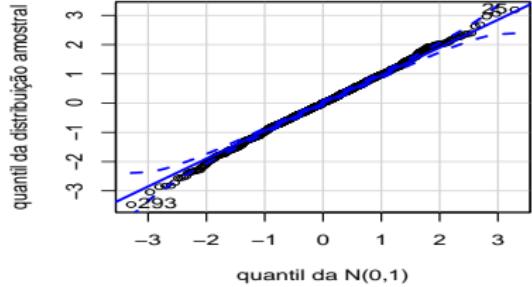
n = 30



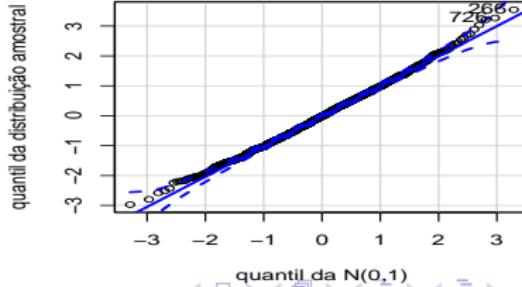
n = 50



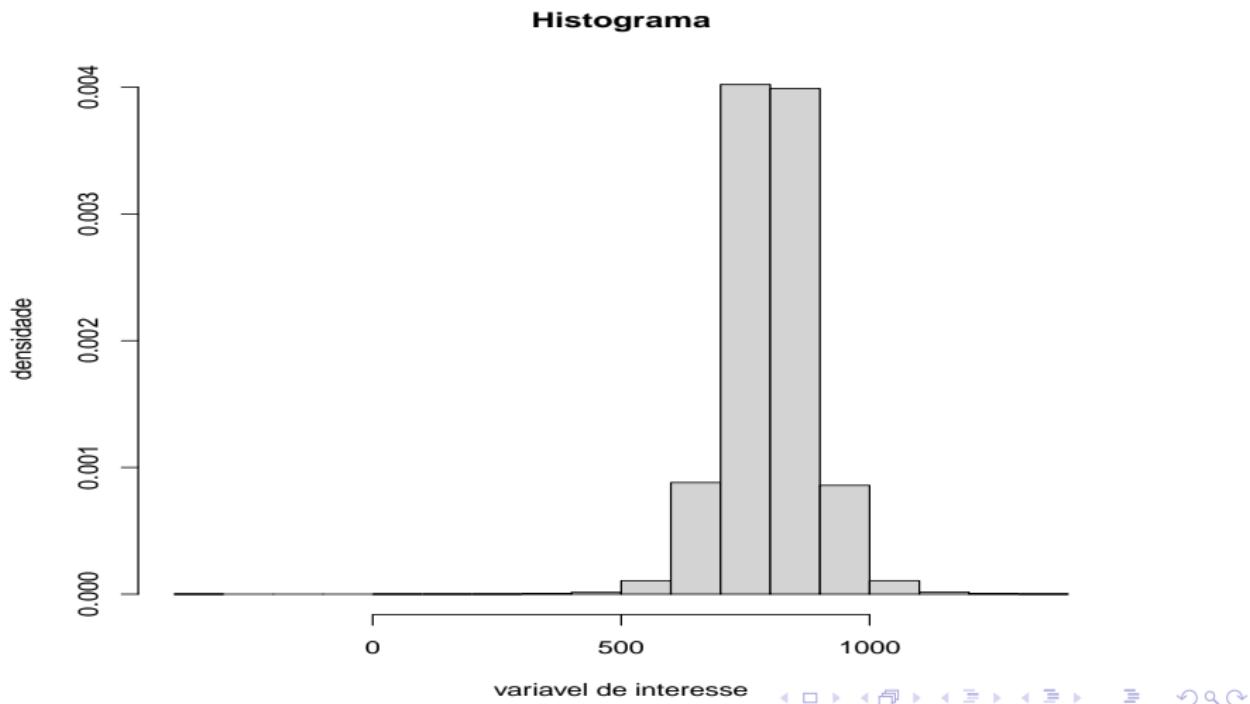
n = 100



n = 1000

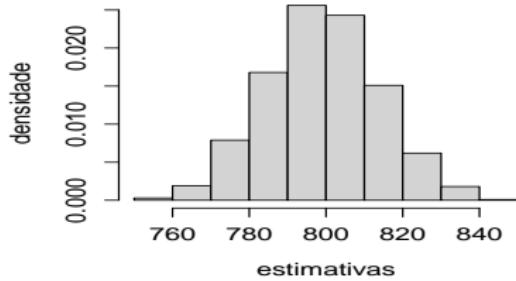


t de Student

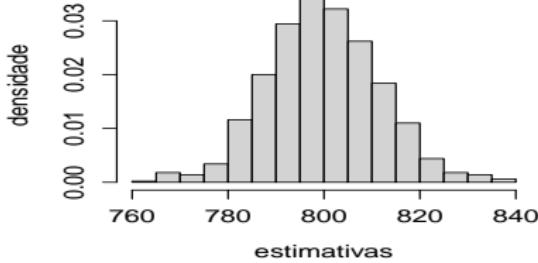


t de Student

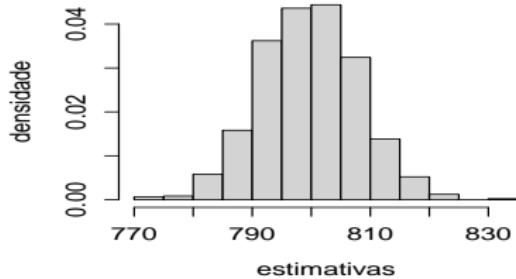
$n = 30$, p-valor (teste-SW) = 0.6486



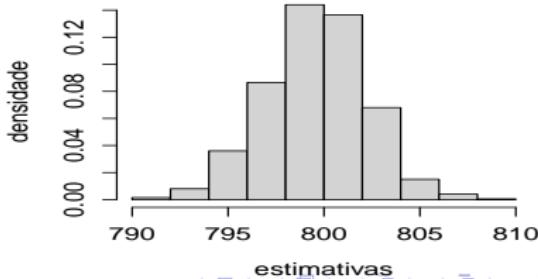
$n = 50$, p-valor (teste-SW) = 0.0454



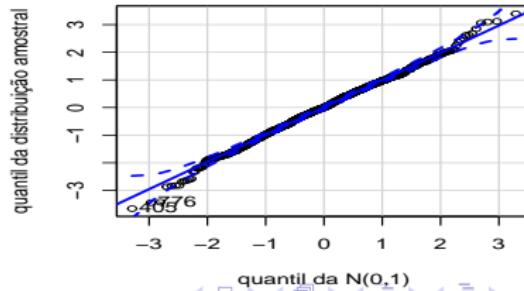
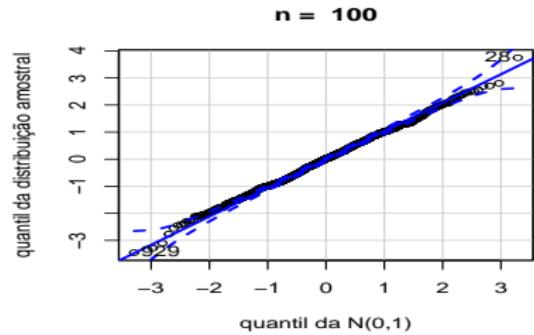
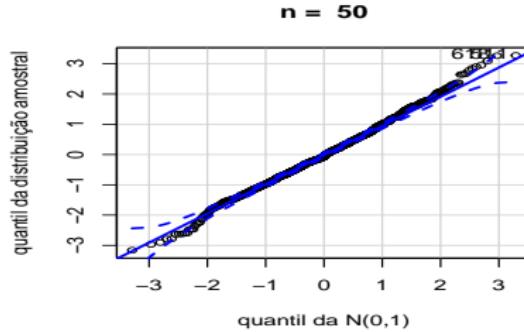
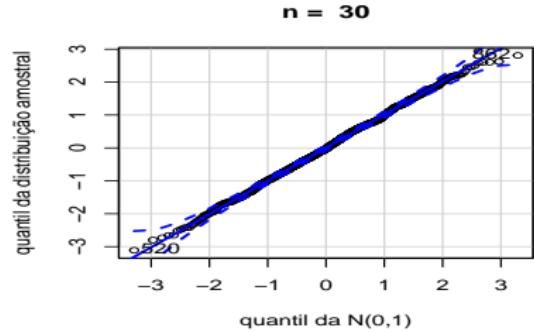
$n = 100$, p-valor (teste-SW) = 0.6574



$n = 1000$, p-valor (teste-SW) = 0.0308

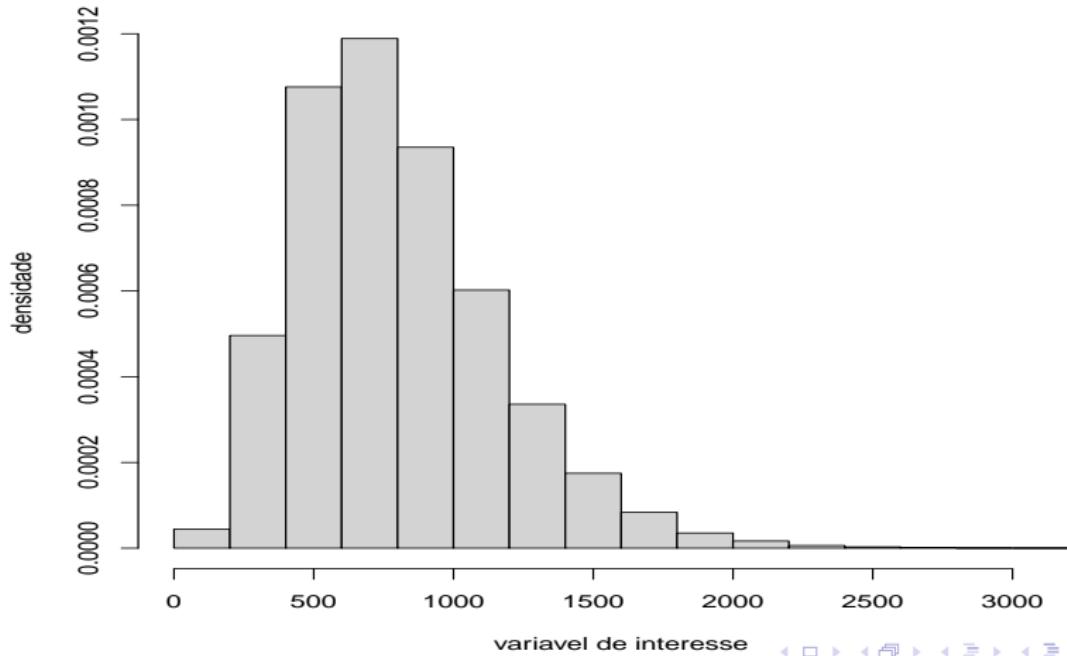


normal

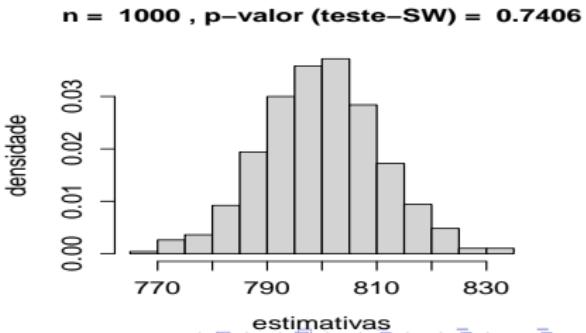
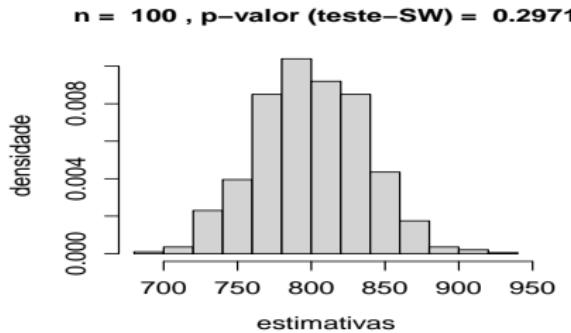
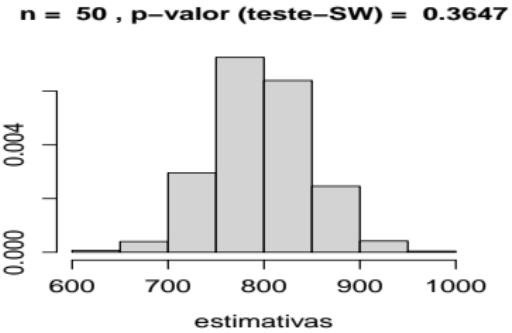
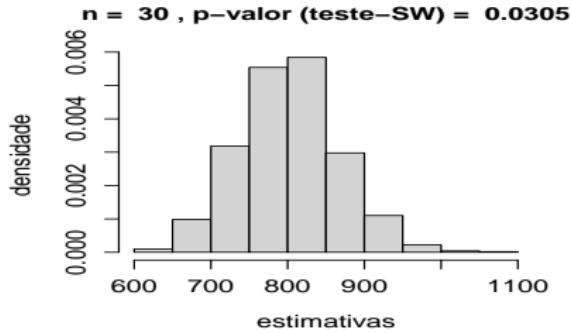


gama

Histograma

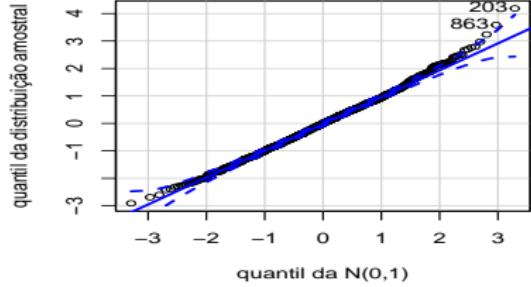


gama

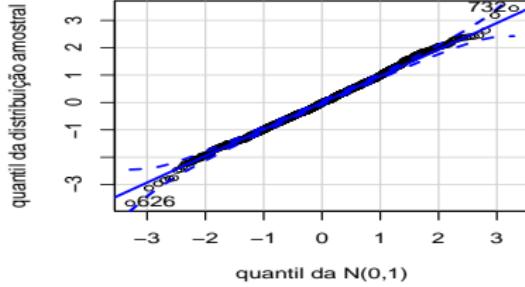


normal

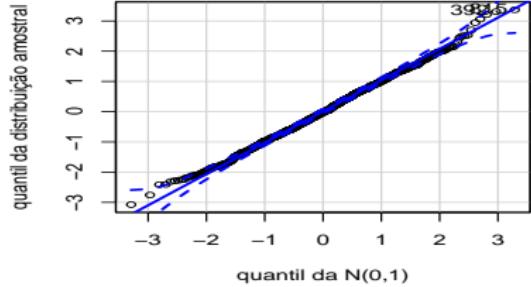
n = 30



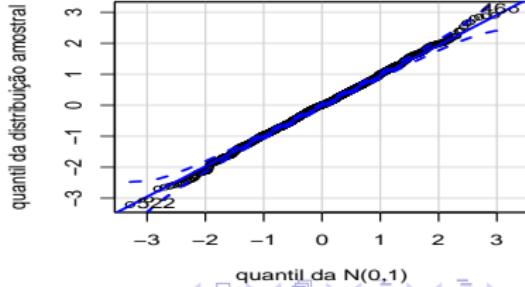
n = 50



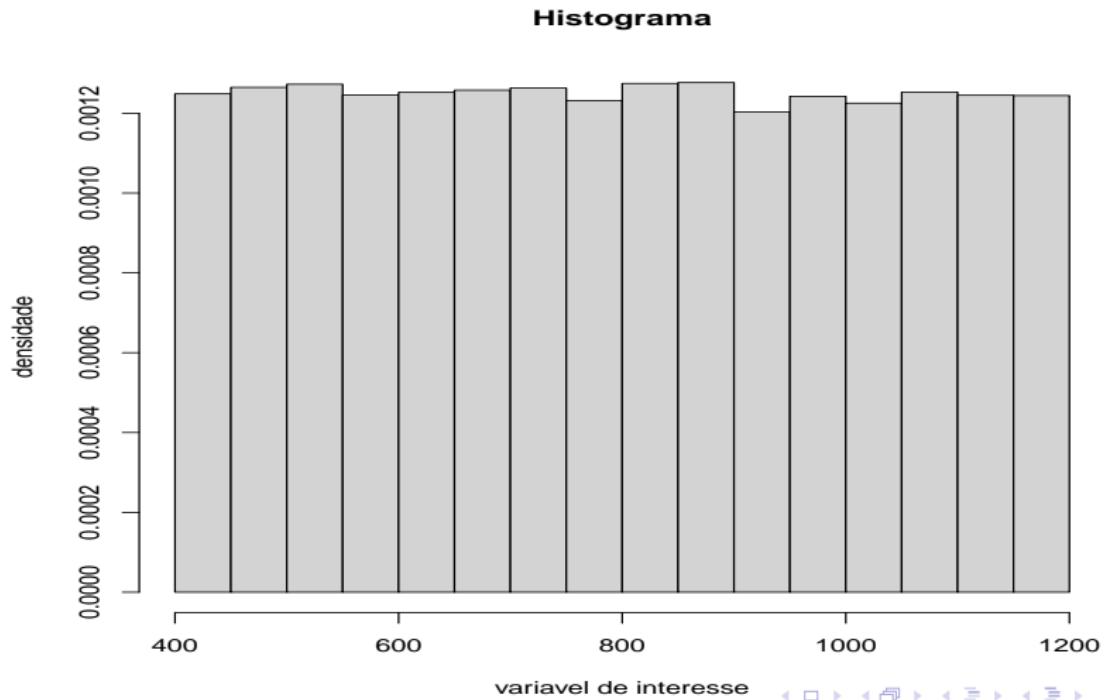
n = 100



n = 1000

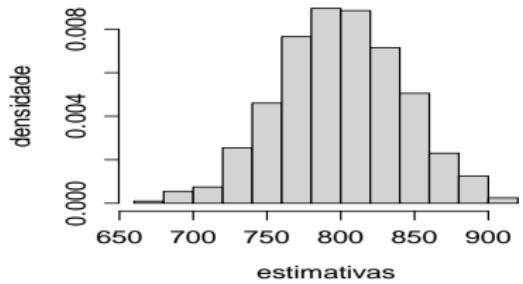


uniforme

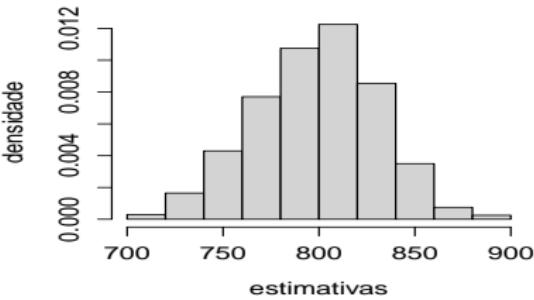


uniforme

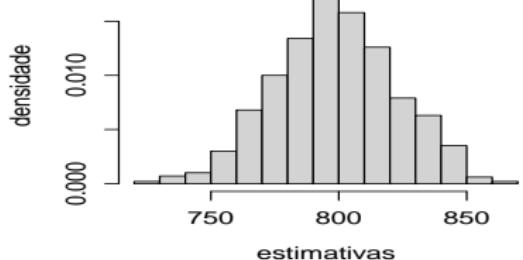
$n = 30$, p-valor (teste-SW) = 0.1679



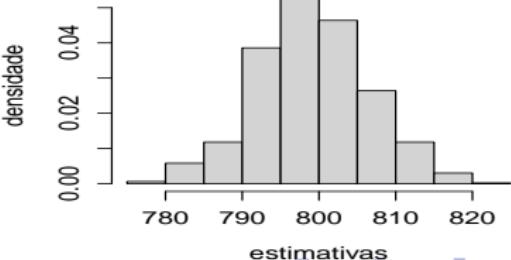
$n = 50$, p-valor (teste-SW) = 0.0671



$n = 100$, p-valor (teste-SW) = 0.2279

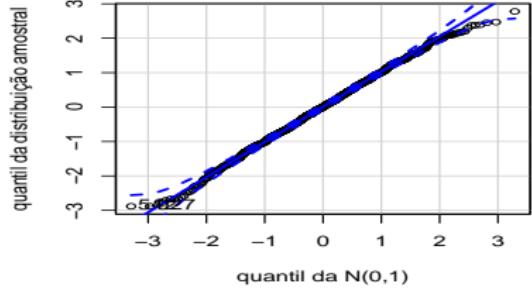


$n = 1000$, p-valor (teste-SW) = 0.1818

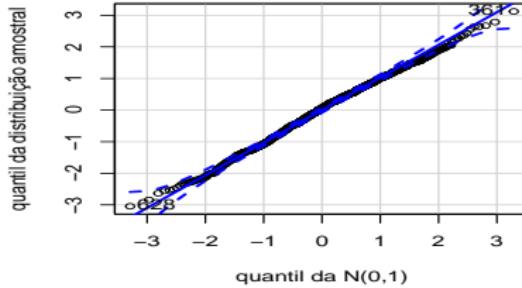


normal

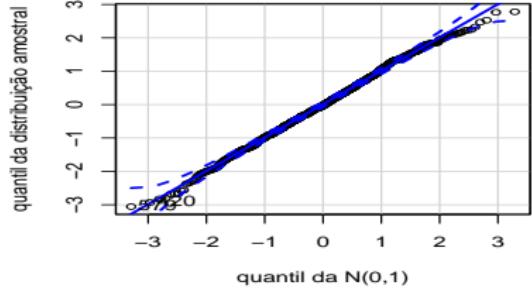
n = 30



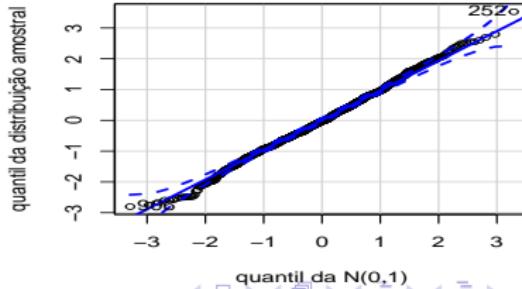
n = 50



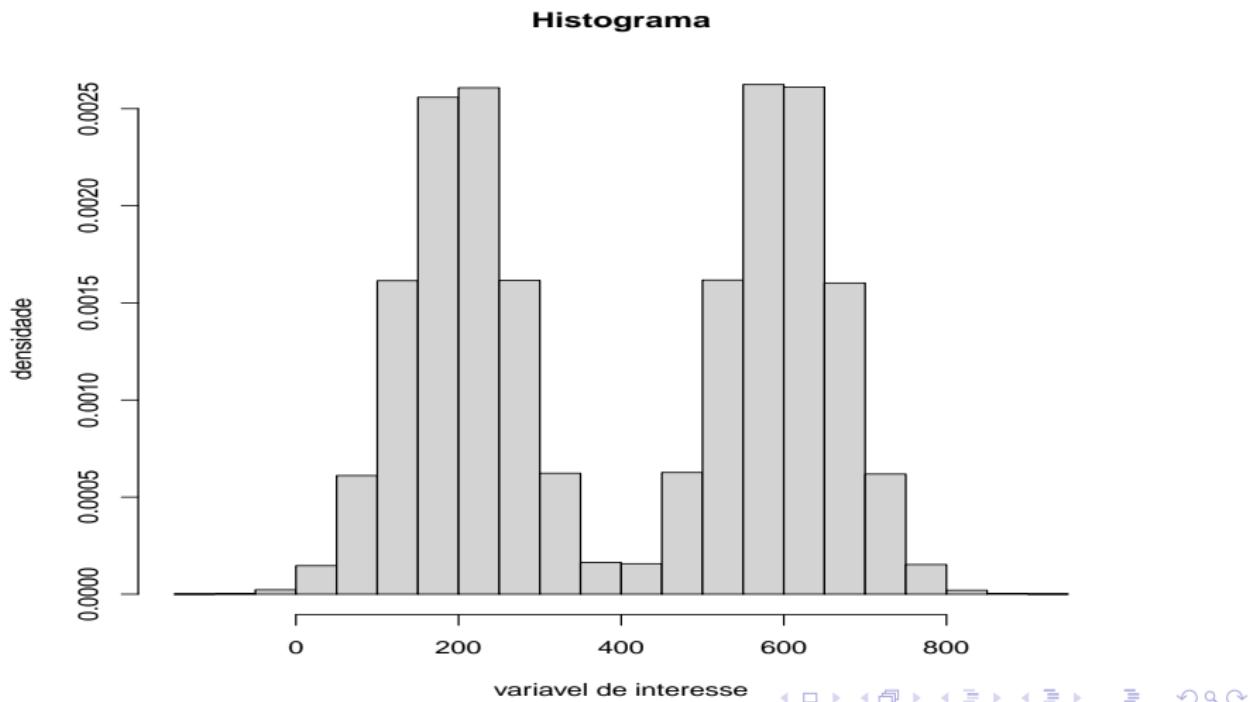
n = 100



n = 1000

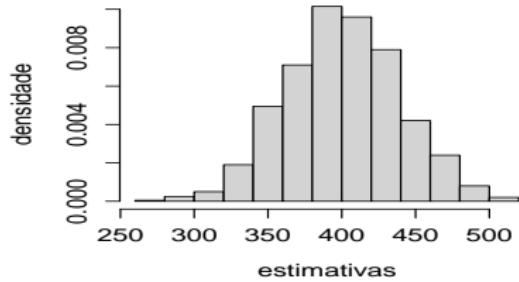


mistura de duas normais

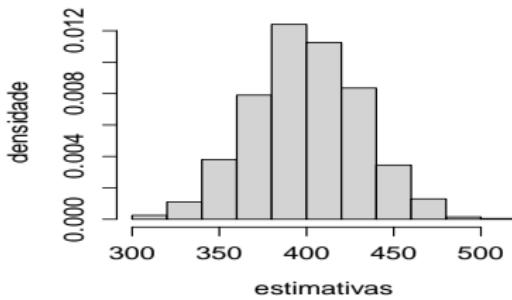


mistura de duas normais

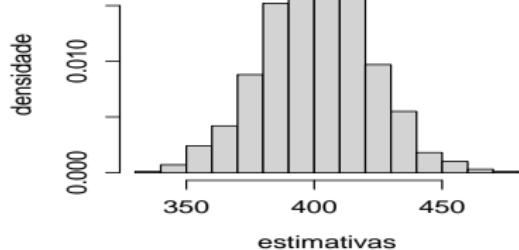
$n = 30$, p-valor (teste-SW) = 0.7755



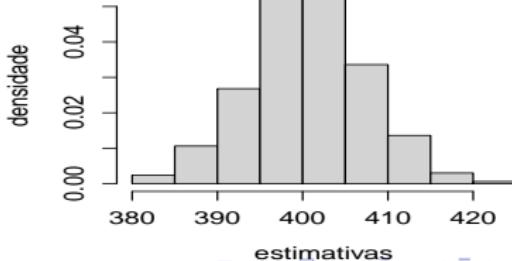
$n = 50$, p-valor (teste-SW) = 0.9061



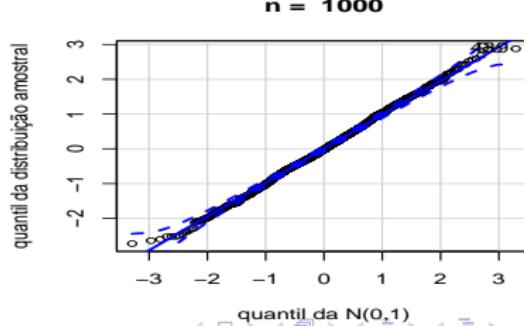
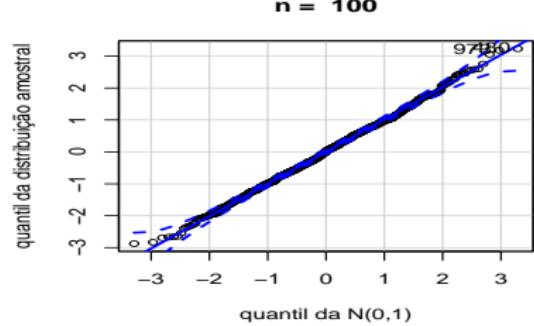
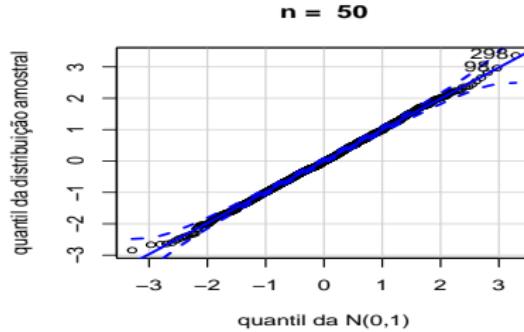
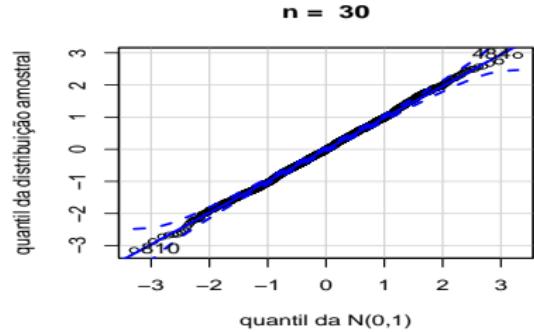
$n = 100$, p-valor (teste-SW) = 0.6228



$n = 1000$, p-valor (teste-SW) = 0.4796



normal



Determinação do tamanho amostral

- Estabelece-se algum critério de interesse acerca da acurácia/precisão na estimativa da média populacional.
- Sob o estimador proposto, calcula-se o tamanho da amostra, com base em sua distribuição assintótica e critério estabelecido.
- Critérios:
 - Erro de estimativa: $z_\gamma \sqrt{\frac{\hat{\sigma}^2}{n}}$. Fixa-se um erro de estimativa de interesse.
 - Precisão (Probabilidade do módulo da diferença):
 $P(|\hat{\mu} - \mu| < \delta) > \gamma, \delta > 0, \gamma \in (0, 1)$ (fixa-se δ).

Determinação do tamanho amostral: erro da estimativa

$$\delta = z_\gamma \sqrt{\frac{\sigma^2}{n}} \rightarrow n = \frac{z_\gamma^2 \sigma^2}{\delta^2}$$

Em geral, o (um) valor de σ^2 é obtido através de pesquisas anteriores ou de uma amostra piloto, de tamanho apropriado.

Determinação do tamanho amostral: precisão

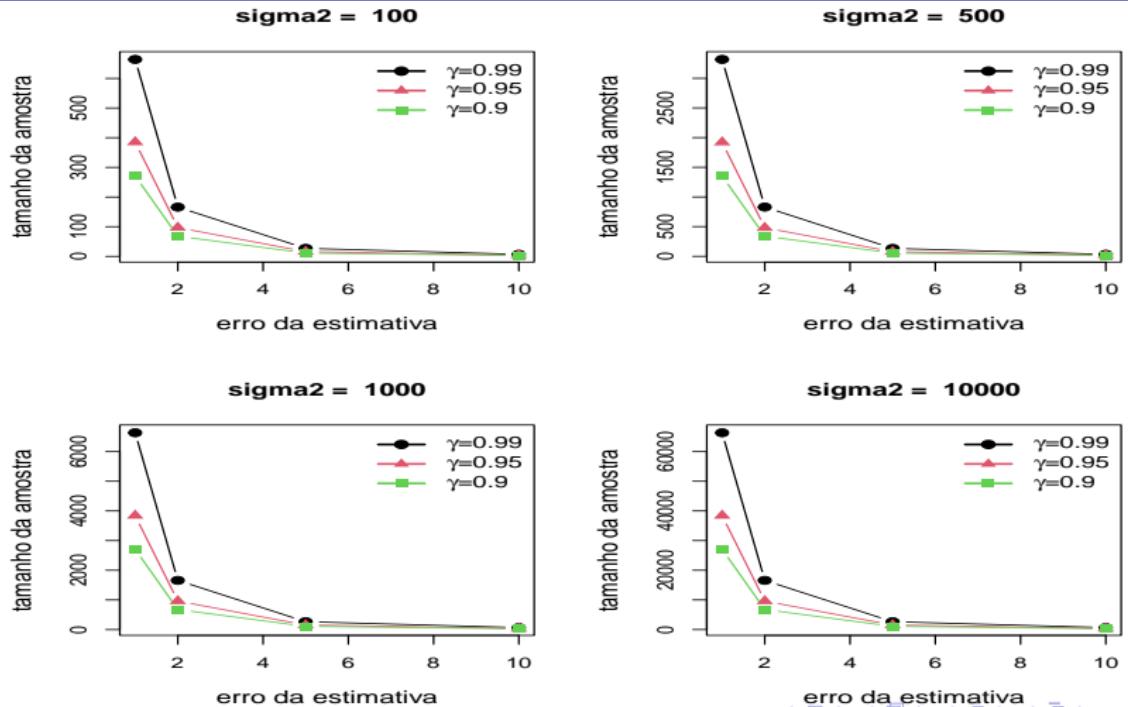
$$\begin{aligned} P_{A_1} (|\hat{\mu} - \mu| < \delta) > \gamma &\leftrightarrow P_{A_1} \left(\left| \frac{\hat{\mu} - \mu}{\sqrt{\sigma^2/n}} \right| < \frac{\sqrt{n}\delta}{\sigma} \right) > \gamma \\ &\leftrightarrow P_{A_1} \left(|Z| < \frac{\sqrt{n}\delta}{\sigma} \right) > \gamma \leftrightarrow \frac{\sqrt{n}\delta}{\sigma} = z_\gamma \end{aligned}$$

em que $Z \approx N(0, 1)$. O que leva ao mesmo procedimento oriundo de se fixar o erro da estimativa.

Tamanhos amostrais

- Situações hipotéticas: cruzamento entre os níveis de diferentes fatores de interesse
 - $\delta \in \{1, 2, 5, 10\}$.
 - $\gamma \in \{0, 9; 0, 95; 0, 99\}$.
 - $\sigma^2 \in \{100, 500, 1.000, 10.000\}$.

Tamanhos amostrais



Estimação do total populacional

- $\tau = \sum_{i=1}^N y_i = N\mu.$
- Estimador “natural”: $\hat{\tau}_u = \sum_{i=1}^n Y_i$. Problema: se os y_i 's foram positivos, $\hat{\tau}_u$ sempre subestimará τ .
- Alternativa $\hat{\tau} = N\hat{\mu}$.
- Estimativa $\tilde{\tau} = N\tilde{\mu}$

Propriedades do estimador

- $\mathcal{E}_{A_1}(\hat{\tau}) = \mathcal{E}_{A_1}(N\hat{\mu}) = N\mathcal{E}(\hat{\mu}) = N\mu = \tau$ (não viciado).
- $\mathcal{V}_{A_1}(\hat{\tau}) = N^2\mathcal{V}_{A_1}(\hat{\mu}) = N^2\frac{\sigma^2}{n}$ (a imprecisão associada à estimação do total é maior do que aquela associada à média).

Propriedades do estimador

- Normalidade assintótica, como

$$\frac{\hat{\mu} - \mu}{\sqrt{\hat{\sigma}^2/n}} \xrightarrow[N-n \rightarrow \infty]{n \rightarrow \infty} N(0, 1),$$

lembrando que N é fixo, temos que

$$\frac{N\hat{\mu} - N\mu}{\sqrt{N^2\hat{\sigma}^2/n}} \xrightarrow[N-n \rightarrow \infty]{n \rightarrow \infty} N(0, 1) \rightarrow \frac{\hat{\tau} - \tau}{\sqrt{N^2\hat{\sigma}^2/n}} \xrightarrow[N-n \rightarrow \infty]{n \rightarrow \infty} N(0, 1)$$

Intervalo de Confiança

- Estimativa da variância:

$$\tilde{\sigma}^2 = \frac{1}{n-1} \sum_{i \in s} (y_i - \tilde{\mu})^2 = \frac{1}{n-1} \sum_{i=1}^N f_i (y_i - \tilde{\mu})^2.$$

- Assim, um intervalo de confiança (assintótico) com coeficiente de confiança de aproximadamente γ é dado por

$$IC(\tau, \gamma) \approx \left[\hat{\tau} - z_\gamma N \sqrt{\frac{\hat{\sigma}^2}{n}}; \hat{\tau} + z_\gamma N \sqrt{\frac{\hat{\sigma}^2}{n}} \right]$$

em que $P(Z \leq z_\gamma) = \frac{1+\gamma}{2}$ e $Z \sim N(0, 1)$.

- Erro da estimativa: $z_\gamma N \sqrt{\frac{\hat{\sigma}^2}{n}}$.

Testes de Hipótese

- Hipóteses usuais (τ_0 conhecido)
 - 1 $H_0 : \tau = \tau_0$ vs $H_1 : \tau < \tau_0$.
 - 2 $H_0 : \tau = \tau_0$ vs $H_0 : \tau > \tau_0$.
 - 3 $H_0 : \tau = \tau_0$ vs $H_0 : \tau \neq \tau_0$.
- Estatística do teste $Z_t = \frac{\tilde{\tau} - \tau_0}{N\hat{\sigma}/\sqrt{n}}$, em que $\hat{\sigma} = \sqrt{\hat{\sigma}^2}$.
- Sob H_0 , vimos que $Z_t \approx N(0, 1)$, para n e $N-n$ suficientemente grandes.
- Defina $z_t = \frac{\tilde{\tau} - \tau_0}{N\hat{\sigma}/\sqrt{n}}$ o valor calculado da estatística do teste e z_c o(s) valor(es) crítico(s).
- Defina ainda $Z \sim N(0, 1)$. Os procedimentos são análogos ao caso da média, com as devidas adaptações (Exercício).

Determinação do tamanho amostral: erro da estimativa

Analogamente ao caso da média populacional, temos que

$$\delta = z_\gamma N \sqrt{\frac{\sigma^2}{n}} \rightarrow n = \frac{z_\gamma^2 N^2 \sigma^2}{\delta^2}$$

Isto vale para qualquer um dos dois critérios: erro da estimativa e precisão.