

Estatística não paramétrica: Métodos baseados em postos

Dorival Leão

Portal Action

2021

- Quando as hipóteses a serem testadas não envolvem parâmetros;
- Os dados são medidas em uma escala de discriminação ruim para aplicar métodos paramétricos. Por exemplo, se os dados são contagens ou postos;
- As suposições necessárias para validar um procedimento paramétrico não são válidas;
- Necessidade de modelagem mais flexível e menos restritiva.

- Quando as hipóteses a serem testadas não envolvem parâmetros;
- Os dados são medidas em uma escala de discriminação ruim para aplicar métodos paramétricos. Por exemplo, se os dados são contagens ou postos;
- As suposições necessárias para validar um procedimento paramétrico não são válidas;
- Necessidade de modelagem mais flexível e menos restritiva.

- Quando as hipóteses a serem testadas não envolvem parâmetros;
- Os dados são medidas em uma escala de discriminação ruim para aplicar métodos paramétricos. Por exemplo, se os dados são contagens ou postos;
- As suposições necessárias para validar um procedimento paramétrico não são válidas;
- Necessidade de modelagem mais flexível e menos restritiva.

- Quando as hipóteses a serem testadas não envolvem parâmetros;
- Os dados são medidas em uma escala de discriminação ruim para aplicar métodos paramétricos. Por exemplo, se os dados são contagens ou postos;
- As suposições necessárias para validar um procedimento paramétrico não são válidas;
- Necessidade de modelagem mais flexível e menos restritiva.

- Consideremos uma população \mathbb{P} com distribuição contínua e simétrica no qual retiramos uma amostra aleatória simples X_1, \dots, X_n ;
- O teste de Wilcoxon é baseado nos postos (ranks) dos valores obtidos. Postos são as posições, representados por números, que os valores observados ocupam quando colocados em ordem crescente. Por exemplo, considere o seguinte conjunto de valores: 12, 17, 15, 19, 14, 16 e 11;
- Colocando em ordem crescente e atribuindo a cada valor seu posto, temos

Valor	11	12	14	15	16	17	19
posto	1	2	3	4	5	6	7

- Consideremos uma população \mathbb{P} com distribuição contínua e simétrica no qual retiramos uma amostra aleatória simples X_1, \dots, X_n ;
- O teste de Wilcoxon é baseado nos postos (ranks) dos valores obtidos. Postos são as posições, representados por números, que os valores observados ocupam quando colocados em ordem crescente. Por exemplo, considere o seguinte conjunto de valores: 12, 17, 15, 19, 14, 16 e 11;
- Colocando em ordem crescente e atribuindo a cada valor seu posto, temos

Valor	11	12	14	15	16	17	19
posto	1	2	3	4	5	6	7

- Consideremos uma população \mathbb{P} com distribuição contínua e simétrica no qual retiramos uma amostra aleatória simples X_1, \dots, X_n ;
- O teste de Wilcoxon é baseado nos postos (ranks) dos valores obtidos. Postos são as posições, representados por números, que os valores observados ocupam quando colocados em ordem crescente. Por exemplo, considere o seguinte conjunto de valores: 12, 17, 15, 19, 14, 16 e 11;
- Colocando em ordem crescente e atribuindo a cada valor seu posto, temos

Valor	11	12	14	15	16	17	19
posto	1	2	3	4	5	6	7

Hipóteses:

- As observações X_i 's são independentes;
- Cada observação X_i é obtida de uma população que é contínua e simétrica em torno de θ_0 . Desta forma, admitimos que a probabilidade (em teoria) de que dois valores amostrais coincidam é zero;

Para a realização do teste de Wilcoxon estabelecemos uma das seguintes hipóteses:

$$\left\{ \begin{array}{l} H_0 : \theta - \theta_0 = 0 \\ H_1 : \theta - \theta_0 \neq 0 \end{array} \right. \quad \left\{ \begin{array}{l} H_0 : \theta - \theta_0 = 0 \\ H_1 : \theta - \theta_0 > 0 \end{array} \right. \quad \left\{ \begin{array}{l} H_0 : \theta - \theta_0 = 0 \\ H_1 : \theta - \theta_0 < 0 \end{array} \right.$$

Hipóteses:

- As observações X_i 's são independentes;
- Cada observação X_i é obtida de uma população que é contínua e simétrica em torno de θ_0 . Desta forma, admitimos que a probabilidade (em teoria) de que dois valores amostrais coincidam é zero;

Para a realização do teste de Wilcoxon estabelecemos uma das seguintes hipóteses:

$$\left\{ \begin{array}{l} H_0 : \theta - \theta_0 = 0 \\ H_1 : \theta - \theta_0 \neq 0 \end{array} \right. \quad \left\{ \begin{array}{l} H_0 : \theta - \theta_0 = 0 \\ H_1 : \theta - \theta_0 > 0 \end{array} \right. \quad \left\{ \begin{array}{l} H_0 : \theta - \theta_0 = 0 \\ H_1 : \theta - \theta_0 < 0 \end{array} \right.$$

- Subtrair θ_0 de cada valor X_1, \dots, X_N da amostra e assim obtemos um novo conjunto de dados: Z_1, Z_2, \dots, Z_n no qual $Z_i = X_i - \theta_0$;
- Ordenamos de forma crescente o novo conjunto de dados $\{|Z_1|, |Z_2|, \dots, |Z_n|\}$ e associamos a cada valor Z_i o posto R_i correspondente. A seguir, definimos a variável indicadora Ψ_i na forma

$$\psi_i = \begin{cases} 1, & \text{se } Z_i > 0 \\ 0, & \text{se } Z_i < 0 \end{cases},$$

para todo $i = 1, \dots, n$.

- Definimos a estatística T^+ como a soma dos postos que têm sinal positivo, ou seja,

$$T^+ = \sum_i^n R_i \psi_i$$

- Subtrair θ_0 de cada valor X_1, \dots, X_N da amostra e assim obtemos um novo conjunto de dados: Z_1, Z_2, \dots, Z_n no qual $Z_i = X_i - \theta_0$;
- Ordenamos de forma crescente o novo conjunto de dados $\{|Z_1|, |Z_2|, \dots, |Z_n|\}$ e associamos a cada valor Z_i o posto R_i correspondente. A seguir, definimos a variável indicadora Ψ_i na forma

$$\psi_i = \begin{cases} 1, & \text{se } Z_i > 0 \\ 0, & \text{se } Z_i < 0 \end{cases},$$

para todo $i = 1, \dots, n$.

- Definimos a estatística T^+ como a soma dos postos que têm sinal positivo, ou seja,

$$T^+ = \sum_i^n R_i \psi_i$$

- Subtrair θ_0 de cada valor X_1, \dots, X_N da amostra e assim obtemos um novo conjunto de dados: Z_1, Z_2, \dots, Z_n no qual $Z_i = X_i - \theta_0$;
- Ordenamos de forma crescente o novo conjunto de dados $\{|Z_1|, |Z_2|, \dots, |Z_n|\}$ e associamos a cada valor Z_i o posto R_i correspondente. A seguir, definimos a variável indicadora Ψ_i na forma

$$\psi_i = \begin{cases} 1, & \text{se } Z_i > 0 \\ 0, & \text{se } Z_i < 0 \end{cases},$$

para todo $i = 1, \dots, n$.

- Definimos a estatística T^+ como a soma dos postos que têm sinal positivo, ou seja,

$$T^+ = \sum_i^n R_i \psi_i$$

Distribuição Exata

Sob H_0 as distribuições de todos os Z_1, \dots, Z_n são simétricas em torno de $\theta = \theta_0$. Portanto, se temos uma amostra de n elementos, temos 2^n possibilidades para a configuração (R_1, R_2, \dots, R_B) e cada uma delas ocorre com probabilidade $\frac{1}{2^n}$, no qual B é o número de postos com Z_i positivo. Neste caso, temos que

$$P(T^+ = t) = \frac{u(t)}{2^n};$$

no qual $u(t)$ é o número de maneiras de atribuir valores para as configurações (R_1, R_2, \dots, R_B) de forma que

$$\sum_{i=1}^B R_i = t.$$

Distribuição Assintótica

Sob a hipótese nula ($\theta = \theta_0$), temos que o valor esperado e a variância são dados por

$$E(T^+ | \theta = \theta_0) = \frac{n(n+1)}{4} \quad \text{e} \quad \text{Var}(T^+ | \theta = \theta_0) = \frac{n(n+1)(2n+1)}{24}.$$

A estatística Z , dada por

$$Z = \frac{T^+ - E_0(T^+)}{\sqrt{\text{Var}_0(T^+)}} = \frac{T^+ - \frac{1}{4}n(n+1)}{\sqrt{[n(n+1)(2n+1)/24]}}.$$

tem distribuição aproximadamente Normal com média 0 e variância 1.

Distribuição Assintótica

Sob a hipótese nula ($\theta = \theta_0$), temos que o valor esperado e a variância são dados por

$$E(T^+ | \theta = \theta_0) = \frac{n(n+1)}{4} \quad \text{e} \quad \text{Var}(T^+ | \theta = \theta_0) = \frac{n(n+1)(2n+1)}{24}.$$

A estatística Z, dada por

$$Z = \frac{T^+ - E_0(T^+)}{\sqrt{\text{Var}_0(T^+)}} = \frac{T^+ - \frac{1}{4}n(n+1)}{\sqrt{[n(n+1)(2n+1)/24]}}.$$

tem distribuição aproximadamente Normal com média 0 e variância 1.

- Seja X uma variável aleatória discreta assumindo valores $\{1, 2, \dots, k\}$ no qual k pode ser finito ou não;
- Tomamos $N(i) = \mathbb{1}_{\{X \leq i\}}$ para todo $i = 1, 2, \dots$. Neste caso, obtemos que N é um submartingale;
- Decomposição de Doob nos garante que $N = Y + A$, no qual Y é um martingale e A é um processo não decrescente tal que

$$A(i) = \sum_{\ell=1}^i h(\ell) V(\ell),$$

no qual

$$h(\ell) = \frac{\mathbb{P}[X = \ell]}{\mathbb{P}[X \geq \ell]} \quad \text{e} \quad V(\ell) = \mathbb{1}_{\{X \geq \ell\}}.$$

- Dado X uma variável aleatória discreta com distribuição de probabilidade $P[X = i]$. Então, existe uma única função intensidade $h : \{1, 2, \dots, k\} \rightarrow [0, 1]$, tal que

$$h(i) = \frac{P[X = i]}{P[X \geq i]},$$

com $i = 1, \dots, k$.

- Dado uma função de intensidade h , existe uma única variável aleatória X satisfazendo

$$\mathbb{P}[X = i] = h(i) \prod_{\ell=1}^{i-1} [1 - h(\ell)] = \prod_{\ell=1}^k [1 - h(\ell)]^{V(\ell) - \Delta N(\ell)} [h(\ell)]^{\Delta N(\ell)},$$

na qual $V(\ell) = \mathbb{1}_{\{X \geq \ell\}}$ e $N(\ell) = \mathbb{1}_{\{X \leq \ell\}}$, para todo $i = 1, \dots, k$.

- Tomamos $X_1^p, \dots, X_{n_p}^p$ uma amostra aleatória simples (iid) da distribuição F^p , tal que $n_p \geq 1$ e $p = 1, \dots, J$;
- Assumimos que as populações também são independentes;
- Como as variáveis aleatórias são independentes, temos que

$$N^{n_p}(i) = \sum_{m=1}^{n_p} \mathbb{1}_{\{X_m^p \leq i\}} = Y^p(i) + A^{n_p}(i),$$

nos quais

$$A^{n_p}(i) = \sum_{\ell=1}^i V^{n_p}(\ell) h^p(\ell) \quad \text{e} \quad V^{n_p}(\ell) = \sum_{m=1}^{n_p} \mathbb{1}_{\{X_m^p \leq \ell\}}$$

- Na decomposição de Doob, o martingale Y^{n_p} representa o ruído. Assim, queremos um estimador que elimine o ruído. Neste caso, queremos encontrar \hat{h}^{n_p} tal que $Y^{n_p}(i) = 0$ para todo $i = 1, 2, \dots, k$;
- Temos que $Y^{n_p}(1) = 0$ implica que

$$\hat{h}^{n_p}(1) = \frac{N^{n_p}(1)}{V^{n_p}(1)} = \frac{\Delta N^{n_p}(1)}{V^{n_p}(1)}, \quad N^{n_p}(0) = 0;$$

- Da mesma forma, se $Y^{n_p}(\ell) = 0$ obtemos o estimador de Kaplan-Meier

$$\hat{h}^{n_p}(\ell) = \frac{\Delta N^{n_p}(\ell)}{V^{n_p}(\ell)}, \quad \Delta N^{n_p}(\ell) = N^{n_p}(\ell) - N^{n_p}(\ell - 1),$$

para todo $\ell = 1, 2, \dots, k$;

- Como V^{n_p} é um processo previsível concluímos que

$$\sum_{\ell=1}^i \hat{h}^{n_p}(\ell) = \underbrace{\sum_{\ell=1}^i \frac{1}{V^{n_p}(\ell)} \Delta Y^{n_p}(\ell)}_{\text{martingale}} + \sum_{\ell=1}^i h^p(\ell);$$

- Assim, obtemos que

$$\mathbb{E} \hat{h}^{n_p}(i) = h^p(i), \quad i = 1, 2, \dots, k;$$

- Temos que

$$\begin{aligned} \mathbb{P}[\widehat{x} = i] &= \prod_{\ell=1}^i [1 - \hat{h}^{n_p}(\ell)]^{V^{n_p}(\ell) - \Delta N^{n_p}(\ell)} [\hat{h}^{n_p}(\ell)]^{V^{n_p}(\ell)} \\ &= \frac{\Delta N^{n_p}(i)}{n_p}, \quad \text{Função de Distribuição Empírica.} \end{aligned}$$

- Como V^{n_p} é um processo previsível concluímos que

$$\sum_{\ell=1}^i \hat{h}^{n_p}(\ell) = \underbrace{\sum_{\ell=1}^i \frac{1}{V^{n_p}(\ell)} \Delta Y^{n_p}(\ell)}_{\text{martingale}} + \sum_{\ell=1}^i h^p(\ell);$$

- Assim, obtemos que

$$\mathbb{E} \hat{h}^{n_p}(i) = h^p(i), \quad i = 1, 2, \dots, k;$$

- Temos que

$$\begin{aligned} \mathbb{P}[\widehat{x} = i] &= \prod_{\ell=1}^i [1 - \hat{h}^{n_p}(\ell)]^{V^{n_p}(\ell) - \Delta N^{n_p}(\ell)} [\hat{h}^{n_p}(\ell)]^{V^{n_p}(\ell)} \\ &= \frac{\Delta N^{n_p}(i)}{n_p}, \quad \text{Função de Distribuição Empírica.} \end{aligned}$$

- Como V^{n_p} é um processo previsível concluímos que

$$\sum_{\ell=1}^i \hat{h}^{n_p}(\ell) = \underbrace{\sum_{\ell=1}^i \frac{1}{V^{n_p}(\ell)} \Delta Y^{n_p}(\ell)}_{\text{martingale}} + \sum_{\ell=1}^i h^p(\ell);$$

- Assim, obtemos que

$$\mathbb{E} \hat{h}^{n_p}(i) = h^p(i), \quad i = 1, 2, \dots, k;$$

- Temos que

$$\begin{aligned} \mathbb{P}[\widehat{x} = i] &= \prod_{\ell=1}^i [1 - \hat{h}^{n_p}(\ell)]^{V^{n_p}(\ell) - \Delta N^{n_p}(\ell)} [\hat{h}^{n_p}(\ell)]^{V^{n_p}(\ell)} \\ &= \frac{\Delta N^{n_p}(i)}{n_p}, \quad \text{Função de Distribuição Empírica.} \end{aligned}$$

- A variância do estimador de Kaplan-Meier é dado por

$$\text{Var}[\hat{h}^{n_p}(\ell)] = h^{(p)}(\ell) [1 - h^{(p)}(\ell)] \mathbb{E} \left[\frac{1}{V^{n_p}(\ell)} \right], \ell \leq i;$$

- Temos que $V^{n_p}(\ell)$ tem distribuição Binomial com parâmetros n_p e $\mathbb{P}[X^p \geq \ell]$;

- Dada uma sequência $\{\hat{h}^{n_p}\}$ de estimadores da função intensidade $h^{(p)}$ temos que

$$\mathbb{P} \left[\sup_{\ell \leq i} |\hat{h}^{n_p}(\ell) - h^{(p)}(\ell)| \right] \rightarrow 0,$$

ou seja, \hat{h}^{n_p} é um estimador consistente para a função $h^{(p)}$;

- O estimador $\widehat{\mathbb{P}[X = i]}$ é consistente para a função de distribuição $\mathbb{P}[X = i]$;
- Temos que

$$\sqrt{n_p} \left[\hat{h}^p(\ell) - h^p(\ell) \right]$$

converge em distribuição para uma variável aleatória normal com média zero e variância

$$\sigma_h^2(\ell) = \frac{h^p(\ell)(1 - h^p(\ell))}{\mathbb{P}[X^p \geq \ell]}, \quad \ell = 1, 2, \dots, k.$$

- Dada uma sequência $\{\hat{h}^{n_p}\}$ de estimadores da função intensidade $h^{(p)}$ temos que

$$\mathbb{P} \left[\sup_{\ell \leq i} |\hat{h}^{n_p}(\ell) - h^{(p)}(\ell)| \right] \rightarrow 0,$$

ou seja, \hat{h}^{n_p} é um estimador consistente para a função $h^{(p)}$;

- O estimador $\mathbb{P}[\widehat{X} = i]$ é consistente para a função de distribuição $\mathbb{P}[X = i]$;
- Temos que

$$\sqrt{n_p} \left[\hat{h}^p(\ell) - h^p(\ell) \right]$$

converge em distribuição para uma variável aleatória normal com média zero e variância

$$\sigma_h^2(\ell) = \frac{h^p(\ell)(1 - h^p(\ell))}{\mathbb{P}[X^p \geq \ell]}, \quad \ell = 1, 2, \dots, k.$$

- Dada uma sequência $\{\hat{h}^{n_p}\}$ de estimadores da função intensidade $h^{(p)}$ temos que

$$\mathbb{P} \left[\sup_{\ell \leq i} |\hat{h}^{n_p}(\ell) - h^{(p)}(\ell)| \right] \rightarrow 0,$$

ou seja, \hat{h}^{n_p} é um estimador consistente para a função $h^{(p)}$;

- O estimador $\mathbb{P}[\widehat{X} = i]$ é consistente para a função de distribuição $\mathbb{P}[X = i]$;
- Temos que

$$\sqrt{n_p} \left[\hat{h}^p(\ell) - h^p(\ell) \right]$$

converge em distribuição para uma variável aleatória normal com média zero e variância

$$\sigma_h^2(\ell) = \frac{h^p(\ell) (1 - h^p(\ell))}{\mathbb{P}[X^p \geq \ell]}, \quad \ell = 1, 2, \dots, k.$$

- Denotamos $n^* := (n_1, \dots, n_J) \in \mathbb{N}^J$, $N_J := \max\{n_1, \dots, n_J\}$ e $n = n_1 + \dots + n_J$;
- $n^* \rightarrow \infty$ significa $n_p \rightarrow \infty$ para todo $p \in \mathcal{J}$ e assumimos que $b_p := \lim_{n^* \rightarrow \infty} n_p/n$; $p \in \mathcal{J}$ existe;
- Queremos testar as hipóteses

$$H_0 : h^1(\ell) = h^2(\ell) = \dots = h^J(\ell); \ell \in \mathbb{N};$$

H_1 : Pelos menos uma função intensidade diferente;

- Seja $R^{n^*}(i) := \sum_{p=1}^J R^{n_p}(i)$ e $V^{n^*}(i) = \sum_{p=1}^J V^{n_p}(i)$ o número total de eventos de interesse e o número total sob risco na categoria i , respectivamente.

Estatística de Logrank ponderado é dada por:

$$\begin{aligned} LR_q(n^*, i) &:= \sum_{\ell=1}^i \sum_{q_1 \neq q} \left(\frac{1}{n}\right)^{1/2} u(n^*, \ell) \left(\frac{V^{n_q}(\ell) V^{n_{q_1}}(\ell)}{V^{n^*}(\ell)} \right) \left[\hat{h}^{n_q}(\ell) - \hat{h}^{n_{q_1}}(\ell) \right] \\ &= \sum_{\ell=1}^i \left(\frac{1}{n}\right)^{1/2} u(n^*, \ell) \left[\Delta R^{n_q}(\ell) - V^{n_q}(\ell) \frac{\Delta R^{n^*}(\ell)}{V^{n^*}(\ell)} \right], \quad q \in \mathcal{J}, \end{aligned}$$

no qual o processo peso $u(n^*; \cdot)$ é limitado e converge em probabilidade para uma função limitada.

- Gehan e Wilcoxon ($J = 2$) e Kruskal-Walis ($J > 2$)

$$u(n^*, \ell) := \frac{V^{n^*}(\ell)}{n}$$

- Tarone e Ware

$$u(n^*, \ell) := \left(\frac{V^{n^*}(\ell)}{n} \right)^\gamma, \quad \gamma > 0;$$

- Logrank

$$u(n^*, \ell) := 1.$$

- Gehan e Wilcoxon ($J = 2$) e Kruskal-Walis ($J > 2$)

$$u(n^*, \ell) := \frac{V^{n^*}(\ell)}{n}$$

- Tarone e Ware

$$u(n^*, \ell) := \left(\frac{V^{n^*}(\ell)}{n} \right)^\gamma, \quad \gamma > 0;$$

- Logrank

$$u(n^*, \ell) := 1.$$

Como a soma dos componentes LR_q é nula, a estatística de Logrank multivariada é definida por:

$$LR_0(n^*, i) := (LR_1(n^*, i), \dots, LR_{J-1}(n^*, i))^T,$$

para $n^* \in \mathbb{N}^J$ e $i \geq 1$. A estrutura de covariância é dada por

$$[\hat{\Gamma}(n^*, i)]_{rk} := \begin{cases} \sum_{\ell=1}^i \hat{\phi}_{k, n^*}^2(\ell); & \text{if } k = r \\ \sum_{\ell=1}^i \hat{\psi}_{n^*}(k, r, \ell); & \text{if } k \neq r, \end{cases} \quad (1)$$

Variância:

$$\hat{\phi}_{q,n^*}^2(\ell) = \frac{1}{n} u^2(n^*, \ell) \frac{V^{n_q}(\ell)}{V^{n^*}(\ell)} \left[1 - \frac{V^{n_q}(\ell)}{V^{n^*}(\ell)} \right] \left[\frac{V^{n^*}(\ell) - \Delta R^{n^*}(\ell)}{V^{n^*}(\ell) - 1} \right] \Delta R^{n^*}(\ell).$$

Covariância:

$$\hat{\psi}_{n^*}(k, r, \ell) = -\frac{1}{n} u^2(n^*, \ell) \frac{V^{n_k}(\ell)}{V^{n^*}(\ell)} \frac{V^{n_r}(\ell)}{V^{n^*}(\ell)} \left[\frac{V^{n^*}(\ell) - \Delta R^{n^*}(\ell)}{V^{n^*}(\ell) - 1} \right] \Delta R^{n^*}(\ell).$$

se $r \neq k$ em \mathcal{J} .

Variância:

$$\hat{\phi}_{q,n^*}^2(\ell) = \frac{1}{n} u^2(n^*, \ell) \frac{V^{n_q}(\ell)}{V^{n^*}(\ell)} \left[1 - \frac{V^{n_q}(\ell)}{V^{n^*}(\ell)} \right] \left[\frac{V^{n^*}(\ell) - \Delta R^{n^*}(\ell)}{V^{n^*}(\ell) - 1} \right] \Delta R^{n^*}(\ell).$$

Covariância:

$$\hat{\psi}_{n^*}(k, r, \ell) = -\frac{1}{n} u^2(n^*, \ell) \frac{V^{n_k}(\ell)}{V^{n^*}(\ell)} \frac{V^{n_r}(\ell)}{V^{n^*}(\ell)} \left[\frac{V^{n^*}(\ell) - \Delta R^{n^*}(\ell)}{V^{n^*}(\ell) - 1} \right] \Delta R^{n^*}(\ell).$$

se $r \neq k$ em \mathcal{J} .

- Sob H_0 , o vetor aleatório $LR_0(n^*, i)$ converge em distribuição para uma distribuição normal multivariada $N(0, \Gamma_0(i))$ quando $n^* \rightarrow \infty$, no qual a matriz de covariâncias $\Gamma_0(i)$ pode ser consistentemente estimada por $\hat{\Gamma}_0(n^*, i)$, no qual $\hat{\Gamma}_0(n^*, \cdot)$ é dada por $\hat{\Gamma}(n^*, \cdot)$ sem a última linha e a última coluna;
- A estatística de logrank ponderada relacionada com LR_0 dada por

$$X^2(n^*, i) := LR_0(n^*, i)^\top \hat{\Gamma}_0(n^*, i)^{-1} LR_0(n^*, i), \quad n^* \in \mathbb{N}^J,$$

converge em distribuição para um chi-quadrado $J - 1$ -graus de liberdade.