



Testes Não Paramétricos

KAI (k Amostras Independentes)

Prof. Lori Vialli, Dr.
<http://www.mat.ufrgs.br/vialli/>
 vialli@mat.ufrgs.br

UFSCAR
UFSCAR

Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Testes para k amostras independentes

UFSCAR
UFSCAR

Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

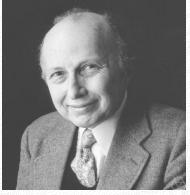
Os testes

- ❖ O teste de Kruskal-Wallis (Análise de variância de uma classificação por postos)
- ❖ O teste qui-Quadrado

UFSCAR
UFSCAR

Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

O teste de Kruskal-Wallis



William Henry Kruskal
(1919 - 2005)



William Allen Wallis
(1912 - 1998)

UFSCAR
UFSCAR

Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Objetivo

O teste de Kruskal-Wallis é utilizado para decidir se k amostras independentes podem ter sido extraídas de populações diferentes.

UFSCAR
UFSCAR

Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Os valores amostrais diferem entre si e deve-se decidir se essas diferenças amostrais significam diferenças efetivas entre as populações, ou se representam apenas variações casuais.

UFSCAR
UFSCAR

Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

O teste supõe que a variável em estudo tenha distribuição contínua e exige mensuração no mínimo ao nível ordinal.



Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



Metodologia

Cada um dos n valores é substituído por um posto. Isto é, os escores de todas as k amostras combinadas são dispostos em uma única série de postos. Ao menor escore é atribuído o posto 1, ao seguinte o posto 2 e assim por diante até o maior posto que é $n =$ número total de observações.



Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



Feito isso, determina-se a soma dos postos em cada amostra (coluna). A prova então testa se estas somas são tão diferentes entre si, de modo que não seja provável que tenham sido todas retiradas de uma mesma população.



Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



Tratamentos

T_1	T_2	...	T_k
X_{11}	X_{12}	...	X_{1k}
X_{21}	X_{22}	...	X_{2k}
X_{31}	X_{32}	...	X_{3k}
...
X_{n1}	X_{n2}	...	X_{nk}



Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



Suposições

No artigo original de Kruskal-Wallis de 1952 apenas suposições gerais foram estabelecidas:

- (i) As observações são independentes;
- (ii) Dentro de cada amostra as observações são da mesma população e
- (iii) As k populações são da mesma forma e contínuas.



Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



Hipóteses

H_0 : Os k tratamentos não diferem entre si;

H_1 : Pelos menos dois tratamentos diferem entre si.



Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



A estatística teste

Se as k amostras forem de uma mesma população (H_0 é V) então a estatística de Kruskal-Wallis tem distribuição conhecida (Tabela O) se as amostras forem pequenas ($n < 5$) ou Qui-Quadrado com $gl = k - 1$, desde que os tamanhos das k amostras não sejam muito pequenos (5 ou mais elementos).

Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

A estatística amostral é:

$$H = \frac{12}{n(n+1)} \sum_{j=1}^k \left(\frac{(\sum R_j)^2}{n_j} \right) - 3(n+1)$$

Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Onde:

k = número de amostras;

n_j = número de elementos na amostra "j";

R_j = soma dos postos do tratamento (amostra ou coluna) "j";

$n = \sum n_j$ = número total de elementos de todas as amostras combinadas;

Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Alguns autores recomendam que se existe um número grande de empates o valor de H dever ser corrigido. A correção consiste em aumentar levemente o valor de H . A seguinte equação é utilizada para obter o valor da correção de H :

$$C = 1 - \frac{\sum_{i=1}^s (t_i^3 - t_i)}{n^3 - n}$$

Onde:
 S = número de grupos empatados;
 t_i = número de valores empatados.

Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

O valor de H corrigido será igual então a:

$$H_C = H/C$$

Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Decisão:

Rejeitamos H_0 se $H \geq h$, onde $P(H \geq h) = \alpha$.

A tabela O fornece os limites de h para $n_i \leq 6$ e $k = 3$.

À medida que os n_i crescem a distribuição de H sob H_0 tende para a χ^2 com $k - 1$ graus de liberdade.

Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

E x e m p l o

Verificar a influência do Fator "Idade" sobre a variável "tempo, em dias, para conseguir um emprego", considerando as seguintes amostras:

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

<i>Acima de 40 anos</i>	<i>Entre 25 e 40</i>	<i>Abaixo de 25</i>
63	33	25
20	42	31
43	27	6
58	28	14
57	51	18
71	64	33
45	12	
	30	

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Tem-se $n = 21$ (total de informações). Então o maior posto será 21.

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

	<i>Postos(1)</i>	<i>Postos(2)</i>	<i>Postos(3)</i>
1	5	2	1
2	14	7	3
3	15	8	4
4	17	9	6
5	18	11,5	10
6	19	13	11,5
7	21	16	
8		20	
ΣR_j	109	86,5	35,5
Média	15,57	10,81	5,92

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

A variável teste será:

$$\begin{aligned} H &= \frac{12}{n(n+1)} \sum_{j=1}^k \left(\frac{(\sum R_j)^2}{n_j} \right) - 3(n+1) = \\ &= \frac{12}{21(21+1)} \left(\frac{109^2}{7} + \frac{86,5^2}{8} + \frac{35,5^2}{6} \right) - 3(21+1) = \\ &= 73,834 - 66 = 7,834 \end{aligned}$$

O grau de liberdade é:

$$v = k - 1 = 3 - 1 = 2$$

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Como ocorreu apenas um conjunto de empates e com apenas dois valores, não vale a pena utilizar a correção para H.

$$C = 1 - \frac{\sum_{i=1}^s (t_i^3 - t_i)}{n^3 - n}$$

Contudo se isto fosse feito o novo valor de H, isto é, $H_c = 7,839$.

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



O qui-quadrado tabelado será:

Argumentos da função

DIST.QUIQUA

X	7,384	=	7,384
Graus.Liberdade	2	=	2
Cumulativo	1	=	VERDADEIRO

Retorna a probabilidade de cauda esquerda da distribuição qui-quadrado.

Cumulativo é um valor lógico a ser retornado pela função a função de distribuição cumulativa = VERDADEIRO; a função de densidade da probabilidade = FALSO.

Resultado da fórmula = 0,975077892

Auxílio sobre esta função

OK Cancelar

Assim o valor-p deste resultado será

$$1 - 0,9751 = 2,49\%$$

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



Conclusão

A 5% de significância é possível afirmar que o fator “idade” tem influência sobre o “tempo para encontrar trabalho”.

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



S o l u ç ã o
S P S S

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



Resultados SPSS

Kruskal-Wallis Test

Controle	n	Mean Rank
0	7	15,57
1	8	10,81
2	6	5,92
Total	21	

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



	Tempo
Chi-Square	7,839
df	2
Assymp. Sig.	0,020

Exercício

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



Uma indústria de pneus testou a distância de frenagem, em pista molhada, das suas cinco opções de pneus. As distâncias observadas, em metros, estão na tabela. Verifique se existe diferença entre as marcas.

	A	B	C	D	E
1	45,8	47,6	40,9	44,5	44,2
2	43,3	47,9	44,2	52,7	51,8
3	48,1	45,4	43,0	54,2	50,6
4	46,0	43,0	39,1	49,4	43,9
5	47,2	42,4	42,1	44,8	44,5
6				50,0	50,3

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

	A	B	C	D	E
1					
2					
3					
4					
5					
6					
Total					
Média					

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Comparações Múltiplas

Quando a diferença for significativa, isto é, existem tratamentos que diferem é possível identificar qual ou quais pares diferem por intermédio das comparações múltiplas.

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Para $j = 1, 2, \dots, k$, sejam \mathcal{R}_j a soma dos postos e $r_j = \mathcal{R}_j/n_j$ a média do postos do tratamento j . Dados r_i e r_j diremos que os dois tratamentos diferem se $|r_i - r_j|$ for significativamente grande.

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Para comparar todos os tratamentos dois a dois é necessário fazer $k(k - 1)/2$ comparações. Nesse caso, é razoável adotar uma probabilidade maior de erro. Em geral 10% ou até um pouco mais.



Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



Para um dado determinamos se dois tratamentos diferem adotando o seguinte procedimento:

Determinar o valor z que corresponde à probabilidade $\alpha' = 2.\alpha/k(k - 1)$ da cauda superior da normal padrão.



Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



Para cada parámetro i, j com $i \neq j$ calcula-se:

$$z_{ij} = \frac{r_i - r_j}{\sigma_{ij}}$$

Onde:

$$\sigma_{ij} = \sqrt{\frac{n(n+1)}{12}} \left(\frac{1}{n_i} + \frac{1}{n_j} \right)^{-1}$$



Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



Diremos que o tratamento i produz medidas menores que o j se $z_{ij} < -z$; medidas maiores do que j se $z_{ij} > z$ e medidas da mesma ordem de grandeza se $-z \leq z \leq z$.



Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



Retornando ao exercício dos pneus, onde queremos comparar as cinco marcas, duas a duas, com respeito ao desempenho na frenagem. Vamos supor que estamos dispostos a tolerar uma significância de 10%.



Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



Então $\alpha' = \alpha/k(k - 1) = 1\%$ e $z = 2,326$.

Os postos médios são:

15,0 12,1 4,2 20,1 16,8

Ao invés de comparar $z = 2,326$ com o quociente $z_{ij} = \frac{r_i - r_j}{\sigma_{ij}}$ vamos comparar as diferenças $r_i - r_j$ com os produtos $z\sigma_{ij}$



Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



Como os tamanhos das amostras são diferentes temos σ_{ij} diferentes. Então:

Tamanhos das amostras	σ_{ij}	$z\sigma_{ij}$
5 e 5	5,02	
5 e 6	4,81	
6 e 6	4,58	

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

O teste Qui-Quadrado

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

O teste qui-quadrado

O teste χ^2 de “ k ” amostras independentes pode ser utilizado para verificar a dependência ou independência entre as variáveis sendo consideradas.

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

O teste é uma extensão direta do qui-quadrado para duas amostras independentes. Em geral, o teste é o mesmo, tanto para duas, como para k amostras independentes.

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Hipóteses e Cálculo

\mathcal{H}_0 : As variáveis são independentes

\mathcal{H}_1 : As variáveis são dependentes

A variável teste é:

$$\chi_v^2 = \frac{\sum_{i=1}^k \sum_{j=1}^l (O_{ij} - E_{ij})^2}{E_{ij}}$$

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Expressão alternativa

A variável teste é:

$$\chi_v^2 = \frac{\sum_{i=1}^k \sum_{j=1}^l (O_{ij} - E_{ij})^2}{E_{ij}} = \frac{\sum_{i=1}^k \sum_{j=1}^l O_{ij}^2}{E_{ij}} - n$$

Prof. Lori Viali, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Onde:

r = número de linhas da tabela;

L = número de colunas da tabela;

O_{ij} = frequência observada na interseção da linha i com a coluna j .

E_{ij} = número de casos esperados na interseção da linha i com a coluna j .

 Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Onde:

χ^2_v é a estatística teste;

$n = \sum_{i=1}^k \sum_{j=1}^L O_{ij}$ = tamanho da amostra;

$E_{ij} = np_{ij}$ são as frequências esperadas de cada célula ij da tabela.

 Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

p_{ij} é a probabilidade de ocorrer uma observação na célula ij . Se as variáveis são supostamente independentes (H_0 é Verdadeira), então $p_{ij} = p_i p_j$, onde p_i é a probabilidade marginal correspondente à linha “ i ” e p_j é a probabilidade marginal correspondente a coluna j .

 Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Como não se conhecem as probabilidades marginais, elas devem ser estimadas através das correspondentes frequências relativas. Então:

$$E_{ij} = n p_{ij} = n p_{i\cdot} \cdot p_{\cdot j} = n \cdot \frac{f_{i\cdot}}{n} \cdot \frac{f_{\cdot j}}{n} = \frac{f_{i\cdot} f_{\cdot j}}{n}$$

 Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

$$f_{i\cdot} = \sum_{j=1}^L f_{ij} \quad e \quad f_{\cdot j} = \sum_{i=1}^k f_{ij}$$

 Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Teste de
Jonckheere-Terpstra

 Prof. Lori Vialli, Dr. – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

Jonckheere-Terpstra Test. This test for differences among several independent samples is more powerful than the Kruskal-Wallis H or median tests. However, it requires that the independent samples be ordinally arranged on the criterion variable (ex, city samples arranged by welfare caseload per 10,000 population, where this is the variable of interest).



Prof. Lori Vialli, Dr – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



The J-T test tests the hypothesis that as one moves from samples low on the criterion to samples high on the criterion, the within-sample magnitude of the criterion variable increases.

Correção para empates

http://www.ens.gu.edu.au/stats/aes3121/lectures/exam_fo.htm



Prof. Lori Vialli, Dr – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística



KRUSKAL, William Henry; WALLIS, William Allen.
Use of ranks in one-criterion variance analysis. *Journal of the American Statistical Association*, v. 47, n. 260, p. 583–621, 1952.



Prof. Lori Vialli, Dr – UFRGS – Instituto de Matemática - Departamento de Estatística – Curso de Estatística

