



# Testes Não Paramétricos

## CAC (Coeficientes de Associação e Correlação)

Prof. Lorí Vialí, Dr.  
<http://www.mat.ufrgs.br/vialí/>  
vialí@mat.ufrgs.br



Prof. Lorí Vialí, Dr. – UFRGS – Instituto de Matemática – Departamento de Estatística – Curso de Estatística



# Medidas de Associação, Correlação e Testes de Significância

*Em muitas situações é necessário saber se dois conjuntos de dados estão relacionados e com que intensidade ocorre esta relação. Medidas destinadas a determinar o grau de relacionamento entre duas ou mais variáveis são denominadas medidas de associação (variáveis qualitativas) ou correlação (variáveis quantitativas).*



Prof. Lorí Vialí, Dr. – UFRGS – Instituto de Matemática – Departamento de Estatística – Curso de Estatística



*Estas medidas são expressas através de um número, que geralmente varia no intervalo de -1 a 1 e são denominados de coeficientes de associação ou de correlação.*



Prof. Lorí Vialí, Dr. – UFRGS – Instituto de Matemática – Departamento de Estatística – Curso de Estatística



# O Coeficiente de Contingência $C$



Prof. Lorí Vialí, Dr. – UFRGS – Instituto de Matemática – Departamento de Estatística – Curso de Estatística



## Conceito

*O coeficiente de contingência  $C$  é uma medida associação entre dois conjuntos de atributos. É útil quando se dispõem apenas de dados apresentados em escala nominal em um ou nos dois conjuntos de atributos.*



Prof. Lorí Vialí, Dr. – UFRGS – Instituto de Matemática – Departamento de Estatística – Curso de Estatística



Para determinar esta medida não é necessário dispor as variáveis em uma determinada maneira. Não importa quem seja linha e quem seja coluna, o valor obtido será o mesmo.



Para calcular o coeficiente de contingência  $C$  os dados devem ser apresentados em uma tabela de contingência como a ilustrada a seguir. Os dados podem ser divididos em qualquer número de categorias, isto é, a tabela pode ser do tipo  $k \times r$ , onde  $k$  = número de colunas e  $r$  = número de linhas.



	$A_1$	$B_2$	...	$B_k$	Total
$B_1$	$x_{11}$	$x_{12}$	...	$x_{1k}$	$s_{1.}$
$B_2$	$x_{21}$	$x_{22}$	...	$x_{2k}$	$s_{2.}$
...	...	...	...	...	...
$B_r$	$x_{r1}$	$x_{r2}$	...	$x_{rk}$	$s_{r.}$
Total	$s_{.1}$	$s_{.2}$	...	$s_{.k}$	$s_{..}$



O coeficiente de contingência pode, então, ser obtido através da seguinte expressão:

$$C = \sqrt{\frac{\chi^2}{n + \chi^2}}$$

Onde

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

é o qui-quadrado calculado conforme já visto.



## Exemplo

Considere-se os valores os valores da tabela como sendo o resultado das variáveis: “Grau de instrução” (coluna) e “Procedência” (linha). Determinar o grau de associação entre as duas variáveis.





	<i>Prim. Grau</i>	<i>Seg. Grau</i>	<i>Superior</i>	<i>Total</i>
<i>Capital</i>	4	5	6	15
<i>Interior</i>	11	4	3	18
<i>Outra</i>	2	3	2	7
<i>Total</i>	17	12	11	40



O qui-quadrado será:

$$\chi^2 = \sum_{i=1}^3 \sum_{j=1}^3 \frac{(O_{ij} - E_{ij})^2}{E_{ij}} = 5,0989$$

O coeficiente de contingência será:

$$C = \sqrt{\frac{\chi^2}{n + \chi^2}} = \sqrt{\frac{5,0989}{40 + 5,0989}} = 0,34$$



O teste de significância  
para o coeficiente  
de contingência



Uma vez observado uma relação entre dois conjuntos de atributos em amostras, quer-se determinar se é plausível concluir pela associação desses mesmos atributos na população de onde foram retiradas as amostras.



Ao se testar a significância de uma medida de associação, está-se na realidade testando a hipótese de nulidade de que não existe associação na população, isto é, que o valor observado poderia ter ocorrido aleatoriamente entre as amostras mesmo que as populações não apresentam qualquer relação.



Para testar a hipótese de nulidade, determina-se a distribuição amostral da estatística, neste caso, a medida de associação, sob  $H_0$ . Utiliza-se, então, uma prova estatística adequada para determinar, a um nível de significância pré-fixado, se o valor observado pela estatística considerada pode ter provavelmente ocorrido sob  $H_0$ .



Embora, muitas estatísticas de associação possam ser determinadas por este método o coeficiente de contingência  $C$ , constitui um caso especial. Uma das razões por que não se pode utilizar a distribuição amostral de  $C$  para testar um determinado valor observado, reside na considerável complexidade matemática de tal procedimento.



Outra razão é que no desenvolvimento do cálculo de  $C$ , já se calcula de forma intermediária uma estatística que constitui uma indicação simples e adequada da significância de  $C$ .



Tal estatística é o  $\chi^2$ . Pode-se determinar se um valor de  $C$  difere significativamente de um valor causal simplesmente determinando se um valor de  $\chi^2$  é significativo.



Para qualquer tabela de contingência  $k \times r$  pode-se determinar a significância do grau de associação pela estatística  $C$ , determinando a probabilidade de ocorrência, sob  $H_0$ , de valores tão grandes quanto o valor observado de  $\chi^2$ , com  $gl = (k - 1)(r - 1)$ .



Se essa probabilidade não supera  $\alpha$ , pode-se rejeitar a hipótese de nulidade, àquele nível. Se o qui-quadrado baseado nos valores amostrais é significativo, pode-se concluir que, na população, a associação entre os dois conjuntos é diferente de zero.



Exemplo





No exemplo anterior foi determinado que o coeficiente de associação entre as variáveis: escolaridade e procedência é  $C = 0,34$ . Para chegar a este valor foi utilizado o valor  $\chi^2 = 5,0989$ . É este valor que vai ser usado para testar a significância de  $C$ .



Nesse caso o grau de liberdade será  $gl = (3 - 1)(3 - 1) = 4$ .

A significância do resultado encontrado, isto é, 5,0989 é 27,73%.

Assim não é possível afirmar que existe associação na população.



## Limitações do Coeficiente de Contingência



A grande aplicabilidade e a determinação relativamente fácil de  $C$  podem dar a entender que se trata de uma medida ideal de associação. Este não é o caso, no entanto, em razão das limitações desta estatística.



Em geral, pode-se dizer que um coeficiente de associação (correlação) deve apresentar pelo menos as seguintes características:

- Onde houver completa falta de associação o coeficiente deve dar zero.
- Quando as variáveis são completamente dependentes entre si, isto é, estão perfeitamente relacionadas o coeficiente deve ser igual a 1.



O coeficiente  $C$  tem a primeira destas características, mas não a segunda. Ele é zero quando não existe associação, mas não atinge o valor um, quando a relação é perfeita, sendo esta a primeira limitação do coeficiente de contingência  $C$ .



O limite superior de  $C$  é uma função do número de categorias. Quando  $k = r$ , o limite superior de  $C$ , isto é, o valor que deveria ocorrer se as variáveis tivessem uma relação perfeita é:

$$\sqrt{\frac{k-1}{k}}$$



Por exemplo, o limite superior de  $C$  para uma tabela  $2 \times 2$  é igual a 0,71. Para uma tabela  $3 \times 3$ , o máximo que  $C$  pode atingir é um valor de 0,82.



O fato de o valor máximo de  $C$ , depender de  $k$  e  $r$  é uma segunda limitação, pois dois coeficientes de contingência só serão comparáveis se provierem de tabelas com o mesmo número de linhas e colunas.



Uma terceira limitação de  $C$  é que os dados devem se prestar para o cálculo do  $\chi^2$  antes que  $C$  possa ser convenientemente utilizado, isto é, o cálculo de  $C$  sofre das mesmas limitações do cálculo do qui-quadrado.



Uma última limitação de  $C$  é que ele não é diretamente comparável com nenhuma outra medida de associação (correlação), como por exemplo, o coeficiente de Pearson, o de Spearman ou o de Kendall.





*A despeito destas limitações o coeficiente de contingência é uma medida útil pela sua larga aplicabilidade, pois não exige suposições sobre a forma da população de escores, não exige continuidade da variável em estudo e requer apenas mensuração nominal.*



*Isto faz do coeficiente de contingência uma medida que pode ser aplicada em situações em que nenhuma outra pode ser aplicada.*



## Exercício



*Resolva o exercício um do Laboratório Sete.*



## O Coeficiente $V$ de Crámer



### Considerações

*Apesar de sua popularidade o coeficiente de contingência tem a desvantagem de que o número de linhas e colunas influencia o resultado. A alternativa é utilizar o coeficiente  $V$  (de Cramer), definido por:*



$$V = \sqrt{\frac{\chi^2}{n \cdot (k - 1)}}$$

Onde:

$n$  = tamanho da amostra

$k$  =  $\min$  {linhas, colunas}



## Exercício



Resolva o exercício dois do  
Laboratório sete.



## O Coeficiente de Correlação por postos de Spearman



### Considerações

Dentre todas as estatísticas com base em postos, o coeficiente de correlação de Spearman foi a que surgiu primeiro e é talvez a mais conhecida hoje. A sua principal vantagem é não exigir normalidade dos dados.



Esta estatística, por vezes designada “rho” ( $\rho$ ), é representada, aqui por  $r_s$ . É uma medida de associação que exige que as duas variáveis tenham mensuração pelo menos ordinal para que os postos possam ser determinados.





## Determinação

Suponha que existam  $n$  pares ordenados por postos representando duas variáveis. Por exemplo, um grupo de estudantes ordenado de acordo com suas notas no vestibular de uma universidade e também de acordo com sua classificação ao fim do primeiro ano.



Representando os escores do vestibular por:  $X_1, X_2, \dots, X_n$  e os escores da classificação ao final do primeiro ano por:  $Y_1, Y_2, \dots, Y_n$  pode-se utilizar uma medida de correlação por postos para determinar o relacionamento entre as duas variáveis.



A correlação entre a classificação no vestibular e a classificação ao fim do primeiro ano seria perfeita se e somente se  $X_i + Y_i = C = \text{Constante}$ , para todo “ $i$ ”. Portanto, parece lógico usar as diversas diferenças:  $d_i = X_i - Y_i$  como indicativo da diferença entre os dois conjuntos de postos.



Suponha que o aluno  $A$  tenha obtido o primeiro lugar no vestibular, mas ao fim do primeiro ano esteja em sexto lugar. Neste caso,  $d = 1 - 6 = -5$ . Um aluno  $B$ , por outro lado, ficou em nono lugar no vestibular e agora, ao final do primeiro ano, é o segundo colocado. O valor de  $d$  para ele é então:  $d = 9 - 2 = 7$ .



O valor das diversas diferenças “ $d$ ” fornece uma ideia do relacionamento entre as duas variáveis. Se a relação entre os dois conjuntos de postos fosse perfeita, todos os valores de “ $d$ ” seriam zero. Quanto maiores os diversos valores de “ $d$ ”, menor será a associação entre as duas variáveis.



A utilização direta das diferenças ( $d$ ) para o cálculo do coeficiente de correlação acarreta dificuldades. Por exemplo, os valores negativos e positivos se cancelam se forem somados. Por isso é utilizado o valor de  $d$  ao quadrado,  $d^2$ , para eliminar esta dificuldade.



A expressão para o cálculo do coeficiente de correlação de Spearman é baseada no cálculo do coeficiente de Pearson (estatística paramétrica)  $r$ , onde:

$$r = \frac{\sum xy}{\sqrt{\sum x^2 \sum y^2}}$$

Onde:  $x = X - \bar{X}$   
 $y = Y - \bar{Y}$

Mas quando  $X$  e  $Y$  são postos,  $r = r_s$  e a soma de  $n$  inteiros:  $1, 2, \dots, n$  é dada por:

$$\sum X = \sum Y = \frac{n(n+1)}{2}$$

E a soma dos quadrados dos postos, isto é,  $1^2 + 2^2 + \dots + n^2$  é dada por:

$$\sum X^2 = \sum Y^2 = \frac{n(n+1)(2n+1)}{6}$$

Como:  $x = X - \bar{X}$ , então:

$$\sum x^2 = \sum (X - \bar{X})^2 = \sum X^2 - \frac{(\sum X)^2}{n} = \sum X^2 - n\bar{X}^2$$

Mas:  $\sum X = \sum Y = \frac{n(n+1)}{2}$

e:

$$\sum X^2 = \sum Y^2 = \frac{n(n+1)(2n+1)}{6}$$

Assim:

$$\begin{aligned} \sum x^2 &= \sum X^2 - \frac{(\sum X)^2}{n} = \frac{n(n+1)(2n+1)}{6} - \frac{n^2(n+1)^2}{4n} = \\ &= \frac{n(n+1)(2n+1)}{6} - \frac{n(n+1)^2}{4} = \frac{n^3 - n}{12} = \sum y^2 \end{aligned}$$

Mas:  $d = x - y$ .

Então  $d^2 = (x - y)^2 = x^2 + y^2 - 2xy$

Assim:

$$\sum d^2 = \sum (x - y)^2 = \sum x^2 + \sum y^2 - 2\sum xy$$

Pela expressão do cálculo do coeficiente de correlação de Pearson, tem-se:

$$r = \frac{\sum xy}{\sqrt{\sum x^2 \sum y^2}} = r_s$$



Então:  $\sum xy = r_S \sqrt{\sum x^2 \sum y^2}$

e  $\sum d^2 = \sum x^2 + \sum y^2 - 2r_S \sqrt{\sum x^2 \sum y^2}$

Portanto:

$$r_S = \frac{\sum x^2 + \sum y^2 - \sum d^2}{2\sqrt{\sum x^2 \sum y^2}}$$



Substituindo  $\sum x^2$  e  $\sum y^2$  na expressão e simplificando, tem-se:

$$r_S = 1 - \frac{6\sum d^2}{n^3 - n}$$



## Exemplo

Determinar o coeficiente de correlação de Spearman para as variáveis:  $X$  e  $Y$  do exercício três do laboratório sete.



	$X$	$Y$
1	5	6
2	9	16
3	17	18
4	1	1
5	2	3
6	21	21
7	3	7
8	29	20
9	7	15
10	100	22



	$X$	$Y$	$P_X$	$P_Y$	$d_i$
1	5	6	4	3	1
2	19	16	6	6	0
3	17	18	7	7	0
4	1	1	1	1	0
5	2	3	2	2	0
6	21	21	8	9	-1
7	3	7	3	4	-1
8	29	20	9	8	1
9	7	15	5	5	0
10	100	22	10	10	0
Total	---	---	---	---	0



O valor do coeficiente de correlação será então:

$$r_S = 1 - \frac{6.4}{10^3 - 10} = 0,9760$$



## Empates

Ocasionalmente podem ocorrer empates entre os escores de dois valores na mesma variável. Quando isto ocorre, a cada um deles é atribuído a média dos postos que seriam atribuídos caso o empate não ocorresse, isto é, adota-se o procedimento usual.



Quando a proporção de empates é grande torna-se necessário a utilização de um fator de correção.

O efeito de postos empatados na variável  $X$  ou  $Y$ , reduz a soma dos quadrados. Portanto, quando houver empates é necessário corrigir a soma dos quadrados.



Neste caso: 
$$T = \frac{t^3 - t}{12}$$

Onde  $t$  = número de observações empatadas em determinado posto.

A soma dos quadrados corrigida será então:

$$\sum x^2 = \frac{n^3 - n}{12} - \sum T_X \quad e \quad \sum y^2 = \frac{n^3 - n}{12} - \sum T_Y$$



$$\sum x^2 = \frac{n^3 - n}{12} - \sum T_X \quad e \quad \sum y^2 = \frac{n^3 - n}{12} - \sum T_Y$$

$\sum T$ , onde a soma de  $T$  indica o somatório sobre os vários valores de  $T$  para todos os grupos de observações empatadas.



Assim se o número de empates for considerável o cálculo do coeficiente de correlação de Spearman deve ser realizado por:

$$r_S = \frac{\sum x^2 + \sum y^2 - \sum d^2}{2\sqrt{\sum x^2 \sum y^2}}$$

Onde:

$$\sum x^2 = \frac{n^3 - n}{12} - \sum T_X \quad e \quad \sum y^2 = \frac{n^3 - n}{12} - \sum T_Y$$





## Teste para o Coeficiente de Correlação de Spearman



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



Se as amostras utilizadas no cálculo do coeficiente de correlação de Spearman foram selecionadas aleatoriamente, então pode-se utilizar os seus valores para testar se as variáveis correspondentes estão associadas na população, isto se  $r_S$  pode ser considerado diferente de zero.



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



### Pequenas Amostras

Suponha verdadeira a hipótese de nulidade, isto é, suponha-se que  $\rho_S = 0$ . Se as amostras são aleatórias, então para uma dada ordem dos escores de  $X$ , todas as ordens possíveis dos escores  $Y$  tem a mesma probabilidade.



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



Para  $n$  valores existem  $n!$  ordenações possíveis dos escores  $X$  que podem ocorrer com qualquer ordenação dos escores  $Y$ . Como essas ordenações são igualmente prováveis, a probabilidade de ocorrência de determinada ordenação dos escores  $X$  conjuntamente com dada ordenação dos escores  $Y$  é  $1/n!$ .



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



A cada uma das possíveis ordenações de  $Y$  está associado um valor de  $r_S$ . A probabilidade de ocorrência, sob  $H_0$ , de cada valor de  $r_S$  é então proporcional ao número de permutações que originam aquele valor.

Aplicando a fórmula do cálculo do  $r_S$  pode-se perceber que:



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



Se  $n = 2$ , então  $r_S$  só pode assumir os valores  $-1$  e  $+1$ . Cada um destes valores tem probabilidade  $1/2$ .

Se  $n = 3$ , então os possíveis valores de  $r_S$  são  $-1$ ,  $-1/2$ ,  $+1/2$  e  $+1$ . Cada um destes valores tem probabilidade de ocorrência, sob  $H_0$ , respectivamente de:  $1/6$ ,  $1/3$ ,  $1/3$  e  $1/6$ .



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



A tabela  $P$  (Siegel, pg. 315) fornece os valores críticos unilaterais de  $r_S$  obtidos por este método. Para  $n$  variando de 4 a 30, a tabela fornece o valor de  $r_S$  com a probabilidade associada, sob  $H_0$ , para  $p = 0,05$ , e  $p = 0,01$ .

## Exemplo

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

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

Suponha que 12 pares das variáveis  $X$  e  $Y$  forneceram um coeficiente de correlação  $r_S = 0,82$ . Verifique se é possível afirmar que esse valor é significativamente maior do que zero a uma probabilidade de 1%.

Pela tabela  $P$  vê-se que esse valor é significativo ao nível  $p < 0,01$  (teste unilateral). Pode-se então rejeitar a hipótese concluindo que, na população estudada, as duas variáveis estão positivamente associadas.

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

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

## Grandes Amostras

Quando  $n$  é 10 ou mais, a significância de um valor obtido de  $r_S$ , sob a hipótese de nulidade, pode ser comprovado através de (Kendall, 1948):

$$t_{n-2} = r_S \sqrt{\frac{n-2}{1-r_S^2}}$$

## O Coeficiente de Correlação por Postos de Kendall

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

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



### Conceito

O coeficiente de correlação por postos de Kendall,  $\tau$  (tau) é uma medida de associação para variáveis ordinais. Neste caso,  $\tau$  dará uma medida do grau de associação entre os dois conjuntos de postos.



A distribuição amostral de  $\tau$ , sob  $H_0$  é conhecida e pode, portanto ser testada. Uma vantagem de  $\tau$  sobre o coeficiente  $r_s$  é que  $\tau$  pode ser generalizado para um coeficiente de correlação parcial que será visto posteriormente.



Suponha-se que se peça a dois juizes  $X$  e  $Y$ , para atribuir postos a quatro objetos. Por exemplo, poderíamos solicitar que classificassem quatro ensaios por ordem de qualidade de estilo.



Represente-se os quatro ensaios por  $a, b, c$  e  $d$ . Os postos obtidos foram:

Ensaio	$a$	$b$	$c$	$d$
Juiz $X$	3	4	2	1
Juiz $Y$	3	1	4	2



Reordenando os ensaios, de forma que os postos atribuídos pelo juiz  $X$  apareçam na ordem natural (1, 2, ...,  $n$ ), tem-se:

Ensaio	$a$	$b$	$c$	$d$
Juiz $X$	1	2	3	4
Juiz $Y$	2	4	3	1



Temos agora condições de determinar o grau de correspondência entre os julgamentos de  $X$  e de  $Y$ . Os postos atribuídos pelo juiz  $X$  já estando na ordem natural, passa-se a determinar quantos pares de postos atribuídos pelo juiz  $Y$  se acham em sua ordem correta (natural) em relação ao outro.



Considera-se primeiro todos os pares de postos em que figura o posto 2 do juiz  $\mathcal{Y}$  - o posto mais à esquerda em seu conjunto. O primeiro par, 2 e 4, está na ordem correta, isto é, 2 precede 4. Como a ordem é "natural", atribui-se o escore +1 a este par.



Os postos 2 e 3 constituem o segundo par, que também está na ordem correta (o 2 vem antes do 3), recebendo, assim, também o escore +1. O terceiro par consiste dos postos 2 e 1.



Esses escores não estão na ordem "natural", pois 2 não vem antes do 1. Atribui-se então ao par o escore -1. O total dos escores de todos os pares de postos que incluem o posto 2 é:  $+1 + 1 - 1 = 1$ .



Considera-se, em seguida, todos os pares possíveis de postos que incluem o posto 4 (segundo posto do juiz  $\mathcal{Y}$  a contar da esquerda) e um outro posto que o segue. Um par é o 4 e 3 cujos elementos não estão em ordem, recebendo, por isso, o escore -1. O total destes escores é:  $-1 - 1 = -2$ .



Considerando agora o posto 3 e os seguintes, obtém-se um único par: 3 e 1, cujos elementos não estão em ordem natural; o par recebe o escore -1. O total de todos os escores assim atribuídos é:  $1 - 2 - 1 = -2$ .



Qual é o total máximo possível que se pode obter para os escores atribuídos a todos os pares de postos do juiz  $\mathcal{Y}$ ?





Obter-se-ia o total máximo se os postos dos juízes  $X$  e  $Y$  tivessem apresentado perfeita concordância, porque então, colocados os postos de  $X$  em sua ordem natural, cada par de postos do juiz  $Y$  se apresentaria também na ordem natural, recebendo, assim, o escore +1.



O total máximo possível, no caso de uma concordância perfeita entre  $X$  e  $Y$ , seria 6.

O grau de relacionamento entre os dois conjuntos de postos é dado pela razão do total efetivo de escores +1 e -1, para o total máximo possível.



O coeficiente de correlação por postos de Kendall é a razão:

$$\tau = (\text{total efetivo}) / (\text{total máximo possível}) = -2 / 6 = -0,33.$$



Isto é,  $\tau = -0,33$  é uma medida da concordância entre os postos atribuídos aos ensaios pelos juízes  $X$  e  $Y$ .



Podê-se considerar  $\tau$  como função do número mínimo de inversões ou permutas entre elementos vizinhos, necessário para transformar um posto em outro. Este coeficiente é uma espécie de coeficiente de desordenamento.



## Método

Viu-se que:

$$\tau = (\text{total efetivo}) / (\text{total máximo possível})$$

Em geral, o escore máximo possível

será:

$$\binom{n}{2} = \frac{n(n-1)}{2}$$



Anotando por  $S$  a soma dos escores +1 e -1 para todos os pares, tem-se:

$$\tau = \frac{S}{n(n-1)} = \frac{2S}{n(n-1)}$$



Onde  $n$  = número de pares envolvidos.

O cálculo de  $S$  pode ser abreviado da seguinte forma:

Após colocados em sua ordem natural os postos do juiz  $X$ , os postos correspondentes do Juiz  $Y$  se apresentam na seguinte ordem:

Juiz  $Y$ : 2 4 3 1



Pode-se determinar o valor de  $S$  partindo do primeiro número à esquerda e contando o número de postos à sua direita que são superiores. Deste número subtrai-se o número de postos à direita que são inferiores. Procedendo desta forma para todos os postos e somando os resultados se obtém  $S$ .



Assim, para os valores acima, os postos à direita de 2 e superiores a 2 são 3 e 4, e o 1 é inferior. O posto 2 contribui, então, com  $2 - 1 = 1$  para o valor de  $S$ .



Para o posto 4 existe 0 valores superiores e dois inferiores, então sua contribuição é:  $0 - 2 = -2$ . Para o posto 3, existe à direita apenas um inferior, então sua contribuição para  $S$  é  $0 - 1 = -1$ .



O total destas contribuições é então de:

$$1 - 2 - 1 = -2 = S.$$

Conhecido  $S$  pode-se aplicar a expressão para o cálculo do coeficiente  $\tau$  para os postos atribuídos pelos dois juizes:

$$\tau = \frac{S}{n(n-1)} = \frac{2S}{n(n-1)} = \frac{2(-2)}{4(4-1)} = \frac{-4}{12} = -0,33$$





## Exemplo

Abaixo as variáveis autoritarismo e aspirações de status social para 12 estudantes.

Calcular o valor de  $\tau$  para os dados.

1	2	3	4	5	6	7	8	9	10	11	12
3	4	2	1	8	11	10	6	7	12	5	9
3	6	5	1	10	9	8	3	4	12	7	11

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

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

Para calcular  $\tau$  vamos reordenar os estudantes de modo que o primeiro conjunto de postos se apresente na ordem natural:

1	2	3	4	5	6	7	8	9	10	11	12
1	2	3	4	5	6	7	8	9	10	11	12
1	5	2	6	7	3	4	10	11	8	9	12

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

1	2	3	4	5	6	7	8	9	10	11	12
1	2	3	4	5	6	7	8	9	10	11	12
1	5	2	6	7	3	4	10	11	8	9	12

Dispostos em sua ordem natural os postos de  $X$ , determinamos o valor de  $S$  para os postos de  $Y$ :

$$S = (11 - 0) + (7 - 3) + (9 - 0) + (6 - 2) + (5 - 2) + (6 - 0) + (5 - 0)(2 - 2) + (1 - 2) + (2 - 0) + (1 - 0) = 44$$

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

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

O posto relativo a autoritarismo mais à esquerda é 1. Este posto tem 11 postos superiores a sua direita e nenhum que lhe seja inferior. Sua contribuição para  $S$  é, pois,  $(11 - 0)$ . O posto 5 contribui com  $(7 - 3)$  para  $S$ , pois a sua direita existem 7 superiores e a sua esquerda estão 3 postos que lhe são inferiores. E assim por diante.

Sabido que  $S = 44$  e  $n = 12$ , aplica-se então a expressão do cálculo do coeficiente.

$$\tau = \frac{S}{\frac{n(n-1)}{2}} = \frac{2S}{n(n-1)} = \frac{2 \cdot 44}{12(12-1)} = \frac{88}{132} = 0,67$$

Esse valor representa o grau de relacionamento entre o autoritarismo e as aspirações de status social dos 12 estudantes.

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

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

## Empates

Quando há empate entre duas ou mais observações de  $X$  ou de  $Y$ , atribui-se as observações empatadas a média dos postos que lhes caberiam se não houvesse empate.

O efeito dos empates consiste em modificar o denominador da fórmula de  $\tau$ .



Assim, a expressão para o cálculo do coeficiente quando ocorrem empates é:

$$\tau = \frac{S}{\sqrt{\frac{1}{2}n(n-1) - T_x} \sqrt{\frac{1}{2}n(n-1) - T_y}}$$

Onde  $T_X = \frac{1}{2}\sum t(t-1)$  e  $T_Y = \frac{1}{2}\sum t(t-1)$ , onde  $t$  é o número de observações empatadas em cada grupo de empates nas variáveis  $X$  e  $Y$ .



## Teste para o Coeficiente Tau de Kendall



Se uma amostra aleatória for extraída de uma população em que  $X$  e  $Y$  não estão relacionados e se atribuem aos elementos da amostra postos relativos à  $X$  e  $Y$ , então, para uma dada ordem de postos de  $X$  todas as ordens possíveis de postos de  $Y$  são igualmente verossímeis.



Isto é, para uma dada ordem dos postos de  $X$ , qualquer ordem de  $Y$  tem a mesma probabilidade de ocorrência que qualquer outra ordem. Suponhamos os valores de  $X$  dispostos na ordem natural  $1, 2, 3, \dots, n$ .



Para tal ordenação dos postos de  $X$ , todas as  $n!$  ordens possíveis dos postos de  $Y$  são igualmente prováveis sob  $H_0$ . Portanto, qualquer ordenação em particular dos postos de  $Y$  tem probabilidade  $1/n!$  de ocorrência, sob  $H_0$ .





Probabilidades de  $\tau$ , sob  $H_0$  para  $n = 4$ .

Valor de $\tau$	Frequência de ocorrência sob $H_0$	Probabilidade de ocorrência sob $H_0$
-1,00	1	1/24
-0,67	3	3/24
-0,33	5	5/24
0,00	6	6/24
0,33	3	5/24
0,67	5	3/24
1,00	1	1/24



A cada uma das  $n!$  disposições possíveis de postos de  $Y$  acha-se associado um valor de  $\tau$ . Esses valores possíveis do índice variarão de  $+1$  a  $-1$  e podem ser dispostos em uma distribuição de frequências.



Por exemplo, para  $n = 4$ , há  $4! = 24$  ordenações possíveis dos postos de  $Y$  e a cada uma delas está associado um valor de  $\tau$ . A tabela anterior fornece a frequência de ocorrência sob  $H_0$ . A medida que  $n$  cresce é cada vez mais trabalhoso construir as distribuições.



A medida que  $n$  cresce a distribuição de  $\tau$  tende para uma normal de média  $\mu_\tau = 0$  e desvio padrão dado por:

$$\sigma_\tau = \sqrt{\frac{2(2n+5)}{9n(n-1)}}$$



## O Coeficiente de Correlação Parcial de Postos de Kendal

Quando se observa uma correlação entre duas variáveis existe sempre a possibilidade de que tal correlação seja devida à associação de cada uma das duas variáveis com uma terceira variável.



*Por exemplo, em um grupo de pessoas de diversas idades, pode-se verificar uma alta correlação entre a amplitude do vocabulário e a altura.*



*Tal correlação, entretanto, pode não refletir um relacionamento verdadeiro ou direto entre as duas variáveis mas resultado do fato de que tanto a amplitude do vocabulário quanto a altura estão relacionados com uma terceira variável a idade.*



*Problemas deste tipo podem ser abordados através da determinação de um coeficiente de correlação parcial. Na correlação parcial os efeitos de uma terceira variável  $Z$  sobre as variáveis  $X$  e  $Y$  são controlados mantendo-a constante.*



*Ao planejar o experimento, pode-se adotar dois caminhos. Introduzir controles experimentais com o propósito de eliminar a influência da terceira variável ou utilizar métodos estatísticos para eliminar tal influência.*



*Por exemplo, para se estudar a relação entre a capacidade de memorização e a capacidade para resolver certos tipos de problemas será necessário controlar o efeito das diferenças de inteligência.*



*Uma alternativa é escolher pessoas com o mesmo nível de inteligência. Se isto não for possível, pode-se aplicar então o controle estatístico.*





Com a correlação parcial o efeito da inteligência sobre a relação entre memorização e capacidade de resolução de problemas poderá ser determinada de forma direta ou não-contaminada.



Suponha que os postos de 4 pessoas em relação a 3 variáveis  $X$ ,  $Y$  e  $Z$  foram obtidos. Deseja-se determinar a correlação entre  $X$  e  $Y$  quando  $Z$  é controlada.

Pessoas	$a$	$b$	$c$	$d$
Posto de $Z$	1	2	3	4
Posto de $X$	3	1	2	4
Posto de $Y$	2	1	3	4



Para cada uma das variáveis sabe-se que há  $\binom{4}{2}$  pares de postos possíveis. Colocados os postos de  $Z$  em sua ordem natural, observa-se cada par de postos possível em  $X$ ,  $Y$  e  $Z$ . Atribui-se o sinal  $+$  aos pares em que o posto mais baixo precede o posto mais alto e um sinal  $-$  caso contrário.



Suponha que os postos de 4 pessoas em relação a 3 variáveis  $X$ ,  $Y$  e  $Z$  foram obtidos. Deseja-se determinar a correlação entre  $X$  e  $Y$  quando  $Z$  é controlada.

Par	$(a, b)$	$(a, c)$	$(a, d)$	$(b, c)$	$(b, d)$	$(c, d)$
$Z$	+	+	+	+	+	+
$X$	-	-	+	+	+	+
$Y$	-	+	+	+	+	+



As informações obtidas são resumidas em uma tabela  $2 \times 2$ .

Sinal do Par	+	-
+	$(+, +)$	$(+, -)$
-	$(-, +)$	$(-, -)$



No primeiro par  $(a, b)$  tanto  $X$  quanto  $Y$  discordam do sinal de  $Z$  então a frequência vai para a célula  $D$   $(-, -)$ . No segundo par  $(c, d)$   $Y$  concorda com  $Z$  mas  $X$  não. A frequência é registrada na célula  $C$   $(-, +)$ .



Os pares restantes apresentam todos o mesmo sinal e portanto a frequência vai para a célula A (+, +). Em resumo, tem-se:

Sinal do Par	+	-	Total
+	4	0	4
-	1	1	2
Total	5	1	6

O coeficiente de correlação por postos de Kendall entre duas variáveis ( $X$ ,  $Y$ ) considerando constante uma terceira variável ( $Z$ ) é dado então por:

$$\tau_{XY.Z} = \frac{AD - BC}{\sqrt{(A+D)(C+D)(A+C)(B+D)}}$$

Para os dados sendo analisados, tem-se:

$$\begin{aligned} \tau_{XY.Z} &= \frac{AD - BC}{\sqrt{(A+D)(C+D)(A+C)(B+D)}} = \\ &= \frac{4 \cdot 1 - 0 \cdot 1}{\sqrt{(4+0)(1+1)(4+1)(0+1)}} = \\ &= \frac{4}{\sqrt{4 \cdot 2 \cdot 5 \cdot 1}} = \frac{4}{\sqrt{40}} = \sqrt{0,4} = 0,6325 \end{aligned}$$

A correlação entre  $X$  e  $Y$ , com o efeito de  $Z$  constante é então:  $\tau_{XY.Z} = 0,63$ . Se fosse calculado a correlação entre  $X$  e  $Y$  sem considerar  $Z$  o resultado seria:  $\tau = 4/6 = 0,67$ .

A expressão para o cálculo do coeficiente de correlação parcial por postos de Kendall é algumas vezes denominada de "Coeficiente Phi" e pode-se mostrar que:

$$\tau_{XY.Z} = \sqrt{\frac{\chi^2}{n}}$$

A maneira de calcular o CCPPK não é prática quando  $n$  é grande. Nesse caso, pode-se utilizar a seguinte expressão alternativa devida a Kendall:

$$\tau_{XY.Z} = \frac{\tau_{XY} - \tau_{XZ}\tau_{YZ}}{\sqrt{(1 - \tau_{XZ}^2)(1 - \tau_{YZ}^2)}}$$



## A teste de associação linear ou Qui-quadrado de Mantel-Haenszel

$X_i \ Y_j$	1	2	...	$k$	Total
1	$f_{11}$	$f_{12}$	...	$f_{1k}$	$r_1$
2	$f_{21}$	$f_{22}$	...	$f_{2k}$	$r_2$
...	...	...	...	...	...
$l$	$f_{l1}$	$f_{l2}$	...	$f_{lk}$	$r_l$
Total	$c_1$	$c_2$	...	$c_k$	$W$

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

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

O qui-quadrado de Mantel-Haenszel também denominado de teste qui-quadrado de associação linear por linear é uma medida de significância para variáveis ordinais. Ele é utilizado para testar a significância do relacionamento linear entre duas variáveis ordinais, porque é mais poderoso do que o qui-quadrado de Pearson.

O qui-quadrado de Mantel-Haenszel não é adequado para variáveis nominais. Se ele for significativo então é possível dizer que o aumento de uma variável está associado com o aumento (ou decréscimo, para relacionamentos negativos) da outra variável.

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

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

Como outras estatísticas que utilizam o qui-quadrado ele não deve ser utilizado com valores baixos de frequências.

O teste de associação linear de Mantel-Haenszel é dado por:

$$\chi^2_{MH} = (W - 1)r^2$$

onde  $r$  é o coeficiente de correlação de Pearson definido conforme o apresentado a seguir. O grau de liberdade da estatística é 1.

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

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

O algoritmo para o cálculo do coeficiente de correlação de Pearson para uma tabela de contingência é dado por:

$$r = \frac{\text{cov}(X, Y)}{\sqrt{S_X S_Y}}$$



Onde:

$$\text{Cov}(X, Y) = \sum x_i y_j f_{ij} - \left( \sum_{i=1}^l x_i r_i \right) \left( \sum_{j=1}^k y_j c_j \right) / W$$

e:

$$S_X = \sum_{i=1}^l x_i^2 r_i - \left( \sum_{i=1}^l x_i r_i \right)^2 / W$$

$$S_Y = \sum_{j=1}^k y_j^2 c_j - \left( \sum_{j=1}^k y_j c_j \right)^2 / W$$



## Exemplo

	1	2	3	Total
1	4	5	6	15
2	11	4	3	18
3	2	3	2	7
Total	17	12	11	40



Onde:

$$\text{Cov}(X, Y) = \sum x_i y_j f_{ij} - \left( \sum_{i=1}^l x_i r_i \right) \left( \sum_{j=1}^k y_j c_j \right) / W = -3,20$$

e:

$$S_X = \sum_{i=1}^l x_i^2 r_i - \left( \sum_{i=1}^l x_i r_i \right)^2 / W = 20,40$$

$$S_Y = \sum_{j=1}^k y_j^2 c_j - \left( \sum_{j=1}^k y_j c_j \right)^2 / W = 27,10$$



$$W = 40.$$

Portanto:

$$\begin{aligned} \chi^2_{MH} &= (W - 1)r^2 = (40 - 1)(-0,14)^2 \\ &= 0,7224. \end{aligned}$$





<http://www.statsguides.bham.ac.uk/>

Guias do SPSS 9, 10 e Minitab 12.

<http://www.uc.edu/sashtml/proc/zompmeth.htm>

Fórmulas de vários tipos de coeficientes

<http://www.nyu.edu/its/socsci/Docs/correlate.html>

Correção de empates para o cc de Spearman

<http://www.uc.edu/sashtml/stat/chap28/sect20.htm>

*SHESKIN, David J. Handbook of Parametric and Nonparametric Statistical Procedures. 4<sup>th</sup> ed. Boca Raton (FL): Chapman & Hall/CRC, 2007.*

