

Krzysztof Trajkowski

# **Pakiet CressieReadTest**

28 maja 2013

## Test Cressie-Read

Do badania tabel kontyngencji bardzo często stosuje się testy niezależności  $\chi^2$  Pearsona lub  $G^2$  największej wiarygodności. Istnieje jednak bardzo ciekawa (choć mniej popularna) statystyka  $D^2$  zaproponowana przez Reada i Cressie która ma na celu ujednoczenie zapisu całej rodziny statystyk za pomocą poniższego wzoru:

$$D^2 = \frac{2}{\lambda(\lambda + 1)} \sum_{i=1}^r \sum_{j=1}^c O_{ij} \left[ \left( \frac{O_{ij}}{E_{ij}} \right)^\lambda - 1 \right]$$

gdzie:

- $O_{ij}$  – empiryczna liczebność  $i$ -tego wiersza oraz  $j$ -tej kolumny,
- $E_{ij}$  – oczekiwana liczebność  $i$ -tego wiersza oraz  $j$ -tej kolumny,
- $r$  – liczba wierszy,
- $c$  – liczba kolumn.

Zwróćmy uwagę, że wyrażenie  $\lambda(\lambda + 1)$  musi być różne od zera. A więc parametr  $\lambda$  nie może być równy 0 lub  $-1$ . Cressie oraz Read sugerują, aby wartość parametru  $\lambda$  była równa  $\frac{2}{3}$  jako kompromis między statystyką  $\chi^2$  Pearsona ( $\lambda = 1$ ) i  $G^2$  wskaźnika wiarygodności ( $\lambda \rightarrow 0$ ).

```
m = matrix(c(25, 15, 23, 56), 2, 2)
library(CressieReadTest)
cr.test(m)

##
## D-squared Cressie-Read test
##
## data: m
## D = 12.2532, lambda = 0.6667, df = 1.0000, p-value = 0.0004645
```

Dobierając odpowiednią wartość parametru  $\lambda$  możemy uzyskać wyniki dla kilku różnych testów niezależności opartych na statystyce  $\chi^2$ . Np. statystykę  $\chi^2$  Pearsona otrzymamy gdy  $\lambda = 1$ , z kolei statystykę Neymana dla  $\lambda = -2$  która jest modyfikacją testu  $\chi^2$  Pearsona. Statystykę testu  $G^2$  największej wiarygodności uzyskamy dla parametru  $\lambda \rightarrow 0$ , a jego modyfikację Kullback-Leibler gdy  $\lambda \rightarrow -1$ . Natomiast rozwiązanie zaproponowane przez Freemana i Tukeya otrzymamy dla  $\lambda = -\frac{1}{2}$ . Poniżej przykłady z wykorzystaniem tych testów.

Statystyka chi-kwadrat Pearsona (Pearson chi-squared statistic)

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

```
cgf.test(m, test = "p")

##
## X-squared Pearson test
##
## data: m
## P = 12.3, df = 1.0, p-value = 0.0004532
```

```

cr.test(m, lambda = 1)

##
## D-squared Cressie-Read test (Pearson)
##
## data: m
## D = 12.3, lambda = 1.0, df = 1.0, p-value = 0.0004532

```

Modyfikacja Neyman's statystyki  $\chi^2$ :

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

```

cgf.test(m, test = "n")

##
## X-squared Neyman's test
##
## data: m
## N = 13.2, df = 1.0, p-value = 0.0002793

cr.test(m, lambda = -2)

##
## D-squared Cressie-Read test (Neyman's)
##
## data: m
## D = 13.2, lambda = -2.0, df = 1.0, p-value = 0.0002793

```

Inna często spotykana statystyka to wskaźnik wiarygodności (log likelihood ratio statistic)

$$G^2 = 2 \sum_{i=1}^r \sum_{j=1}^c O_{ij} \ln \left( \frac{O_{ij}}{E_{ij}} \right)$$

```

cgf.test(m, test = "g")

##
## G-squared Likelihood Ratio test
##
## data: m
## G = 12.27, df = 1.00, p-value = 0.0004603

cr.test(m, lambda = 1e-05)

##
## D-squared Cressie-Read test (G-squared)
##
## data: m
## D = 12.27, lambda = 0.00, df = 1.00, p-value = 0.0004603

```

Modyfikacja Kullback-Leibler statystyki  $G^2$ :

$$KL = 2 \sum_{i=1}^r \sum_{j=1}^c E_{ij} \ln \left( \frac{E_{ij}}{O_{ij}} \right)$$

```
cgf.test(m, test = "kl")
##
## G-squared Kullback-Leibler test
##
## data: m
## KL = 12.57, df = 1.00, p-value = 0.0003929
cr.test(m, lambda = -0.99999)
##
## D-squared Cressie-Read test (Kullback-Leibler)
##
## data: m
## D = 12.57, lambda = -1.00, df = 1.00, p-value = 0.0003929
```

Poniżej statystyka zaproponowana przez Freemana i Tukeya:

$$FT = 4 \sum_{i=1}^r \sum_{j=1}^c \left( \sqrt{O_{ij}} - \sqrt{E_{ij}} \right)^2$$

```
cgf.test(m, test = "ft")
##
## F-squared Freeman-Tukey's test
##
## data: m
## FT = 12.38, df = 1.00, p-value = 0.0004347
cr.test(m, lambda = -0.5)
##
## D-squared Cressie-Read test (Freeman-Tukey's)
##
## data: m
## D = 12.38, lambda = -0.50, df = 1.00, p-value = 0.0004347
```

Na bazie statystyki  $\chi^2$  można obliczyć kilka współczynników, które określają siłę związku badanych zmiennych.

- współczynnik Yule'a – ma zastosowanie dla tabel o wymiarach  $2 \times 2$  oraz  $\phi \in \langle -1; 1 \rangle$ :

$$\phi = \sqrt{\frac{\chi^2}{n}}$$

- współczynnik Pearsona – ma zastosowanie dla tabel o wymiarach  $r \times c$  oraz  $C \in \langle 0; \sqrt{\frac{\min(r,c)-1}{\min(r,c)}} \rangle$ :

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

- współczynnik Cramera – nie wskazuje kierunku korelacji oraz  $V \in \langle 0; 1 \rangle$ :

$$V = \sqrt{\frac{\chi^2}{n(\min(r, c) - 1)}}$$

- współczynnik Czupiurowa – nie wskazuje kierunku korelacji oraz  $T \in \langle 0; 1 \rangle$ :

$$T = \sqrt{\frac{\chi^2}{n\sqrt{(r-1)(c-1)}}$$

Poniżej są przedstawione obliczenia dla wszystkich omówionych testów oraz współczynniki korelacji:

```
allcr.test(m)

## $test
##                lambda Statistic df      p-val
## Pearson's Chi-squared  1.0000     12.30  1 0.0004532
## Log likelihood ratio   0.0000     12.27  1 0.0004603
## * Williams correction  0.0000     12.08  1 0.0005086
## Cressie-Read           0.6667     12.25  1 0.0004645
## Freeman-Tukey's       -0.5000     12.38  1 0.0004347
## Neyman's              -2.0000     13.20  1 0.0002793
## Kullback-Leibler      -1.0000     12.57  1 0.0003929
##
## $coefficient
##                Y-Yule'a C-Pearson V-Cramer T-Czupurow
## Coefficient:    0.3215    0.3061    0.3215    0.3215
```

Przedstawione powyżej formuły matematyczne (testy niezależności) są także wykorzystywane do badania zgodności danych liczbowych z określonym rozkładem np. jednostajnym. Poniżej przykłady dla dwóch rozkładów jednostajnych.

### Rozkład jednostajny–dyskretny:

```
set.seed(8746)
s = sample(0:6, 150, T)
table(s)

## s
##  0  1  2  3  4  5  6
## 29 14 27 21 20 20 19

w = as.numeric(table(s))
cr.gof(w)
```

```
##
## D-squared Cressie-Read test for given probabilities
##
## data: w
## D = 7.1584, lambda = 0.6667, df = 6.0000, p-value = 0.3064
cr.gof(w, lambda = 1)

##
## D-squared Cressie-Read test (Pearson) for given probabilities
##
## data: w
## D = 7.173, lambda = 1.000, df = 6.000, p-value = 0.3051
```

### Rozkład jednostajny–ciągły:

```
set.seed(3254)
s = runif(150)
p = seq(0, 1, 0.2)
table(cut(s, p))

##
## (0,0.2] (0.2,0.4] (0.4,0.6] (0.6,0.8] (0.8,1]
## 21 29 36 30 34

w = as.numeric(table(cut(s, p)))
cr.gof(w)

##
## D-squared Cressie-Read test for given probabilities
##
## data: w
## D = 4.5347, lambda = 0.6667, df = 4.0000, p-value = 0.3385
cr.gof(w, lambda = 1)

##
## D-squared Cressie-Read test (Pearson) for given probabilities
##
## data: w
## D = 4.467, lambda = 1.000, df = 4.000, p-value = 0.3465
```