

Laboratori del corso di Statistica (cp)

3. Modelli per Tabelle di Frequenze

Leonardo Egidi

AA 2021/2022

Tutti i dati per questa esercitazione sono nell'archivio `glm.Rdata`, che carichiamo con il comando

```
load("glm.Rdata")
```

1 Dati sul cancro della pelle

```
skin  
##   Counts Type Site  
## 1      22 Melan HeadN  
## 2      16 Super HeadN  
## 3      19 Nodul HeadN  
## 4      11 Indet HeadN  
## 5       2 Melan Trunk  
## 6      54 Super Trunk  
## 7      33 Nodul Trunk  
## 8      17 Indet Trunk  
## 9      10 Melan Extrm  
## 10     115 Super Extrm  
## 11      73 Nodul Extrm  
## 12      28 Indet Extrm
```

Si tratta di una tabella a doppia entrata con le due variabili tipo di tumore `Type` e sito del medesimo `Site`, possiamo riorganizzare i dati in forma tabellare con il comando `xtabs`.

```
skin.tab=xtabs(skin, formula=Counts~Type+Site)  
skin.tab
```

```

##      Site
## Type   Extrm HeadN Trunk
## Indet    28    11    17
## Melan     10    22     2
## Nodul    73    19    33
## Super   115    16    54

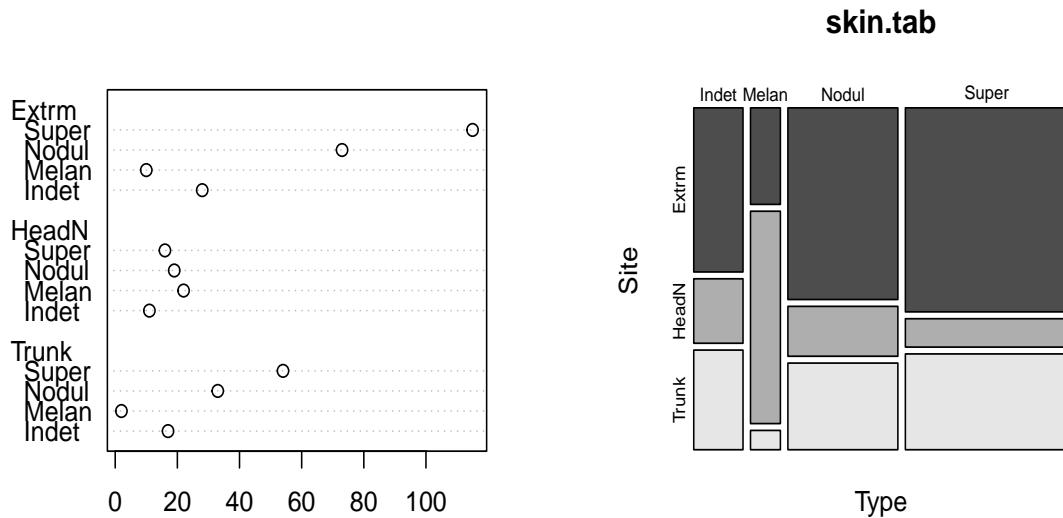
```

I dati possono essere rappresentati graficamente con un diagramma a punti o un mosaico

```

dotchart(skin.tab)
mosaicplot(skin.tab, color=TRUE)

```



Notiamo che si possono cambiare i ruoli delle due variabili

```

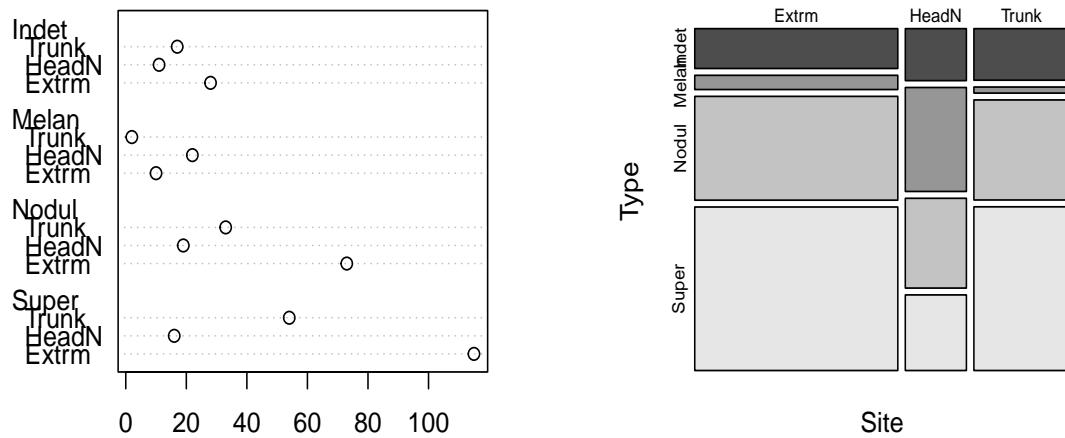
skin.tab=xtabs(skin, formula=Counts~Site+Type)
skin.tab

##      Type
## Site   Indet Melan Nodul Super
## Extrm    28    10    73   115
## HeadN     11    22    19    16
## Trunk     17     2    33    54

par(mfrow=c(1,2))
dotchart(skin.tab)
mosaicplot(skin.tab, color=TRUE)

```

skin.tab



Stimando un modello con effetti principali si può valutare l'ipotesi di indipendenza tra le due variabili.

```

skin.fit <- glm(Counts~Type+Site,family=poisson,data=skin)
skin.fit

## 
## Call: glm(formula = Counts ~ Type + Site, family = poisson, data = skin)
## 
## Coefficients:
## (Intercept)      TypeMelan      TypeNodul      TypeSuper      SiteHeadN
##       3.4544      -0.4990       0.8030       1.1950      -1.2010
##   SiteTrunk
##     -0.7571
## 
## Degrees of Freedom: 11 Total (i.e. Null);  6 Residual
## Null Deviance:    295.2
## Residual Deviance: 51.8  AIC: 122.9

summary(skin.fit)

## 
## Call:
## glm(formula = Counts ~ Type + Site, family = poisson, data = skin)
## 
## Deviance Residuals:
##      Min        1Q     Median        3Q       Max
## 
```

```

## -3.0453 -1.0741 0.1297 0.5857 5.1354
##
## Coefficients:
##             Estimate Std. Error z value Pr(>|z|)
## (Intercept) 3.4544    0.1406 24.561 < 2e-16 ***
## TypeMelan   -0.4990    0.2174 -2.295  0.0217 *
## TypeNodul    0.8030    0.1608  4.993 5.93e-07 ***
## TypeSuper    1.1950    0.1525  7.835 4.69e-15 ***
## SiteHeadN   -1.2010    0.1383 -8.683 < 2e-16 ***
## SiteTrunk   -0.7571    0.1177 -6.431 1.27e-10 ***
## ---
## Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## (Dispersion parameter for poisson family taken to be 1)
##
## Null deviance: 295.203 on 11 degrees of freedom
## Residual deviance: 51.795 on 6 degrees of freedom
## AIC: 122.91
##
## Number of Fisher Scoring iterations: 5

```

Il fatto che i coefficienti siano significativamente diversi da zero indica semplicemente che non è uniforme la distribuzione dei tumori né per tipo né per sito: ad esempio sono più frequenti quelli di tipo **Super** rispetto agli altri tipi, e sono più frequenti quelli alle estremità che quelli alla testa o al tronco.

Il modello così costruito assume vi sia indipendenza tra tipo e sito; un indicatore di quanto questa ipotesi sia compatibile con i dati è nella bontà o meno dell'adattamento. Notiamo allora che la devianza è pari a 52 con 6 g.d.l., un valore troppo alto, che corrisponde a un valore p per l'ipotesi di indipendenza pari a

```

1-pchisq(51.8,6)

## [1] 2.045725e-09

```

Ricordiamo che qui possiamo ricorrere a questo tipo di test (devianza diviso coefficiente di dispersione, in questo caso $\phi = 1$) siccome stiamo considerando un modello di Poisson con soli fattori come covariate. Dobbiamo quindi concludere che le variabili **Type** e **Site** non sono indipendenti. Avremmo potuto fare un test simile tramite la statistica χ^2 di Pearson.

```

chi2Pearson=sum((skin$Counts-fitted(skin.fit))^2/fitted(skin.fit))
chi2Pearson

## [1] 65.81293

1-pchisq(chi2Pearson,6)

## [1] 2.943201e-12

```

che conduce alla stessa conclusione, seppure i valori delle funzioni test non siano uguali.
Infine si noti che il modello con interazioni produce il modello saturo (senza gradi di libertà):

```
fitSaturo=glm(Counts~Type*Site,poisson,skin)
summary(fitSaturo)

##
## Call:
## glm(formula = Counts ~ Type * Site, family = poisson, data = skin)
##
## Deviance Residuals:
## [1] 0 0 0 0 0 0 0 0 0 0 0 0
##
## Coefficients:
##                               Estimate Std. Error z value Pr(>|z|)
## (Intercept)            3.3322    0.1890 17.632 < 2e-16 ***
## TypeMelan          -1.0296    0.3684 -2.795 0.005192 **
## TypeNodul           0.9583    0.2223  4.311 1.63e-05 ***
## TypeSuper           1.4127    0.2107  6.704 2.03e-11 ***
## SiteHeadN          -0.9343    0.3558 -2.626 0.008649 **
## SiteTrunk           -0.4990    0.3075 -1.623 0.104612
## TypeMelan:SiteHeadN 1.7228    0.5216  3.303 0.000957 ***
## TypeNodul:SiteHeadN -0.4117    0.4393 -0.937 0.348618
## TypeSuper:SiteHeadN -1.0380    0.4448 -2.334 0.019602 *
## TypeMelan:SiteTrunk -1.1104    0.8334 -1.332 0.182713
## TypeNodul:SiteTrunk -0.2950    0.3722 -0.792 0.428092
## TypeSuper:SiteTrunk -0.2570    0.3489 -0.736 0.461479
## ---
## Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## (Dispersion parameter for poisson family taken to be 1)
##
## Null deviance: 2.9520e+02 on 11 degrees of freedom
## Residual deviance: -1.1102e-15 on 0 degrees of freedom
## AIC: 83.111
##
## Number of Fisher Scoring iterations: 3
```

Nel modello saturo l'adattamento è perfetto, di conseguenza la devianza è nulla.

```
predict(fitSaturo,type="response")

##   1   2   3   4   5   6   7   8   9   10  11  12
## 22 16 19 11  2 54 33 17 10 115 73 28
```

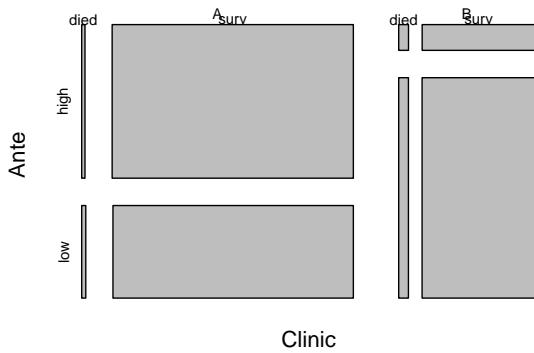
```
skin$Counts  
## [1] 22 16 19 11 2 54 33 17 10 115 73 28
```

2 Neonati e cure antenatali

I dati `babies` riguardano la sopravvivenza di bimbi nati in due diverse cliniche da madri con due diversi tipi di cura antenatale.

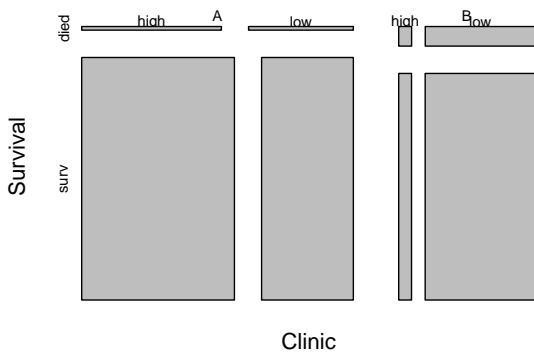
```
babies  
##   Counts Clinic Ante Survival  
## 1    176      A  low     surv  
## 2    293      A high     surv  
## 3    197      B  low     surv  
## 4     23      B high     surv  
## 5      3      A  low    died  
## 6      4      A high    died  
## 7     17      B  low    died  
## 8      2      B high    died  
  
ftable(xtabs(babies, formula=Counts~Clinic+Ante+Survival))  
  
##                               Survival died surv  
## Clinic Ante  
## A      high             4 293  
##       low              3 176  
## B      high             2 23  
##       low             17 197  
  
plot(xtabs(babies, formula=Counts~Clinic+Ante+Survival))
```

```
xtabs(babies, formula = Counts ~ Clinic + Ante + Survival)
```



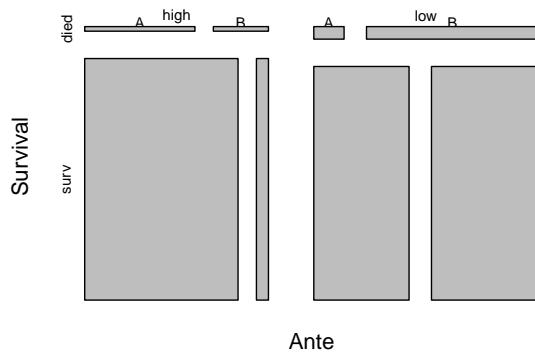
```
plot(xtabs(babies, formula=Counts~Clinic+Survival+Ante))
```

```
xtabs(babies, formula = Counts ~ Clinic + Survival + A)
```



```
plot(xtabs(babies, formula=Counts~Ante+Survival+Clinic))
```

xtabs(babies, formula = Counts ~ Ante + Survival + Cli



Stimiamo un modello con i soli effetti principali:

```
babies.fit <- glm(Counts~Clinic+Ante+Survival,poisson,data=babies)
babies.fit

##
## Call: glm(formula = Counts ~ Clinic + Ante + Survival, family = poisson,
##           data = babies)
##
## Coefficients:
## (Intercept)      ClinicB       Antelow   Survivalsurv
##           2.0535      -0.6890       0.1993      3.2771
##
## Degrees of Freedom: 7 Total (i.e. Null);  4 Residual
## Null Deviance:    1066
## Residual Deviance: 211.5  AIC: 259.7
```

Chiaramente il modello non va bene. Comunque, dovremmo includere i termini che sono fissati dal disegno: in questo caso è probabile che le frequenze di `Clinic` \times `Ante` fossero fissate, quindi un modello più appropriato è

```
babies.fit2 <- glm(Counts~Clinic*Ante+Survival,poisson,data=babies)
babies.fit2

##
## Call: glm(formula = Counts ~ Clinic * Ante + Survival, family = poisson,
##           data = babies)
##
## Coefficients:
## (Intercept)      ClinicB       Antelow   Survivalsurv
##           2.3795      -2.4749      -0.5063      3.2771
```

```

## ClinicB:Antelow
##          2.6534
##
## Degrees of Freedom: 7 Total (i.e. Null);  3 Residual
## Null Deviance:      1066
## Residual Deviance: 17.83  AIC: 68.01

```

Però, anche in questo caso la devianza residua è grande rispetto i gradi di libertà.
Stimiamo allora il modello saturo per confrontare i contributi alla devianza.

```

babies.fit3 <- glm(Counts~Clinic*Ante*Survival,poisson,data=babies)
anova(babies.fit3)

## Analysis of Deviance Table
##
## Model: poisson, link: log
##
## Response: Counts
##
## Terms added sequentially (first to last)
##
##
##           Df Deviance Resid. Df Resid. Dev
## NULL                  7    1066.43
## Clinic       1     80.06      6    986.36
## Ante         1      7.06      5    979.30
## Survival     1    767.82      4    211.48
## Clinic:Ante   1    193.65      3     17.83
## Clinic:Survival 1     17.75      2      0.08
## Ante:Survival  1      0.04      1      0.04
## Clinic:Ante:Survival 1      0.04      0      0.00

```

L'analisi della devianza suggerisce che le interazioni che includono sia **Ante** che **Survival** non siano necessarie.

Semplifichiamo allora il modello

```

babies.fit4 <- glm(Counts~Clinic*Ante + Clinic*Survival,poisson,babies)
babies.fit4

##
## Call: glm(formula = Counts ~ Clinic * Ante + Clinic * Survival, family = poisson,
##           data = babies)
##
## Coefficients:
## (Intercept)          ClinicB          Antelow

```

```

##          1.4742      -0.7874      -0.5063
## Survivalsurv    ClinicB:Antelow  ClinicB:Survivalsurv
##          4.2047      2.6534     -1.7555
##
## Degrees of Freedom: 7 Total (i.e. Null);  2 Residual
## Null Deviance:    1066
## Residual Deviance: 0.08229  AIC: 52.26

```

Con questo modello la devianza residua è piccola rispetto ai gradi di libertà. Il modello implica che la sopravvivenza dipende dalla clinica ma non dal tipo di cura.

Si parla in questo caso di indipendenza condizionata: cura e sopravvivenza sono indipendenti condizionatamente alla clinica.

Possiamo confermare questa circostanza anche guardando semplicemente alla tabella dei dati

```

tabbabies=xtabs(Counts~Ante+Survival+Clinic,babies)
ftable(tabbabies)

##          Clinic   A   B
## Ante Survival
##   high died      4   2
##       surv     293  23
##   low  died      3  17
##       surv     176 197

```

Ottieniamo le probabilità di sopravvivenza condizionatamente alla clinica e per i due livelli di trattamento antenatale con

```

prop.table(tabbabies,c(1,3))

## , , Clinic = A
##
##       Survival
##   Ante      died      surv
##   high 0.01346801 0.98653199
##   low  0.01675978 0.98324022
##
## , , Clinic = B
##
##       Survival
##   Ante      died      surv
##   high 0.08000000 0.92000000
##   low  0.07943925 0.92056075

```

Più formalmente possiamo testare l'ipotesi di indipendenza per ciascuna delle tabelle a due vie che si ottengono condizionandosi rispetto alla clinica

```

xtabs(Counts~Ante+Survival,babies,subset=Clinic=="A")

##      Survival
## Ante   died surv
##   high     4   293
##   low      3   176

summary(xtabs(Counts~Ante+Survival,babies,subset=Clinic=="A"))

## Call: xtabs(formula = Counts ~ Ante + Survival, data = babies, subset = Clinic ==
##           "A")
## Number of cases in table: 476
## Number of factors: 2
## Test for independence of all factors:
##  Chisq = 0.08352, df = 1, p-value = 0.7726
## Chi-squared approximation may be incorrect

xtabs(Counts~Ante+Survival,babies,subset=Clinic=="B")

##      Survival
## Ante   died surv
##   high     2    23
##   low     17   197

summary(xtabs(Counts~Ante+Survival,babies,subset=Clinic=="B"))

## Call: xtabs(formula = Counts ~ Ante + Survival, data = babies, subset = Clinic ==
##           "B")
## Number of cases in table: 239
## Number of factors: 2
## Test for independence of all factors:
##  Chisq = 9.619e-05, df = 1, p-value = 0.9922
## Chi-squared approximation may be incorrect

```

In un modo o nell'altro i conteggi non mostrano scostamenti significativi dall'indipendenza. Per vedere che il modello sopra implica l'indipendenza condizionata (esatta) si scriva il modello nella forma

$$\log \mu_{ijk} = \mu + \alpha_i + \beta_j + \gamma_k + \delta_{ik} + \epsilon_{jk}$$

dove col triplo indice si indica la frequenza di osservazioni nelle classi determinate dalle variabili esplicative, in particolare

- l'indice i indica la cura prenatale, $i = 1$ per `high`, $i = 2$ per `low`;
- l'indice j indica la sopravvivenza, $j = 1$ per `died`, $j = 2$ per `surv`;
- l'indice k indica la clinica, $k = 1$ per A, $k = 2$ per B;

alla specificazione sopra vanno aggiunti i vincoli

$$\alpha_1 = \beta_1 = \gamma_1 = 0$$

e

$$\delta_{1k} = \delta_{i1} = \epsilon_{1k} = \epsilon_{j1} = 0 \quad \forall i, j, k$$

In pratica sono non nulli solo α_2 , β_2 , γ_2 , δ_{22} e ϵ_{22} che corrispondono ai coefficienti stimati in `babies.fit4`.

Con ciò condizionatamente a `Clinic` i logaritmi delle frequenze attese della tabella a doppia entrata per sopravvivenza e cura (`Survival` e `Ante`) sono

		Clinic=A	
		died	surv
high	μ	$\mu + \beta_2$	
	$\mu + \alpha_2$	$\mu + \alpha_2 + \beta_2$	

		Clinic=B	
		died	surv
high	$\mu + \gamma_2$	$\mu + \beta_2 + \gamma_2 + \epsilon_{22}$	
	$\mu + \alpha_2 + \gamma_2 + \delta_{22}$	$\mu + \alpha_2 + \beta_2 + \gamma_2 + \delta_{22} + \epsilon_{22}$	

e pertanto gli *odds-ratio* della sopravvivenza rispetto la cura condizionatamente alla clinica sono

$$OR_{AS|Clinic=A} = \frac{\frac{\exp\{\mu+\beta_2\}}{\exp\{\mu\}}}{\frac{\exp\{\mu+\alpha_2+\beta_2\}}{\exp\{\mu+\alpha_2\}}} = 1$$

$$OR_{AS|Clinic=B} = \dots = 1$$

che corrisponde appunto all'indipendenza condizionata¹.

¹Alternativamente, il modello può essere scritto nella forma

$$\log \mu_i = \lambda_0 + \lambda_A x_{iA} + \lambda_S x_{iS} + \lambda_C x_{iC} + \lambda_{AC} x_{iAC} + \lambda_{CS} x_{iCS}$$

dove

$$x_{iA} = \begin{cases} 1 & \text{se } \text{Ante}=low \\ 0 & \text{altrimenti} \end{cases}, \quad x_{iS} = \begin{cases} 1 & \text{se } \text{Survival}=surv \\ 0 & \text{altrimenti} \end{cases}, \quad x_{iC} = \begin{cases} 1 & \text{se } \text{Clinic}=B \\ 0 & \text{altrimenti} \end{cases}$$

$$x_{iAC} = \begin{cases} 1 & \text{se } \text{Ante}=low \text{ e } \text{Clinic}=B \\ 0 & \text{altrimenti} \end{cases}, \quad x_{iCS} = \begin{cases} 1 & \text{se } \text{Survival}=surv \text{ e } \text{Clinic}=B \\ 0 & \text{altrimenti} \end{cases}$$

condizionatamente a `Clinic` i logaritmi delle frequenze attese della tabella a doppia entrata per sopravvivenza e cura (`Survival` e `Ante`) sono

		Clinic=A	
		died	surv
low	$\lambda_0 + \lambda_A$	$\lambda_0 + \lambda_A + \lambda_S$	
	λ_0	$\lambda_0 + \lambda_S$	

		Clinic=B	
		died	surv
low	$\lambda_0 + \lambda_C + \lambda_A + \lambda_{AC}$	$\lambda_0 + \lambda_C + \lambda_A + \lambda_S + \lambda_{AC} + \lambda_{CS}$	
	$\lambda_0 + \lambda_C$	$\lambda_0 + \lambda_C + \lambda_S + \lambda_{CS}$	

3 Donne fumatrici

Nell'ambito di uno studio ventennale, sono state osservate alcune donne rispetto al fatto che siano fumatrici e alla sopravvivenza (per i venti anni di durata dello studio).

```
library(faraway)

## Warning: package 'faraway' was built under R version 4.1.2

data(femsmoke)
femsmoke

##      y smoker dead   age
## 1    2     yes  yes 18-24
## 2    1      no  yes 18-24
## 3    3     yes  yes 25-34
## 4    5      no  yes 25-34
## 5   14     yes  yes 35-44
## 6    7      no  yes 35-44
## 7   27     yes  yes 45-54
## 8   12      no  yes 45-54
## 9   51     yes  yes 55-64
## 10  40      no  yes 55-64
## 11  29     yes  yes 65-74
## 12 101      no  yes 65-74
## 13  13     yes  yes 75+
## 14  64      no  yes 75+
## 15  53     yes    no 18-24
## 16  61      no    no 18-24
## 17 121     yes    no 25-34
## 18 152      no    no 25-34
## 19  95     yes    no 35-44
## 20 114      no    no 35-44
## 21 103     yes    no 45-54
## 22  66      no    no 45-54
## 23  64     yes    no 55-64
## 24  81      no    no 55-64
```

e pertanto gli *odds-ratio* della sopravvivenza rispetto la cura sono

$$OR_{AS|Clinic=A} = \frac{\frac{\exp\{\lambda_0 + \lambda_S\}}{\exp\{\lambda_0\}}}{\frac{\exp\{\lambda_0 + \lambda_A + \lambda_S\}}{\exp\{\lambda_0 + \lambda_A\}}} = 1$$

$$OR_{AS|Clinic=B} = \frac{\frac{\exp\{\lambda_0 + \lambda_C + \lambda_S + \lambda_{CS}\}}{\exp\{\lambda_0 + \lambda_C\}}}{\frac{\exp\{\lambda_0 + \lambda_C + \lambda_A + \lambda_S + \lambda_{AC} + \lambda_{CS}\}}{\exp\{\lambda_0 + \lambda_C + \lambda_A + \lambda_{AC}\}}} = 1$$

```

## 25    7    yes   no 65-74
## 26   28     no   no 65-74
## 27    0    yes   no 75+
## 28    0     no   no 75+

```

Se in prima battuta ignoriamo la suddivisione in classi di età, e consideriamo la tabella marginale

```

margSD=xtabs(y~smoker+dead,data=femsmoke)
margSD

```

```

##      dead
## smoker yes no
##   yes 139 443
##   no  230 502

prop.table(margSD,1)

##      dead
## smoker      yes      no
##   yes 0.2388316 0.7611684
##   no  0.3142077 0.6857923

```

dovremmo concludere che il fumo ha un effetto benefico sulla sopravvivenza, si può calcolare un test del χ^2 che farà concludere che tale effetto non è ascrivibile al caso.

Osserviamo però che se la probabilità di morte è calcolata condizionatamente alla classe di età, questa è maggiore per le fumatrici in tutte le classi tranne la classe 25-34.

```

tavola=xtabs(y~smoker+dead+age,data=femsmoke)
prop.table(tavola,c(1,3))[,1,]

##      age
## smoker    18-24    25-34    35-44    45-54    55-64
##   yes 0.03636364 0.02419355 0.12844037 0.20769231 0.44347826
##   no  0.01612903 0.03184713 0.05785124 0.15384615 0.33057851
##      age
## smoker    65-74    75+
##   yes 0.80555556 1.00000000
##   no  0.78294574 1.00000000

```

Il fatto che marginalmente l'associazione tra fumo e sopravvivenza sia contraria si deve alla prevalenza di fumatrici nelle diverse classi di età, si nota infatti che vi sono molte più fumatrici tra le giovani.

```

prop.table(xtabs(y~smoker+age,data=femsmoke),2)

##      age
## smoker    18-24     25-34     35-44     45-54     55-64     65-74
##   yes 0.4700855 0.4412811 0.4739130 0.6250000 0.4872881 0.2181818
##   no  0.5299145 0.5587189 0.5260870 0.3750000 0.5127119 0.7818182
##      age
## smoker     75+
##   yes 0.1688312
##   no  0.8311688

```

Stimiamo dapprima il modello con i soli effetti marginali, questo risulta poco soddisfacente in termini di devianza residua,

```

mod1=glm(y~smoker+dead+age,family=poisson,data=femsmoke)
summary(mod1)

##
## Call:
## glm(formula = y ~ smoker + dead + age, family = poisson, data = femsmoke)
##
## Deviance Residuals:
##      Min        1Q     Median        3Q       Max
## -7.9306   -5.3175   -0.5514    2.4229   11.1895
##
## Coefficients:
##             Estimate Std. Error z value Pr(>|z|)
## (Intercept) 2.67778   0.10702 25.021 < 2e-16 ***
## smokerno    0.22931   0.05554  4.129 3.64e-05 ***
## deadno      0.94039   0.06139 15.319 < 2e-16 ***
## age25-34    0.87618   0.11003  7.963 1.67e-15 ***
## age35-44    0.67591   0.11356  5.952 2.65e-09 ***
## age45-54    0.57536   0.11556  4.979 6.40e-07 ***
## age55-64    0.70166   0.11307  6.206 5.45e-10 ***
## age65-74    0.34377   0.12086  2.844  0.00445 **
## age75+     -0.41837   0.14674 -2.851  0.00436 **
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## (Dispersion parameter for poisson family taken to be 1)
##
## Null deviance: 1193.9 on 27 degrees of freedom
## Residual deviance: 735.0 on 19 degrees of freedom
## AIC: 887.2
##

```

```
## Number of Fisher Scoring iterations: 6
```

All'opposto, stimiamo il modello saturo e analizziamo le devianze delle componenti, risulta che l'interazione a tre ha un contributo trascurabile, quella tra **dead** e **smoker** ha invece un contributo modesto ma potenzialmente rilevante.

```
modS=glm(y~age*dead*smoker,family=poisson,data=femsmoke)
anova(modS)

## Analysis of Deviance Table
##
## Model: poisson, link: log
##
## Response: y
##
## Terms added sequentially (first to last)
##
##
##          Df Deviance Resid. Df Resid. Dev
## NULL              27    1193.94
## age      6    180.50    21   1013.44
## dead     1    261.27    20    752.16
## smoker   1     17.16    19    735.00
## age:dead  6    633.17    13    101.83
## age:smoker 6     93.51     7     8.33
## dead:smoker 1      5.95     6     2.38
## age:dead:smoker 6      2.38     0     0.00
```

Consideriamo quindi i modelli con tutte le interazioni a due, **mod3**, e il modello che omette quella tra **dead** e **smoker**, **mod2**. Entrambi hanno una devianza residua soddisfacente, si noti però che da **mod3** si può concludere che l'interazione tra **dead** e **smoker** ha un coefficiente significativamente diverso da zero.

```
mod2=glm(y~age*smoker+dead*age,family=poisson,data=femsmoke)
mod3=glm(y~age*smoker+dead*age+smoker*dead,family=poisson,data=femsmoke)
summary(mod2)

##
## Call:
## glm(formula = y ~ age * smoker + dead * age, family = poisson,
##      data = femsmoke)
##
## Deviance Residuals:
##      Min        1Q    Median        3Q       Max
## -1.000000 -0.999999 -0.999999 -0.999999  1.000000
```

```

## -1.30657 -0.26480 -0.00003 0.26643 1.20822
##
## Coefficients:
##                               Estimate Std. Error z value Pr(>|z|)
## (Intercept)                0.34377  0.58563  0.587 0.557199
## age25-34                  0.91760  0.68737  1.335 0.181895
## age35-44                  1.95402  0.62882  3.107 0.001887 **
## age45-54                  2.84979  0.60950  4.676 2.93e-06 ***
## age55-64                  3.44819  0.59868  5.760 8.43e-09 ***
## age65-74                  3.00134  0.61023  4.918 8.73e-07 ***
## age75+                     2.22118  0.64799  3.428 0.000609 ***
## smokerno                  0.11980  0.18523  0.647 0.517785
## deadno                     3.63759  0.58490  6.219 5.00e-10 ***
## age25-34:smokerno        0.11616  0.22078  0.526 0.598789
## age35-44:smokerno        -0.01536  0.22749 -0.068 0.946172
## age45-54:smokerno        -0.63063  0.23414 -2.693 0.007074 **
## age55-64:smokerno        -0.06894  0.22643 -0.304 0.760765
## age65-74:smokerno        1.15649  0.26427  4.376 1.21e-05 ***
## age75+:smokerno          1.47413  0.35617  4.139 3.49e-05 ***
## age25-34:deadno          -0.10756  0.68613 -0.157 0.875435
## age35-44:deadno          -1.33977  0.62810 -2.133 0.032920 *
## age45-54:deadno          -2.17125  0.61128 -3.552 0.000382 ***
## age55-64:deadno          -3.17171  0.59999 -5.286 1.25e-07 ***
## age65-74:deadno          -4.94977  0.61512 -8.047 8.49e-16 ***
## age75+:deadno            -26.30450 5776.51889 -0.005 0.996367
##
## ---
## Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## (Dispersion parameter for poisson family taken to be 1)
##
## Null deviance: 1193.9378 on 27 degrees of freedom
## Residual deviance: 8.3269 on 7 degrees of freedom
## AIC: 184.52
##
## Number of Fisher Scoring iterations: 17

summary(mod3)

##
## Call:
## glm(formula = y ~ age * smoker + dead * age + smoker * dead,
##      family = poisson, data = femsmoke)
##
## Deviance Residuals:
##      Min       1Q   Median       3Q      Max

```

```

## -0.70006 -0.11004 -0.00002 0.12254 0.67272
##
## Coefficients:
##                               Estimate Std. Error z value Pr(>|z|)
## (Intercept)                0.54284   0.58736  0.924 0.355384
## age25-34                  0.92902   0.68381  1.359 0.174273
## age35-44                  1.94048   0.62486  3.105 0.001900 **
## age45-54                  2.76845   0.60657  4.564 5.02e-06 ***
## age55-64                  3.37507   0.59550  5.668 1.45e-08 ***
## age65-74                  2.86586   0.60894  4.706 2.52e-06 ***
## age75+                     2.02211   0.64955  3.113 0.001851 **
## smokerno                 -0.29666   0.25324 -1.171 0.241401
## deadno                    3.43271   0.59014  5.817 6.00e-09 ***
## age25-34:smokerno        0.11752   0.22091  0.532 0.594749
## age35-44:smokerno        0.01268   0.22800  0.056 0.955654
## age45-54:smokerno       -0.56538   0.23585 -2.397 0.016522 *
## age55-64:smokerno        0.08512   0.23573  0.361 0.718030
## age65-74:smokerno        1.49088   0.30039  4.963 6.93e-07 ***
## age75+:smokerno          1.89060   0.39582  4.776 1.78e-06 ***
## age25-34:deadno         -0.12006   0.68655 -0.175 0.861178
## age35-44:deadno         -1.34112   0.62857 -2.134 0.032874 *
## age45-54:deadno         -2.11336   0.61210 -3.453 0.000555 ***
## age55-64:deadno         -3.18077   0.60057 -5.296 1.18e-07 ***
## age65-74:deadno         -5.08798   0.61951 -8.213 < 2e-16 ***
## age75+:deadno          -27.31727 8839.01146 -0.003 0.997534
## smokerno:deadno         0.42741   0.17703  2.414 0.015762 *
##
## Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## (Dispersion parameter for poisson family taken to be 1)
##
## Null deviance: 1193.9378 on 27 degrees of freedom
## Residual deviance: 2.3809 on 6 degrees of freedom
## AIC: 180.58
##
## Number of Fisher Scoring iterations: 18

```

4 Boy scout

Si considerino i dati riportati nella seguente tabella in cui un campione di individui è classificato secondo l'essere o meno stato boy scout (B), l'aver avuto problemi con la legge (L) e lo status socio-economico (S):

Status socioeconomico	Boy scout	Problemi legali	
		Sì	No
Basso	Sì	12	37
	No	42	154
Medio	Sì	19	140
	No	22	128
Alto	Sì	8	192
	No	3	51

1. Individuare un modello log-lineare opportuno.
2. Calcolare le frequenze attese.
3. Si costruisca la marginale (B-L) e la si esamini. Perché e fuorviante sostenere che fare il boy scout conduce a un tasso di delinquenza minore? Si risponda al quesito anche interpretando la struttura del modello log-lineare individuato.

```

Count=c(12, 37, 42, 154, 19, 140, 22, 128, 8, 192, 3, 51)
Legal=gl(2,1,12,labels=c("S","N"))
Boyscout=gl(2,2,12,labels=c("S","N"))
Socioec=gl(3,4,12,labels=c("Basso","Medio","Alto"))
d=data.frame(Count,Legal,Boyscout,Socioec)
ftable(xtabs(d,formula=Count~Socioec+Boyscout+Legal))

##                                     Legal   S   N
## Socioec Boyscout
## Basso    S              12  37
##          N              42 154
## Medio    S              19 140
##          N              22 128
## Alto     S              8 192
##          N              3  51

bs=glm(Count~Socioec*Boyscout+Socioec*Legal+Boyscout*Legal,family=poisson,data=d)
summary(bs)

##
## Call:
## glm(formula = Count ~ Socioec * Boyscout + Socioec * Legal +
##     Boyscout * Legal, family = poisson, data = d)
##
## Deviance Residuals:
##      1       2       3       4       5       6       7 
## 0.54708 -0.29073 -0.27338  0.14535 -0.29116  0.11000  0.28227 
##      8       9      10      11      12 
## 
```

```

## -0.11430 -0.17295 0.03606 0.30595 -0.06967
##
## Coefficients:
##                               Estimate Std. Error z value Pr(>|z|)
## (Intercept)                2.32271   0.24294  9.561 < 2e-16 ***
## SocioecMedio               0.68779   0.25565  2.690  0.00714 **
## SocioecAlto                -0.18274   0.37119 -0.492  0.62251
## BoyscoutN                  1.45685   0.24813  5.871 4.32e-09 ***
## LegalN                     1.33563   0.24817  5.382 7.37e-08 ***
## SocioecMedio:BoyscoutN    -1.43710   0.19705 -7.293 3.03e-13 ***
## SocioecAlto:BoyscoutN     -2.68021   0.22500 -11.912 < 2e-16 ***
## SocioecMedio:LegalN       0.58621   0.23941  2.449  0.01434 *
## SocioecAlto:LegalN        1.77929   0.37199  4.783 1.73e-06 ***
## BoyscoutN:LegalN          -0.08997   0.24070 -0.374  0.70857
## ---
## Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## (Dispersion parameter for poisson family taken to be 1)
##
## Null deviance: 722.84954 on 11 degrees of freedom
## Residual deviance: 0.79897 on 2 degrees of freedom
## AIC: 86.043
##
## Number of Fisher Scoring iterations: 4

bs2=glm(Count~Socioec*Boyscout+Socioec*Legal,family=poisson,data=d)
summary(bs2)

##
## Call:
## glm(formula = Count ~ Socioec * Boyscout + Socioec * Legal, family = poisson,
##      data = d)
##
## Deviance Residuals:
##      1       2       3       4       5       6       7 
## 0.35868 -0.19519 -0.18343  0.09695 -0.46446  0.17813  0.46215 
##      8       9      10      11      12 
## -0.18436 -0.22770  0.04779  0.41421 -0.09222 
##
## Coefficients:
##                               Estimate Std. Error z value Pr(>|z|)
## (Intercept)                2.3795   0.1867 12.747 < 2e-16 ***
## SocioecMedio               0.6696   0.2496  2.683  0.00730 **
## SocioecAlto                -0.2207   0.3561 -0.620  0.53548
## BoyscoutN                  1.3863   0.1597  8.680 < 2e-16 ***

```

```

## LegalN           1.2633    0.1541   8.197 2.47e-16 ***
## SocioecMedio:BoyscoutN -1.4446    0.1961  -7.365 1.77e-13 ***
## SocioecAlto:BoyscoutN -2.6956    0.2214 -12.174 < 2e-16 ***
## SocioecMedio:LegalN    0.6141    0.2278   2.696  0.00701 **
## SocioecAlto:LegalN     1.8319    0.3446   5.315 1.06e-07 ***
## ---
## Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## (Dispersion parameter for poisson family taken to be 1)
##
## Null deviance: 722.84954 on 11 degrees of freedom
## Residual deviance: 0.93903 on 3 degrees of freedom
## AIC: 84.183
##
## Number of Fisher Scoring iterations: 4

bs3=glm(Count~Socioec+Boyscout*Legal,family=poisson,data=d)
summary(bs3)

##
## Call:
## glm(formula = Count ~ Socioec + Boyscout * Legal, family = poisson,
##      data = d)
##
## Deviance Residuals:
##      Min        1Q        Median         3Q        Max
## -8.2394   -2.2105   -0.0217    1.8107    6.4423
##
## Coefficients:
##             Estimate Std. Error z value Pr(>|z|)
## (Intercept) 2.47026   0.16878 14.636 < 2e-16 ***
## SocioecMedio 0.23208   0.08554  2.713  0.00667 **
## SocioecAlto  0.03608   0.08955  0.403  0.68704
## BoyscoutN    0.54113   0.20141  2.687  0.00722 **
## LegalN       2.24723   0.16838 13.346 < 2e-16 ***
## BoyscoutN:LegalN -0.64379   0.21513 -2.993  0.00277 **
## ---
## Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## (Dispersion parameter for poisson family taken to be 1)
##
## Null deviance: 722.85 on 11 degrees of freedom
## Residual deviance: 212.70 on 6 degrees of freedom
## AIC: 289.94
##

```

```

## Number of Fisher Scoring iterations: 5

## marginale B-L
d.array=xtabs(d,formula=Count~Socioec+Boyscout+Legal)
dim(d.array)

## [1] 3 2 2

margBL=apply(d.array,c(2,3),sum)
d.margBL=as.data.frame.table(margBL)
mod.margBL=glm(Freq~Boyscout*Legal,family=poisson,data=d.margBL)

```

5 Larve

Larve di mosche *drosophila fruit fly* vengono immerse in un recipiente che contiene DDT. Le stesse sono poi classificate secondo il sesso della mosca, la posizione nel recipiente e la presenza o meno di segni di avvelenamento:

```

ddt

##   Counts   Sex      Site Poisoned
## 1     55 Male    In medium  Healthy
## 2     34 Female   In medium  Healthy
## 3     23 Male   Medium margin  Healthy
## 4     15 Female  Medium margin  Healthy
## 5      7 Male    Vial wall  Healthy
## 6      3 Female   Vial wall  Healthy
## 7      8 Male    Top of medium  Healthy
## 8      5 Female   Top of medium  Healthy
## 9      6 Male    In medium Poisoned
## 10    17 Female   In medium Poisoned
## 11      1 Male   Medium margin Poisoned
## 12      5 Female  Medium margin Poisoned
## 13      4 Male    Vial wall Poisoned
## 14      5 Female   Vial wall Poisoned
## 15      3 Male    Top of medium Poisoned
## 16      3 Female   Top of medium Poisoned

```

Si organizzino i dati in tabelle di frequenza: si possono osservare delle regolarità nei dati?

Si stimi un modello GLM per questi dati, assumendo che il disegno sperimentale fissasse la posizione nel recipiente e il sesso.

Cosa si conclude?

6 Titanic

I dati `Titanic` descrivono caratteristiche dei passeggeri della famosa nave. Si veda `help(Titanic)` per una descrizione dei dati. Si costruisca un modello GLM per analizzare i dati in un modo appropriato.