

Regressão de Poisson e parentes próximos

Filipa Januário



Janeiro 2012

Família Exponencial

Seja Y uma variável aleatória. A distribuição de probabilidade de Y pertence à família exponencial se a sua função densidade de probabilidade é da forma

$$f(y|\theta, \varphi) = \exp\left(\frac{y\theta - b(\theta)}{\varphi} + c(y, \varphi)\right) \quad (1)$$

onde

- θ é o parâmetro de localização, designado por parâmetro canónico
- φ é o parâmetro de dispersão
- $b(\cdot)$ e $c(\cdot)$ são funções reais conhecidas.

Se f verificar (1), diz-se que Y está na forma canónica. Nessa situação, pode-se mostrar que

$$E(Y) = \mu = b'(\theta)$$

$$\text{Var}(Y) = \sigma^2 = \varphi b''(\theta)$$

Exemplos

- Distribuição de Poisson: $Y \sim P(\lambda)$

$$f(y|\lambda) = \lambda^y \frac{e^{-\lambda}}{y!} = \exp[\log(\lambda)y - \lambda - \log(y!)]$$

- Distribuição Binomial: $Y \sim B(n, p)$

$$f(y|n, p) = \binom{n}{p} p^y (1-p)^{n-y} = \exp \left[y \log \left(\frac{p}{1-p} \right) + n \log(1-p) + \log \binom{n}{p} \right]$$

- Distribuição Binomial Negativa: $Y \sim BN(r, p)$

$$f(y|p, r) = \binom{y+r-1}{r-1} p^r (1-p)^y = \exp \left[y \log(1-p) + r \log(p) + \log \left(\frac{y+r-1}{r-1} \right) \right]$$

- Distribuição Normal, Distribuição Gamma,...

Modelos Lineares Generalizados

No modelo de regressão linear usual:

- A variável resposta Y , condicionada pelas variáveis explicativas, segue uma distribuição Normal.
- A combinação linear das variáveis explicativas prevê diretamente a média da resposta.

No modelo linear generalizado:

- A variável resposta Y , condicionada pelas variáveis explicativas, segue uma distribuição pertencente à família exponencial.
- A combinação linear das variáveis explicativas prevê uma função (previamente definida) da média da resposta.

Componentes de um Modelo Linear Generalizado

Considerando n observações independentes y_1, \dots, y_n com p covariáveis, X_1, \dots, X_p , os MLG são caracterizados pela seguinte estrutura:

1. **Componente aleatória:** As observações da variável resposta Y , que se quer modelar, provêm de distribuições independentes que pertencem à família exponencial.
2. **Componente sistemática:** Consiste numa combinação linear de variáveis explicativas

$$\beta_0 + \beta_1 X_{1(i)} + \beta_2 X_{2(i)} + \dots + \beta_p X_{p(i)}, \quad i = 1, \dots, n.$$

3. **Função de ligação:** função diferenciável e monótona $g(\cdot)$ que associa as componentes aleatória e sistemática, através duma relação da forma

$$g(\mu_i) = \beta_0 + \beta_1 X_{1(i)} + \beta_2 X_{2(i)} + \dots + \beta_p X_{p(i)}, \quad i = 1, \dots, n.$$

Os MLG usam o método da Máxima Verosimilhança para estimar os coeficientes.

Regressão de Poisson

- Utilizada para modelar **dados de contagem** num período de tempo ou espaço específico.

Assume-se que $Y|X = x_i \sim P(\mu(x_i))$. **Pretendemos modelar a média de $Y|X = x_i$ como combinação linear das variáveis explicativas.**

Uma modelação do tipo:

$$\mu(x_i) = \beta_0 + \beta_1 X_{1(i)} + \beta_2 X_{2(i)} + \dots + \beta_p X_{p(i)}, \quad i = 1, \dots, n,$$

é **desajustada** dado que o termo do lado direito pode tomar qualquer valor real, enquanto que o termo de lado esquerdo só pode tomar valores não negativos.

Uma Solução: considerar a **função logarítmica** como função de ligação

$$\log(\mu(x_i)) = \beta_0 + \beta_1 X_{1(i)} + \beta_2 X_{2(i)} + \dots + \beta_p X_{p(i)}, \quad i = 1, \dots, n.$$

Regressão Binomial Negativa

- Utilizada para modelar **dados de contagem** quando a variância das observações excede a média.¹
- $E(Y) = \mu$ e $Var(Y) = \mu + \alpha\mu^2$
- Assume-se que $Y|X = x_i \sim BN(r, p(x_i))$.
- Tal como na regressão de Poisson, pode considerar-se a função logaritmo como função de ligação:

$$\log(\mu(x_i)) = \beta_0 + \beta_1 X_{1(i)} + \beta_2 X_{2(i)} + \dots + \beta_p X_{p(i)}, \quad i = 1, \dots, n.$$

¹ $E(Y) = Var(Y) = \mu$ na distribuição de Poisson

Regressão Logística

- Utiliza-se quando a variável resposta é binária.

Considere-se que a variável resposta Y é uma v.a binária, codificada por 0 e 1.

- Assume-se que $Y|X = x_i \sim B(1, \pi(x_i))$.

- A função de ligação mais usual neste tipo de regressão é o

$$\text{logit}(\pi_i) = \log\left(\frac{\pi_i}{1 - \pi_i}\right):$$

$$\text{logit}(\pi_i) = \beta_0 + \beta_1 X_{1(i)} + \beta_2 X_{2(i)} + \dots + \beta_p X_{p(i)} \Leftrightarrow$$

$$\Leftrightarrow \pi(x_i) = \frac{1}{1 + \exp^{-(\beta_0 + \beta_1 X_{1(i)} + \beta_2 X_{2(i)} + \dots + \beta_p X_{p(i)})}}$$

Exemplos

família exponencial: $f(y, \theta, \varphi) = \exp \left[\frac{y\theta - b(\theta)}{\varphi} + c(y, \varphi) \right]$

Distribuição $f(y, \theta, \varphi)$	Função de ligação $\eta = g(\mu) = x.\beta$	Modelo de regressão	$b(\theta)$	φ	$E(y) =$ $= b'(\theta)$	$b''(\theta)$	$Var(y) =$ $= \varphi b''(\theta)$
Normal(μ, σ^2)	$g(\mu) = \mu$	linear	$\frac{\theta^2}{2}$	σ^2	$\mu = \theta$	1	σ^2
Binomial(n, p)	$g(\mu) = \text{logit}(p)$ $= \text{logit}(\frac{\mu}{n})$	logística	$\log(1 + \exp(\theta))$	1	$\pi = \frac{\exp(\theta)}{1 + \exp(\theta)}$	$\pi(1 - \pi)$	$\pi(1 - \pi)$
Poisson(λ)	$g(\mu) = \log(\mu)$	de Poisson	$\exp(\theta)$	1	$\lambda = \exp(\theta)$	λ	λ
Gamma(μ, ν)	$g(\mu) = -\frac{1}{\mu}$	Gama	$-\log(-\theta)$	$\frac{1}{\nu}$	$\mu = -\frac{1}{\theta}$	μ^2	$\frac{\mu^2}{\nu}$
IGauss(μ, σ^2)	$g(\mu) = -\frac{1}{\mu^2}$	Gaussiana inversa	$-(-2\theta)^{1/2}$	σ^2	$\mu = (-2\theta)^{-1/2}$	μ^3	$\mu^3 \sigma^2$

Modelos de Zeros Inflacionados

- Surgem com o intuito de modelar o excesso de zeros, e consequentemente sobredispersão, existente numa grande parte de dados de contagens reais.
- São aplicados em áreas como:
 - Medicina: ausência de dentes (dentes todos bons ou dentes implantados)
 - Ecologia: presença ou não de determinada espécie num determinado habitat
 - Produção: Defeitos de fabricação (contar o número de parafusos imperfeitos)
 - Alimentação: frequência alimentar de determinados alimentos

Modelo de regressão de Poisson com zeros inflacionados

- Este modelo surge com o intuito de modelar o excesso de zeros existente nos dados.


Considere-se uma amostra aleatória Y_1, \dots, Y_n da variável resposta Y . Para cada variável Y_i , existem **dois processos**:

$$Y_i \sim \begin{cases} 0 & \text{com probabilidade } \pi_i \\ \text{Poisson}(\mu_i) & \text{com probabilidade } 1 - \pi_i, \end{cases}$$





onde π_i é a probabilidade de existirem zeros falsos. O modelo de zeros inflacionados de Poisson assume que:

$$P_r(Y_i = y_i | x_i) = \begin{cases} \pi_i + (1 - \pi_i) \exp(-\mu_i) & \text{PARA } y_i = 0 \\ (1 - \pi_i) \frac{\exp(-\mu_i) \mu_i^{y_i}}{y_i!} & \text{PARA } y_i \geq 1. \end{cases}$$

Zeros Falsos vs Zeros Verdadeiros



Comportamento da função de probabilidade do modelo ZIP



Modelo de Regressão de Poisson com zeros inflacionados

Este modelo modela:

- a média μ de uma variável de Poisson através de uma regressão de Poisson.
- a probabilidade π de existirem zeros falsos através de uma regressão Logística.

Assim, os parâmetros $\mu = (\mu_1, \dots, \mu_n)'$ e $\pi_i = (\pi_1, \dots, \pi_n)'$ satisfazem:

$$\begin{aligned}\log(\mu) &= X\beta \\ \text{logit}(\pi) &= \log\left(\frac{\pi}{1-\pi}\right) = Z\gamma,\end{aligned}$$

onde X e Z são matrizes de observações das variáveis explicativas de interesse e β e γ (vetores) são os parâmetros da regressão.

Como avaliar a qualidade do ajustamento de um modelo?

Desviância:

$$D(y, \hat{\mu}) = -2\varphi \log \left(\frac{\text{função de verosimilhança de um modelo } \omega}{\text{função de verosimilhança do modelo saturado}^2} \right)$$

- A desviância de um modelo avalia a discrepância entre os valores observados (modelos saturado) e os valores estimados pelo modelo ω , ou seja, **avalia a qualidade do ajustamento do modelo**.
- O **valor de D será tanto maior** (em módulo) **quanto maior for a discrepância** entre o modelo estimado e os dados.

²melhor modelo em termos de ajustamento; tem um parâmetro por observação

Teste de Hipóteses - Modelo ω vs Modelo Saturado

Pretende-se avaliar se um determinado modelo ω faz um bom ajustamento aos dados. Para isso, consideremos o seguinte teste:

H_0 : o ajustamento do modelo ω é igual ao ajustamento do modelo saturado

H_1 : os ajustamentos não são iguais (e pto o ajustamento do modelo saturado é melhor)

Estatística de teste: Sob determinadas condições, $D \sim X^2(df)$

onde df é o número de graus de liberdade que é igual a $p_s - p_\omega$, onde p_s é o número de parâmetros do modelo saturado e p_ω é o número de parâmetros do modelo ω .

Decisão: Rejeitar H_0 com um nível de significância α se **$D > X^2_{1-\alpha}(df)$**

Exemplo - PhD

Pretende-se saber qual o número médio de artigos publicados por um bioquímico nos últimos 3 anos de doutoramento.

As variáveis dos dados são:

- **art** - artigos publicados nos últimos 3 anos de doutoramento
- **fem** - sexo feminino (codificada como 1)
- **mar** - casado (codificada como 1)
- **kid5** - número de filhos com idade inferior a 6 anos
- **phd** - prestígio do programa de doutoramento, varia entre 0.75 e 5.
- **ment** - artigos publicados pelo orientador nos últimos três anos

Exemplo - PhD

```
. summarize art
```

Variable	Obs	Mean	Std. Dev.	Min	Max
art	915	1.692896	1.926069	0	19

```
. di r(Var)
3.7097416
```

- existem 915 observações (915 bioquímicos)
- a média do número de artigos publicados é de 1.69
- a variância do número de artigos publicados é de 3.71

PhD - Regressão de Poisson

Modelo:

$$\log(\mu(x)) = \beta_0 + \beta_1 * fem + \beta_2 * mar + \beta_3 * kid5 + \beta_4 * phd + \beta_5 * ment$$

```
. glm art fem mar kid5 phd ment, family(poisson) nolog
```

```
Generalized linear models           No. of obs   =           915
Optimization      : ML              Residual df  =           909
                                                Scale parameter =           1
Deviance          = 1634.370984      (1/df) Deviance = 1.797988
Pearson          = 1662.54655        (1/df) Pearson = 1.828984

Variance function: v(u) = u
Link function     : g(u) = ln(u)

[poisson]
[Log]

Log likelihood    = -1651.056316
AIC               = 3.621981
BIC               = -4564.031
```

art	Coef.	OIM Std. Err.	z	P> z	[95% Conf. Interval]	
fem	-.2245942	.0546138	-4.11	0.000	-.3316352	-.1175532
mar	.1552434	.0613747	2.53	0.011	.0349512	.2755356
kid5	-.1848827	.0401272	-4.61	0.000	-.2635305	-.1062349
phd	.0128226	.0263972	0.49	0.627	-.038915	.0645601
ment	.0255427	.0020061	12.73	0.000	.0216109	.0294746
_cons	.3046168	.1029822	2.96	0.003	.1027755	.5064581

PhD - Modelo de Regressão de Poisson

- Qual o número médio de artigos publicados por um bioquímico do sexo **masculino**, **casado**, com **1 filho com idade inferior a 6**, com um programa de doutoramento de **prestígio 5** e com **4 artigos** publicados pelo orientador nos últimos 3 anos?

$$\log(\mu(x)) = \beta_0 + \beta_1 * fem + \beta_2 * mar + \beta_3 * kid5 + \beta_4 * phd + \beta_5 * ment$$

$$\Leftrightarrow \mu(x) = \exp(0.305 - 0.2245 * 0 + 0.1552 * 1 - 0.1849 * 1 + 0.0128 * 5 + 0.3046 * 4) \Leftrightarrow$$

$$\Leftrightarrow \mu(x) = 4.7$$

Tendo em conta o teste de hipóteses: ³

- $D=1634$, $df=909$, $\alpha = 0.05$, $\chi_{0.95}^2(909)=980.3$

$$1634 > 980.3 \text{ logo } \textbf{rejeitamos } H_0.$$

³ H_0 : o ajustamento do modelo ω é igual ao ajustamento do modelo saturado H_1 : os ajustamentos não são iguais (e pto o ajustamento do modelo saturado é melhor); **Estatística de teste:** Sob determinadas condições, $D_\omega \sim \chi^2(909)$; **Decisão:** Rejeitar H_0 com um nível de significância α se $D > \chi_{1-\alpha}^2(909)$

PhD

A tabela seguinte contém os dados sobre o número de artigos publicados tendo em conta o sexo, casamento, nº de filhos com idade inferior a 6, prestígio do programa doutoral e nº de artigos publicados pelo orientador.

phd	$fem = 1 mar = 1 kid5 = 1 ment = [0 - 6]$
[0-4.00]	1.52 ← média
	2.03 ← variância
	27 ← nº observações

phd	$fem = 0 mar = 0 kid5 = 1 ment = [23 - 30]$
[0-4.00]	4.29 ← média
	11.24 ← variância
	7 ← nº observações

- Existe sobredispersão ⇒ Modelo de Regressão Binomial Negativa

PhD - Modelo de Regressão Binomial Negativa

Modelo:

$$\log(\mu(x)) = \beta_0 + \beta_1 * fem + \beta_2 * mar + \beta_3 * kid5 + \beta_4 * phd + \beta_5 * ment$$

```
. glm art fem mar kid5 phd ment, family(nb `v') nolog
Generalized linear models          No. of obs   =       915
Optimization      : ML             Residual df =       909
                                   Scale parameter =      1
Deviance           =      1004.2815 (1/df) Deviance =   1.10482
Pearson           =      944.5494622 (1/df) Pearson  =   1.039108

Variance function: V(u) = u+(.4416000000000001)u^2 [Neg. Binomial]
Link function     : g(u) = ln(u)                 [Log]

Log likelihood    = -1560.958338                AIC           =   3.425046
                                                         BIC           = -5194.12
```

art	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
fem	-.2164184	.0726706	-2.98	0.003	-.3588501	-.0739867
mar	.1504895	.0821062	1.83	0.067	-.0104358	.3114147
kid5	-.1764152	.0530587	-3.32	0.001	-.2804084	-.0724221
phd	.0152712	.0360382	0.42	0.672	-.0553624	.0859047
ment	.0290823	.0034657	8.39	0.000	.0222896	.0358751
_cons	.256144	.1385256	1.85	0.064	-.0153613	.5276493

PhD - Modelo de Regressão Binomial Negativa

- Qual o número médio de artigos publicados por um bioquímico do sexo **masculino, casado**, com **1 filho com idade inferior a 6**, com um programa de doutoramento de **prestígio 5** e com **4 artigos** publicados pelo orientador nos últimos 3 anos?

$$\log(\mu(x)) = \beta_0 + \beta_1 * fem + \beta_2 * mar + \beta_3 * kid5 + \beta_4 * phd + \beta_5 * ment$$

$$\Leftrightarrow \mu(x) = \exp(0.2561 - 0.02164 * 0 + 0.1505 * 1 - 0.1764 * 1 + 0.0153 * 5 + 0.0291 * 4) \Leftrightarrow$$


$$\mu(x) = 1.5267$$

Tendo em conta o teste de hipóteses: ⁴


- $D=1004$, $df=909$, $\alpha=0.05$, $X_{0.95}^2(909)=980.3$

$$1004 > 980.3 \text{ logo rejeitamos } H_0.$$

- O modelo de regressão binomial negativa faz um ajustamento **muito melhor** do que o modelo de regressão de poisson.

⁴ H_0 : o ajustamento do modelo ω é igual ao ajustamento do modelo saturado H_1 : os ajustamentos não são iguais (e pto o ajustamento do modelo saturado é melhor); **Estatística de teste:** Sob determinadas condições, $D_\omega \sim \chi^2(909)$; **Decisão:** Rejeitar H_0 com um nível de significância α se $D > X_{1-\alpha}^2(909)$ 

PhD - Modelo de Regressão de Poisson vs Modelo de Regressão Binomial Negativa



- A função variância no caso da distribuição de Poisson faz um bom trabalho na maior parte dos dados, mas não consegue captar as variações mais elevadas dos bioquímicos mais produtivos.
- A função variância no caso da distribuição Binomial Negativa não é muito diferente mas sendo uma função quadrática, faz um melhor trabalho nas variações mais elevadas.

PhD - Modelo de Regressão de Poisson com zeros inflacionados

```
. sum zobs zfitp
```

variable	Obs	Mean	Std. Dev.	Min	Max
zobs	915	.3005464	.4587464	0	1
zfitp	915	.2092071	.0794247	.0000659	.4113403

- 30% dos bioquímicos não publicaram artigos nos últimos 3 anos de doutoramento
- O modelo de Regressão de Poisson prevê que apenas 20.9% dos bioquímicos não publicaram artigos nos últimos 3 anos de doutoramento -**existe inflação de zeros**.

Modelo ZIP:

$$\log(\mu(x)) = \beta_0 + \beta_1 * fem + \beta_2 * mar + \beta_3 * kid5 + \beta_4 * phd + \beta_5 * ment$$

$$\text{logit}(\pi(x)) = \gamma_0 + \gamma_1 * fem + \gamma_2 * mar + \gamma_3 * kid5 + \gamma_4 * phd + \gamma_5 * ment$$

PhD - Modelo de Regressão de Poisson com zeros inflacionados

- **Zeros falsos** - aqueles estudantes para quem publicar não é relevante; querem entrar, por exemplo, no mundo do trabalho e não estão interessados em publicar.



- **Zeros verdadeiros** - aqueles estudantes cujas publicações são importantes mas não conseguem publicar por determinado motivo.



PhD - Modelo de Regressão de Poisson com zeros inflacionados

Zero-inflated Poisson regression

Number of obs = 915
 Nonzero obs = 640
 Zero obs = 275

Inflation model = logit
 Log likelihood = -1604.773

LR chi2(5) = 78.56
 Prob > chi2 = 0.0000

art	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
art						
fem	-.2091446	.0634047	-3.30	0.001	-.3334155	-.0848737
mar	.103751	.071111	1.46	0.145	-.035624	.243126
kid5	-.1433196	.0474293	-3.02	0.003	-.2362793	-.0503599
phd	-.0061662	.0310086	-0.20	0.842	-.066942	.0546096
ment	.0180977	.0022948	7.89	0.000	.0135999	.0225955
_cons	.640839	.1213072	5.28	0.000	.4030814	.8785967
inflate						
fem	.1097465	.2800813	0.39	0.695	-.4392028	.6586958
mar	-.3540107	.3176103	-1.11	0.265	-.9765155	.2684941
kid5	.2171001	.196481	1.10	0.269	-.1679956	.6021958
phd	.0012702	.1452639	0.01	0.993	-.2834418	.2859821
ment	-.134111	.0452461	-2.96	0.003	-.2227918	-.0454302
_cons	-.5770618	.5093853	-1.13	0.257	-1.575439	.421315

PhD - Modelo de Regressão de Poisson com zeros inflacionados

- Tendo em conta a equação de inflação, a única variável que **influencia a probabilidade de existirem zeros falsos** é a variável **ment**.

$$OR = \frac{Odds(P|ment + 1)}{Odds(P|ment)} = \exp(-0.134111) \Leftrightarrow$$

$$\Leftrightarrow \frac{Odds(P|ment + 1)}{Odds(P|ment)} = 0.875 \Leftrightarrow$$

$$\Leftrightarrow Odds(P|ment + 1) = (1 - 0.125)Odds(P|ment) \Leftrightarrow$$

$$\Leftrightarrow Odds(P|ment + 1) = Odds(P|ment) - 0.125Odds(P|ment).$$

- Por cada artigo publicado pelo orientador, o odds para a publicação de artigos pelos alunos bioquímicos baixa de 12.5 %.

PhD - Modelo de Regressão de Poisson com zeros inflacionados

- Analisando a equação que traduz o número médio de artigos, verifica-se que as variáveis **fem**, **kid5** e **ment** são **estatisticamente significativas**.
- Encontram-se desvantagens para bioquímicos do sexo feminino* ou com filhos com idade inferior a 6 anos.

$$* RR = \frac{E(P|F)}{E(P|\bar{F})} = \exp(-0.209) \Leftrightarrow E(P|F) = 0.81E(P|\bar{F}) \Leftrightarrow$$

$$E(P|F) = (1 - 0.19)E(P|\bar{F}) \Leftrightarrow E(P|F) = E(P|\bar{F}) - 0.19E(P|\bar{F})$$

- Um bioquímico do sexo feminino publica **em média** menos 19% do que um bioquímico do sexo masculino.

PhD - O modelo ZIP resolveu o problema do excesso de zeros?

O modelo prevê:

- π para saber qual a probabilidade de não existirem publicações (zeros falsos)
- μ para prever o número médio de publicações

```
. gen zfitz = pz + (1-pz)*exp(-muz)
```

```
. sum zfitz
```

variable	Obs	Mean	Std. Dev.	Min	Max
zfitz	915	.2985684	.1280144	.0007119	.5815108

- O modelo previu que 29,9% (cerca de 273) dos bioquímicos não publicaram nenhum artigo, muito perto do valor observado, 30%.
- **O modelo ZIP resolveu o problema do excesso de zeros.**

Referências

- [1] Cheung, Y. (2002). Zero-Inflated models for regression analysis of count data: a study of growth and development. In: Statistics in Medicine, n° 21, pp. 1461-1469.
- [2] Hilbe, J. M. (2011). Negative Binomial Regression. Cambridge:University Press.
- [3] Ridout, M.; Demétrio, C.; Hinde, J. (1998). Models for Count data with many zeros. In: International Biometric Conference, Cape Town.
- [4] Rodríguez, G. (2007). Lecture Notes on Generalized Linear Models. Disponível em <http://data.princeton.edu/wws509/>.
- [5] Zuur, A.; Ieno, E.; Walker, N.; Saveliev, A.; Smith, G. (2009). Mixed Effects Models and Extensions in Ecology with R. New York: Springer Science+Business Media.

Regressão de Poisson e parentes próximos

Filipa Januário



Janeiro 2012