

Análise de Dados Categóricos

Modelo de Regressão Polítômica

Enrico A. Colosimo/UFMG

<http://www.est.ufmg.br/~enricoc/>

Departamento de Estatística
Universidade Federal de Minas Gerais

Extensões do Modelo de Regressão Logística Binário

- 1 Regressão Politômica: resposta com mais de duas categorias
 - Nominal;
 - Ordinal.
- 2 Medidas Repetidas ou Longitudinais.
 - Desenho Pareado.
 - Exemplo: Mais de um dente por paciente.
 - Exemplo: Acompanhamento longitudinal.
 - Modelos: Marginal e de Efeitos aleatórios.

Modelo de Regressão Logística para Respostas Multicategóricas

1 Resposta Nominal

- Exemplos: escolha da marca de um produto (A, B, C e D), escolha do meio de locomoção (ônibus, avião, trem), etc.
- Modelagem padrão: utilizar logit para pares de categorias.

2 Resposta Ordinal

- Exemplos: qualidade de vida (excelente, boa, razoável, ruim), opção política (muito liberal, liberal, moderada, conservadora), etc.
- Modelagem padrão: utilizar logit para probabilidades cumulativas.

3 Em ambos casos, o objetivo é modelar a dependência de π_{ij} para o i -ésimo indivíduo na j -ésima categoria,

$$\pi_{ij} = P(Y_i = j), \quad j = 1, \dots, r,$$

em função de um conjunto de covariáveis x (categóricas ou contínuas).

4 Os modelos tratam as respostas y , para fixo X , como multinomiais Y_{ij} para $j = 1, \dots, r$.

1-Regressão Logística Politémica Nominal (Modelos de logitos generalizados)

$$Y : 1, 2, \dots, r, \quad r > 2$$

Vamos tomar a categoria r como referência

$$\text{logit}\pi_j(x) = x\beta_j, \quad j = 1, 2, \dots, r$$

em que,

$$\text{logit}\pi_1(x) = \log\left(\frac{P[y=1|x]}{P[y=r|x]}\right) = \log\frac{\pi_1(x)}{\pi_r(x)} = \beta_{01} + \beta_{11}X_1 + \dots + \beta_{p1}X_p$$

Isto significa que temos $(p + 1) \times (r - 1)$ parâmetros

$$\pi_1(x) = P[y = 1|x]$$

$$\pi_r(x) = P[y = r|x] = 1 - \sum_{j=1}^{r-1} \pi_j(x)$$

Modelo de logitos generalizados

$$\pi_1(x) = P[y = 1|x] = \frac{e^{X'\beta_1}}{1 + \sum_{j=1}^{r-1} e^{X'\beta_j}}$$

$$\pi_{r-1}(x) = P[y = r - 1|x] = \frac{e^{X'\beta_{r-1}}}{1 + \sum_{j=1}^{r-1} e^{X'\beta_j}}$$

$$\pi_r(x) = 1 - \sum_{j=1}^{r-1} \pi_j(x) = 1 - \frac{\sum_{j=1}^{r-1} e^{X'\beta_j}}{1 + \sum_{j=1}^{r-1} e^{X'\beta_j}} = \frac{1}{1 + \sum_{j=1}^{r-1} e^{X'\beta_j}}$$

$$\text{logit}\pi_1(x) = X'\beta_1 \quad \dots \quad \text{logit}\pi_{r-1}(x) = X'\beta_{r-1}$$

Isto é equivalente a termos $r - 1$ regressões logísticas binárias.

Tudo que foi visto para o caso $r=2$ (binária) vale para este politômico.

Exemplo: Profa. Juliana - Traumatismo Odontológico

- Resposta: Tipo de Reabsorção
 - 0- ausente,
 - 1- substituição e
 - 2-inflamatória
- Objetivo: avaliar o efeito das variáveis na resposta:
 - 1- Idade (usei os pontos de corte de 11 e 16 anos),
 - 2- SAT - Uso de Antibiótico,
 - 3- TempoCont1 (tempo entre o reimplante e o TER),
 - 4- MeioG (1- úmido, 2- leite e 3- seco) e
 - 5-7 Genéticas (RANKL, OPG e IL10)

Exemplo: Profa. Juliana - Traumatismo Odontológico

Descritiva




- Estudo com 269 pacientes.

	n	%	Total
Tipo de absorção			268
Ausente	56	20,9%	
Substituição	187	69,8%	
Inflamatória	25	9,3%	
NA	1		
Meio			269
Úmido	104	38,7%	
Leite	60	22,3%	
Seco	105	39,0%	
Antibiótico			175
Sim	46	26,3%	
Não	129	73,7%	
NA	94		

	n	%	Total
Rank			265
1	154	58,1%	
2	85	32,1%	
3	26	9,8%	
OPG			266
1	32	12,0%	
2	108	40,6%	
3	126	47,4%	
NA	3		
IL10			269
1	127	47,2%	
2	110	40,9%	
3	32	11,9%	

Exemplo: Profa. Juliana - Traumatismo Odontológico

Descritiva



Ajuste do modelo - library VGAM

- Ajuste com a variável antibiótico

```
> fit1 <- vglm(Tipol~SAT, family="multinomial", data=dados) #  
> summary(fit1)
```

Call:

```
vglm(formula = Tipol ~ SAT, family = "multinomial", data = dados)
```

Pearson residuals:

	Min	1Q	Median	3Q	Max
$\log(\mu_{[,1]}/\mu_{[,3]})$	-1.8073	-0.8974	0.6155	0.6671	0.6671
$\log(\mu_{[,2]}/\mu_{[,3]})$	-0.9858	-0.1551	-0.1551	-0.1226	3.0782

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept):1	1.38217	0.78715	1.756	0.0791
(Intercept):2	-1.08286	1.24795	-0.868	0.3856
SAT:1	-0.08289	0.44205	-0.188	0.8513
SAT:2	0.27193	0.68860	0.395	0.6929

Ajuste do modelo - library VGAM

- Ajuste com as variáveis: IdadeG11, OPGGen e TempoContLog

```
> fit11<-vglm(Tipol~IdadeG11 + factor(OPGGen) + log(TempoCont1) -  
  factor(MeioG) - factor(Rank1Gen), family = "multinomial", data=dados)  
> summary(fit11)
```

```
Call:  
vglm(formula = Tipol ~ IdadeG11 + factor(OPGGen) + log(TempoCont1), family = "multinomial",  
  data = dados)
```

Pearson residuals:

	Min	1Q	Median	3Q	Max
log(mu[,1]/mu[,3])	-5.366	-0.7593	0.4121	0.57639	1.554
log(mu[,2]/mu[,3])	-4.044	-0.2440	-0.1218	-0.05447	5.332

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)	
(Intercept):1	-2.1840	1.1917	-1.833	0.06684	.
(Intercept):2	-3.1748	1.6597	-1.913	0.05576	.
IdadeG11:1	-0.6680	0.4195	-1.592	0.11128	
IdadeG11:2	-1.7572	0.5936	-2.960	0.00308	**
factor(OPGGen)2:1	-0.1229	0.6824	-0.180	0.85704	
factor(OPGGen)2:2	-1.8592	0.8648	-2.150	0.03157	*
factor(OPGGen)3:1	-0.7652	0.6548	-1.168	0.24261	
factor(OPGGen)3:2	-2.1670	0.8149	-2.659	0.00783	**
log(TempoCont1):1	1.2945	0.2252	5.749	9.00e-09	***
log(TempoCont1):2	1.7133	0.3010	5.693	1.25e-08	***

- A interpretação é feita comparando com a categoria de referência, ou seja,
 - Logit 1: Substituição/Ausente
 - Logit 2: Inflamatória/Ausente
- Para a variável IdadeG11:
 - a chance de reabsorção por substituição para os pacientes com idade maior que 11 anos é $0,2(\exp(-1,757))$ (IC; 95%; 0,05; 0,55) vezes a chance daqueles com idade menor que 11 anos (comparado com ausência de reabsorção).

2 Regressão Logística Politémica Ordinal (Modelos de logitos cumulativos)

Como levar em consideração na modelagem o fato das categorias serem ordenadas?

y (*melhora*) : nenhuma(1), alguma(2), muita(3)

$\pi(x) = P[y = j|x], j = 1, 2, 3.$

- Logitos cumulativos

$$\text{logit}(\pi_{1.2-3}) = \log\left[\frac{\pi_1(x)}{\pi_2(x) + \pi_3(x)}\right]$$

compara nenhuma melhora com pelo menos alguma melhora

$$\text{logit}_1(x) = \log\left[\frac{P(y=1|x)}{P(y>1|x)}\right]$$

$$\text{logit}_2(x) = \log\left[\frac{P(y\leq 2|x)}{P(y=3|x)}\right]$$

Geral:

$$\text{logit}_k(x) = \log\left[\frac{P(y\leq k|x)}{P(y>k|x)}\right]$$

Modelo de Logitos Acumulados

$$P(y \leq k|x) = \frac{e^{X' \beta_k}}{1 + e^{X' \beta_k}}$$

$$P(y < k|x) = 1 - P(y \geq k|x) = \frac{1}{1 + e^{X' \beta_k}}$$

$$\text{logit}_k(x) = X' \beta_k$$

Isto significa que cada β_k está comparando as primeiras k 's categorias com as restantes $r - k + 1$ categorias

- Exemplo $r = 3$

β_1 compara $\log \frac{\pi_1}{\pi_2 + \pi_3}$ 1 vs 2-3

β_2 compara $\log \frac{\pi_1 + \pi_2}{\pi_3}$ 1-2 vs 3

Modelo de Chances Proporcionais

- Assumimos que

$$\beta_k = \beta$$

para $k = 1, \dots, r - 1$.

- Ou seja, o mesmo efeito de X para todas as comparações categorias acumuladas.

Exemplo (Variável resposta politômica ordinal)

Uma amostra de 84 pacientes com dores de artrite foi submetida ao um tratamento experimental. O objetivo do estudo é avaliar para a resposta grau de melhora (acentuada, alguma ou nenhuma) a possível associação com o tratamento e sexo.

Variáveis:

- Sexo

Feminino; Masculino

- Tratamento

A; Placebo

- Graus de melhora

Melhora acentuada; Alguma melhora; Nenhuma melhora

Exemplo (Variável resposta politômica ordinal)

A tabela a seguir mostra os dados associados ao estudo.

Sexo	Tratamento	Grau de Melhora			Total
		Acentuada	Alguma	Nenhuma	
F	A	16	5	6	27
F	Placebo	6	7	19	32
M	A	5	2	7	14
M	Placebo	1	0	10	11

Um modelo adequado para analisar esses dados é o de logitos cumulativos.

Exemplo (Variável resposta politômica ordinal)

Defina as quantidades:

π_1 : probabilidade de melhora acentuada

π_2 : probabilidade de alguma melhora

π_3 : probabilidade de nenhuma melhora

$X_1 = 1$: sexo feminino; $X_1 = 2$: sexo masculino

$X_2 = 1$: uso do tratamento A; $X_2 = 2$: placebo

Como existem 3 categorias de respostas ordinais, defini-se dois logitos cumulativos

$$\text{logit}(P(Y \leq 1|X)) = \log\left(\frac{\pi_1}{\pi_2 + \pi_3}\right) \quad \text{logit}(Y \leq 2|X) = \ln\left(\frac{\pi_1 + \pi_2}{\pi_3}\right)$$

Exemplo (Variável resposta politômica ordinal)

Análise da tabela de *deviance*

Modelos	g.l.	Deviance residual	Diferenças de deviances	Diferenças de g.l.
Nulo	6(8-2)	22.59		
X_1	5(8-3)	18.79	3.80	1
$X_2 X_1$	4(8-4)	2.71	16.08	1
$X_1 * X_2 X_1, X_2$	3(8-5)	2.40	0.31	1

Utiliza-se o teste da razão de verossimilhança para testar o modelo

Exemplo (Variável resposta politômica ordinal)

Resultados

- Iteração de sexo e tratamento não significativa

($p = 0.5786$, $g.l. = 1$)

- Sexo significativo

($p = 0.051$)

- Tratamento na presença de sexo significativo

($p < 0.0001$)

- Teste de proporcionalidade

Hipótese nula não é rejeitada

($p = 0.39$, $g.l. = 2$)

Respostas Repetidas ou Longitudinais

1 Exemplos:

- Medidas Repetidas: Mais de um dente em cada paciente;
- Medidas Longitudinais: Mecanismo Evacuatório de Recém-Nascidos avaliado em cada mês, no primeiro ano de vida.

2 Dificuldade: Dados não mais independentes.

Respostas Repetidas ou Longitudinais

1 Y_{ij} , $i = 1, \dots, N$; $j = 1, \dots, k$: binária, contagem, etc.

2 Modelos Estatísticos

- Modelos Lineares Generalizados Mistos.
- Modelos Marginais: GEE