



# Modelos Lineares Generalizados

unificação metodológica

Alexandre Adalardo de Oliveira

PlanECO 2017

## Conceitos

- estrutura do erro
- preditora linear
- função de ligação

# Modelos Lineares Generalizados

# Função de ligação

- o preditor apresenta resposta linear  $\eta$

$$\eta = \alpha + \sum \beta_i x_i$$

- a função inversa da ligação retorna à escala da preditora

$$Y = g(\eta)^{-1}$$

# Função de ligação: canônica

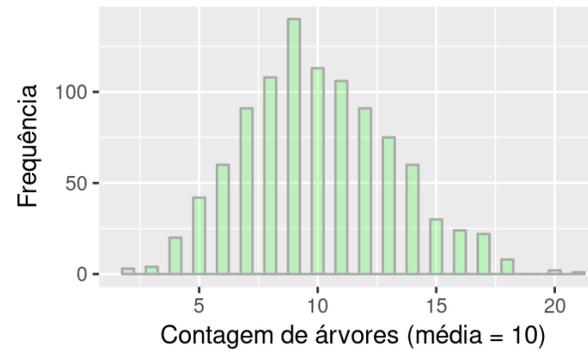
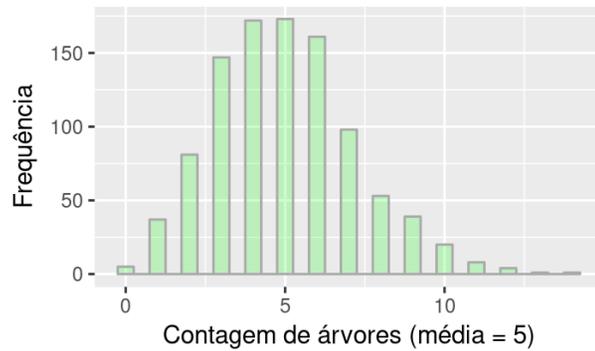
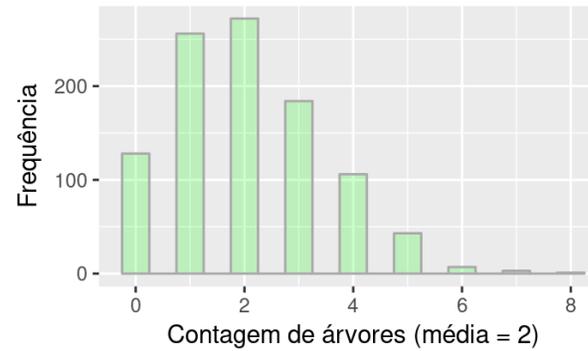
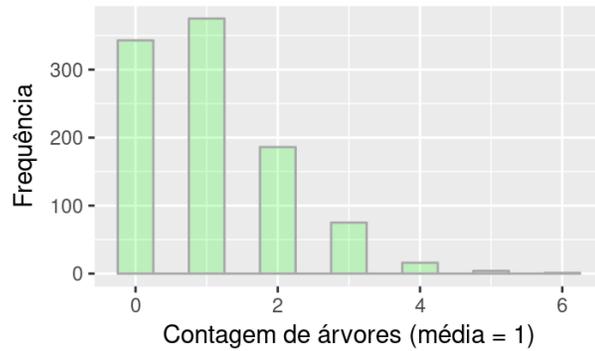
- dependendo da estrutura de erro há uma função de ligação padrão

resposta	resíduos	ligação
contínua	gaussiano	identidade
contagem	poisson	log
proporção	binomial	logit
binária	binomial	logit

---

# Diferentes estruturas de erro

Contagem: árvores por parcela



# Dados de Contagem

- contagem é limitada no zero
- variância não é constante (aumenta com a média)
- erro não tem distribuição normal
- valores inteiros (não contínuos)

Função de ligação

$$\log(\alpha + \sum \beta_i x_i)$$

# GLM: ajuste de modelo de contagem

- faça o modelo cheio usando a família de ligação **poisson(log)**
- avalie o sobre-dispersão do erro pela razão "Residual deviance" e "degrees of freedom"
- se o valor da razão for muito maior que 1, ajuste o modelo cheio novamente com a família "quasipoisson"
- compare os modelos simplificados com o mais complexo usando "anova"
  - com "poisson" use o argumento "test = "Chisq" "
  - com "quasipoisson" use o argumento "test = "F" "
- retenha o modelo mínimo adequado
- retorne os coeficientes e preditos do modelo para escala original (antilog)

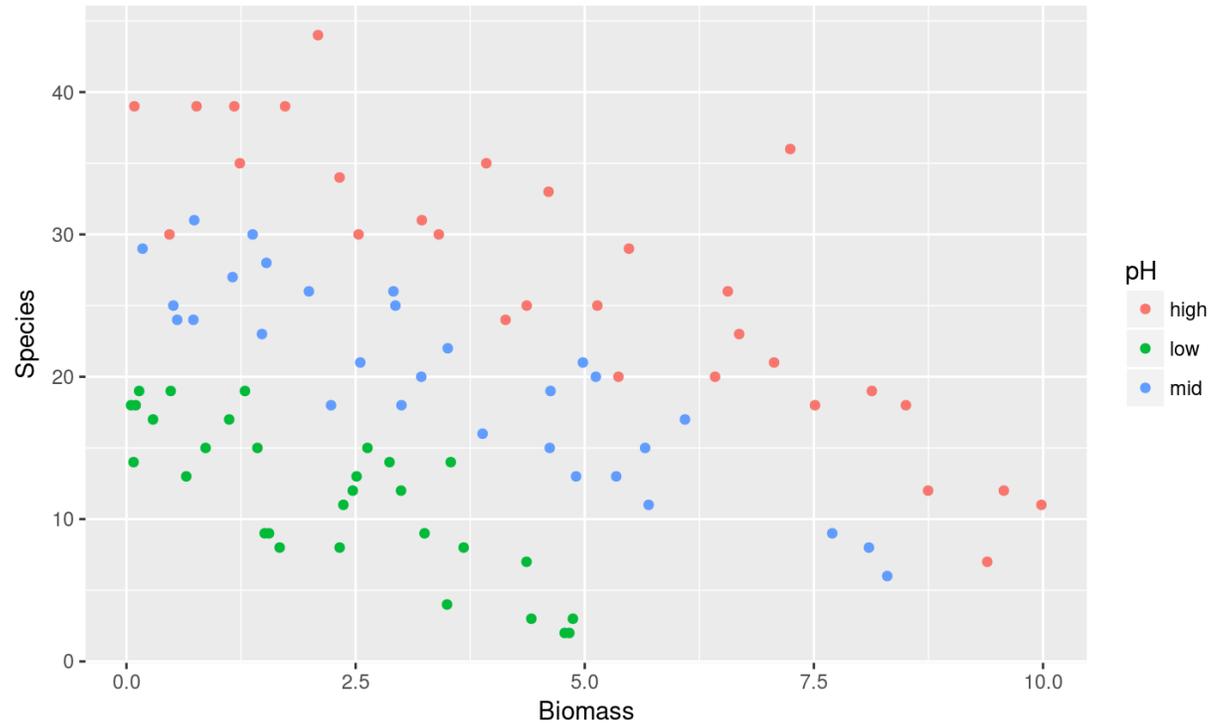
# Exemplo: Contagem de espécies

- Biomassa e ph do solo estão relacionados à coexistência de espécies

pH	Biomass	Species
high	0.4692972	30
high	1.7308704	39
high	2.0897785	44
high	3.9257871	35
high	4.3667927	25
high	5.4819747	29

---

# Gráfico: riqueza de espécies



# Modelo

```
glm01 <- glm(Species ~ Biomass + pH + Biomass:pH, family = poisson, data= arv)
anova(glm01, test = "Chisq")
```

```
## Analysis of Deviance Table
```

```
##
```

```
## Model: poisson, link: log
```

```
##
```

```
## Response: Species
```

```
##
```

```
## Terms added sequentially (first to last)
```

```
##
```

```
##
```

```
##           Df Deviance Resid. Df Resid. Dev  Pr(>Chi)
```

```
## NULL                89      452.35
```

```
## Biomass             1    44.673      88    407.67 2.328e-11 ***
```

```
## pH                  2   308.431      86     99.24 < 2.2e-16 ***
```

```
## Biomass:pH         2    16.040      84     83.20 0.0003288 ***
```

```
## ---
```

```
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

10/43

## *summary(glm01)*

```
##
## Call:
## glm(formula = Species ~ Biomass + pH + Biomass:pH, family = poisson,
##      data = arv)
##
## Deviance Residuals:
##      Min        1Q    Median        3Q        Max
## -2.4978  -0.7485  -0.0402   0.5575   3.2297
##
## Coefficients:
##              Estimate Std. Error z value Pr(>|z|)
## (Intercept)   3.76812    0.06153  61.240 < 2e-16 ***
## Biomass       -0.10713    0.01249  -8.577 < 2e-16 ***
## pHlow         -0.81557    0.10284  -7.931 2.18e-15 ***
## pHmid         -0.33146    0.09217  -3.596 0.000323 ***
## Biomass:pHlow -0.15503    0.04003  -3.873 0.000108 ***
## Biomass:pHmid -0.03189    0.02308  -1.382 0.166954
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## (Dispersion parameter for poisson family taken to be 1)
```

11/43

## *summary(glm01)*

```
 #(Dispersion parameter for poisson family taken to be 1)  
 # Null deviance: 452.346 on 89 degrees of freedom  
 # Residual deviance: 83.201 on 84 degrees of freedom  
 # AIC: 514.39
```

# Simplificando o Modelo

ligação da família Poisson: Qui-quadrado

```
glm02 <- glm(Species ~ Biomass + pH, family = poisson, data= arv)
anova(glm01, glm02, test = "Chisq")
```

```
## Analysis of Deviance Table
```

```
##
```

```
## Model 1: Species ~ Biomass + pH + Biomass:pH
```

```
## Model 2: Species ~ Biomass + pH
```

```
##   Resid. Df Resid. Dev Df Deviance Pr(>Chi)
```

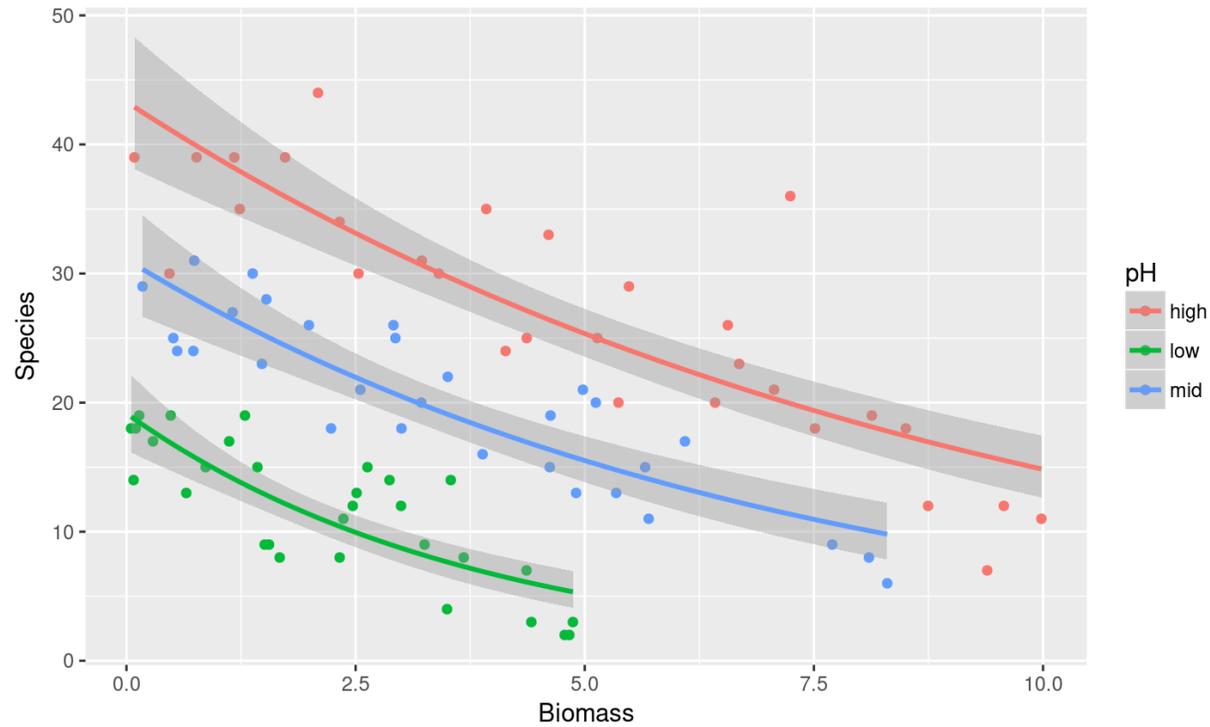
```
## 1         84      83.201
```

```
## 2         86      99.242 -2   -16.04 0.0003288 ***
```

```
## ---
```

```
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

# Gráfico do nosso modelo



# Predito pelo modelo: preditor linear

- alto pH, biomassa 0.47 e 7.5

```
coefglm01 <- coef(glm01)
(bio01 <- coefglm01[[1]] + coefglm01[[2]] * 0.47)
```

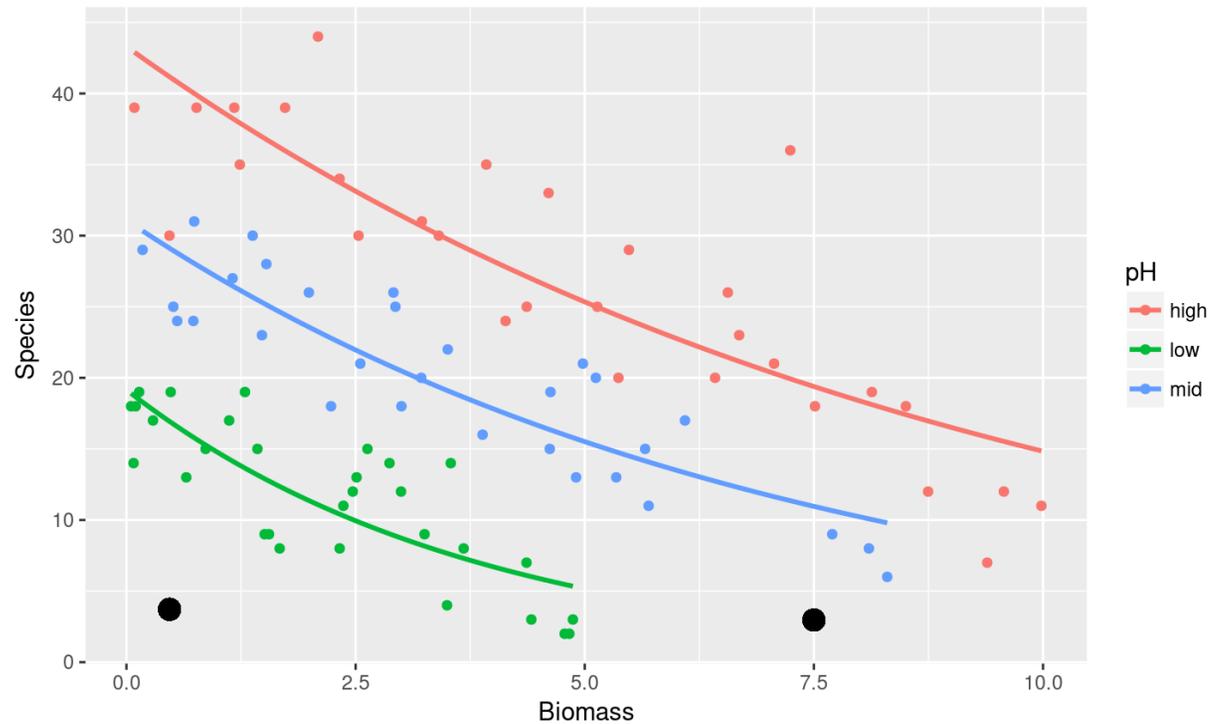
```
## [1] 3.717773
```

```
(bio02 <- coefglm01[[1]] + coefglm01[[2]] * 7.5)
```

```
## [1] 2.96465
```

# Predito pelo modelo: preditor linear

- alto pH, biomassa 0.47 e 7.5



# Predito pelo modelo: preditor linear

- alto pH, biomassa 0.47 e 7.5
- antilog: `exp()`

```
(exp(bio01))
```

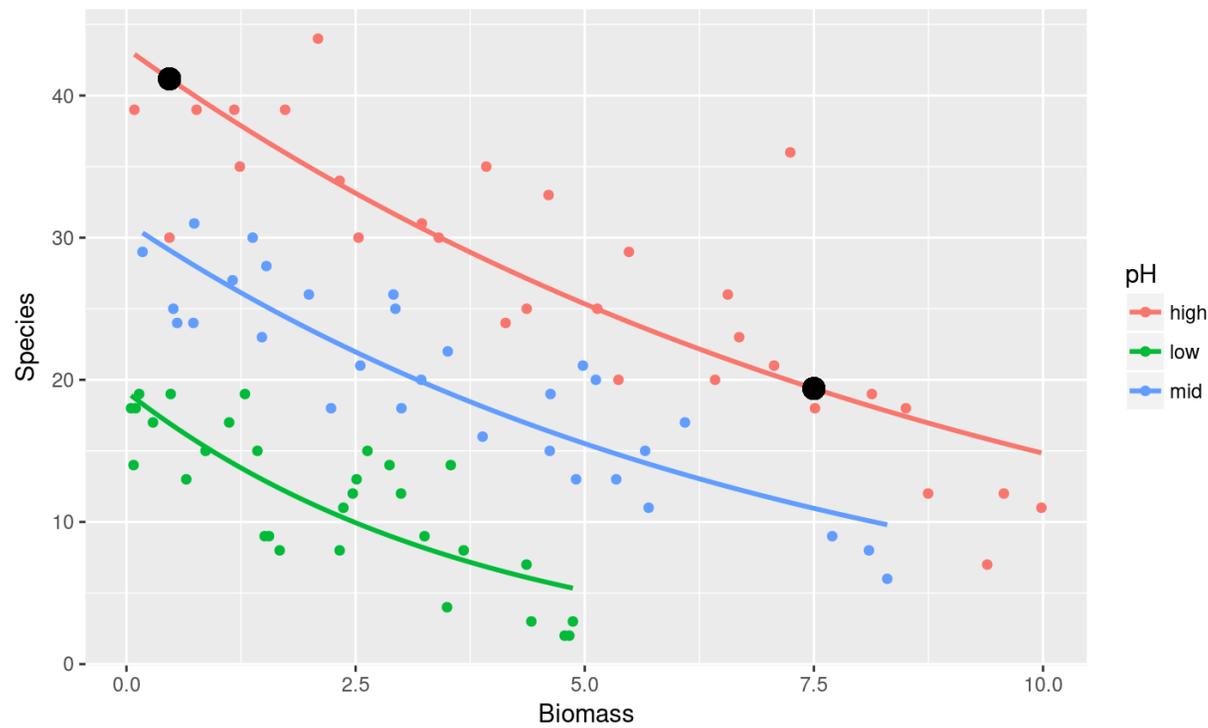
```
## [1] 41.17258
```

```
(exp(bio02))
```

```
## [1] 19.38792
```

# Predito pelo modelo: função inversa

$$\exp(E_{(y)})$$



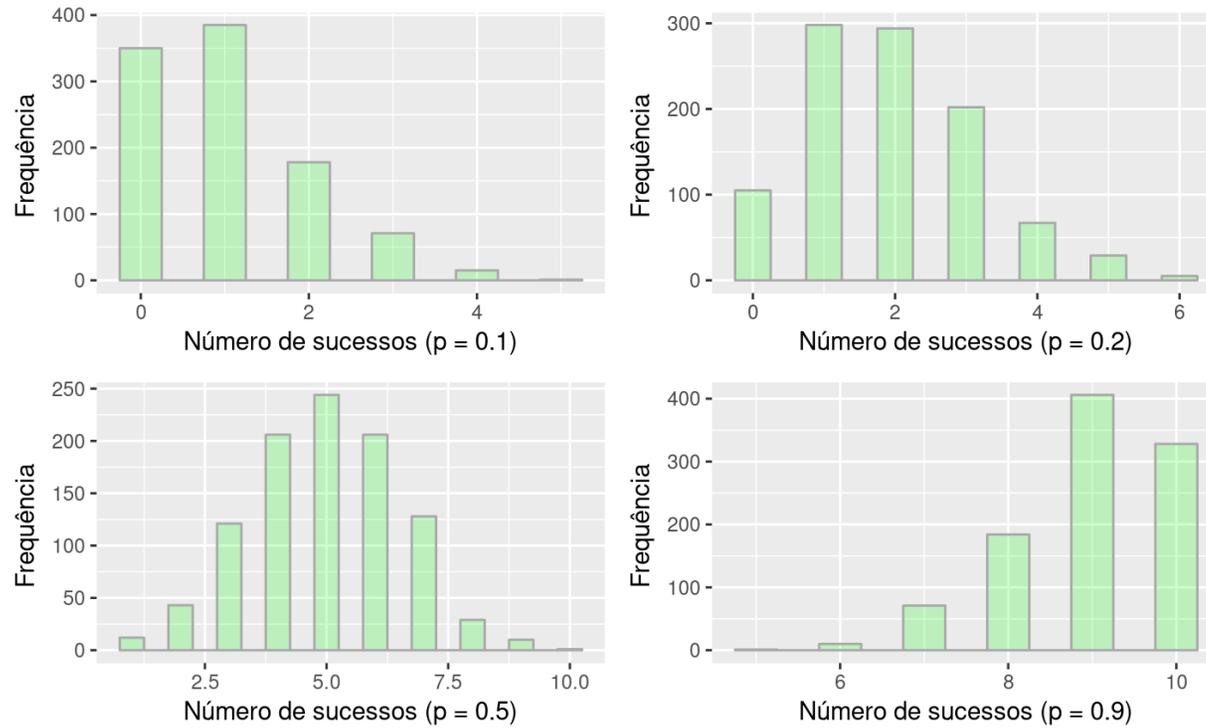
# Atividade



- Proporção (sucessos/tentativas)
- Binária:
  - sim x não
  - vivo x morto
  - germinou x não germinou

# GLM Binomial

# GLM Binomial: estrutura do erro



# GLM Binomial: logit

$$\eta = \log\left(\frac{a + bx}{1 - a + bx}\right)$$

$$\eta = \frac{e^{a+bx}}{1 - e^{a+bx}}$$

$$x = +\infty; y_p = 1$$

$$x = -\infty; y_p = 0$$

# GLM Binomial: odds ratio (razão de chance)

- probabilidade : sucessos/tentativas
- chance: sucessos/falhas
  - sucessos/(tentativas - sucessos)

$p$  = sucessos

$q$  = falha

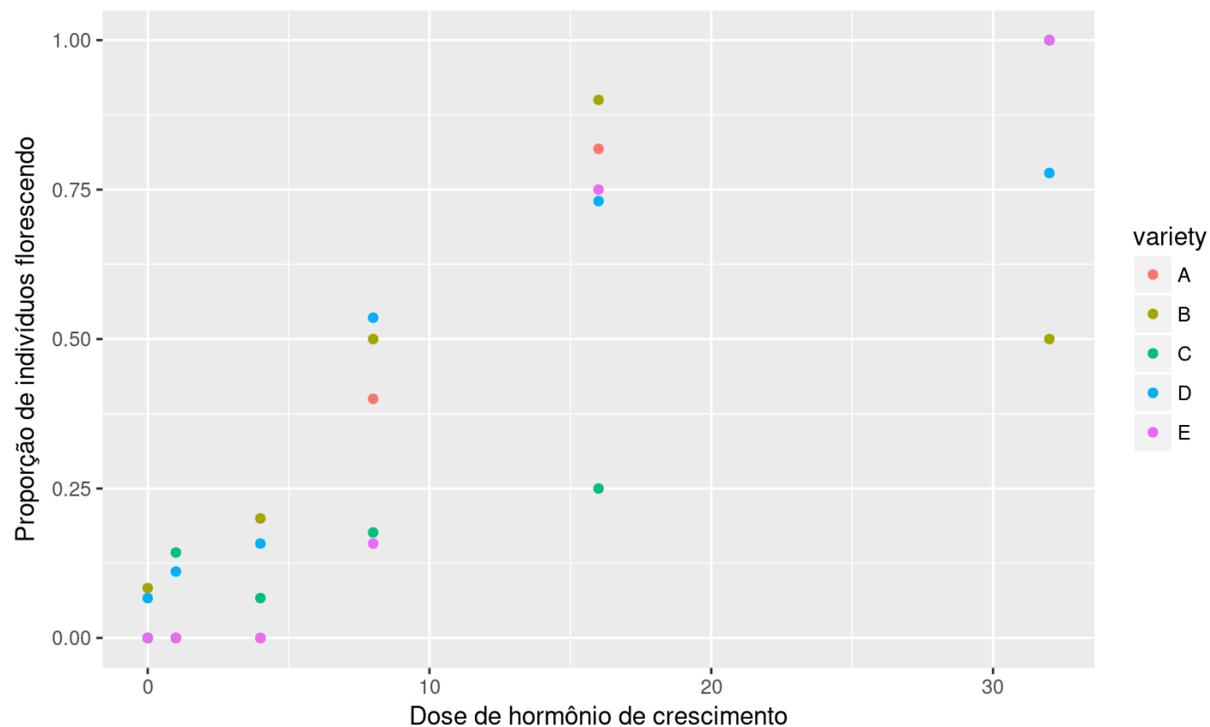
$$\log\left(\frac{p}{q}\right) = a + bx$$

# GLM binomial: florescer

flowered	number	dose	variety	pf
0	12	1	A	0.0000000
0	17	4	A	0.0000000
4	10	8	A	0.4000000
9	11	16	A	0.8181818
10	10	32	A	1.0000000
0	17	1	B	0.0000000

---

# Gráfico dos dados



# Variável preditora (sucesso, falhas)

```
(yb <- cbind(sucesso = flor$flowered, falha= flor$number-flor$flowered))
```

```
##      sucesso falha
## [1,]      0    12
## [2,]      0    17
## [3,]      4     6
## [4,]      9     2
## [5,]     10     0
## [6,]      0    17
## [7,]      3    12
## [8,]      6     6
## [9,]      9     1
## [10,]     9     9
## [11,]     2    12
## [12,]     1    14
## [13,]     3    14
## [14,]     5    15
## [15,]    15     0
## [16,]     2    16
## [17,]     3    16
## [18,]    15    13
```

26/43

# GLM Binomial: ajustando o modelo

```
bin01 <- glm(yb ~ dose + variety + dose:variety, data=flor, family=binomial)
anova(bin01, test = "Chisq")
```

```
## Analysis of Deviance Table
##
## Model: binomial, link: logit
##
## Response: yb
##
## Terms added sequentially (first to last)
##
##
##              Df Deviance Resid. Df Resid. Dev  Pr(>Chi)
## NULL                29    303.350
## dose                 1   197.098    28   106.252 < 2.2e-16 ***
## variety              4    9.483    24    96.769   0.0501 .
## dose:variety         4   45.686    20    51.083 2.863e-09 ***
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

27/43

# GLM Binomial: ajustando o modelo

```
##
## Call:
## glm(formula = yb ~ dose + variety + dose:variety, family = binomial,
##      data = flor)
##
## Deviance Residuals:
##      Min        1Q    Median        3Q        Max
## -2.6648  -1.1200  -0.3769   0.5735   3.3299
##
## Coefficients:
##              Estimate Std. Error z value Pr(>|z|)
## (Intercept)  -4.59165    1.03215  -4.449 8.64e-06 ***
## dose           0.41262    0.10033   4.113 3.91e-05 ***
## varietyB      3.06197    1.09317   2.801 0.005094 **
## varietyC      1.23248    1.18812   1.037 0.299576
## varietyD      3.17506    1.07516   2.953 0.003146 **
## varietyE     -0.71466    1.54849  -0.462 0.644426
## dose:varietyB -0.34282    0.10239  -3.348 0.000813 ***
## dose:varietyC -0.23039    0.10698  -2.154 0.031274 *
## dose:varietyD -0.30481    0.10257  -2.972 0.002961 **
## dose:varietyE -0.00649    0.13292  -0.049 0.961057
```

28/43

# GLM Binomial: simplificando o modelo

```
bin02 <- glm(yb ~ dose + variety, data=flor, family=binomial)
anova(bin01, bin02, test = "Chisq")
```

```
## Analysis of Deviance Table
```

```
##
```

```
## Model 1: yb ~ dose + variety + dose:variety
```

```
## Model 2: yb ~ dose + variety
```

```
##   Resid. Df Resid. Dev Df Deviance Pr(>Chi)
```

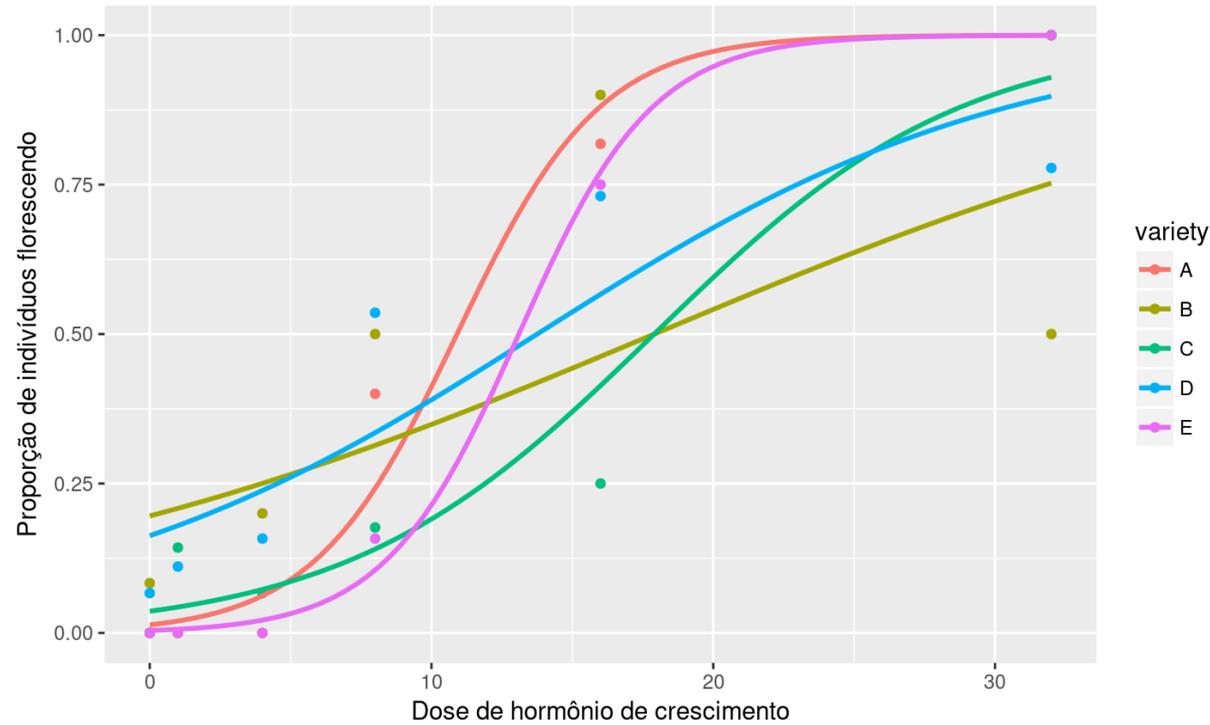
```
## 1         20      51.083
```

```
## 2         24      96.769 -4  -45.686 2.863e-09 ***
```

```
## ---
```

```
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

# GLM Binomial: gráfico do modelo



# Predito pelo modelo: linear

```
predict(bin01)
```

```
##          1          2          3          4          5          6
## -4.1790352 -2.9411862 -1.2907208  2.0102098  8.6120711 -1.4598882
##          7          8          9         10         11         12
## -1.2504982 -0.9713115 -0.4129381  0.7038087 -3.1769379 -2.6302485
##         13         14         15         16         17         18
## -1.9013292 -0.4434907  2.4721863 -1.3087930 -0.9853868 -0.5541786
##         19         20         21         22         23         24
##  0.3082377  2.0330705 -4.9001833 -3.6818046 -2.0572996  1.1917103
##         25         26         27         28         29         30
##  7.6897302 -4.5916515 -1.5296848 -3.3591677 -1.4165950 -5.3063095
```

# Predito pelo modelo: antilogit

```
1/(1+ 1/exp(predict(bin01)))
```

```
##          1          2          3          4          5          6
## 0.015082316 0.050154735 0.215730827 0.881864884 0.999818136 0.188484430
##          7          8          9         10         11         12
## 0.222613918 0.274619176 0.398207832 0.669031659 0.040042874 0.067216871
##          13         14         15         16         17         18
## 0.129958109 0.390909521 0.922168829 0.212688893 0.271824227 0.364895476
##          19         20         21         22         23         24
## 0.576455053 0.884225776 0.007390197 0.024559161 0.113316872 0.767046813
##          25         26         27         28         29         30
## 0.999542708 0.010034395 0.178039802 0.033596235 0.195195932 0.004935716
```

# GLM: ajuste de modelo proporção

- ajuste a variável resposta (sucesso, falha)
- use a família de ligação **binomial(logit)**
- avalie o sobre-dispersão do erro pela razão "Residual deviance" e "degrees of freedom"
- razão  $> 1$ , use família "quasibinom"
- busque o modelo mínimo adequado com "anova"
  - "poisson" use "test = "Chisq" "
  - "quasipoisson" use "test = "F" "
- retenha o modelo mínimo adequado
- retorne os coeficientes e preditos do modelo para escala original (antilogit)

# Atividade: GLM Binomial



# Modelos Lineares Mistos

coeficientes da regressão são variáveis aleatórias

- modelo mais simples: intercepto é uma variável aleatória

$$y = \alpha + \beta x + \epsilon$$

$$\alpha = N(\hat{\alpha}, \sigma^2)$$

- estima-se outra variância, associada à variável randômica
- $\alpha$  não é um valor e sim um distribuição de probabilidades de valores

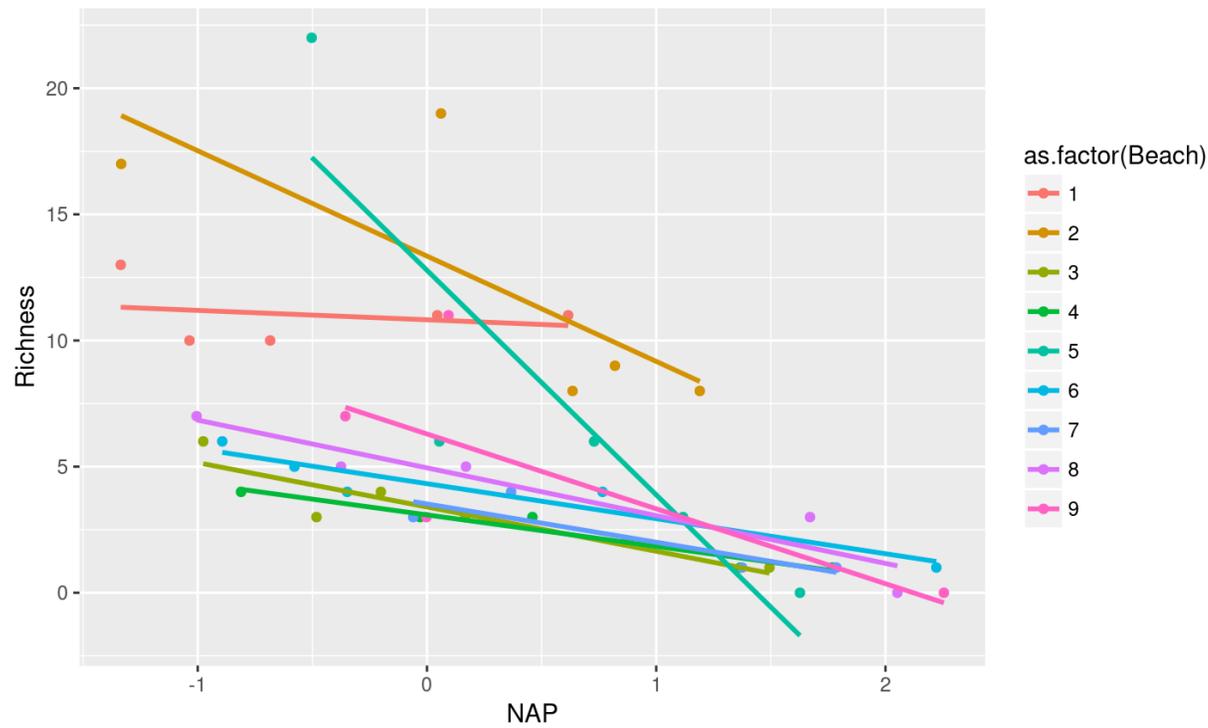
# LMM: riqueza na praia

A riqueza da macrofauna varia em função da altura relativa ao nível médio da mare

Sample	Richness	Exposure	NAP	Beach
1	11	10	0.045	1
2	10	10	-1.036	1
3	13	10	-1.336	1
4	11	10	0.616	1
5	10	10	-0.684	1
6	8	8	1.190	2
## LMM: r	riqueza na p	raia		36/43

# LMM: riqueza na praia

Uma possibilidade: 9 regressões



# LMM: riqueza na praia

há um efeito aleatório da praia

- as observações dentro de cada praia não são independentes

```
library(lme4)
```

```
## Loading required package: Matrix
```

```
lmm01 <- lmer(Richness ~ NAP + (1|Beach), data=praia)
```

# LMM: riqueza da praia

```
## Linear mixed model fit by REML ['lmerMod']
## Formula: Richness ~ NAP + (1 | Beach)
## Data: praia
##
## REML criterion at convergence: 239.5
##
## Scaled residuals:
##   Min       1Q   Median       3Q      Max
## -1.4227 -0.4848 -0.1576  0.2519  3.9794
##
## Random effects:
##   Groups   Name      Variance Std.Dev.
##   Beach    (Intercept) 8.668    2.944
##   Residual                9.362    3.060
## Number of obs: 45, groups: Beach, 9
##
## Fixed effects:
##              Estimate Std. Error t value
## (Intercept)   6.5819    1.0958   6.007
## NAP           -2.5684    0.4947  -5.192
##
```

39/43

# LMM: modelo mínimo adequado

## Comparando modelos mistos

- os modelos devem ser comparados por "ML"
- devem ser apresentados com "RML"

```
lmm01r <- lmer(Richness ~ NAP + (1|Beach), data=praia, REML = FALSE)
lmm00r <- lmer(Richness ~ 1 + (1|Beach), data=praia, REML = FALSE)
anova(lmm00r, lmm01r)

## Data: praia
## Models:
## lmm00r: Richness ~ 1 + (1 | Beach)
## lmm01r: Richness ~ NAP + (1 | Beach)
##           Df    AIC    BIC  logLik deviance  Chisq Chi Df Pr(>Chisq)
## lmm00r    3 269.30 274.72 -131.65   263.30
## lmm01r    4 249.83 257.06 -120.92   241.83 21.474      1 3.586e-06 ***
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

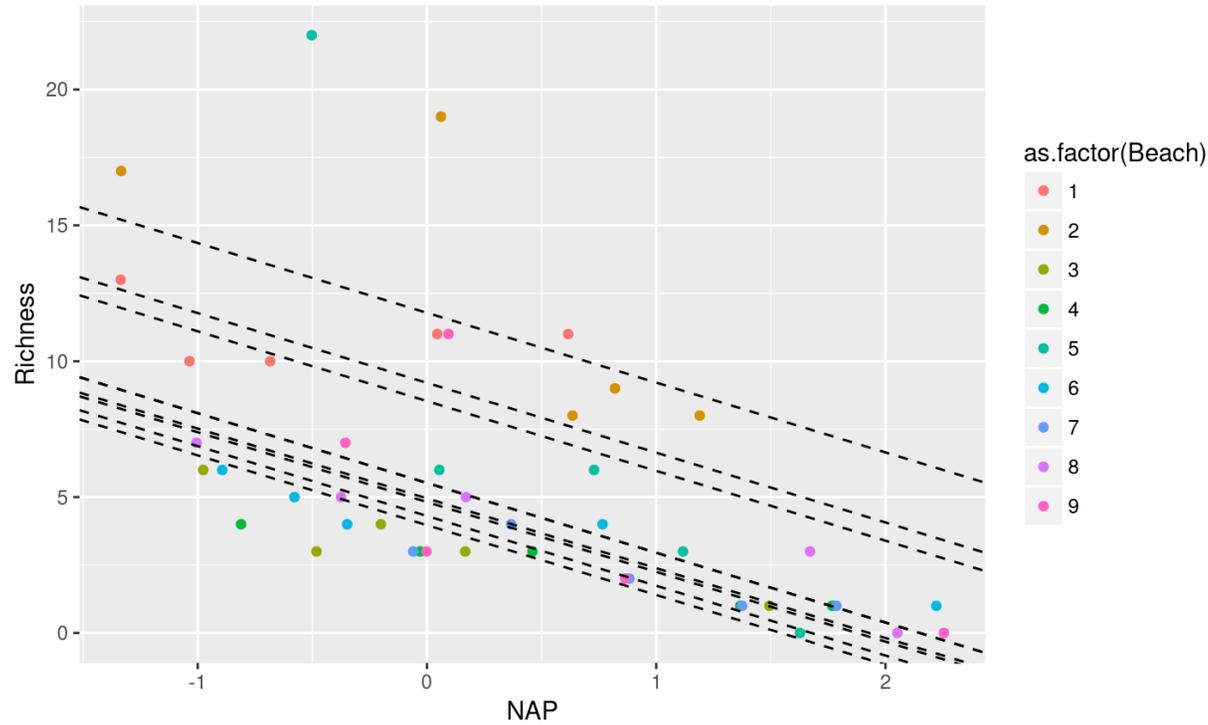
40/43

# LMM: resultado do modelo

```
(coeflmm <- coef(lmm01))
```

```
## $Beach
##   (Intercept)      NAP
## 1    9.203412 -2.5684
## 2   11.781501 -2.5684
## 3    3.966113 -2.5684
## 4    4.306275 -2.5684
## 5    8.532072 -2.5684
## 6    4.952491 -2.5684
## 7    4.816416 -2.5684
## 8    5.520228 -2.5684
## 9    6.158529 -2.5684
##
## attr(,"class")
## [1] "coef.mer"
```

# LMM: resultado do modelo



# Atividade: LMM intercepto e inclinação

