

# Inferência Estatística - Modelos e MLE

Renato Martins Assunção

UFMG

2013

# Um modelo para os dados

- Suponha que  $y_1, \dots, y_n$  são os dados da amostra.
- São instâncias das v.a.'s  $Y_1, \dots, Y_n$ .
- Precisamos assumir um modelo de probabilidade para a distribuição conjunta dessas v.a.'s
- Aprendemos até agora:
  - $Y_1, \dots, Y_n$  são i.i.d.: Exemplo: todas são  $N(\mu, \sigma^2)$ .
  - $Y_1, \dots, Y_n$  são independentes mas não são i.d. Exemplo: modelo de regressão linear ou logística
  - $Y_1, \dots, Y_n$  não são independentes: Exemplo: só vimos um até agora:  $\mathbf{Y} \sim N_n(\mu, \Sigma)$
- Vamos assumir que a distribuição conjunta possa ser indexada por um vetor de parâmetros  $\boldsymbol{\theta} = (\theta_1, \dots, \theta_k)$ .
- Isto leva ao conceito de modelo estatístico para uma amostra de dados.

# Modelos Estatísticos para Amostras de Dados

- **Modelo estatístico:** um conjunto de hipóteses que se supõem válidas para a distribuição de probabilidades das variáveis aleatórias medidas na amostra.
- Estas hipóteses serão satisfeitas de forma *aproximada*.
- A qualidade de um modelo para descrever a distribuição de uma população será dada pelo grau de aproximação que tenham as consequências teóricas do modelo com a distribuição real, como observada nos dados.
- Um modelo contínuo (distribuição normal) pode ser usado para a distribuição de variáveis discretas.
- Por exemplo, para a colheita num conjunto de 5000 lotes de uma fazenda, a distribuição de  $Y$ , a colheita no lote, é normal com média  $\mu$  e variância  $\sigma^2$ .

# Modelos paramétricos

- A distribuição  $F(y)$  de cada variável  $Y$  medida na população pertence a uma família de distribuição  $F(y)$  que depende de um número finito de parâmetros reais. Por exemplo:
  - $F(y)$  pertence à família  $N(\mu, \sigma^2)$ .
  - $(Y|x)$  tem  $F(y)$  na família  $N(\beta_0 + \beta_1 x, \sigma^2)$ .
  - $F(y)$  pertence à família  $\text{Bin}(n, \theta)$
  - $(Y|x)$  tem  $F(y)$  na família  $\text{Bin}(n, 1/(1 + \exp(\beta_0 + \beta_1 x)))$
  - $F(y)$  pertence à família  $\text{Poisson}(\lambda)$ .
  - $(Y|x)$  tem  $F(y)$  na família  $\text{Poisson}(e^{\beta_0 + \beta_1 x})$ .

# Modelos paramétricos

- Em geral, um modelo paramétrico para a distribuição  $F(y)$  de uma única variável  $Y$  terá a seguinte forma:
  - $F(y)$  é especificada para  $Y$  ou para  $(Y|x)$  (condicional a  $x$ ).
  - Vamos considerar apenas o caso mais geral  $(Y|x)$ . O caso para  $Y$  significa condicionar em nada.
  - $F(y|x)$  pertence à uma família  $F(y|x, \theta)$
  - onde  $\theta = (\theta_1, \dots, \theta_k)$  é o vetor de parâmetros
  - $\theta$  toma valores em um conjunto  $\Theta \subset \mathbb{R}^k$ .
  - $\Theta$  é chamado de *espaço paramétrico*.

# Modelos

- Isto significa que existe algum valor  $\theta \in \Theta$ , digamos  $\theta_0$ , tal que  $F(y|x, \theta_0)$  coincide com a verdadeira distribuição  $F(y|x)$  dos dados.
- Não esperamos que exista uma coincidência perfeita
- Esperamos apenas que a verdadeira distribuição dos dados  $F(y|x)$  e uma das distribuições da família escolhida,  $F(y|x, \theta_0)$ , sejam parecidas.
- A similaridade deve ser tal que conclusões baseadas no modelo aproximado  $F(y|x, \theta_0)$  sejam aproximadamente verdadeiras para a distribuição real  $F(y)$ .

## Exemplos de modelos para uma v.a.

- $Y$  é a colheita agrícola num lote. Podemos assumir  $Y \sim N(\mu, \sigma^2)$ . Neste caso,  $\theta = (\mu, \sigma^2)$  e  $\Theta = \mathbb{R} \times (0, \infty)$ .
- $Y$  é o tempo de espera até a ocorrência de um evento (a próxima view de um vídeo no YouTube). Um possível modelo é assumir  $Y \sim \exp(\lambda)$  sendo que  $\Theta = \{\lambda \in \mathbb{R}; \lambda > 0\} = (0, \infty)$
- $Y$  é binária significando SPAM versus NÃO-SPAM.  $\mathbb{P}(Y = \text{SPAM})$  depende de features coletadas no vetor  $x = (1, x_1, \dots, x_k)$  e relacionadas ao conteúdo da mensagem (palavras-chave no subject ou no corpo da msg), ao endereço IP de envio, e características do receptor.

Podemos assumir então um modelo logístico:

$$\mathbb{P}(Y = \text{SPAM}) = \frac{1}{1 + \exp(-x' \theta)}$$

onde  $\theta = (\beta_0, \beta_1, \dots, \beta_k)$ . Como não existe restrição nos  $\beta$ 's, o espaço paramétrico é  $\Theta = \{\theta \in \mathbb{R}^{k+1}\}$ .

# Logística para SPAM

## Partitioned Logistic Regression for Spam Filtering

Ming-wei Chang  
University of Illinois  
201 N Goodwin Ave  
Urbana, IL, USA  
mchang21@uiuc.edu

Wen-tau Yih  
Microsoft Research  
One Microsoft Way  
Redmond, WA, USA  
scottiyh@microsoft.com

Christopher Meek  
Microsoft Research  
One Microsoft Way  
Redmond, WA, USA  
meek@microsoft.com

Figura: Paper recente: KDD 2008 (Knowledge Discovery and Data Mining).

## Exemplos de modelos para UMA v.a.

- $Y$  é contínua e sua distribuição depende de covariáveis no vetor  $\mathbf{x} = (1, x_1, \dots, x_k)$ . Podemos assumir

$$(Y | \mathbf{x}) \sim N(\beta_0 + \beta_1 x_1 + \dots + \beta_k x_k, \sigma^2) = N(\mathbf{x}' \boldsymbol{\beta}, \sigma^2)$$

onde  $\boldsymbol{\theta} = (\boldsymbol{\beta}, \sigma^2) = (\beta_0, \beta_1, \dots, \beta_k, \sigma^2)$ .

O valor de  $\sigma^2$  deve ser maior que zero mas usualmente  $\beta_j$  não tem restrição.

Assim, o espaço paramétrico é  $\Theta = \{\boldsymbol{\theta} \in \mathbb{R}^{k+1} \times (0, \infty)\}$ .

- Suponha que sejam medidas as asas direita ( $Y_1$ ) e esquerda ( $Y_2$ ) de um passáro escolhido dentro de certa região. Podemos usar como modelo para a distribuição  $F(y_1, y_2)$  do vetor  $(Y_1, Y_2)$  a normal bivariada  $N_2(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)$  e

$$\Theta = \mathbb{R} \times \mathbb{R} \times (0, \infty) \times (0, \infty) \times (-1, 1)$$

# Definição geral de modelo estatístico

- **Definição:** Um *modelo estatístico paramétrico* para um fenômeno aleatório gerando variáveis aleatórias  $Y_1, \dots, Y_n$  com covariáveis FIXAS (não-aleatórias)  $x_1, \dots, x_n$  é constituído de TRÊS elementos:
  - (i) Família  $\mathcal{F}$  de distribuições do vetor aleatório  $\mathbf{Y} = (Y_1, \dots, Y_n)$  (possivelmente dependente de covariáveis  $x_1, \dots, x_n$ ).
  - (ii) Conjunto  $\mathcal{Y} \subset \mathbb{R}^n$  de todos os valores possíveis de  $\mathbf{Y}$ .
  - (iii) Conjunto  $\Theta \subseteq \mathbb{R}^k$  chamado *espaço paramétrico* tal que existe bijeção entre  $\mathcal{F}$  e  $\Theta$ . Isto é,  $\Theta$  é índice de  $\mathcal{F}$  de forma que, cada elemento  $\theta \in \Theta$  está associado com uma única distribuição em  $\mathcal{F}$ , e vice-versa.
- Queremos inferir sobre uma função  $q(\theta)$ . A distribuição  $\mathcal{F} = \{F_\theta : \theta \in \Theta\}$  e a função  $q(\theta)$  dependem do problema.

# Modelo de Sequências de Bernoulli i.i.d.

- $Y_1, \dots, Y_n$ : nascimentos sucessivos de não gêmeos numa maternidade.
- $$Y_i = \begin{cases} 1, & \text{se } i\text{-ésimo nascimento é do sexo masculino} \\ 0, & \text{se } i\text{-ésimo nascimento é do sexo feminino} \end{cases}$$
- Esta distribuição é especificada dando a probabilidade de sucesso.
- Vamos escrever  $P(Y_i = 1) = \theta_i$  onde  $\theta_i \in (0, 1)$ .
- Assim,

$$P(Y_i = y) = \begin{cases} \theta_i, & \text{se } y = 1 \\ 1 - \theta_i, & \text{se } y = 0. \end{cases} \quad (1)$$

# Modelo de Sequências de Bernoulli

- Precisamos especificar a distribuição *conjunta* das  $n$  variáveis aleatórias.
- Para isto precisamos responder:
  - as variáveis aleatórias são independentes? Não é possível *provar* isso matematicamente. Considerando o problema, tudo leva a crer que essa é uma *suposição razoável* acerca desses dados.
  - É possível verificar se esta hipótese é realmente razoável num estágio posterior da análise mas nos momentos iniciais é apenas o conhecimento prévio, ou o puro chute bem informado, que guia o analista.
  - As v.a.'s possuem a MESMA probabilidade de sucesso  $\theta$ ?
- Se a resposta é SIM, o vetor  $\mathbf{Y}$  é composto de variáveis aleatórias i.i.d

# Um truque de notação

- Para  $y = 0$  ou  $y = 1$ , podemos escrever (VERIFIQUE)

$$P(Y_i = y) = \theta^y(1 - \theta)^{1-y}$$

- Com isto, se  $y_i = 0$  ou  $1$ , temos a conjunta:

$$f_{\theta}(\mathbf{y}) = f_{\theta}(y_1, \dots, y_n) = \prod_{i=1}^n \theta^{y_i} (1 - \theta)^{1-y_i} = \theta^{\sum_i y_i} (1 - \theta)^{n - \sum_i y_i} \quad (2)$$

- Note  $\theta$  na notação  $f_{\theta}(\mathbf{y})$  da densidade. Às vezes:  $f(\mathbf{y} | \theta)$ .
- Modelo estatístico: com  $y_i = 0$  ou  $y_i = 1$ , para  $i = 1, \dots, n$ , e  $\theta \in (0, 1)$ , temos

$$\mathcal{F}_{\theta} = \left\{ f_{\theta}(\mathbf{y}) = \theta^{\sum_i y_i} (1 - \theta)^{n - \sum_i y_i} \right\}$$

# Modelo de erro de medição

- $n$  observações são feitas com erro em um mesmo objeto.
- Represente como v.a.'s  $y_i = \mu + \varepsilon_i$
- $\mu$  é uma constante desconhecida (o valor real do objeto medido)
- $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$  são i.i.d. com distribuição  $N(0, \sigma^2)$ .
- Note que este modelo implica em supor que:
  - A distribuição dos erros não depende de  $\mu$ .
  - Um erro em uma medição não afeta o erro em outra medição.
  - O objeto não se altera e dessa forma o valor de  $\mu$  é constante ao longo das medições.
  - A distribuição do erro é a mesma ao longo de todas as medições.
  - A distribuição dos erros é simétrica em torno de zero e contínua.

# Modelo de erro de medição

- $Y_1, \dots, Y_n$  são i.i.d com  $Y_i \sim N(\mu, \sigma^2)$ . Seja  $\theta = (\mu, \sigma^2)$ .
- A distribuição conjunta de  $\mathbf{y}$  é um membro da família  $\mathcal{F} = \{f(\mathbf{y} | \theta) ; \theta \in \Theta\}$  onde conjunta é

$$\begin{aligned}
 f_{\theta}(\mathbf{y}) &= \prod_{i=1}^n f_{\theta}(y_i) \\
 &= \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \prod_{i=1}^n \exp \left( -\frac{1}{2} \left( \frac{y_i - \mu}{\sigma} \right)^2 \right) \\
 &= (2\pi\sigma^2)^{-n/2} \exp \left( -\frac{1}{2} \sum_{i=1}^n \left( \frac{y_i - \mu}{\sigma} \right)^2 \right)
 \end{aligned}$$

para  $y_i \in \mathbb{R}$ . O espaço paramétrico é

$$\Theta = \{\theta = (\mu, \sigma^2) \in \mathbb{R}^2 : \mu \in \mathbb{R}, \sigma^2 \in (0, \infty)\}$$

## Questões de interesse

- Questões de interesse num modelo de erro de medição:
- Conhecer o tamanho típico do erro de medição.
- Assim, queremos saber o valor de  $q(\theta) = \sqrt{\sigma^2} = \sigma$
- Ou então: conhecer o tamanho do erro de medição relativamente ao tamanho do objeto sendo medido.
- Isto é, conhecer o coeficiente de variação  $q(\theta) = \sigma/|\mu|$  (que faz sentido apenas se  $\mu \neq 0$ ).

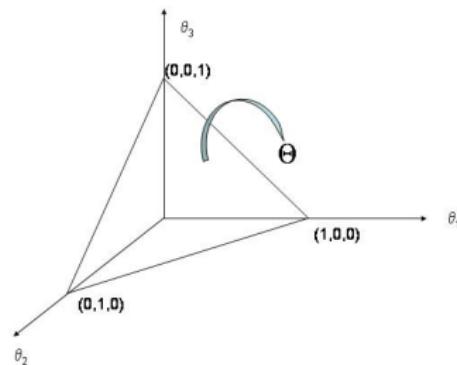
# Modelo multinomial

- $Y_1, Y_2$ , e  $Y_3$  são as contagens do número de pessoas que são católicos ( $Y_1$ ), protestantes ( $Y_2$ ), outras religiões ou sem religião ( $Y_3$ ).
- Estas contagens foram obtidas a partir de uma amostra de tamanho  $n$ .
- Modelo natural é a Multinomial  $F(y_1, y_2, y_3)$  que pertence à família  $M(\theta_1, \theta_2, \theta_3, n)$ .
- $\theta_j$  é proporção de indivíduos na *população* que estão na categoria  $j$ .
- Temos

$$\Theta = \{(\theta_1, \theta_2, \theta_3) \in [0, 1]^3 \text{ tal que } \theta_1 + \theta_2 + \theta_3 = 1\}$$

- Uma representação de  $\Theta$  está no próximo slide.

# Espaço paramétrico do modelo multinomial



**Figura:** Espaço paramétrico  $\Theta$  de um vetor  $\theta = (\theta_1, \theta_2, \theta_3)$  de uma multinomial com três categorias.  $\Theta$  é representado pelo triângulo de vértices  $(1, 0, 0)$ ,  $(0, 1, 0)$  e  $(0, 0, 1)$ .

# Explicar bonus-malus em seguro de automóveis

- Sistema que ajusta o prêmio de acordo com a história individual do cliente.
- Tipicamente: entra na seguradora num nível de referência para a sua categoria de idade-sexo-etc
- A partir daí, em cada renovação anual do contrato:
  - Se teve pelo menos um sinistro no ano anterior, sofre incremento de prêmio (malus)
  - Quanto mais sinistros, maior o incremento.
  - se não teve sinistros, tem redução do prêmio (bonus).
- Precisa fazer cálculos fazer estabelecer níveis de bonus e malus.

# Regras de Transição em bonus-malus

- Imagine um sistema com cinco classes.
- Segurado entra na CLASSE 3.
- Se passar para a classe 4, seu prêmio aumenta em 130% em relação ao prêmio da classe 3.
- Se passar para a classe 5, aumenta em 160%
- Se passar para a classe 2, o prêmio diminui para 80% do prêmio de referêcia (classe 3)

Relatividades	Classe	Classe após $k$ sinistros			
		$k = 0$	$k = 1$	$k = 2$	$k \geq 3$
160%	5	4	5	5	5
130%	4	3	5	5	5
100%	3	2	3	4	5
80%	2	1	3	4	5
70%	1	1	3	5	5

# Matriz de Probabilidades de Transição

- Coleta-se amostra de 1000 segurados em cada classe (1 a 5).
- Dentro de cada classe, contam-se quantos indivíduos terminaram na classe  $K$ .
- Deseja-se saber quais são as probabilidades de migrar da categoria atual para outra categoria.
- Isto é, deseja-se preencher a seguinte tabela:

Classe Atual	Nova Classe				
	5	4	3	2	1
5	*	*	0	0	0
4	*	0	*	0	0
3	*	*	*	*	0
2	*	*	*	0	*
1	*	0	*	0	*

# Matriz de Probabilidades de Transição

- Isto é, temos CINCO vetores de dimensão 5 a serem estimados, um vetor para cada classe.
- $\theta = (\theta_1, \theta_2, \theta_3, \theta_4, \theta_5)$  com  $\sum_i \theta_i = 1$ .
- Por exemplo, para a classe 4, temos  $\theta = (0, 0, \theta_3, 0, \theta_5)$  com  $\theta_3 + \theta_5 = 1$ .

Classe Atual	Nova Classe				
	5	4	3	2	1
5	*	*	0	0	0
4	$\theta_5$	0	$\theta_3$	0	0
3	*	*	*	*	0
2	*	*	*	0	*
1	*	0	*	0	*

- O vetor para a classe 3 será diferente do vetor para a classe 4, etc.

# Regressão Linear Simples

- $\mathbf{Y} = (Y_1, \dots, Y_n)$  é composto por variáveis aleatórias independentes
- $Y_i \sim N(\mu_i, \sigma^2) = N(\beta_0 + \beta_1 x_i, \sigma^2)$
- onde  $x_1, \dots, x_n$  são números fixos e conhecidos.
- Não temos interesse em modelar a variação de  $x$ . Serve só para explicar em parte porquê  $Y_i$  varia.
- Eles variam porquê sua média  $\mu_i$  muda (e a média muda apenas se  $x$  mudar) e porquê existe um erro aleatório.

# Regressão Linear Simples

- Seja  $\boldsymbol{\theta} = (\beta_0, \beta_1, \sigma^2)$ . Conjunta de  $\mathbf{y}$  é:

- 

$$\begin{aligned}
 f_{\boldsymbol{\theta}}(\mathbf{y}) &= \prod_{i=1}^n f_{\boldsymbol{\theta}}(y_i) = \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \prod_{i=1}^n \exp \left( -\frac{1}{2} \left( \frac{y_i - \beta_0 - \beta_1 x_i}{\sigma} \right)^2 \right) \\
 &= (2\pi\sigma^2)^{-n/2} \exp \left( -\frac{1}{2} \sum_{i=1}^n \left( \frac{y_i - \beta_0 - \beta_1 x_i}{\sigma} \right)^2 \right)
 \end{aligned}$$

- O espaço paramétrico é

$$\Theta = \{ \boldsymbol{\theta} = (\beta_0, \beta_1, \sigma^2) \in \mathbb{R}^3 : \beta_0 \in \mathbb{R}, \beta_1 \in \mathbb{R}, \sigma^2 \in (0, \infty) \}$$

# Questões de interesse em regressão

- Saber o valor de  $q(\theta) = \beta_1$ .
- Algumas vezes, o interesse é apenas saber se  $\beta_1$  é igual a zero ou não.
- Se  $\beta_1 = 0$  então a covariável  $y$  não afeta  $E(Y)$ .
- Assim, o interesse reside em saber o valor da função  $q(\theta)$  definida da seguinte forma:

$$q(\theta) = \begin{cases} 1, & \text{se } \beta_1 = 0 \\ 0, & \text{caso contrário} \end{cases}$$

- Esta é uma maneira estranha de saber se  $\beta_1 = 0$  ou não mas, acredite, ela será útil no contexto de testes de hipóteses.

# Regressão Logística Simples

- $Y_1, \dots, Y_n$  ensaios de Bernoulli independentes

$$Y_i = \begin{cases} 1, & \text{com probabilidade } p_i; \\ 0, & \text{com probabilidade } 1 - p_i \end{cases}$$

- $p_i = p(x_i) = \frac{1}{1 + \exp(-\beta(x_i - \mu))}.$
- Dependendo dos valores de  $\mu$  e  $\beta$  nós obtemos diferentes curvas
- Interesse: estimar os valores de  $\mu$  e  $\beta$  para traçar o gráfico de  $x$  versus  $p(x)$ .

# Modelo estatístico

- Temos

$$P(Y = y_i) = p_i^{y_i} (1 - p_i)^{1-y_i}.$$

- Vamos escrever  $\theta = (\mu, \beta)$ .
- indep implica conjunta:

$$\begin{aligned}
 p_{\theta}(y) &= \prod_{i=1}^n p_i^{y_i} (1 - p_i)^{1-y_i} \\
 &= \prod_{i=1}^n \left( \frac{1}{1 + e^{-\beta(x_i - \mu)}} \right)^{y_i} \left( \frac{e^{-\beta(x_i - \mu)}}{1 + e^{-\beta(x_i - \mu)}} \right)^{1-y_i} \\
 &= \frac{\exp(-\beta \sum_i (x_i - \mu)(1 - y_i))}{\prod_{i=1}^n (1 + e^{-\beta(x_i - \mu)})} \\
 &= \frac{\exp(n\mu\beta(1 - \bar{y}) - n\beta(\bar{x} - \bar{xy}))}{\prod_{i=1}^n (1 + e^{-\beta(x_i - \mu)})}
 \end{aligned}$$

onde  $\bar{y} = \sum_i y_i / n$ ,  $\bar{x} = \sum_i x_i / n$  e  $\bar{xy} = \sum_i x_i y_i / n$ .

## Questão de interesse

- Interesse é descobrir a idade  $x_{90}$  tal que 90% das crianças devem estar executando a tarefa.
- Isto é, queremos encontrar a idade  $x_{90}$  que satisfaz a equação  $p(x_{90}) = 0.9$ .
- Ou seja,

$$0.9 = \frac{1}{1 + \exp(-\beta(x_{90} - \mu))}$$

Manipulando algebraicamente, encontramos

$$x_{90} = \frac{-1}{\beta} \left( \log \left( \frac{0.1}{0.9} \right) + \beta\mu \right) .$$

- Assim,  $x_{90}$  é uma função  $q(\theta)$ .

# Verossimilhança e MLE

- Suponha que a distribuição conjunta dos dados pertença a um modelo estatístico
- Este modelo será indexado por um vetor  $\theta$ .
- Por exemplo, no caso da regressão logística,  $\theta = (\beta_0, \beta_1)$ .
- Usando o modelo estatístico  $\mathcal{P}_\theta$ , calcule o valor aproximado da probabilidade de observar os dados da amostra.

# Verossimilhança e MLE

- Se as  $y_i$ 's são discretas, calcule a probabilidade de observar os dados da amostra.
- Se as  $y_i$ 's são contínuas, obtenha a densidade de probabilidade avaliada nos dados da amostra.
- Esta é a *função de verossimilhança*  $L(\theta)$  onde apenas  $\theta$  pode variar.
- Obtenha o valor  $\hat{\theta}$  que maximiza  $L(\theta)$ .
- Este valor é a estimativa de máxima verossimilhança (maximum likelihood estimator, ou MLE).
- O MLE é o valor  $\hat{\theta}$  de  $\theta$  que é o mais verossímil tendo em vista os dados à mão.
- O MLE  $\hat{\theta}$  é aquele em que, aproximadamente, é máxima a probabilidade de observar os dados realmente observados.

# Função de verossimilhança

- $\mathbf{Y} = (Y_1, \dots, Y_n)$  é composto por v.a.'s com função de probabilidade (caso discreto) ou densidade (caso contínuo) conjunta  $p(\mathbf{y}, \theta)$ .
- O parâmetro  $\theta$  pertence ao conjunto  $\Theta$ , chamado de espaço paramétrico.
- ASSUMA QUE  $\Theta \subseteq \mathbb{R}$  (uni-dimensional).
- Considere  $p(\mathbf{y}, \theta)$  como uma função de  $\theta$  para  $\mathbf{y}$  fixo.
- Nós chamamos esta função de *função de verossimilhança*
- NOTAÇÃO:  $L(\theta)$ .

## EMV

- EMV  $\hat{\theta} = \hat{\theta}(\mathbf{y}) \in \Theta$  é o valor mais verossímil em termos de gerar os dados  $\mathbf{x}$ .
- Isto é, se observamos  $\mathbf{Y} = \mathbf{y}$ , nós procuramos  $\hat{\theta}(\mathbf{y})$  que satisfaça

$$L(\hat{\theta}(\mathbf{y})) = p(\mathbf{y}, \hat{\theta}(\mathbf{x})) = \max_{\theta} \{p(\mathbf{x}, \theta) : \theta \in \Theta\} = \max_{\theta} \{L(\theta) : \theta \in \Theta\}$$

- O vetor  $\mathbf{y}$  aparece na expressão de  $L(\theta)$  mas ele é considerado fixo nas instâncias observadas na amostra.
- $\mathbf{y}$  significa o conjunto de valores realmente obtidos em um experimento, os valores realizados do vetor aleatório  $\mathbf{Y}$ .
- Se  $\hat{\theta}(\mathbf{y})$  é o EMV de  $\theta$ , então estimamos qualquer função  $q(\theta)$  por  $q(\hat{\theta}(\mathbf{x}))$ .

# Log-verossimilhança

- O mais comum é que a função de verossimilhança seja um produto de várias funções envolvendo  $\theta$ .
- A derivada de produtos de funções é obtida aplicando-se a regra do produto e a equação de verossimilhança pode resultar numa expressão complicada.
- A derivada de somas de funções é geralmente muito mais simples.
- Nós definimos a *função de log-verossimilhança*, denotada por  $\ell(\theta)$ :

$$\ell(\theta) = \log L(\theta) = \log p(\mathbf{y}, \theta)$$

# Log-verossimilhança

- Se  $\hat{\theta}$  maximiza  $L(\theta) = p(\mathbf{y}, \theta)$  então  $\hat{\theta}$  também maximiza  $\ell(\theta) = \log p(\mathbf{y}, \theta)$ .
- Assim, a estimativa de máxima verossimilhança é obtida como a solução da equação

$$\frac{\partial \ell(\theta)}{\partial \theta} = \frac{\partial \log L(\theta)}{\partial \theta} = 0$$

- Esta equação é chamada de *equação de log-verossimilhança* ou, de forma mais curta, simplesmente *equação de verossimilhança*.
- Se  $\theta$  é um vetor então a equação de verossimilhança é na verdade um sistema de equações, cada uma delas associada com uma derivada parcial. Veja os exemplos de MLE multivariado no próximo bloco de slides.

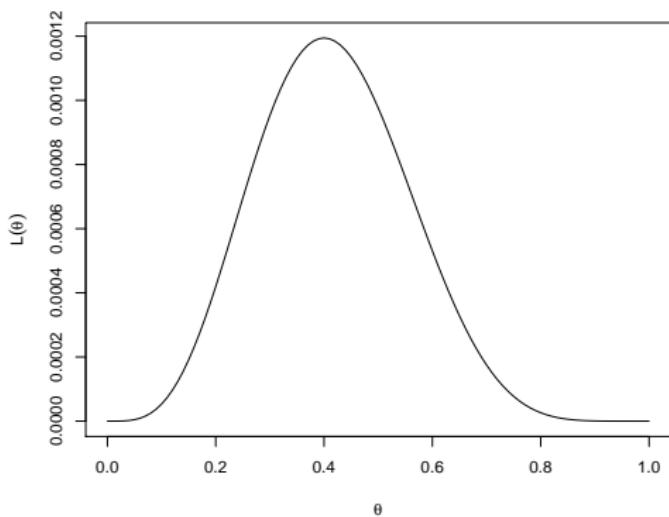
# Experimento de Bernoulli

- Experimento de Bernoulli é realizado independentemente 10 vezes.
- $\theta$  a probabilidade de sucesso
- Espaço paramétrico  $\Theta = [0, 1]$ .
- Observa-se  $\mathbf{y} = (0, 1, 0, 0, 1, 0, 1, 0, 1, 0)$  onde 1 indica  $S$  e 0 indica  $F$ .
- Função de verossimilhança de  $\theta$ :

$$L(\theta) = \mathbb{P}(\mathbf{Y} = \mathbf{y}) = \mathbb{P}(\mathbf{Y} = (0, 1, 0, 0, 1, 0, 1, 0, 1, 0)) = \theta^4(1 - \theta)^6.$$

- Gráfico mostra a função de verossimilhança  $L(\theta)$  versus  $\theta$ .

# Experimento de Bernoulli



**Figura:** Função de verossimilhança  $L(\theta) = \theta^4(1 - \theta)^6$

# Experimento de Bernoulli

- Função log-verossimilhança:

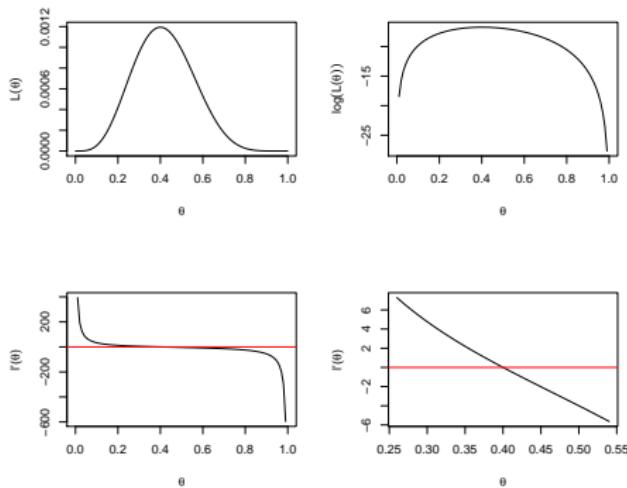
$$\ell(\theta) = \log L(\theta) = 4 \log(\theta) + 6 \log(1 - \theta)$$

- A equação de verossimilhança é

$$\ell'(\theta) = \frac{4}{\theta} - \frac{6}{1 - \theta} = 0$$

- Solução  $\hat{\theta} = 0.4$ .
- A partir do gráfico, já sabemos que esta solução é um máximo global.

# Experimento de Bernoulli



**Figura:** Função de verossimilhança  $L(\theta)$ , log-verossimilhança  $\ell(\theta)$ , Derivada da log-verossimilhança  $\ell'(\theta)$  e restrição de  $\ell'(\theta)$  no intervalo  $\theta \in (0.25, 0.55)$

## Bernoulli - Caso Geral

- Podemos obter uma fórmula geral a estimativa de máxima verossimilhança EM FUNÇÃO DO QUE SERÁ OBSERVADO na amostra.
- Seja  $\mathbf{y} = (y_1, \dots, y_{10})$  uma realização do experimento, uma lista de 1's e 0's
- Seja  $k = \sum_{i=1}^{10} y_i$ , o número de caras que ocorreram nesta particular realização do experimento.
- A probabilidade de ocorrer  $\mathbf{y}$  é igual a

$$\mathbb{P}(\mathbf{Y} = \mathbf{y} | \theta) = \theta^k (1 - \theta)^{10 - k} = L(\theta)$$

## Bernoulli - Caso Geral

- A probabilidade de ocorrer  $\mathbf{y}$  é igual a

$$\mathbb{P}(\mathbf{Y} = \mathbf{y} | \theta) = \theta^k (1 - \theta)^{10 - k} = L(\theta)$$

- O valor de  $\theta$  que maximiza a verossimilhança  $L(\theta)$  é encontrado facilmente:

$$\begin{aligned} \frac{d}{d\theta} \log \mathbb{P}(\mathbf{Y} = \mathbf{y} | \theta) &= \frac{d}{d\theta} (k \log(\theta) + (10 - k) \log(1 - \theta)) \\ &= \frac{k}{\theta} - \frac{10 - k}{1 - \theta} = 0 \end{aligned}$$

- Isto produz  $\hat{\theta} = k/10 = \sum_i y_i/n$ .

# Modelo de Contagens de Poisson

- Suponha que  $\mathbf{Y} = (Y_1, \dots, Y_4)$  é composto por v.a.'s iid Poisson( $\lambda$ ).
- Observa-se  $\mathbf{y} = (1, 0, 3, 1)$ . A função de verossimilhança  $L(\lambda)$  é

$$\begin{aligned}
 L(\lambda) &= \mathbb{P}(\mathbf{Y} = \mathbf{y} | \lambda) \\
 &= \mathbb{P}(Y_1 = 1 | \lambda) \times \mathbb{P}(Y_2 = 0 | \lambda) \times \mathbb{P}(Y_3 = 3 | \lambda) \times \mathbb{P}(Y_4 = 1 | \lambda) \\
 &= \left( \frac{\lambda^1}{1!} e^{-\lambda} \right) \times \left( \frac{\lambda^0}{0!} e^{-\lambda} \right) \times \left( \frac{\lambda^3}{3!} e^{-\lambda} \right) \times \left( \frac{\lambda^1}{1!} e^{-\lambda} \right) \times \\
 &= \frac{\lambda^{1+0+3+1}}{1!0!3!1!} e^{-4\lambda} \\
 &= \frac{\lambda^{y_1+y_2+y_3+y_4}}{y_1!y_2!y_3!y_4!} e^{-4\lambda}
 \end{aligned}$$

# Modelo de Contagens de Poisson - caso geral

- $\mathbf{Y} = (Y_1, \dots, Y_n)$  é composto por v.a.'s iid Poisson( $\lambda$ ).
- Função de verossimilhança de  $\lambda$ :

$$L(\lambda) = p(\mathbf{Y} = \mathbf{y}, \lambda) = \prod_{i=1}^n p(y_i, \lambda) = \prod_{i=1}^n \frac{\lambda^{y_i} e^{-\lambda}}{y_i!} = \frac{\lambda^{\sum_i y_i} e^{-n\lambda}}{y_1! \dots y_n!}$$

- A função log-verossimilhança e suas derivadas são as seguintes:

$$\ell(\lambda) = -\log(y_1! \dots y_n!) + \left( \sum_{i=1}^{10} y_i \right) \log \lambda - n\lambda$$

- Veja que, para achar o EMV, podemos IGNORAR o produto  $y_1! \dots y_n!$ .

# Contagens de Poisson

- Equação de verossimilhança:

$$\frac{d\ell(\lambda)}{d\lambda} = \frac{1}{\lambda} \sum_{i=1}^{10} y_i - n = 0$$

- Veja que o produto  $y_1! \dots y_n!$  NÃO APARECE NESTA EQUAÇÃO.
- EMV é  $\hat{\lambda}(\mathbf{y}) = \sum_i y_i / n = \bar{y}$ .
- É ponto de máximo se  $\sum_i y_i > 0$  pois

$$\frac{d^2\ell(\lambda)}{d\lambda^2} = - \frac{1}{\lambda^2} \sum_{i=1}^{10} y_i < 0$$

## Contagens de Poisson

- Se  $\sum_i y_i = 0$  então  $\hat{\lambda}(\mathbf{x}) = \bar{x} = 0$  também é ponto de máximo.
- Veja que, neste caso,  $L(\lambda) = \lambda^0 e^{10\lambda} / 0! = e^{10\lambda}$ .
- Esta função está definida para  $\lambda \in \Theta$ . Isto é, para  $\lambda \geq 0$ .
- Seu máximo ocorre na fronteira do espaço paramétrico, quando  $\lambda = 0$ .
- Este ponto de máximo corresponde a  $\bar{y} = \sum_i y_i / 10$  mas veja que  $l'(\lambda)$  NÃO É igual a zero em  $\lambda = 0$ .

## Caso normal, apenas $\mu$ desconhecido

- $Y_1, \dots, Y_n$  iid  $N(\mu, \sigma_0^2)$  onde  $\sigma_0^2$  é CONHECIDO.
- Densidade conjunta é o produto das densidades marginais:

$$\begin{aligned}
 L(\mu) &= f(y_1, \dots, y_n | \mu) \\
 &= \prod_{i=1}^n \left( \frac{1}{\sqrt{2\pi}\sigma_0} \right) \exp \left( -\frac{1}{2\sigma_0^2} (y_i - \mu)^2 \right) \\
 &= \left( \frac{1}{\sqrt{2\pi}\sigma_0} \right)^n \exp \left( -\frac{1}{2\sigma_0^2} \sum_{i=1}^n (y_i - \mu)^2 \right)
 \end{aligned}$$

- Portanto, a log-verossimilhança de  $\mu$  é dada por

$$\ell(\mu) = \log(f(y_1, \dots, y_n | \mu)) = -n \log(\sqrt{2\pi}\sigma_0) - \frac{1}{2\sigma_0^2} \sum_{i=1}^n (y_i - \mu)^2$$

# Caso normal, apenas $\mu$ desconhecido

- Logo,

$$\begin{aligned}
 \frac{d}{d\mu} \ell(\mu) &= \frac{d}{d\mu} \left[ -n \ln(\sqrt{2\pi}\sigma_0) - \frac{1}{2\sigma_0^2} \sum_{i=1}^n (y_i - \mu)^2 \right] \\
 &= \frac{1}{2\sigma_0^2} \left( \sum_{i=1}^n -2(y_i - \mu) \right) \\
 &= \frac{1}{\sigma_0^2} \left( \sum_{i=1}^n y_i - n\mu \right) \\
 &= \frac{n}{\sigma_0^2} (\bar{y} - \mu)
 \end{aligned}$$

- onde  $\bar{y} = \sum_i y_i / n$ .
- A equação  $\ell'(\mu) = 0$  tem a solução  $\hat{\mu} = \bar{y}$ .
- Como  $\ell''(\mu) < 0$ , este é de fato um ponto de máximo.

# Verossimilhança relativa

- Ao comparar diferentes experimentos, será preciso comparar diferentes funções de verossimilhança.
- Para efeito de padronização de escala nos diferentes gráficos de  $L(\theta)$ , será conveniente selecionar um valor para  $\theta$  com o qual todos os outros valores de  $\theta$  possam ser comparados.
- A escolha natural é tomar a estimativa de máxima verossimilhança  $\hat{\theta}$  para ser este valor de referência.
- Definimos a *função de verossimilhança relativa* de  $\theta$  como

$$R(\theta) = \frac{L(\theta)}{L(\hat{\theta})} = \frac{L(\theta)}{\max_{\theta} L(\theta)},$$

- Qualquer constante com respeito a  $\theta$  que apareça na verossimilhança é cancelada por aparecer no numerador e no denominador de  $R(\theta)$ .

# Verossimilhança relativa

- Temos

$$0 \leq R(\theta) = \frac{L(\theta)}{L(\hat{\theta})} = \frac{L(\theta)}{\max_{\theta} L(\theta)} \leq 1$$

- $R(\theta)$  é a razão de quão verossímil é  $\theta$  versus o valor mais verossímil  $\hat{\theta}$  :
- Seja  $\theta_1$  um valor qualquer para o parâmetro.
- Se  $R(\theta_1) \leq 0.1$  então  $\theta_1$  é um valor do parâmetro mais ou menos implausível porque existem outros valores de  $\theta$  para os quais os dados que acabamos de observar são 10 vezes mais prováveis de ocorrer.
- Se  $R(\theta_1) \geq 0.8$  então  $\theta_1$  é um valor do parâmetro razoavelmente verossímil porque a chance dos dados aparecerem está entre 80% e 100% do valor de  $L(\hat{\theta})$ , a maior probabilidade possível sob o modelo.

# Verossimilhança relativa

- A função de verossimilhança relativa dá uma ordenação a todos os valores do parâmetro de acordo com a verossimilhança de cada um.
- Tome  $c \approx 1$ .
- O conjunto de valores de  $\theta \in \Theta$  tais que  $R(\theta) > c$  (isto é, tais que  $L(\theta) > cL(\hat{\theta})$ ) são também valores verossímeis para  $\theta$ .
- Em geral,  $c$  é escolhido igual a 0.5 ou maior.

# Verossimilhança relativa

- Muitas vezes, este conjunto de valores vai formar um intervalo.
- Se este intervalo for pequeno, isto quer dizer que o experimento está conseguindo separar do espaço paramétrico  $\Theta$  um pequeno intervalo de valores bastante verossímeis para  $\theta$ .
- Se o intervalo for muito grande, então o experimento não é capaz de diferenciar muito entre valores muito diferentes de  $\theta$ .
- O experimento está dizendo que valores muito diferentes de  $\theta$  são igualmente verossímeis.
- Neste sentido, ele não discrimina muito entre os valores possíveis de  $\theta$ .

# Verossimilhança relativa - Poisson

- $Y_1, \dots, Y_n$  i.i.d. Poisson( $\lambda$ ).
- Verossimilhança:  $L(\lambda) = \text{cte } \lambda^{\sum_i y_i} e^{-n\lambda}$
- EMV  $\hat{\lambda} = \bar{y}$ .
- Portanto,

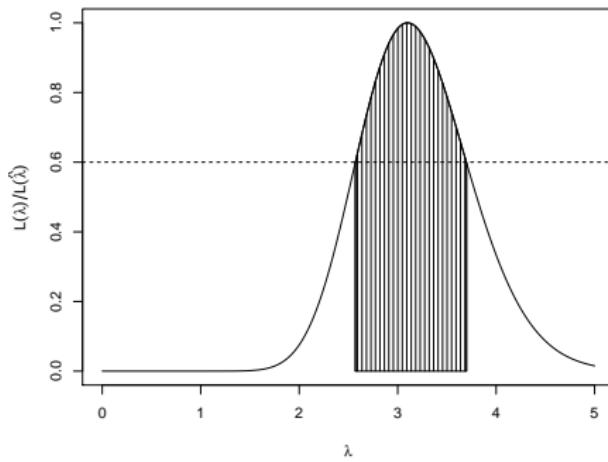
$$R(\lambda) = \frac{L(\lambda)}{L(\hat{\lambda})} = \frac{\lambda^{\sum_i y_i} e^{-n\lambda}}{\bar{y}^{\sum_i y_i} e^{-n\bar{y}}} = \left(\frac{\lambda}{\bar{y}}\right)^{\sum_i y_i} e^{-n(\lambda - \bar{y})}.$$

- Suponha que  $n = 10$  e que as seguintes contagens foram observadas: 1, 5, 4, 3, 5, 3, 2, 0, 5, 3 gerando  $\bar{y} = 3.1$ .
- Portanto,

$$R(\lambda) = \left(\frac{\lambda}{3.1}\right)^{31} e^{-10(\lambda - 3.1)}.$$

# Verossimilhança relativa - Poisson

- $R(\lambda) > 0.6$  implica no intervalo  $(2.571, 3.698)$ .
- São apenas um pouco menos verossímeis para  $\lambda$  que o EMV  $\hat{\lambda} = \bar{y}$ .



# Log Verossimilhança relativa

- Às vezes, usamos a LOG-verossimilhança relativa  $r(\theta)$ :

$$r(\theta) = \log R(\theta) = \log L(\theta) - \log L(\hat{\theta}) = \ell(\theta) - \ell(\hat{\theta})$$

- Como  $R(\theta)$  está entre 0 e 1, então

$$-\infty < r(\theta) = \log R(\theta) < 0 = r(\hat{\theta}) = 0 .$$

# Log Verossimilhança relativa

- $\theta$  = fração de pessoas que tem tuberculose.
- Amostra de  $n$  indivíduos, contagem  $Y = k$  do número de doentes.
- Verossimilhança de  $\theta$ :

$$L(\theta) = \binom{n}{k} \theta^k (1 - \theta)^{n-k}$$

- EMV  $\widehat{\theta} = k/n$ .
- A função de verossimilhança relativa é então

$$R(\theta) = \frac{\binom{n}{k} \theta^k (1 - \theta)^{n-k}}{\binom{n}{k} \widehat{\theta}^k (1 - \widehat{\theta})^{n-k}} = \left(\frac{\theta}{\widehat{\theta}}\right)^k \left(\frac{1 - \theta}{1 - \widehat{\theta}}\right)^{n-k}$$

# Log Verossimilhança relativa

- Dentre 100 pessoas examinadas, 3 tem tuberculose.
- Com base nestas observações que valores de  $\theta$  são mais verossímeis?
- Compare com os resultados que seriam obtidos se 200 pessoas fossem examinadas e 6 tivessem tuberculose.
- A estimativa de máxima verossimilhança é a mesma nos dois casos ( $= 0.03$ ) mas baseada em amostras de tamanho bem diferentes.
- Log-verossimilhança para a amostra de tamanho  $n = 100$  é igual a

$$\ell(\theta) = 3 \log(\theta) + 97 \log(1 - \theta)$$

- A estimativa de máxima verossimilhança é  $\hat{\theta} = 3/100 = 0.03$ .
- O máximo da log-verossimilhança é

$$\ell(\hat{\theta}) = 3 \log(0.03) + 97 \log(0.97) = -13.47$$

- A função log-verossimilhança relativa é então

$$r(\theta) = \ell(\theta) - \ell(\hat{\theta}) = 3 \log(\theta) + 97 \log(1 - \theta) + 13.47$$

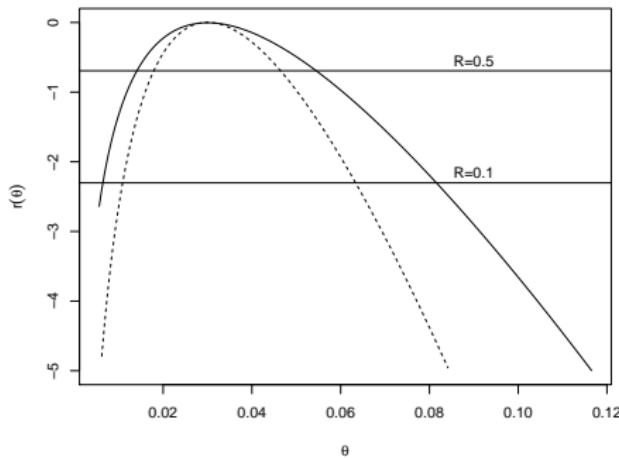
# Log Verossimilhança relativa

- Se nós observamos 6 doentes em 200 nós teremos

$$\ell(\theta) = 6 \log(\theta) + 194 \log(1 - \theta)$$

- EMV  $\hat{\theta} = 0.03$ , exatamente como antes.
- O máximo da log-verossimilhança é agora  $\ell(\hat{\theta}) = -26,95$ .
- A figura a seguir mostra a função log-verossimilhança relativa  $r(\theta)$  de cada situação.

# Log Verossimilhança relativa



**Figura:** Gráfico da função log da verossimilhança relativa,  $r(\lambda) = \log R(\theta)$ , versus  $\theta$ . A linha contínua é a verossimilhança para 3 casos em amostra de 100 indivíduos e a linha tracejada é para a situação de 6 casos em 200 indivíduos.

## Log Verossimilhança relativa

- A função  $r(\theta) = \log R(\theta)$  baseada na amostra de 200 pessoas tem uma curvatura maior no ponto de máximo que a função  $r(\theta)$  baseada na amostra de 100 pessoas.
- A amostra maior gera intervalos mais curtos que satisfazem  $R(\theta) \geq c$ .
- O intervalo  $(0.011, 0.063)$  satisfaz  $R(\theta) \geq 0.1$  para a amostra com  $n = 200$  e o intervalo  $(0.006, 0.081)$  satisfaz  $R(\theta) \geq 0.1$  para a amostra com  $n = 100$ .
- Em geral, aumentando a quantidade de dados produzirá funções de verossimilhança com maior curvatura e portanto um intervalo mais curto de valores verossímeis para o parâmetro  $\theta$ .

# Introdução

- Nem sempre a equação de verossimilhança  $\partial\ell(\theta)/\partial\theta = 0$  admite solução analítica.
- Nestes casos, precisamos usar um método numérico
- É sempre uma boa idéia fazer um gráfico da função de verossimilhança, especialmente se ela tiver apenas um parâmetro  $\theta$  unidimensional.
- A inspeção do gráfico pode revelar situações problemáticas tais como:
  - máximo não-único com vários máximos locais;
  - máximo na fronteira do espaço paramétrico, o que pode significar que o máximo de  $\ell(\theta)$  não se encontra num ponto crítico dessa função.

# Suposições

- Suponha que:
  - O espaço paramétrico  $\Theta$  é um intervalo  $[a, b]$ .
  - A estimativa de máxima verossimilhança encontra-se no interior de  $\Theta$ .
  - A função log-verossimilhança  $l(\theta)$  possui derivadas contínuas até segunda ordem.
- Para encontrar o máximo de  $L(\theta)$ , basta pesquisar entre as raízes da equação
- $$\frac{\partial \log L(\theta)}{\partial \theta} = \ell'(\theta) = 0$$
- Vamos ver um dos métodos mais importantes para encontrar as raízes de  $\ell'(\theta) = 0$ , o método de Newton (ou Newton-Raphson).

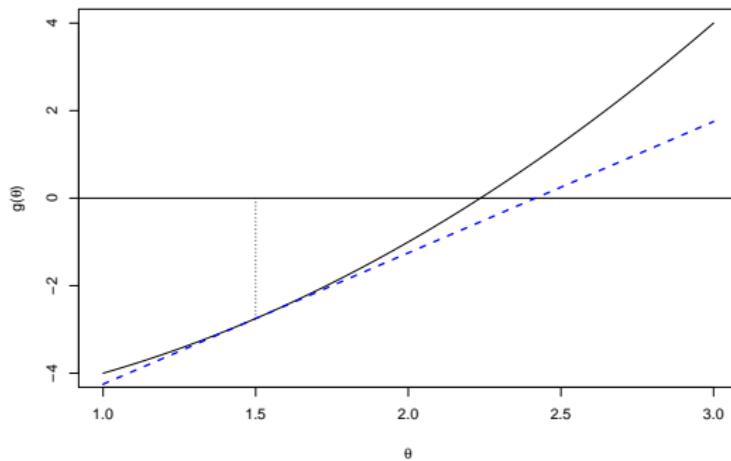
## Gráfico de $\ell(\theta)$

- Pesquisaremos um intervalo  $I$  supondo que ele contem apenas uma única raiz de  $\ell'(\theta) = 0$ .
- Ou seja, vamos supor que conseguimos isolar uma raiz dentro de um intervalo  $I$ .
- A maneira mais simples de se achar um tal intervalo dentro de  $\Theta$  é fazendo um gráfico.
- Basta que se faça um esboço da função  $\ell(\theta)$  ou da função  $\ell'(\theta)$ .
- A seguir, escolha dois pontos do eixo das abscissas entre os quais a função  $\ell(\theta)$  tem seu máximo ou a função  $\ell'(\theta)$  corta o eixo  $\theta$ .
- Denotaremos por  $\bar{\theta}$  a raiz procurada.

# Método de Newton-Raphson

- Raiz  $\bar{\theta}$  da equação  $g(\theta) = 0$
- $g(\theta)$  é uma função complicada de  $\theta$ .
- Temos um valor inicial  $\theta_o$  (com sorte, não está muito longe de  $\bar{\theta}$ ).
- Figura a seguir mostra a função não-linear  $g(\theta) = \theta^2 - 5$
- Sua raiz é  $\bar{\theta} = \sqrt{5} \approx 2.24$
- Valor inicial é  $\theta_o = 1.5$ .
- O objetivo é encontrar um novo valor  $\theta_1$  que esteja mais próximo da raiz  $\bar{\theta}$ .

# Método de Newton-Raphson



**Figura:** Gráfico de uma função  $g(\theta)$  e sua aproximação por uma reta que passa pelo ponto  $(1.5, g(1.5))$ .

# Método de Newton-Raphson

- Newton-Raphson aproxima a curva complicada  $g(\theta)$  por uma linha reta do tipo  $a + b\theta$  com intercepto  $a$  e inclinação  $b$ .
- Ao invés de encontrar a raiz da equação  $g(\theta) = 0$ , encontramos a raiz da equação  $a + b\theta = 0$  que é simplesmente  $\theta = -a/b$ .
- Esta raiz da reta deve ser um valor mais próximo da raiz desejada  $\bar{\theta}$ .
- Na figura anterior: reta que é aproximadamente igual à função  $g(\theta)$  *em torno do ponto*  $(1.5, g(1.5))$ .
- A raiz da linha reta é aproximadamente 2.42.
- Este é um valor mais próximo da raiz desejada  $\bar{\theta} \approx 2.24$  do que o valor inicial  $\theta_o = 1.5$ .
- Iteramos até convergência.

# Método de Newton-Raphson

- Como encontrar a reta que melhor aproxima a curva  $g(\theta)$  em torno do ponto  $(\theta_o, g(\theta_o))$ ?
- A reta deve passar pelo ponto  $(\theta_o, g(\theta_o))$  que pertence também ao gráfico da função  $g$ .
- Se fixarmos o ponto  $(\theta_o, g(\theta_o))$  pelo qual passa a reta, basta estabelecermos a inclinação da reta.
- A equação de uma reta que passa pelo ponto  $(\theta_o, g(\theta_o))$  é dada por  $g(\theta_o) + b(\theta - \theta_o)$ .
- Por exemplo, na figura anterior, a reta que passa por  $(1.5, g(1.5)) = (1.5, 1.5^2 - 5) = (1.5, -2.75)$  é igual a  $-2.75 + b(\theta - 1.5)$ .

# Método de Newton-Raphson

- Falta encontrar  $b$ .
- A reta que melhor aproxima uma curva é a reta tangente à curva no ponto e por isto  $b = g'(\theta_o)$ .
- Isto é, a reta que melhor aproxima a curva  $g(\theta)$  no ponto  $(\theta_o, g(\theta_o))$  é dada por  $g(\theta_o) + g'(\theta_o)(\theta - \theta_o)$ .
- Ao invés de resolver a equação  $g(\theta) = 0$ , achamos a raiz da reta tangente.
- Isto é, achamos  $\theta_1$  que soluciona a equação

$$g(\theta_o) + g'(\theta_o)(\theta - \theta_o) = 0$$

- A resposta é

$$\theta_1 = \theta_o - \frac{g(\theta_o)}{g'(\theta_o)}$$

# Método de Newton-Raphson

- Observe a iteração:

$$\theta_1 = \theta_o - \frac{g(\theta_o)}{g'(\theta_o)}$$

- Atualizamos  $\theta_o$  dando-lhe o acréscimo  $-g(\theta_o)/g'(\theta_o)$ .
- O acréscimo será *positivo* se a função  $g$  e a derivada  $g'$  no ponto  $\theta_o$  tiverem sinais trocados.
- Por exemplo, se  $g(\theta_o) < 0$  e a função estiver crescendo (isto é,  $g'(\theta_o) > 0$ ), então aumentamos  $\theta_o$  para chegar a um valor  $\theta_1$  em que  $g(\theta_1) \approx 0$ .
- O tamanho do acréscimo depende de dois fatores:
  - $g(\theta_o)$ : quão distante nós estamos de  $0 = g(\bar{\theta})$ . Se estivermos muito distantes, devemos fazer acréscimos maiores.
  - $g'(\theta_o)$ : quão rapidamente a função  $g$  está mudando de valor. Se  $g'(\theta_o)$  for muito grande, podemos fazer um acréscimo pequeno.

# Método de Newton-Raphson

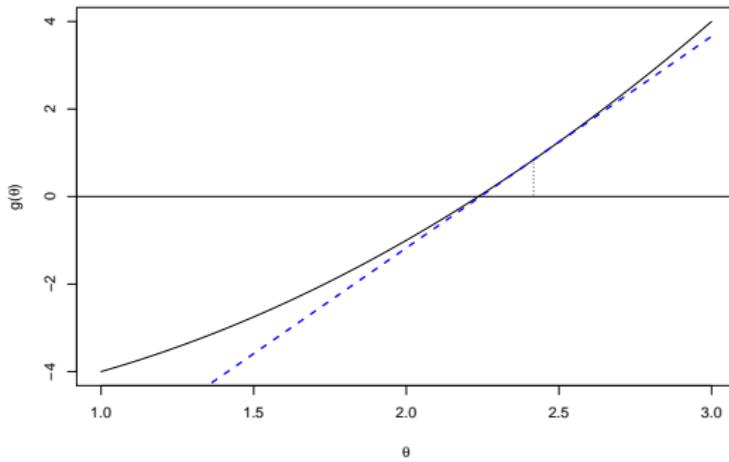
- Seja  $g(\theta) = \theta^2 - 5$
- Valor inicial  $\theta_o = 1.5$
- Temos

$$\theta_1 = \theta_o - \frac{g(\theta_o)}{g'(\theta_o)} = \theta_o - \frac{\theta_o^2 - 5}{2\theta_o} = 1.5 - \frac{1.5^2 - 5}{2 \cdot 1.5} = 1.5 + 0.916 = 2.417.$$

- Agora, basta iterar o método.
- Usando o novo ponto  $\theta_1$  como valor inicial, repetimos o procedimento acima para encontrar uma nova aproximação  $\theta_2$  para a raiz  $\bar{\theta}$ .

$$\theta_2 = \theta_1 - \frac{g(\theta_1)}{g'(\theta_1)}.$$

# Método de Newton-Raphson



**Figura:** Gráfico da função  $g(\theta)$  versus  $\theta$  com a reta tangente que passa pelo ponto  $(\theta_1, g(\theta_1)) = (2.417, g(2.417))$ . A raiz desta NOVA reta é quase idêntica à raiz desejada.

# Método de Newton-Raphson

- Iterando, obtemos  $\theta_3, \theta_4, \dots$
- A equação recursiva é

$$\theta_{n+1} = \theta_n - \frac{g(\theta_n)}{g'(\theta_n)}$$

- Quando a diferença absoluta  $|\theta_{n+1} - \theta_n|$  for menor que um pequeno limite  $\epsilon$ , interrompemos o procedimento numérico.
- Usamos o último valor calculado no processo iterativo como sendo a aproximação final para  $\bar{\theta}$ .
- Podemos também interromper as iterações quando a diferença relativa  $|\theta_{n+1} - \theta_n|/|\theta_n|$  for pequena.

# Newton-Raphson e Verossimilhança

- A equação recursiva de Newton-Raphson é

$$\theta_{n+1} = \theta_n - \frac{g(\theta_n)}{g'(\theta_n)}$$

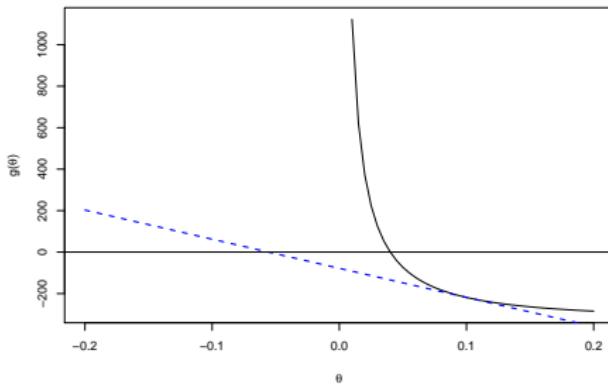
- A função  $g(\theta)$  de nosso interesse é a derivada da função de log-verossimilhança  $g(\theta) = \ell'(\theta)$
- Newton-Raphson fica então:

$$\theta_{n+1} = \theta_n - \frac{\ell'(\theta_n)}{\ell''(\theta_n)}$$

- Convergência costuma ser rápida.

# Dificuldades com o método de Newton-Raphson

- Precisamos ter um valor inicial  $\theta_0$ . Se ele for muito ruim, o método pode demorar a convergir ou pode até não convergir.
- Nem sempre o método de Newton-Raphson funciona.



**Figura:** Exemplo onde o método de Newton-Raphson não converge se iniciarmos com o valor  $\theta_0 = 0.1$ . Iniciando com  $\theta_0 < 0.05$ , teremos convergência.

## Exemplo: Acidentes de trabalho

- Quando há um acidente com um funcionário em uma fábrica, este acontecimento é registrado.
- Lista dos  $n$  funcionários acidentados num dado ano com número de acidentes sofridos:

Funcionário	1	2	3	4	5	...	$n-1$	$n$
No. de acidentes	1	1	2	1	1	...	1	1

- Não se sabe quantos funcionários existem ao todo na fábrica.
- Isto é, não ficou registrado o número de funcionários que *não se acidentaram no ano*.

# Um modelo para acidentes de trabalho

- Suponha que o número de acidentes  $S$  que um funcionário sofre num ano segue uma  $\text{Poisson}(\lambda)$ .
- Assim, o número esperado de acidentes que um funcionário sofre ao longo de um ano é  $\lambda$ .
- Vamos supor o mesmo  $\lambda$  para todos os funcionários.
- Suponha também que os funcionários sofrem acidentes independentemente uns dos outros.

# EMV de $\lambda$

- Qual o EMV de  $\lambda$ ?
- Problema: Não observamos  $X$ !!
- Observamos apenas as v.a.'s  $X$  quando  $X \geq 1$ . (Distribuição truncada).
- Nunca observamos o evento  $[X = 0]$ .
- Não temos como estimar diretamente  $\mathbb{P}(X = 0)$  pois não sabemos quantos funcionários existem ao todo na fábrica e quantos deles tiveram 0 acidentes.

# Variáveis truncadas

- Temos  $\mathbb{P}(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}$  para  $k = 0, 1, 2, \dots$
- A tabela apresenta 11 valores observados independentemente da variável aleatória  $X$  truncada em  $X = 0$ .
- Isto é, se um funcionário não sofre nenhum acidente isto não é registrado.
- A variável medida é  $Y = (X \mid X > 0)$ , o valor de  $X$  dado que  $X$  é maior que zero.
- Assim temos na tabela  $y_1, \dots, y_n$ , os valores observados de  $Y_1, \dots, Y_n$  que são i.i.d.
- As variáveis aleatórias observadas possuem distribuição dada por

$$\mathbb{P}_\lambda(Y = k) = P_\lambda(X = k \mid X > 0) = \frac{\mathbb{P}_\lambda(X = k)}{\mathbb{P}_\lambda(X > 0)} = \frac{\lambda^k}{k!} \frac{1}{e^\lambda - 1}$$

# Verossimilhança em acidentes de trabalho

- Assumindo que são i.i.d., a função de probabilidade conjunta  $\mathbb{P}(\mathbf{Y} = \mathbf{y}) = \mathbb{P}(Y_1 = y_1) \dots \mathbb{P}(Y_{11} = y_{11})$  é dada por

$$\prod_{i=1}^n \left( \frac{e^{-\lambda}}{1 - e^{-\lambda}} \frac{\lambda^{y_i}}{y_i!} \right) = \frac{\lambda^{\sum_{i=1}^n y_i}}{(e^\lambda - 1)^n \prod_{i=1}^n y_i!}$$

- onde  $\mathbf{y} = (y_1, y_2, \dots, y_n)$ .
- A função de log-verossimilhança é igual a

$$\begin{aligned} \ell(\lambda) &= \log \mathbb{P}(\mathbf{Y} = \mathbf{y}) \\ &= -n \log(e^\lambda - 1) + \left( \sum_{i=1}^n y_i \right) \log \lambda - \sum_{i=1}^n \log(y_i!) \end{aligned}$$

# Verossimilhança em acidentes de trabalho

- Portanto,

$$\ell'(\lambda) = \frac{-ne^\lambda}{e^\lambda - 1} + \frac{1}{\lambda} \sum_i y_i = \frac{-ne^\lambda}{e^\lambda - 1} + \frac{\sum_i y_i}{\lambda}$$

- A estimativa de máxima verossimilhança será a solução  $\hat{\lambda}$  da equação

$$\ell'(\lambda) = \frac{-ne^\lambda}{e^\lambda - 1} + \frac{n\bar{y}}{\lambda} = 0$$

- NOte que trocamos  $\sum_i y_i$  por  $n\bar{y}$ .

# Newton-Raphson em acidentes de trabalho

- Precisamos das expressões analíticas de  $\ell'(\lambda)$  e de  $\ell''(\lambda)$ .
- A primeira já temos. A segunda é igual a

$$\ell''(\lambda) = \frac{ne^{-\lambda}}{(1 - e^{\lambda})^2} - \frac{n\bar{y}}{\lambda^2}$$

- Fórmula de recursão do método de Newton-Raphson fica

$$\lambda_{k+1} = \lambda_k - \frac{\frac{-n}{1 - e^{-\lambda_k}} + \frac{n\bar{y}}{\lambda_k}}{\frac{ne^{-\lambda_k}}{(1 - e^{\lambda_k})^2} - \frac{n\bar{y}}{\lambda_k^2}}$$

- Isto é,

$$\lambda_{k+1} = \lambda_k - \frac{\lambda_k(1 - e^{-\lambda_k})(-n\lambda_k + n\bar{y}(1 - e^{-\lambda_k}))}{-n\lambda_k^2 e^{-\lambda_k} - n\bar{y}(1 - e^{-\lambda_k})^2}$$

# Exemplo em acidentes de trabalho

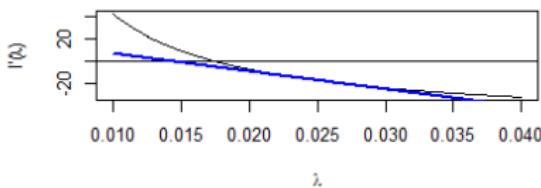
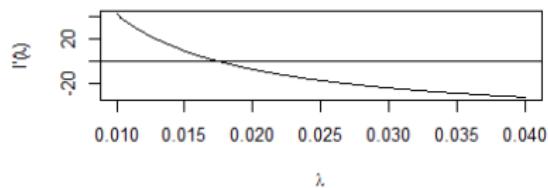
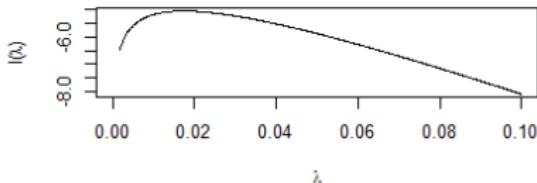
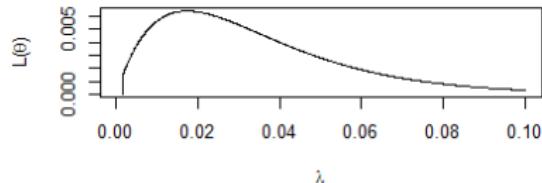
- Vamos simular dados de uma indústria com 10 mil funcionários sendo o número de acidentes de cada funcionário no ano uma v.a. de Poisson com  $\lambda = 0.01$  e independente dos demais funcionários.

```
set.seed(12)
x = rpois(10000, 0.01)
table(x)
##      0      1      2      3
## 8987  955   56     2
```

```
x = x[x > 0]
n = length(x)
sx = sum(x)
```

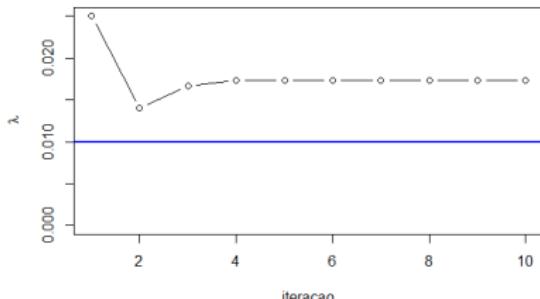
- Vamos usar apenas os  $955 + 56 + 2 = 1013$  funcionários que tiveram pelo menos um acidente no ano.
- A média aritmética desses dados é  $(955 + 56 \cdot 2 + 2 \cdot 3) / 1013 = 1.06$ , muito maior que o verdadeiro valor  $\lambda = 0.01$ .

# Acidentes de trabalho



**Figura:** Gráfico da função de verossimilhança  $L(\lambda)$ , da função log-verossimilhança  $l(\lambda)$  e da função  $l''(\lambda)$ . É mostrado também o primeiro passo do método de Newton-Raphson usando  $\lambda_0 = 0.025$ .

# Os 10 primeiros passos do Newton-Raphson: $\rightarrow 0.01734$



```

a = rep(0, 10)
a[1] = 0.025
for(i in 2:10){
  ga = -n/(1-exp(-a[i-1])) + sx/a[i-1]
  gla = n*exp(-a[i-1])/(1-exp(-a[i-1]))^2 - sx/(a[i-1])^2
  a[i] = a[i-1] - ga/gla
}

```