

Aprendizagem Estatística  
Machine learning  
Learning from data

Seleção Estatística de modelos

### Bibliografia

- Hastie, Tibshirani, Friedman. The elements of Statistical learning.
- Notas de Rafael.

Objetivo: Queremos encontrar padrões em dados.

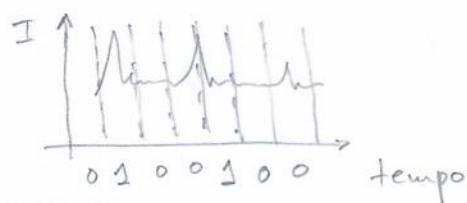
O que é um padrão?

Exemplo 1: Um dos períodos do sono é REM (rapid eye movement). Os registros REM parecem os registros feitos durante vigília

Sidarta Ribeiro (UFRN) tem a seguinte conjectura:

O cérebro "reverbera" as experiências da vigília durante o sono REM e assim aprende, constitui memória.

D. Brillinger, famoso estatístico dos anos 70 } Tive a ideia de discretizar uma sinai a sequências de 0's e 1's



Exemplo 2 : (Seq 1)

Seq 1 : 01101000 101001 ↪

tem um padrão comum?

Seq 2 : 010010001 ↪

Ambas sequências têm proporção de números 1  $\approx 1/2$   
(talvez isso é um padrão)

$$\hat{p}_n \xrightarrow[n \rightarrow \infty]{} 1/2 \quad \text{Ley dos grandes números}$$

O que é um padrão ???

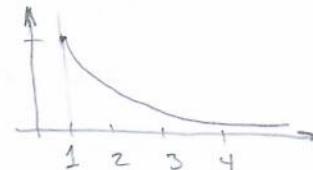
Exemplo 3: (Seq 2)

1 0000 ... 0111 ... 100 ... 01

C: comprimento é aleatório e tem uma distribuição geométrica de parâmetro  $p$  ( $1/2 < p < 1$ )

$$P(C=k) = p^{k-1} (1-p)$$

$$\uparrow \\ k = 1, 2, 3, \dots$$



$$\begin{aligned} \sum_{k=1}^{\infty} p^{k-1} (1-p) &= \sum_{j=1}^{\infty} p^j (1-p) \\ &= (1-p) \sum_{j=0}^{\infty} p^j \\ &= (1-p) \frac{1}{1-p} \quad \text{progressão geométrica} \\ &= 1. \end{aligned}$$

00 000 1111 ... 1 000 ... 01 ... 1

$c_i^o$

$c_i^i$

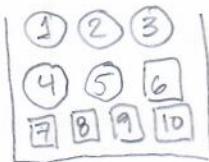
$c_2^o$

$c_2^i$

$$P(c_i^o = k) = p^{k-1} (1-p)$$

$$P(c_i^i = k) = p^{k-1} (1-p)$$

Gerador Seq 1

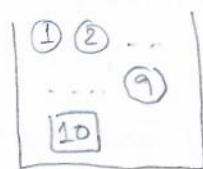


1. Escolho uma bola:

2. Se a bola é branca (○) coloco 0,

Se a bola é amarela (□) coloco 1.

Gerador Seq 2



Urna 0

Urna 1

1. Escolho uma das 2 urnas ao acaso com prob.  $1/2, 1/2$

2. Escolho ao acaso uma bola da urna sorteada. Se a bola for da cor maioria numero na urna

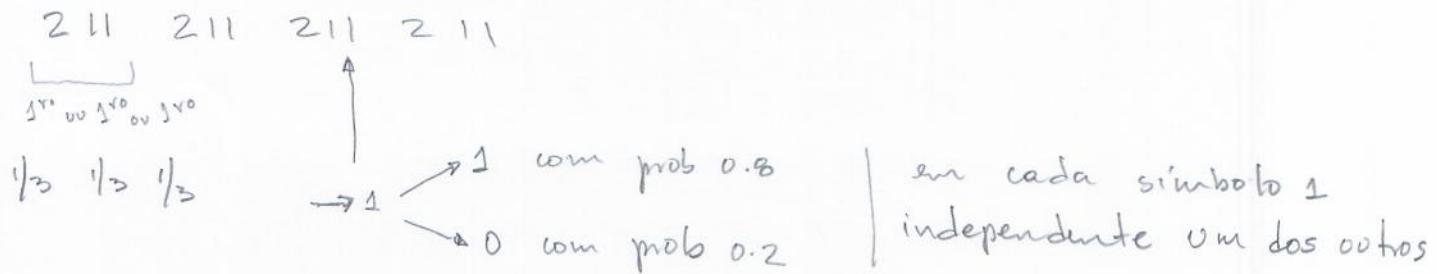
e faço novo sorteio

3. Se a bola for da cor minoritária, mudo de urna
4. Depois de cada sorteio reponho a bola na urna.

### Exercício (para casa)

Escrever pseudo-códigos para implementar algoritmos gerando as 2 experiências de urna, mais a seguinte experiência

### Jogo do bolo:



### Geração

1. Escolho começar com 2  
 ou com 1º símbolo 1 com probabilidade  $1/3, 1/3, 1/3$   
 ou com 2º símbolo 1
2. A partir do símbolo escolhido concateno
3. Atualizo cada símbolo 1 de maneira iid da seguinte maneira:  
 1 permanece 1 com prob 0.8  
 1 é alterado para 0 com prob. 0.2

### M. Gromov (geometria)

Padrão: (Definição provisória)

Conjunto coerente de regularidade estatística.

Resumo: O que fizemos na 1ª parte.

- Discutimos como "classificar" sequências de 0's e 1's.
- Tentamos fazer isso utilizando proporções relativas
- No final atribuímos um algoritmo de geração para cada sequência.

Sequência

$$x_1, x_2, \dots, x_n = \mathcal{X}, \quad x_i \in \{0,1\}$$



modelo - [algoritmo de  
geração]

Problema de classificação  
sem supervisão

Classificação com supervisão:

$\mathcal{S}$ : conjunto

$\xi_1, \xi_2, \dots, \xi_n$  são elementos de  $\mathcal{S}$

$f$  (  $y_1, y_2, \dots, y_n$  ,  $y_n = f(\xi_n)$  ,  $y_n \in \{0,1\}$  )

$(\xi_n, y_n)$  são iid

Hipótese simplificadora:  $y_n$  = função determinista de  $\xi_n$

Dado amostra  $(\xi_1, y_1), \dots, (\xi_n, y_n)$  iid.

Sei que  $y_n$  = função  $(\xi_n)$  e sei também que esa função desconhecida pertence ao conjunto  $\mathcal{H}$  de funções

$\mathcal{H}$  = conjunto de "hipóteses" ou de "modelos" que tenho à minha disposição

Problema: Escolher  $\hat{f}_n \in \mathcal{H}$  que "melhor se ajuste" aos dados

Erro do ajuste (Risco):

Tomo  $h \in \mathcal{H}$ ,

$$\begin{aligned} R(h) &= \text{probabilidade de } h(\xi) \neq y \\ &= P(h(\xi) \neq y) \end{aligned}$$

$\hookrightarrow$  não conheço  $P$ .

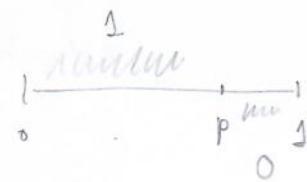
Obs:

$$f = \arg \min \{ R(h) : h \in \mathcal{H} \}, \quad R(f) = 0 \text{ por hipótese}$$

(5)

Exemplo:

$$\delta = [0, 1]$$



$\xi_1, \xi_2, \dots, \xi_n$  são sorteios independentes feitos com uma distribuição uniforme em  $[0, 1]$ .

$$Y_n = \mathbb{1}_{\{\xi_n \leq p\}} \text{ onde } 0 < p < 1 \text{ fixado.}$$

$$\mathcal{H} = \left\{ h : [0, 1] \rightarrow \{0, 1\} : h \text{ é da forma } h(u) = \mathbb{1}_{\{u \leq q\}} \text{ para algum } q \in [0, 1] \right\}$$

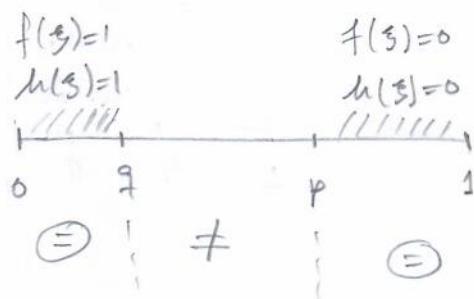
$P$  = distribuição uniforme em  $[0, 1]$

$$R(h) = P(h(\xi) \neq f(\xi)) \text{ onde } h(\xi) = \mathbb{1}_{\{\xi \leq q\}}$$

$$P([q, p]) = p - q$$

Vamos supor que  $q < p$

$$f(\xi) = \begin{cases} 1 & \text{se } \xi \leq p \\ 0 & \text{se } \xi > p \end{cases}$$



Em geral  $R(\mathbb{1}_{\{\xi \leq q\}}) = |p - q|$ , e  $\min h(h) = 0$

ocorre quando  $p = q$ .

Escolho  $h \in \mathcal{H}$ , isto é  $h$  da forma  $\mathbb{1}_{[0, q]}$  para algum  $q \in [0, 1]$

$$\hat{R}_n(h) = \frac{1}{n} \sum_{m=1}^n \mathbb{1}_{\{h(\xi_m) \neq y_m\}} \text{ onde } (\xi_1, y_1), \dots, (\xi_n, y_n)$$

é a amostra de que dispomos

$$\hat{R}_n(h) \xrightarrow{n \rightarrow \infty} R(h) \quad \left. \right\} \text{Ley de los grandes números}$$

Fixo  $\delta$ ,

$$\mathbb{P}(|\hat{R}_n(h) - R(h)| > \delta) \leq \varepsilon(n) \rightarrow 0$$

(gostaria de ter a menor majoração possível).

$$\hat{R}_n(h) = \frac{1}{n} \sum_{m=1}^n \mathbb{I}_{\{h(\xi_m) \neq y_m\}}$$

$$\frac{1}{n} \sum_{m=1}^n \mathbb{I}_{\{h(\xi_m) \neq y_m\}} \xrightarrow{\text{Zm}} \mathbb{P}(h(\xi) \neq y) \text{ onde } y = f(\xi)$$

$Z_m \rightarrow$  var. aleatorias iid

$$\mathbb{E}(\mathbb{I}_{\{h(\xi) \neq y\}})$$

Obs:

$$A \subset [0,1]$$

$$\mathbb{I}_A = \begin{cases} 1 & \text{se } u \in A \\ 0 & \text{se } u \notin A \end{cases}$$

$$\mathbb{P}(A) = \mathbb{E}(\mathbb{I}_A)$$

$$\begin{aligned} \mathbb{E}(\mathbb{I}_A) &= 1 \cdot \mathbb{P}(u: u \in A) + 0 \cdot \mathbb{P}(u: u \notin A) \\ &= \mathbb{P}(A). \end{aligned}$$

$$\hat{R}_n(h) = \frac{1}{n} \sum_{m=1}^n z_m \quad , \quad R(h) = \mathbb{E}(z).$$

$$\hat{R}_n(h) - R(h) = \underbrace{\frac{1}{n} \sum_{m=1}^n z_m - \mathbb{E}(z)}_{\begin{array}{l} \text{media} \\ \text{empírica} \\ (\text{conheço}) \end{array}} \quad . \quad \underbrace{\mathbb{E}(z)}_{\begin{array}{l} \text{media teórica} \\ (\text{não conheço}) \end{array}}$$

Lei dos grandes números diz que sob certas hipóteses a média empírica converge para a média teórica.

$$\begin{aligned}
 P(|\hat{R}_n(n) - R(n)| > s) &= P\left(\left|\frac{1}{n} \sum_{m=1}^n z_m - E(z)\right| > s\right) \quad (7) \\
 &= P\left(\left|\sum_{m=1}^n z_m - nE(z)\right| > ns\right) \\
 &\leq \frac{1}{n} \frac{\text{var}(z)}{s^2} \quad \text{Desigualdade de Chebyshov} \\
 &\quad \downarrow \\
 &\quad \varepsilon(n) \quad \text{está pode ser majorado por } 1/4
 \end{aligned}$$

Na verdade podemos obter:

$$\varepsilon(n) = e^{-2ns^2} \quad \text{Desigualdade de Hoeffding} \sim (1960).$$