



- Classificação não supervisionado de seqüências simbólicas
- Predição

Desigualdades

- Markov
- Cramer - Chernoff
- Hoeffding → desenvolver Teoria VC
- Vapnik-Chervan

Kolmogorov
 Vitany
 Rissanen

Amostra: $X^{(N)} = (X_0^{(N)}, \dots, X_n^{(N)}) \in A^n$

Classe de modelos \mathcal{M}

Algoritmo $A : (X^{(1)}, \dots, X^{(N)}) \rightarrow \hat{c} \in \mathcal{M}$

modelo de geração de seqüências simbólicas induzido de passado para futuro
 ↓
 sequencial.

A = alfabeto finito

$$\mathcal{M}_k(A) = \left\{ p : A^k \times A \rightarrow [0,1] : \forall a_{-k}, \dots, a_{-1} \in A^k, \sum_{b \in A} p(b|a_{-k}, \dots, a_{-1}) = 1 \right\}$$

Notacao

$$a_{-k}, \dots, a_{-1} = a_{-k}^{-1}$$

$$X_m, X_{m+1}, \dots, X_n = X_m^n$$

$(X_n)_n$ é uma cadeia de Markov de alcance k assumindo valores em A se ela puder ser gerada por um algoritmo do tipo:

Algoritmo:

- Seja U_0, U_1, \dots i.i.d uniformemente distribuídas no intervalo $[0,1]$
 - seja $k \geq 1$ fixado, A alfabeto finito fixado, seja $p \in \mathcal{M}_k(A)$ fixado e seja $f : A^k \times [0,1] \rightarrow A$ tal que $\forall a_{-k} \in A^k, b \in A$ tenhamos $\mathbb{P}(f(a_{-k}, U) = b) = p(b|a_{-k})$, $U \sim \text{Unif}([0,1])$
1. Escolho de alguma forma livre de ...

2. Para $n \geq 0$, faça

$$X_n = f(X_{n-k}^{n-1}, u_n)$$

Exemplo

$$A = \{1, 2, 3\}, \quad k=1$$

Dado $p = \{p(b|a) : a \in A, b \in A\}$ com $p \in M_1(A)$

$$f(a, u) = \begin{cases} 1 & \text{se } u \in [0, p(1|a)[\\ 2 & \text{se } u \in [p(1|a), p(1|a) + p(2|a)[\\ 3 & \text{se } u \in [p(1|a) + p(2|a), 1] \end{cases}$$

Por abuso de notação as vezes diremos que $(X_n)_{n \geq -k} \in M_k(A)$ si $(X_n)_n$ for gerado por um algoritmo associado a $p \in M_k(A)$.

Proposição: Se $(X_n)_{n \geq -k}$ for gerado por um algoritmo associado a $p \in M_k(A)$, então para todo $n \geq 0$

$$\begin{aligned} \mathbb{P}(X_n = b \mid X_{n-k}^{n-1} = a_{n-k}^{n-1}) &= \mathbb{P}(X_n = b \mid X_{n-k}^{n-1} = a_{n-k}^{n-1}) \\ &= p(b \mid a_{n-k}^{n-1}) \end{aligned}$$

$M_k(A)$, $k \geq 1$

$$M_0(A) = \left\{ p: A \rightarrow [0,1] : \sum_{b \in A} p(b) = 1 \right\}$$

Dado $p \in M_0(A)$, (X_n) é uma sequência de variáveis aleatórias assumindo valores em A independentes identicamente distribuídas com distribuição p , se $(X_n)_{n \geq 0}$ pode ser gerado por um algoritmo do tipo:

Algoritmo

0. Seja A alfabeto finito

Seja $p \in M_0(A)$

Seja U_0, U_1, \dots v.a iid com distribuição uniforme em $[0,1]$

Seja $f: [0,1] \rightarrow A$ tal que $\mathbb{P}(f(U) = a) = p(a)$

1. Para $n \geq 0$ faça

$$X_n = f(u_n)$$

$M(A) = \bigcup_{k \geq 0} M_k(A)$	Classe dos modelos de memória finita e Classe das cadeias de Markov
------------------------------------	---

Dada uma amostra $X_{-k}, X_{-k+1}, \dots, X_0, X_1, \dots, X_n$ de símbolos em A , queremos encontrar \hat{h}_n e \hat{p}_n em $M_{\hat{h}_n}(A)$ que "melhor se ajuste" à amostra.

Que algoritmo para isso? | Seleção estatística de modelos

Não se vai falar hoje sobre \hat{h}_n	Algoritmo contexto MDL (Minimum description length) ↑ Navalha de Occam
---	---

- Dado A :
- Fixo $k \geq 1$
 - Fixo $p \in M_k(A)$

Quero calcular: $TP(X_0^n = a_0^n | X_{-k}^{-1} = a_{-k}^{-1})$ | Verossimilhança da Amostra.

$$= TP(X_0 = a_0 | X_{-k}^{-1} = a_{-k}^{-1}) TP(X_1 = a_1 | X_0 = a_0, X_{-k}^{-1} = a_{-k}^{-1}) \dots TP(X_n = a_n | X_{-k}^{n-1} = a_{-k}^{n-1})$$

$$= TP(X_1 = a_1 | X_0^0 = a_0^0, X_{-k}^{-1} = a_{-k}^{-1}) \dots TP(X_n = a_n | X_{n-k}^{n-k} = a_{n-k}^{n-k})$$

$$= \prod_{m=0}^n p(a_m | a_{m-k}^{m-1})$$

$$= \prod_{u_{-k}^{-1} \in A^k} \prod_{v \in A} p(v | u_{-k}^{-1} v) N(u_{-k}^{-1} v)$$

$N(u_{-k}^{-1} v)$ = número de vezes em que a sequência $u_{-k}^{-1} v$ seguida do

$$N_n(u_{-k}^{-1}v) = N_{n-1}(u_{-k}^{-1}v) + \mathbb{1}_{\{X_{n-k}^{n-1} = u_{-k}^{-1}, X_n = v\}}$$

$$N_0(u_{-k}^{-1}v) = \mathbb{1}_{\{X_{-k}^{-1} = u_{-k}^{-1}, X_0 = v\}}$$

$$\sum_{v \in A} \sum_{u_{-k}^{-1} \in A^k} N_n(u_{-k}^{-1}v) = n+1$$

$$\log P(X_0^n = a_0^n | X_{-k}^{-1} = a_{-k}^{-1}) = \sum_{u_{-k}^{-1} \in A^k} \sum_{v \in A} N_n(u_{-k}^{-1}v) \log p(v | u_{-k}^{-1})$$

$$N_n(u_{-k}^{-1}v) \sim \text{cte}(u_{-k}^{-1}v) \cdot n$$

↑ número aleatório, depende da amostra X_{-k}, \dots, X_n

Lei dos grandes números garante:

$$\frac{N_n(u_{-k}^{-1}v)}{n} \xrightarrow{n \rightarrow \infty} \mu(u_{-k}^{-1}) p(v | u_{-k}^{-1})$$

↑ $p \in \mathcal{M}_k(A)$ que gerou a cadeia

$\mu: A^k \rightarrow [0,1]$ e uma medida de probabilidade

isto é

$$\sum_{u_{-k}^{-1} \in A^k} \mu(u_{-k}^{-1}) = 1 \quad (\mu \in \mathcal{M}_0(A^k))$$

μ satisfaz o sistema de equações

$$\forall u_{-k}^{-1} \in A^k, \quad \mu(u_{-k}^{-1}) = \sum_{\substack{z_{-k}^{-1}: z_{-1} = u_{-2} \\ \vdots \\ z_{-(k-1)} = u_{-k}}} \mu(z_{-k}^{-1}) p(u_{-1} | z_{-k}^{-1})$$

$$L(q) = \sum_{u^{-1}_k \in A^k} \sum_{v \in A} N_u(u^{-1}_k v) \log q(v|u)$$

$$\hat{p} = \operatorname{argmax} \{ L(q) : q \in \mathcal{M}_k(A) \}$$

$$\hat{p} = \hat{p}(k, X_{-k}^n) \leftarrow \text{matrix aleatoria}$$

Notação: $u = u^{-1}_k \in A^k$

Fixados $N_u(uv)$ quero encontrar \hat{p} que maximiza $q \mapsto L(q)$

Máximo com vínculo

Vínculo: $p \in \mathcal{M}_k(A)$, ou seja $\forall u = u^{-1}_k \in A^k$ devemos

$$\text{ter } \sum_{v \in A^k} q(v|u) = 1$$

Solução: usando multiplicadores de Lagrange

$$F(q, \lambda) = L(q) + \sum_{u \in A^k} \lambda(u) \left[1 - \sum_{v \in A} q(v|u) \right]$$

$\lambda = (\lambda(u) : u \in A^k)$

Para cada $u = u^{-1}_k \in A^k$, $v \in A$:

$$\text{derivado } \left. \frac{\partial F}{\partial q(v|u)} \right|_{q=\hat{p}} = 0 \quad , \quad \left. \frac{\partial F}{\partial \lambda(u)} \right|_{\hat{\lambda}} = 0$$

$$\begin{aligned} \frac{\partial F}{\partial q(v|u)} &= \frac{\partial}{\partial q(v|u)} N(uv) \log q(v|u) + \frac{\partial}{\partial q(v|u)} [-\lambda(u) q(v|u)] \\ &= N(uv) \frac{\partial}{\partial q(v|u)} \log q(v|u) + \frac{\partial}{\partial q(v|u)} [-\lambda(u) q(v|u)] \end{aligned}$$

$$= \frac{N(uv)}{f(v|u)} - \lambda(u) \frac{\partial}{\partial f(v|u)} f(v|u)$$

(7)

$$= \frac{N(uv)}{f(v|u)} - \lambda(u) \quad \Bigg|_{(\hat{\lambda}, \hat{f})} = 0 \quad \Rightarrow \quad \boxed{\hat{f}(v|u) = \frac{N(uv)}{\hat{\lambda}(u)}}$$

$$\frac{\partial F}{\partial \lambda(u)} = \frac{\partial}{\partial \lambda(u)} \lambda(u) \left[1 - \sum_{v \in A} f(v|u) \right]$$

$$= 1 - \sum_{v \in A} f(v|u) \quad \Bigg|_{\hat{f} = 0} \quad \Rightarrow \quad \boxed{1 = \sum_{v \in A} \hat{f}(v|u)}$$

$$\hat{\lambda}(u) = \sum_{z \in A} N(uz)$$

$$\hat{f} = \hat{p}_n(v|u^{-1}_k) = \frac{N_n(u^{-1}_k v)}{\sum_{z \in A} N_n(u^{-1}_k z)}$$

Estimador de máxima verosimilhança em $\mathcal{M}_k(A)$.

Fato: Sei dos grandes números garante que

$$\hat{p}_n^{(k)}(v|u^{-1}_k) \xrightarrow{n \rightarrow \infty} p(v|u^{-1}_k)$$

se p for a matriz que gerou a amostra.

Se $(X_n)_n$ for gerado por $p \in \mathcal{M}_k(A)$ e se

$$\hat{p}_n^{[k]}(v|u^{-1}_k) \rightarrow p(v|u^{-1}_k)$$

o que acontece se estimamos

$$\hat{P}_n^{[k+1]}(v | u_{-(k+1)}^{-1}) = \frac{N_n(u_{-(k+1)}^{-1} v)}{\sum_{z \in A} N(u_{-(k+1)}^{-1} z)}$$

Lei dos grandes números $\xrightarrow{n \rightarrow \infty}$ $\mathbb{P}(X_0 = v | X_{-(k+1)}^{-1} = u_{-(k+1)}^{-1})$ (8)

||

$$p(v | u_{-k}^{-1})$$

↑
k basta!

\mathcal{T} árvore finita de contextos

$$A = \{0,1\}$$

$$\mathcal{M}_{\mathcal{T}}(A) = \left\{ p : \mathcal{T} \times A \rightarrow [0,1] : \forall w \in \mathcal{T}, \sum_{a \in A} p(a|w) = 1 \right\}$$

① pseudo-código

0. Defina u_0, u_1, \dots sequência de v.a iid com distribuição uniforme em $[0,1]$,

$$r(X_{n-1}) = p(1|X_{n-1})$$

1. $X_{-1} = 0$

2. Para $n > 0$, faça

$$X_n = \mathbb{1}\{u_n < r(X_{n-1})\}$$

② 0. Defino para todo $w \in \mathcal{T}$, o parâmetro $r(w) = p(1|w)$
Tomo u_0, u_1, \dots v.a iid uniformes em $[0,1]$

1. $X_{-2} = X_{-1} = 1$

2. Para $n > 0$ faça

Se $X_{n-1} \in \mathcal{T}$, então $X_n = \mathbb{1}\{u_n < r(X_{n-1})\}$

Se $X_{n-1} \notin \mathcal{T}$, então $X_n = \mathbb{1}\{u_n < r(X_{n-2}, X_{n-1})\}$

③ $X_{-1}^{-20} = (0, 1, 0, 1, 0, 1, 1, 1, 0, 1, 0, 1, 0, 1, 0, 0, 0, 1, 0, 1)$

$$\hat{p}(011) = \frac{7}{9} \quad \hat{p}(111) = \frac{2}{9}$$

$$\hat{p}(110) = \frac{8}{10} \quad \hat{p}(010) = \frac{2}{10}$$

$$\hat{P}_n(u|v) = \frac{N_n(vu)}{\sum_{u'} N_n(vu')}$$

④ $X_{-1}^{-12} = (0, 0, 1, 1, 1, 0, 0, 0, 1, 0, 1, 1, 1)$

$\begin{matrix} \uparrow & \uparrow & \uparrow & \uparrow & \uparrow & \uparrow & \uparrow & \uparrow & \uparrow & \uparrow & \uparrow & \uparrow & \uparrow \\ p(010) & p(110) & p(110) & p(111) & p(011) & p(010) & p(010) & p(010) & p(010) & p(010) & p(010) & p(110) & p(111) \end{matrix}$

$$\log P(X_{-1}^{-12}) = 3 \cdot \log p(010) + 3 \log p(110) + 2 \log p(1110) + \log p(0110) + 2 \log p(1111) + \log p(0111) = \sum \sum N_n(wa) \log P(a|w)$$