



# Principe MDL et choix de modèles

Aurélien Garivier

Université Paris Sud  
Orsay

# Plan de l'exposé

- Théorie de l'information et MDL
- Chaînes de Markov d'ordre variable
- HMM à émission continue

# Codage source

- Source  $\mathbb{P}$  stationnaire sur l'alphabet  $A$ .
- Pb: transmettre les messages issus de cette source:
- Fonction de codage  $\phi_n : A^n \rightarrow \{0, 1\}^*$ , on veut minimiser la longueur de code moyenne des messages

$$\mathbb{E}_{\mathbb{P}} [|\phi_n(x)|]$$

# Entropie

- Théorème de Shannon ('48) :

$$\mathbb{E}_{\mathbb{P}} [|\phi_n(x)|] \geq H_n(\mathbb{P}) = \mathbb{E}_{\mathbb{P}} [-\log \mathbb{P}(X_1^n)],$$

à peu près atteignable.

- Par ailleurs, si la source est ergodique

$$\frac{1}{n} H_n(\mathbb{P}) \rightarrow H(\mathbb{P})$$

*taux entropique* de la source = nb de bits nécessaires au codage de chaque caractère émis.

- Code  $\phi_n(x) \leftrightarrow$  loi de codage  $q_n = 2^{-|\phi_n(x)|}$   
 $\Rightarrow -\log q_n(x) = \textit{longueur de code}$

# Codage universel

- Codeur et décodeur savent juste  $\mathbb{P} \in \mathcal{S} = \{\mathbb{P}_\theta : \theta \in \Theta\}$ .
- Ex: Markov chains, general stationary ergodic processes.
- Il faut *une seule* loi de codage  $q_n$  pour toutes les sources  $\mathbb{P}_\theta$   
⇒ surcoût appelé *redondance*

$$R_n(q_n, \theta) = \mathbb{E}_{\mathbb{P}_\theta} [|\phi_n(X)|] - H_n(\mathbb{P}_\theta) = KL(\mathbb{P}^n | q_n)$$

# Redondance minimax

- L'universalité du codeur  $q_n$  est mesurée par la redondance dans le pire des cas.
- La meilleure possible est la *redondance minimax*

$$R_n(\mathcal{S}) = \inf_{q_n} \sup_{\theta \in \Theta} R_n(q_n, \theta)$$

- Th: pour les classes  $\mathcal{S}$  paramétriques à  $k$  degrés de liberté, Rissanen (1984) :  $R_n(\mathcal{S}) = \frac{k}{2} \log n + O(1)$   
⇒ il faut au moins

$$nH(\mathbb{P}_\theta) + \frac{k}{2} \log n$$

bits en moyenne pour coder un message de taille  $n$ .

# Choix de modèle

On dispose d'une séquence  $x$ , réalisation d'une va dont la loi est dans un des modèles  $\mathcal{S}_0, \mathcal{S}_1, \dots$

Pb: identifier ce modèle à partir de l'observation.

Exemple :

- chaîne ADN  $x = \text{ACCACTGACTAGACCT} \dots$  vient d'une chaîne de Markov d'ordre 0, 1, 2, ... ?
- suite de nombre réels provenant d'un mélange d'un nombre inconnu de composantes gaussiennes.

# Principe MDL

Minimum Description Length : “choisis le modèle qui donne *la plus courte description des données*” (Rasoir d’Occam).

⇒ Soit  $k_i = \dim \mathcal{S}_i$ , à partir de  $x$  :

- on calcule  $\hat{\theta}_i(x)$  = estimateur du paramètre dans le modèle  $\mathcal{S}_i$  (ex: maximum de vraisemblance).
- on choisit le modèle minimisant

$$nH(\mathbb{P}_{\hat{\theta}_i(x)}) + \frac{k_i}{2} \log n$$

- $\approx$  maximum de vraisemblance pénalisé. Pénalité BIC.

# Plan de l'exposé

- Théorie de l'information et MDL
- Chaînes de Markov d'ordre variable
- HMM à émission continue

# Dictionnaire de suffixes complet

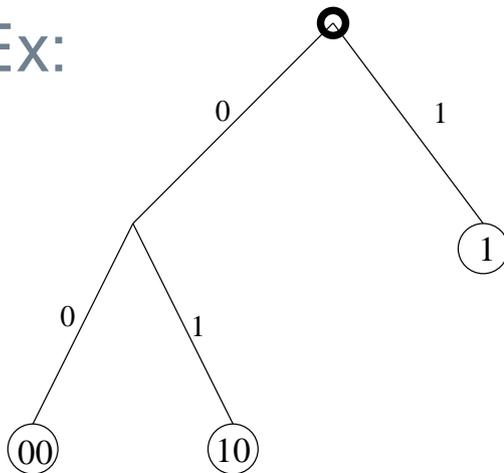
- $\mathcal{T}$  est un *Dictionnaire de suffixes complet* (DSC) si

$$\forall x_{-\infty}^0 \in A^{\mathbb{Z}^-}, \exists ! k \in \mathbb{N} : x_{-k}^0 \in \mathcal{T}.$$

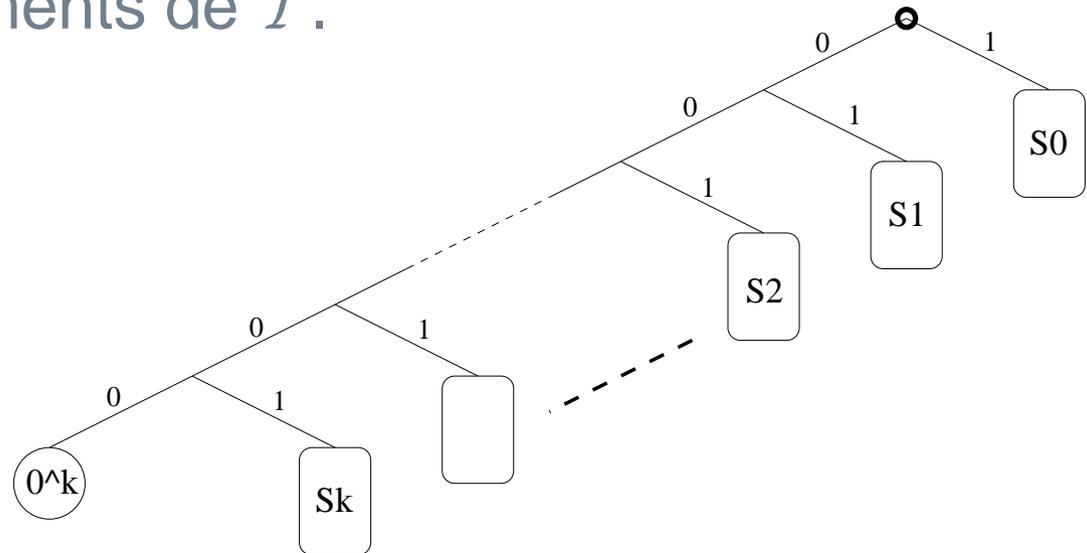
- Si  $x_{-\infty}^0 \in A^{\mathbb{Z}^-}$ , on note  $\mathcal{T}(x)$  son suffixe dans  $\mathcal{T}$ .

- Un DSC peut être représenté par un *trie* dont les feuilles sont les éléments de  $\mathcal{T}$ .

- Ex:



$$\mathcal{T} = \{00, 10, 1\}$$



$$\mathcal{T} = \{0^k\} \cup \{10^j : 0 \leq j \leq k\}$$

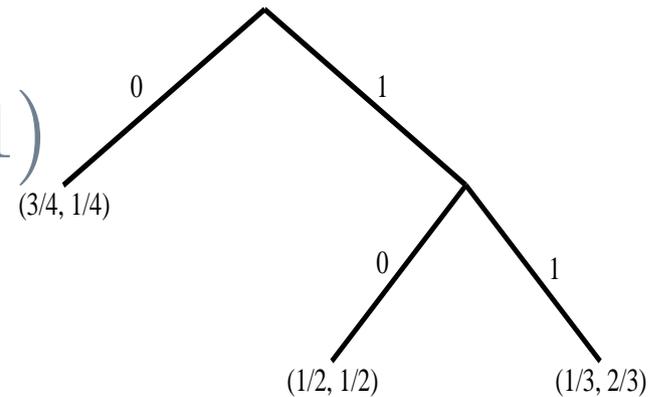
- Soit  $\mathcal{T}$  un DSC et soit  $p = (p(\cdot|w))_{w \in \mathcal{T}}$  un  $|\mathcal{T}|$ -uplet de lois de probabilité sur  $A$ .
- La *chaîne de Markov d'ordre variable*  $\mathbb{P}_{\mathcal{T},p}$  est la distribution stationnaire sur  $A^{\mathbb{Z}}$  définie par

$$\mathbb{P}_{\mathcal{T},p} (X_1 = x_1 | X_{-\infty}^0 = x_{-\infty}^0) = p(x_1 | \mathcal{T}(x_{-\infty}^0)).$$

• Ex:

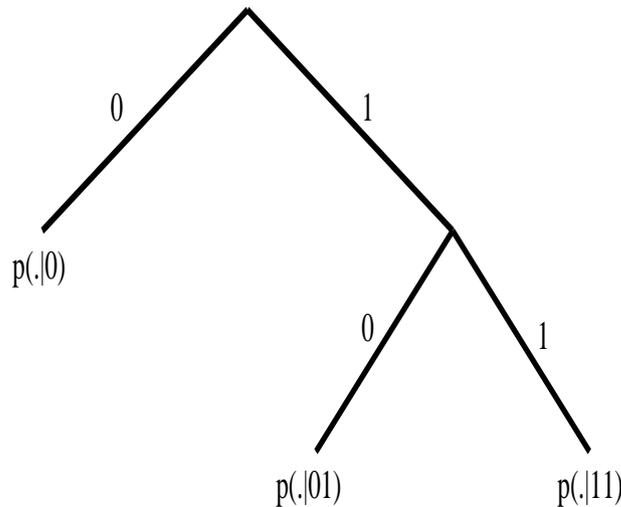
$$\mathbb{P} (X_1^4 = 1001 | X_{-\infty}^0 = \dots 01)$$

$$= \frac{1}{2} \times \frac{1}{3} \times \frac{3}{4} \times \frac{1}{4}$$



# Les VLMC sont des chaînes de Markov

- Profondeur du trie = ordre markovien



$$\rightarrow M = \begin{pmatrix} p(.|0) \\ p(.|0) \\ p(.|01) \\ p(.|11) \end{pmatrix}$$

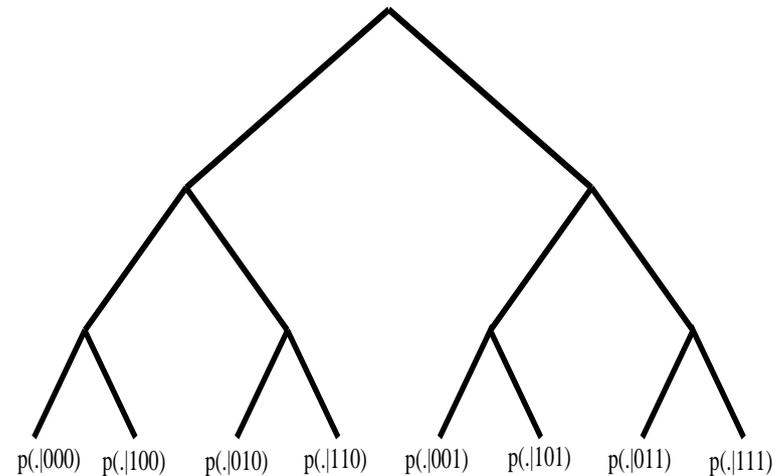
- *Variable Length* Markov Chains :  
potentiellement moins de paramètre pour une  
mémoire donnée

# Les chaînes de Markov sont des VLMC...

- ... correspondant à un arbre complet:

$$M = \begin{pmatrix} p(.|000) \\ p(.|100) \\ \vdots \\ p(.|111) \end{pmatrix}$$

→



- ⇒ les VLMC combinent le pouvoir d'approximation des chaînes de Markov avec une grande souplesse. approach every stationary ergodic source.
- Elles ne sont pas plus compliquées à utiliser.

# Esitmateur de modèle BIC

- L'estimateur BIC pour  $x \in A^n$  s'écrit :

$$\widehat{T}_{BIC} = \arg \min_{\mathcal{T}} \sum_{s \in \mathcal{T}} H(\mathcal{T}(x, s)) + \frac{|\mathcal{T}| (|A| - 1)}{2} \log n$$

- Th: (Csiszár & Talata, Garivier) :  $\widehat{T}_{BIC}$  est un estimateur *consistent*.
- Rq: il existe une procédure qui calcule  $\widehat{T}_{BIC}$  en temps linéaire.

# Plan de l'exposé

- Théorie de l'information et MDL
- Chaînes de Markov d'ordre variable
- HMM à émission continue

# Chaînes de Markov cachées

- chaque état caché a une loi d'émission différente.
- on passe d'un état caché à l'autre par un processus markovien.
- à chaque étape, on émet un caractère.
- Ex:

# Inégalités de mélange

Si  $A = \mathbb{N}$  ou  $A = \mathbb{R}$ , on ne peut appliquer la théorie de l'information classique, mais on peut montrer des inégalités de type BIC. En choisissant pour  $q_n^k$  un mélange de toutes les lois de transition et d'émission possible, on obtient

- Cas Poisson :

$$0 \leq \sup_{\theta \in \Theta_k} \log \mathbb{P}_\theta(X_1^n) - \log q^k(X_1^n) \leq \frac{k^2}{2} \log n + \frac{k}{2\tau^2} |X|_{(n)}^2 + c_{kn} + o_{kn} \quad (1)$$

- Cas gaussien :

$$0 \leq \sup_{\theta \in \Theta_k} \log f_\theta(X_1^n) - \log q^k(X_1^n) \leq \frac{k^2}{2} \log n + k\tau X_{(n)} + c_{kn} + e_{kn} \quad (2)$$

# Chaînes de Markov cachées

- De façon analogue à BIC, on définit l'estimateur :

$$\hat{k} = \arg \min_{k \geq 1} \left\{ - \sup_{\theta \in \Theta_k} \log g_{\theta}(X_1^n) + \text{pen}(n, k) \right\}$$

- Théorème** : Le vrai ordre est identifié à partir d'un certain rang dès que pour  $n \geq 3, k \geq 1$ ,

$$\text{pen}(n, k) = \sum_{\ell=1}^k \frac{\ell^2 + \alpha}{2} \log n + R_{kn},$$

# Commentaires

- Rq: on peut faire la même chose avec des états cachés i.i.d. (mélange), en remplaçant les facteurs  $k^2$  par  $2k - 1$ .
- Avantages : pas besoin de borne a priori sur l'ordre ni sur les paramètres des lois d'émission.
- Inconvénients : en pratique la vraisemblance n'est pas facile à maximiser.

# Micro-bibliography

- **Universal modeling and coding** - Rissanen, Langdon, IEEE-IT 1981
- **Universal coding, Information, Prediction, and Estimation** - Rissanen, IEEE-IT 1984
- **The Context-Tree Weighting Method : basic Properties** - Willems, Shtarkov, Tjalkens IEEE-IT 1995
- **Redundancy Rates for Renewal and Other Processes** - Csiszár, Shields - IEEE-IT 1996
- **Variable length Markov chains** - Bühlmann, Wyner, Abraham, Annals of Statistics 1999
- **Context Tree Estimation for Not Necessarily Finite Memory Processes, via BIC and MDL.** - Csiszár, Talata (Budapest), IEEE-IT 2004