



# Arbres de Contextes Probabilisés

## Le modèle

### Motivations

Noyaux et Arbres de Contextes Probabilisés

## Procédures de choix de modèle

Deux algorithmes

Maximum de vraisemblance pénalisée

Consistance et déviations de processus auto-normalisés

Estimation jointe de deux sources partageant de l'information

## Agrégation de modèles en théorie de l'information

Codage universel

Mélange et double mélange



# Mémoire adaptative

- Compression de données:

trying\_vanilla\_quiet

- Linguistique:

Longtemps, je me suis couché de bonne heure. Parfois, ...

- Processus de renouvellement:

1 0 0 1 0 1 0 0 0 0 1 1 0 0 1 ...

- Musique, biologie, optimisation, ...





## Limites des modèles markoviens

- Compression:  $|A| = 2, k = 8 \implies \dim \Theta = 256$
- Séquences biologiques:  $|A| = 4, k = 6 \implies \dim \Theta \approx 12000$
- Linguistique:  $|A| = 3000, k = 10 \implies \dim \Theta = \dots$
- Processus de renouvellement : mémoire infinie

Besoin d'une **plus grande flexibilité**: il faut pouvoir mettre beaucoup de mémoire uniquement quand c'est nécessaire!




## Arbres de contextes probabilisés

Un **arbre de contexte probabilisé** (CTS) ou **Chaîne de Markov d'ordre variable** (VLMC) est une chaîne de Markov dont l'ordre est autorisé à dépendre des valeurs prises dans le passé.

$$T = \{1, 10, 100, 1000\}$$

$$P(X_1^4 = 00110 | X_{-1}^0 = 10)$$

$$\begin{aligned} &= P(X_1 = 0 | X_{-1}^0 = 10) \\ &\times P(X_2 = 0 | X_{-1}^1 = 100) \\ &\times P(X_3 = 1 | X_{-1}^2 = 1000) \\ &\times P(X_4 = 1 | X_{-1}^3 = 10001) \\ &\times P(X_5 = 0 | X_{-1}^4 = 100011) \end{aligned}$$






## Arbres de contextes probabilisés

Un **arbre de contexte probabilisé** (CTS) ou **Chaîne de Markov d'ordre variable** (VLMC) est une chaîne de Markov dont l'ordre est autorisé à dépendre des valeurs prises dans le passé.

$$T = \{1, 10, 100, 1000\}$$

$$P(X_1^4 = 00110 | X_{-1}^0 = 10)$$

$$\begin{aligned} &= P(X_1 = 0 | X_{-1}^0 = 10) \\ &\times P(X_2 = 0 | X_{-1}^1 = 100) \\ &\times P(X_3 = 1 | X_{-1}^2 = 1000) \\ &\times P(X_4 = 1 | X_{-1}^3 = 10001) \\ &\times P(X_5 = 0 | X_{-1}^4 = 100011) \end{aligned}$$






## Arbres de contextes probabilisés

Un **arbre de contexte probabilisé** (CTS) ou **Chaîne de Markov d'ordre variable** (VLMC) est une chaîne de Markov dont l'ordre est autorisé à dépendre des valeurs prises dans le passé.

$$T = \{1, 10, 100, 1000\}$$

$$P(X_1^4 = 00110 | X_{-1}^0 = 10)$$

$$\begin{aligned} &= P(X_1 = 0 | X_{-1}^0 = 10) \\ &\times P(X_2 = 0 | X_{-1}^1 = 100) \\ &\times P(X_3 = 1 | X_{-1}^2 = 1000) \\ &\times P(X_4 = 1 | X_{-1}^3 = 10001) \\ &\times P(X_5 = 0 | X_{-1}^4 = 100011) \end{aligned}$$





## Arbres de contextes probabilisés

Un **arbre de contexte probabilisé** (CTS) ou **Chaîne de Markov d'ordre variable** (VLMC) est une chaîne de Markov dont l'ordre est autorisé à dépendre des valeurs prises dans le passé.

$$T = \{1, 10, 100, 1000\}$$


$$P(X_1^4 = 00110 | X_{-1}^0 = 10)$$

$$\begin{aligned}
&= P(X_1 = 0 | X_{-1}^0 = 10) \\
&\times P(X_2 = 0 | X_{-1}^1 = 100) \\
&\times P(X_3 = 1 | X_{-1}^2 = 1000) \\
&\times P(X_4 = 1 | X_{-1}^3 = 10001) \\
&\times P(X_5 = 0 | X_{-1}^4 = 100011)
\end{aligned}$$

3/4

1/3

4/5






## Arbres de contextes probabilisés

Un **arbre de contexte probabilisé** (CTS) ou **Chaîne de Markov d'ordre variable** (VLMC) est une chaîne de Markov dont l'ordre est autorisé à dépendre des valeurs prises dans le passé.

$$T = \{1, 10, 100, 1000\}$$

$$P(X_1^4 = 00110 | X_{-1}^0 = 10)$$

$$\begin{aligned} &= P(X_1 = 0 | X_{-1}^0 = 10) \\ &\times P(X_2 = 0 | X_{-1}^1 = 100) \\ &\times P(X_3 = 1 | X_{-1}^2 = 1000) \\ &\times P(X_4 = 1 | X_{-1}^3 = 10001) \\ &\times P(X_5 = 0 | X_{-1}^4 = 100011) \end{aligned}$$






## Arbres de contextes probabilisés

Un **arbre de contexte probabilisé** (CTS) ou **Chaîne de Markov d'ordre variable** (VLMC) est une chaîne de Markov dont l'ordre est autorisé à dépendre des valeurs prises dans le passé.

$$T = \{1, 10, 100, 1000\}$$

$$P(X_1^4 = 00110 | X_{-1}^0 = 10)$$

$$\begin{aligned} &= P(X_1 = 0 | X_{-1}^0 = 10) && \mathbf{3/4} \\ &\times P(X_2 = 0 | X_{-1}^1 = 100) && \mathbf{1/3} \\ &\times P(X_3 = 1 | X_{-1}^2 = 1000) && \mathbf{4/5} \\ &\times P(X_4 = 1 | X_{-1}^3 = 10001) && \mathbf{1/3} \\ &\times P(X_5 = 0 | X_{-1}^4 = 100011) && \mathbf{2/3} \end{aligned}$$



## Le modèle

Motivations

Noyaux et Arbres de Contextes Probabilisés

## Procédures de choix de modèle

Deux algorithmes

Maximum de vraisemblance pénalisée

Consistance et déviations de processus auto-normalisés

Estimation jointe de deux sources partageant de l'information

## Agrégation de modèles en théorie de l'information

Codage universel

Mélange et double mélange



## Les Noyaux

- On munit l'espace des suites semi-infinies  $A^{-\mathbb{N}^*}$  de la distance ultra-métrique suivante :

$$\delta(\underline{w}, \underline{z}) = 2^{\sup\{k \leq 0 : x_k \neq y_k\}}$$

- Les boules (ouvertes et fermées) de cet espace sont les

$$\mathcal{T}(s) = \{\underline{w} \in A : x_{-|s|+1:0} = s\}$$

pour  $s \in A^*$ .

- Un *noyau* est une application  $P : A^{-\mathbb{N}} \rightarrow \mathcal{M}_1(A)$ , et l'image de  $\underline{w} \in A^{-\mathbb{N}}$  est notée  $P(\cdot | \underline{w})$ .
- Un noyau est dit *continu* s'il l'est comme application entre les espaces métriques  $(A^{-\mathbb{N}}, \delta)$  et  $(\mathcal{M}_1(G), |\cdot|_{TV})$ .



## Processus associé à un noyau

- Vieux problème: pour un noyau  $P$  donné, existe-t-il un (unique) processus stationnaire ergodique dont  $P$  est une version des probabilités conditionnelles?
- **Théorème [Fernandez-Galves '02]:** si  $\sum_{a \in A} \inf_{s \in T} P(a|s) > 0$  et si les

$$\beta_k = \max_{a \in A} \sup \left\{ |P(a|s) - P(a|t)| : (s, t) \in T^2 \text{ and } s_{-k+1}^0 = t_{-k+1}^0 \right\}$$

sont sommables, alors la réponse est oui.

- Idée : simulation exacte par *couplage par le passé*.



## Arbres de contextes probabilisés

- Un *arbre complet de suffixes* (CSD) est un ensemble  $T \subset A^*$  qui définit une partition de  $A^{-\mathbb{N}}$ :

$$A^{-\mathbb{N}} = \bigcup_{s \in T} \mathcal{T}(s)$$

- Ainsi,  $T$  est une CSD ssi

$$\forall x_{-\infty}^0 \in A^{-\mathbb{N}}, \exists ! L \in \mathbb{N} : x_{-L}^0 \in T;$$

- Le noyau d'une CTS est constant sur chaque composante d'un CSD : il est donc caractérisé par la donnée d'une **famille de  $|T|$  distributions conditionnelles**  $\{P_T(\cdot|s) : s \in T\}$ :

$$\forall x_{-\infty}^0 \in A^{-\mathbb{N}} P_T(\cdot|x_{-\infty}^0) = P_T(\cdot|x_{-L}^0).$$




## CTS vs Chaines de Markov


- Les **Chaînes de Markov** d'ordre  $r$  sont des **CTS** dont l'arbre est complet de profondeur  $r$ .

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

$\Rightarrow$



- Les **CTS bornés** de profondeur  $d$  sont des **chaînes de Markov** d'ordre  $d$ .



$\Rightarrow$

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



## Vraisemblance et estimation

- La vraisemblance admet une écriture aussi simple que pour les chaînes de Markov:

$$P_T(x_1^n | x_{-\infty}^0) = \prod_{i=1}^n P_T(x_i | x_{i-L_i}^{i-1}) = \prod_{s \in T} \prod_{i \in I_s} P_T(x_i | s),$$

où  $I_s = \{i \in \{1, \dots, n\} : x_{i-|s|}^{i-1} = s\}$ .

- L'estimateur du maximum de vraisemblance dans le modèle  $T$  est donc: pour  $s \in T$ ,

$$\hat{P}_T(\cdot | s) = \frac{N(sa)}{N(s)},$$

où  $N(s) = \sum_{i=1}^n \mathbb{1}_{x_{i-|s|}^{i-1} = s} = |I_s|$ .

## Le modèle

Motivations

Noyaux et Arbres de Contextes Probabilisés

## Procédures de choix de modèle

Deux algorithmes

Maximum de vraisemblance pénalisée

Consistance et déviations de processus auto-normalisés

Estimation jointe de deux sources partageant de l'information

## Agrégation de modèles en théorie de l'information

Codage universel

Mélange et double mélange



## Algorithme Context

- Introduit par Rissanen en 1981, ressemble à CART.
- Pour tout  $s \in A^*$ , on calcule la mesure de distortion

$$\delta(s) = \max_{a \in A} \left\| \hat{P}(\cdot|s) - \hat{P}(\cdot|as) \right\|.$$


- On garde tous les  $s \in A^*$  tels que

$$\exists u \in A^* : \delta(us) \geq \varepsilon(n)$$

comme noeuds internes de  $\hat{T}_C$ . Ainsi  $\hat{T}_C$  contient tous les **noeuds actifs**, leurs ancêtres et leur enfants.



# Algorithm Context: Illustration



Noeuds actifs - Arbre estimé  $\hat{T}_C$

## Le modèle

Motivations

Noyaux et Arbres de Contextes Probabilisés

## Procédures de choix de modèle

Deux algorithmes

**Maximum de vraisemblance pénalisée**

Consistance et déviations de processus auto-normalisés

Estimation jointe de deux sources partageant de l'information

## Agrégation de modèles en théorie de l'information

Codage universel

Mélange et double mélange



## Maximum de vraisemblance pénalisée

- On choisit

$$\hat{T}_{pml} = \operatorname{argmax}_T \log \hat{P}_T(x_1^n | x_{-\infty}^0) + \operatorname{pen}(n, T),$$

où  $\operatorname{pen}(n, T)$  est une fonction de pénalité croissante en  $n$  et  $|T|$ .

- Pénalité BIC

$$\operatorname{pen}(n, T) = \frac{|T|(|A| - 1)}{2} \log n.$$


- Principe Minimum Description Length: choisir le modèle qui donne la plus courte description des données (= qui permet de mieux les compresser)
- Variante MDL: estimé de Krichevski-Trofimov

$$\hat{T}_{KT} = \operatorname{argmax}_T \log KT_T(x_1^n | x_{-\infty}^0).$$



## Calcul de $\hat{T}_{pml}$


Procédure récursive “Context Tree Maximization” : un noeud  $s$  est dit **actif** si  $x_{I(s)}$  se code mieux avec de la mémoire.



En partant du sommet, on ne garde que les noeuds actifs.




# PML: Illustration



Noeuds actifs - Arbre estimé  $\hat{T}_{pml}$




## PML: Exemple






## PML: Exemple






## PML: Exemple






## PML: Exemple






## PML: Exemple





## PML: Exemple





## Comparaison des deux estimateurs

- - Pour l'algorithme Context, l'activité d'un noeud se mesure uniquement dans ce noeud.
  - Pour PML, l'activité d'un noeud prend en compte tout ce qui est sous ce noeud.
- - L'algorithme Context garde une branche dès que son noeud le plus profond est actif.
  - PLM ne garde que des noeuds actifs.
- $\implies$  pour des choix de paramètres comparables, on montre que l'algorithme Context sélectionne systématiquement des arbres plus grands que PLM.

## Le modèle

Motivations

Noyaux et Arbres de Contextes Probabilisés

## Procédures de choix de modèle

Deux algorithmes

Maximum de vraisemblance pénalisée

**Consistance et déviations de processus auto-normalisés**

Estimation jointe de deux sources partageant de l'information

## Agrégation de modèles en théorie de l'information

Codage universel

Mélange et double mélange



# Sous-estimation et Sur-estimation

Deux erreurs d'estimation sont possibles:

1. sous-estimation:

$$\exists s \in T_0 : s \notin \hat{T}$$


$\implies$  "facilement" évitée

(régime de grandes déviations) à vitesse exponentielle

2. sur-estimation:

$$\exists s \in \hat{T} : s \notin T_0$$

$\implies$  plus délicat, pas de taux exponentiels [Finesso '92]





## Résultats asymptotiques

- **Théorème [Rissanen '81, ...]:** Pour un arbre fini  $T_0$ , si  $\varepsilon(n) = C \log(n)/n$ , alors quand  $n \rightarrow \infty$ :

$$P(\hat{T}_C \neq T_0) \rightarrow 0.$$

- **Théorème [Csiszár and Talata '06, Garivier '06]:** Si  $K \in \mathbb{N}^*$  et si  $\hat{T}_{pml}$  maximise la vraisemblance pénalisée parmi les arbres de hauteur  $D(n) = o(\log n)$ , alors

$$\hat{T}_{pml}^K = T_0^K$$

presque sûrement pour  $n$  assez grand. Pour un arbre fini  $T_0$ , pas besoin de restreindre la maximisation.

- Résultats non asymptotiques : cf [Galves-Maume-Deschamps Schmitt '05, Leonardi '08, Garivier-Leonardi] avec hypothèses



## Comment étudier la convergence ?

- Pour l'algorithme Context on doit contrôler

$$\|\hat{P}(\cdot|s) - P(\cdot|s)\|.$$

- Pour le maximum de vraisemblance pénalisée, il faut majorer

$$KL(\hat{P}(\cdot|s), P(\cdot|s)).$$

- Dans les deux cas, on se ramène à l'étude des maxima d'une martingale "moyenne normalisée" du type:

$$Z_t = \frac{1}{\sqrt{N_t(s)}} \sum_{u=1}^t (\mathbb{1}_{\{X_u=a\}} - P(a|s)) \mathbb{1}_{\{X_{u-1|s}=s\}}.$$


- Bornes non-asymptotiques adapter les preuves de LLI.



## Quelle est l'activité normale d'un noeud ?

Pour tout contexte possible  $s$ , l'estimateur du maximum de vraisemblance de la loi conditionnelle est :

$$\forall a \in A, \hat{P}(a|s) = \frac{1}{n} \sum_{k=1}^n \mathbb{1}_{\{X_k=a\}} \mathbb{1}_{\{X_{k-|s|}^{k-1}=s\}}$$



## Le modèle

Motivations

Noyaux et Arbres de Contextes Probabilisés

## Procédures de choix de modèle

Deux algorithmes

Maximum de vraisemblance pénalisée

Consistance et déviations de processus auto-normalisés

Estimation jointe de deux sources partageant de l'information

## Agrégation de modèles en théorie de l'information

Codage universel

Mélange et double mélange



## Formulation du problème

- $X = (X_n)_{n \in \mathbb{Z}}$  et  $Y = (Y_n)_{n \in \mathbb{Z}}$  sont des CTS indépendantes de lois  $P_X$  et  $P_Y$
- $P_X$  et  $P_Y$  partagent certains contextes et certaines lois conditionnelles, mais pas toutes
- On note  $\tau_X = \tau_0 \cup \tau_1$  le CSD de  $P_X$ , et  $\tau_Y = \tau_0 \cup \tau_2$  le CSD de  $P_Y$
- On veut estimer  $\tau_X$  et  $\tau_Y$ : est-ce possible de faire mieux qu'en traitant les deux problèmes séparément?



# Estimation jointe par maximum de vraisemblance

- La vraisemblance jointe s'écrit:

$$\begin{aligned} & \sum_{s \in \tau_1} \sum_{a \in A} N_{n,X}(s, a) \log \left( \frac{N_{n,X}(s, a)}{N_{n,X}(s)} \right) \\ & + \sum_{s \in \tau_2} \sum_{a \in A} N_{m,Y}(s, a) \log \left( \frac{N_{m,Y}(s, a)}{N_{m,Y}(s)} \right) \\ & + \sum_{s \in \tau_0} \sum_{a \in A} [N_{n,X}(s, a) + N_{m,Y}(s, a)] \log \left( \frac{N_{n,X}(s, a) + N_{m,Y}(s, a)}{N_{n,X}(s) + N_{m,Y}(s)} \right) \end{aligned}$$


- Procédure récursive “à la Context Tree Maximization” consistante [Galves-Garivier-Gassiat]



## Exemple de résultats

Quand on répète l'expérience 100 fois avec des échantillons de taille  $n_X = n_Y = 400$ , voici ce qui se passe :

- $\tau_X$  est bien estimé avec  $X$  seul 96 fois, et avec notre algo 80 fois : la performance est donc dégradée.
- Par contre,  $\tau_Y$  est bien estimé avec  $Y$  seul 47 fois, et avec notre algo 85 fois
- Surtout,  $\tau_X$  et  $\tau_Y$  sont séparément bien estimés 45 fois, et conjointement 67 fois.



## Le modèle

Motivations

Noyaux et Arbres de Contextes Probabilisés

## Procédures de choix de modèle

Deux algorithmes

Maximum de vraisemblance pénalisée

Consistance et déviations de processus auto-normalisés

Estimation jointe de deux sources partageant de l'information

## Agrégation de modèles en théorie de l'information

Codage universel

Mélange et double mélange

# Codage source



ATCAGAATC




0011011000110011010

**compression sans perte**

Winzip, compress, etc.

**But : minimiser la longueur  
de code**





# Codage source : Shannon



**Source P**

= processus stationnaire sur l'**alphabet A**

ici,  $A = \{A, C, T, G\}$



ATCAGAATC

message  $X_1^n$  ( $n=9$ )

code  $\phi_n : A \rightarrow \{0, 1\}^*$

**compression sans perte**

Winzip, compress, etc.

0011011000110011010

**mot de code**

$\phi_n(X_1^n)$

**But : minimiser la longueur  
de code moyenne**

$$E_P[|\phi_n(X_1^n)|]$$





- **Théorème (Shannon '48) :**

$$\mathbb{E}_P [|\phi_n(x)|] \geq H_n(P) \stackrel{\text{def}}{=} \mathbb{E}_P [-\log P^n(X_1^n)]$$

... et il existe un code qui atteint ce taux (à 1 bit près).

- En outre,

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

taux entropique de la source  $P$   
=nombre minimal de bit par symbole.



## Loi de codage

- A chaque code  $\phi_n(x)$  on peut associer une (sous-)probabilité  $q_n$  sur  $A^n$  telle que

$$q_n(\cdot) = 2^{-|\phi_n(\cdot)|}$$

- Inversement, grâce au codage arithmétique, on peut associer à toute (sous-)probabilité  $q_n$  sur  $A^n$  un code  $\phi_n$  tel que  $|\phi_n(\cdot)| = -\log q_n(\cdot)$  (+Cte).

Conclusion: code  $\phi_n \iff$  loi de codage  $q_n$

En particulier,  $-\log q_n(x) =$  longueur de code.

- Le théorème de Shannon '48 dit que la meilleure loi de codage est la loi du processus !
- La perte obtenue en utilisant une autre loi  $q_n$  est appelée regret  $-\log q_n(X_1^n) - (-\log P^n(X_1^n)) = \log \frac{P^n(X_1^n)}{q_n(X_1^n)}$ .



## Codage universel

- Que faire si la loi de la source est inconnue ??
- ... et si on veut un seul code pour plusieurs sources à la fois ?

⇒ on a besoin d'une seule loi de codage  $q_n$  pour toute une classe de sources

$$\Lambda = \{P_\theta, \theta \in \Theta\}$$

c'est donc un problème d'estimation de densité...

⇒ Redondance inévitable :

$$\begin{aligned}\mathbb{E}_{P_\theta} [|\phi(X_1^n)|] - H(X_1^n) &= \mathbb{E}_{P_\theta} [\log q_n(X_1^n) + \log P_\theta(X_1^n)] \\ &= KL(P_\theta, q_n)\end{aligned}$$

... avec perte logarithmique = information de Kullback-Leibler entre  $P_\theta$  et  $q_n$ .



# Exemples de codeurs universels

## 1. Codage deux-temps

- Code d'abord  $\hat{\theta}(X_1^n) = \operatorname{argmin}_{\theta \in \Theta} -\log P_{\theta}(X_1^n) \dots$
- ... puis  $X_1^n$  avec la loi de codage  $P_{\hat{\theta}}^n$ .


Ex: (i.i.d.)

$X_1^9 = AAATACAGT : \hat{\theta} = (5, 1, 2, 1)/9$   $\implies$  regret  $\frac{|A| - 1}{2} \log n$ .

## 2. Codage par mélange si $\nu$ est un prior sur $\Theta$ , on prend

$$q_n^{\nu}(x_1^n) = \int_{\Theta} P_{\theta}(x_1^n) d\nu(\theta)$$

Ex: (i.i.d.)  $\rightarrow \nu = \text{Dirichlet}(\frac{1}{2}, \dots, \frac{1}{2})$





## 1. Redondance dans le pire des cas :

$$R^+(q_n, \Theta) = \sup_{\theta \in \Theta} \mathbb{E}_{P_\theta} \left[ \log \frac{P_\theta^n(X_1^n)}{q_n(X_1^n)} \right] = \sup_{\theta \in \Theta} KL(P_\theta, q_n)$$

## 2. Redondance bayésienne avec le prior $\pi$ :

$$R_\pi^-(q_n, \Theta) = \mathbb{E}_\pi \left[ \mathbb{E}_{P_\theta} \left[ \log \frac{P_\theta^n(X_1^n)}{q_n(X_1^n)} \right] \right] = \mathbb{E}_\pi [KL(P_\theta, q_n)]$$

$$\implies R^-(q_n, \Theta) \leq R^+(q_n, \Theta)$$



# Mesures de complexité

## 1. Redondance minimax:

$$R_n^+(\Theta) = \inf_{q_n} R^+(q_n, \Theta) = \min_{q_n} \max_{\theta} KL(P_{\theta}^n, q_n)$$

## 2. Redondance bayésienne:

$$R_{\pi, n}^-(\Theta) = \min_{q_n} \mathbb{E}_{\pi} [KL(P_{\theta}^n, q_n)]$$

$$R_n^-(\Theta) = \max_{\pi} \min_{q_n} \mathbb{E}_{\pi} [KL(P_{\theta}^n, q_n)]$$

## Theorème maximin (Haussler '97, Sion)

$$R_n^-(\Theta) = R_n^+(\Theta),$$

et la redondance minimax est atteinte par un mélange  $\pi$ .

## Le modèle

Motivations

Noyaux et Arbres de Contextes Probabilisés

## Procédures de choix de modèle

Deux algorithmes

Maximum de vraisemblance pénalisée

Consistance et déviations de processus auto-normalisés

Estimation jointe de deux sources partageant de l'information

## Agrégation de modèles en théorie de l'information

Codage universel

Mélange et double mélange



## Mélange pour les VLMC

- Soit  $T$  un arbre de contexte à  $|T|$  feuilles (=  $|T|$  contextes).
- En considérant un produit de  $|T|$  lois de Dirichlet  $(\frac{1}{2}, \dots, \frac{1}{2})$  comme a priori sur  $\Theta_T$ , on définit le **mélange de Krichevky-Trofimov**  $q_T^\nu$  qui vérifie:

$$q_T^\nu(x_1^n | x_{-\infty}^0) = \prod_{s \in T} q^\nu(T(x, s)).$$

- **Proposition (Shtarkov&al '93)**

$$-\log q_T^\nu(x_1^n | x_{-\infty}^0) \leq \inf_{\theta \in \Theta_T} p_\theta(x_1^n | x_{-\infty}^0) + \frac{|A| - 1}{2} |T| \log^+ \frac{n}{T} + |T| \log m + m - 1.$$



## CTW : un double mélange

La relation

$$\pi(T) = 2^{-2|T|+1}$$

définit une loi de probabilité sur l'ensemble  $\mathcal{T}$  de tous les arbres de contextes.

On définit donc la loi de probabilité **Context Tree Weighting** :

$$q_n^{\text{CTW}}(x_1^n) = \sum_T \pi(T) q_T^V(x_1^n)$$

elle se calcule efficacement par CTM.



## CTW : un double mélange

### Proposition (Sharkov & al '93)

$$\begin{aligned} -\log q_n^{\text{CTW}}(x_1^n | x_{-\infty}^0) &\leq \inf_{T \in \mathcal{T}} \inf_{\theta \in \Theta_T} p_\theta(x_1^n | x_{-\infty}^0) \\ &\quad + \frac{|A| - 1}{2} |T| \log \frac{n}{T} + |T|(2 + \log m) + m - 2. \end{aligned}$$

⇒ CTW est adaptatif sur les classes de CTS.

Quelle est sa performance sur des classes plus grandes ?





- **Theorem (G. '06):** Il existe  $C_1$  et  $C_2$  telles que la redondance de sur la classe  $\mathcal{R}$  des processus de renouvellement vérifie:

$$C_1 \sqrt{n} \log n \leq R_n^*(q_n^{\text{CTW}}, \mathcal{R}) \leq C_2 \sqrt{n} \log n.$$

- **Theorem (G. '06):** Il existe  $C_1$  et  $C_2$  telles que la redondance de sur la classe  $\mathcal{MR}$  des processus de renouvellement markoviens vérifie:

$$C_3 n^{\frac{2}{3}} \log n \leq R_n^*(q_n^{\text{CTW}}, \mathcal{MR}) \leq C_4 n^{\frac{2}{3}} \log n.$$



## Commentaires

- Résultat d'adaptivité pour CTW sur une classe massive, équilibre biais/variance.
- Si la loi de renouvellement est bornée, CTW s'adapte aussi avec un regret en  $O(\log n)$ .
- Nécessite la prise en compte de contextes profonds dans le double mélange (  $\implies$  ne pas couper les arbres à profondeur  $\log n$  ).

