

# Analyses d'algorithmes pour l'estimation et l'optimisation stochastiques

Aurélien Garivier

CNRS & Telecom ParisTech

28 novembre 2011

# Deux principes d'ingénieur

## Minimum Description Length

Choisis le modèle qui permet la plus courte description des données.

## Paradigme optimiste

Parmi tous les environnements qui rendent les observations suffisamment vraisemblables, fais comme si tu étais dans celui qui t'est le plus favorable.

# Plan de l'exposé

- 1 Arbres de contextes et mémoire variable
  - Noyaux, processus et simulation exacte
  - Estimation
- 2 Quelques inégalités auto-normalisées
- 3 Apprentissage par renforcements
  - Problèmes de bandits classique
  - Extensions du modèle

# Mémoire adaptative

- Compression de données:

t r y i n g \_ v a n i l l a \_ q u i e t

- 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, ...

# 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.

$$T = \{1, 10, 100, 000\}$$

$$\begin{aligned} & \mathbb{P}(X_1^4 = 00110 | X_{-1}^0 = 10) \\ = & \mathbb{P}(X_1 = 0 | X_{-1}^0 = 10) \\ \times & \mathbb{P}(X_2 = 0 | X_{-1}^1 = 100) \\ \times & \mathbb{P}(X_3 = 1 | X_{-1}^2 = 1000) \\ \times & \mathbb{P}(X_4 = 1 | X_{-1}^3 = 10001) \\ \times & \mathbb{P}(X_5 = 0 | X_{-1}^4 = 100011) \end{aligned}$$




# 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.

$$T = \{1, 10, 100, 000\}$$

$$\begin{aligned} & \mathbb{P}(X_1^4 = 00110 | X_{-1}^0 = 10) \\ = & \mathbb{P}(X_1 = 0 | X_{-1}^0 = 10) \\ \times & \mathbb{P}(X_2 = 0 | X_{-1}^1 = 100) \\ \times & \mathbb{P}(X_3 = 1 | X_{-1}^2 = 1000) \\ \times & \mathbb{P}(X_4 = 1 | X_{-1}^3 = 10001) \\ \times & \mathbb{P}(X_5 = 0 | X_{-1}^4 = 100011) \end{aligned}$$




# 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.

$$T = \{1, 10, 100, 000\}$$

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

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




# 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.

$$T = \{1, 10, 100, 000\}$$

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

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






# 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.

$$T = \{1, 10, 100, 000\}$$

$$\begin{aligned} & \mathbb{P}(X_1^4 = 00110 | X_{-1}^0 = 10) \\ = & \mathbb{P}(X_1 = 0 | X_{-1}^0 = 10) \\ \times & \mathbb{P}(X_2 = 0 | X_{-1}^1 = 100) \\ \times & \mathbb{P}(X_3 = 1 | X_{-1}^2 = 1000) \\ \times & \mathbb{P}(X_4 = 1 | X_{-1}^3 = 10001) \\ \times & \mathbb{P}(X_5 = 0 | X_{-1}^4 = 100011) \end{aligned}$$



# Noyaux

Alphabet fini  $\mathcal{A}$ ,  $\mathcal{A}^* = \bigcup_{n \geq 0} \mathcal{A}^n$ .

Passé  $\underline{w} = w_{-\infty:-1} \in \mathcal{A}^{-\mathbb{N}}$

Distance ultra-métrique  $\delta(\underline{w}, \underline{z}) = 2^{-\sup\{k < 0 : w_k \neq z_k\}}$

Boules  $B \subset \mathcal{A}^{-\mathbb{N}}$  est une boule (ouverte et fermée) si

$$B = \left\{ \underline{z}s : \underline{z} \in \mathcal{A}^{-\mathbb{N}} \right\} \text{ pour un certain } s \in \mathcal{A}^*$$


Arbres, racines  $B = \mathcal{T}(s)$ ,  $s = \mathcal{R}(B)$

Noyau  $P : \mathcal{A}^{-\mathbb{N}} \rightarrow \mathfrak{M}_1(\mathcal{A})$ , on note  $P(a|\underline{w}) = P(\underline{w})(a)$ .

Continu comme application de  $(\mathcal{A}^{-\mathbb{N}}, \delta)$  dans  $(\mathfrak{M}_1(\mathcal{A}), d_{TV})$ .

Oscillation de  $P$  sur la boule  $\mathcal{T}(s)$

$$\eta(s) = \sup \left\{ |P(\cdot|\underline{w}) - P(\cdot|\underline{z})|_{TV} : \underline{w}, \underline{z} \in \mathcal{T}(s) \right\}.$$



# Processus

**Processus** stationnaire  $(X_t)_{t \in \mathbb{Z}}$  de loi  $\mathbb{P}$  sur  $\mathcal{A}^{\mathbb{Z}}$  est dit *compatible* avec le noyau  $P$  si ce dernier est une version régulière de ses lois conditionnelles au passé :

$$\mathbb{P}(X_i = a | X_{i+j} = w_j, j \in -\mathbb{N}^*) = P(a | \underline{w})$$

pour tout  $i \in \mathbb{Z}$ ,  $a \in \mathcal{A}$  et pour  $\nu$ -presque tout  $\underline{w}$ .

**Problème 1** : étant donné un noyau  $P$ , **existe-t-il** un processus compatible avec lui ? Est-il unique ?

**Problème 2** : puis-je alors **simuler** des trajectoires  $(X_t)_{1 \leq t \leq n}$  ?

$\implies$  [Comets, Fernandez, Ferrari '02] **oui aux deux questions ensemble** si le module de continuité de  $P$

$$\sup\{\eta(s) : s \in \mathcal{A}^{-k}\}$$

décroît assez vite vers 0 quand  $k$  tend vers l'infini et sous des hypothèses de **régénération** assez fortes - en particulier  $\eta(\epsilon) > 0$ .

## Chaînes de Markov d'ordre variable

Arbre complet de suffixes (CSD) = ensemble  $T \subset A^*$  qui définit une partition de  $\mathcal{A}$ :

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

Source à arbre de context = processus compatible avec un noyau  $P_T$  constant sur chaque boule associée aux feuilles d'un CSD  $T$

$T$  fini = chaîne de Markov d'ordre  $\text{prof}(T)$

Vraisemblance comme 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'algorithme de Propp-Wilson pour les chaînes de Markov

**Objectif** : simulation d'une variable  $X_0$  suivant la loi stationnaire  $\pi$  d'une chaîne de Markov de noyau  $Q : \mathcal{A} \rightarrow \mathfrak{M}_1(\mathcal{A})$ .


**Chaîne auxiliaire** :  $(F_t)_{t \geq 0}$  à valeur dans  $\mathcal{A}^{\mathcal{A}}$  donné par  $F_0 = \text{id}$  et

$$F_{t+1} = F_t \circ f_t$$

où les  $f_t$  sont i.i.d. de loi  $P(f_t(a) = b) = Q(a; b)$ .

**Temps d'attente** :  $\tau = \inf \{t \geq 1 : F_t \text{ constante}\}$

**Sortie** : si  $\text{Im}(F_\tau) = \{X_0\}$ , alors  $X_0 \sim \pi$



$\mathbb{E}[\tau] \approx$  temps de mélange de la chaîne

## Extension au cas des chaînes à mémoire variable [G.]

**Objectif** : simulation d'un morceau de trajectoire  $X_{1:n}$  sous la loi stationnaire  $\nu$  d'un processus compatible avec le noyau  $P : \mathcal{A}^{-\mathbb{N}} \rightarrow \mathfrak{M}_1(\mathcal{A})$ .

**Chaîne auxiliaire**  $(F_t)_{t \geq 0}$  à valeur dans  $\mathcal{A}^{\mathcal{A}^{-\mathbb{N}}}$  donné par  $F_0 = \text{id}$  et

$$F_{t+1} = F_t \circ f_t$$

où les  $f_t$  sont i.i.d. de loi  $P(f_t(\underline{w}) = b) = P(\underline{w}; b)$ .

**Temps d'attente** :  $\tau = \inf \{t \geq 1 : \Pi^n \circ F_t \text{ constante}\}$  où  $\Pi^n(\underline{w}) = w_{-n:-1}$ .

**Idée** : par *couplage*, on se ramène à un système dynamique sur l'ensemble des arbres étiquetés

**Intérêt** : couplage plus rapide que CFF, efficace même pour les noyaux de Markov d'ordre  $k$

# Plan de l'exposé

- 1 Arbres de contextes et mémoire variable
  - Noyaux, processus et simulation exacte
  - Estimation
- 2 Quelques inégalités auto-normalisées
- 3 Apprentissage par renforcements
  - Problèmes de bandits classique
  - Extensions du modèle

# Algorithme Context


- Introduit par Rissanen en 1981, même principe que 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

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

comme noeuds internes  
de  $\hat{T}_C$ .



# Maximum de vraisemblance pénalisée

- On choisit

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

où  $\text{pen}(n, T)$  = fonction de pénalité croissante en  $n$  et  $|T|$ .


- Pénalité BIC

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

- Interprétation Minimum Description Length: choisit le modèle qui donne la plus courte description des données (= qui permet de mieux les compresser)

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.

# Comparaison des deux estimateurs

[G. & Leonardi '11]

- ■ 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.

# 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

- [Rissanen '81, Bühlmann&Wyner '99. . .] pour un arbre fini  $T_0$ , si  $\epsilon(n) = C \log(n)/n$ , alors quand  $n \rightarrow \infty$ :

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

- [Csiszár & Talata '06, G. '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.

- Quelques résultats non asymptotiques :  
[Galves, Maume-Deschamps&Schmitt '05, Leonardi '08. . .]  
avec hypothèses plus ou moins plaisantes

# Estimation conjointe de deux sources partiellement partagées

- $X = (X_n)_{n \in \mathbb{Z}}$  et  $Y = (Y_n)_{n \in \mathbb{Z}}$  sont des CTS indépendantes de noyaux respectifs  $P_X$  et  $P_Y$
- $P_X$  et  $P_Y$  **partagent certains contextes** et certaines lois conditionnelles, mais pas toutes
- Motivation : Linguistique (portugais européen vs brésilien)
- 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 pénalisé

- La vraisemblance jointe s'écrit:


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

- [Galves, G. & Gassiat]
  - estimation jointe par maximum de vraisemblance pénalisée
  - procédure récursive “à la Context Tree Maximization”
  - consistance pour une pénalité de type BIC

# Exemple de résultats

100 répétitions, échantillons de taille  $n_x = n_y = 400$

- $\tau_X$  est bien estimé avec  $X$  seul 96 fois, et avec notre algo 80 fois : la performance est donc dégradée.
- mais  $\tau_Y$  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.



## Etude non asymptotique [G. & Leonardi '11]

- Pour l'algorithme Context on doit contrôler

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

- Pour le maximum de vraisemblance pénalisée, il faut majorer

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

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

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

- Des inégalités de déviations pour


$$W_t = N_t(s) KL\left(\hat{P}_t(\cdot|s); P(\cdot|s)\right)$$

permettent de se passer d'hypothèses "intrinsèquement inutiles" du genre  $\forall a \in \mathcal{A}, P(a|s) = 0$  ou  $P(s; a) > \epsilon$ .

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

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

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



# Plan de l'exposé

- 1 Arbres de contextes et mémoire variable
  - Noyaux, processus et simulation exacte
  - Estimation
- 2 Quelques inégalités auto-normalisées
- 3 Apprentissage par renforcements
  - Problèmes de bandits classique
  - Extensions du modèle

# Hypothèses

**Processus**  $(S_t)_{t \geq 0}$  réel temps discret tq  $S_0 = 0$  adapté à  $(\mathcal{F}_t)_{t \geq 0}$

**Incréments**  $X_t = S_t - S_{t-1}$  dominés : il existe une fonction  $\phi : ]\lambda_1, \lambda_2[ \rightarrow \mathbb{R}$  telle que pour tout  $\lambda \in ]\lambda_1, \lambda_2[$  et pour  $t \geq 1$ ,

$$\mathbb{E}[\exp(\lambda X_t) | \mathcal{F}_{t-1}] \leq \exp(\phi(\lambda))$$

où  $\phi$  est convexe  $C^\infty(] \lambda_1, \lambda_2[)$ ,  $\phi'(\mu) = 0$ ,

**Transformée de Fenchel-Legendre**  $I(\cdot; \mu)$  définie par

$$I(x; \mu) = \sup_{\lambda \in \mathbb{R}} \{ \lambda x - \phi(\lambda) \} ;$$

convexe,  $C^\infty$  sur  $\mathcal{D}_I$  contenant 0, tq  $I(\mu, \mu) = 0$ , et  $\forall x, I(x) < \infty \implies \exists \lambda(x) \in ]\lambda_1, \lambda_2[$  tq

$$\phi'(\lambda(x)) = x \quad \text{et} \quad I(x; \mu) = \lambda(x)x - \phi(\lambda(x))$$


**Cas sous-gaussien**  $\phi(\lambda) = \sigma^2 \lambda^2 / 2$ , cf. aussi [De La Peña & al. '04]

# Déviations et borne de Chernoff

$$\mathbb{E} [\exp (\lambda S_t - t\phi(\lambda))] \leq 1$$

si  $\bar{X}_t = S_t/t$ , et  $x_t \geq \mu$ , donne  
pour  $\lambda = \lambda(x_t)$  :

$$P(\bar{X}_t \geq x_t) \leq \exp(-tI(x_t; \mu))$$



Autre formulation :

$$P(I(\bar{X}_t; \mu) \geq I(x_t; \mu), \bar{X}_t \geq \mu) \leq \exp(-tI(x_t; \mu))$$

soit, en posant  $\delta = tI(x_t; \mu)$ ,

$$P(tI(\bar{X}_t; \mu) \geq \delta, \bar{X}_t \geq \mu) \leq \exp(-\delta)$$

Intervalles de confiance de risque  $\alpha$  :  $I$ -voisinage de  $\bar{X}_t$


$$[a_t, b_t] = \left\{ \mu : tI(\bar{X}_t; \mu) \leq \log \frac{2}{\alpha} \right\}$$

# Déviations et borne de Chernoff

$$\mathbb{E} [\exp (\lambda S_t - t\phi(\lambda))] \leq 1$$

si  $\bar{X}_t = S_t/t$ , et  $x_t \geq \mu$ , donne  
pour  $\lambda = \lambda(x_t)$  :

$$P(\bar{X}_t \geq x_t) \leq \exp(-tI(x_t; \mu))$$



Autre formulation :

$$P(I(\bar{X}_t; \mu) \geq I(x_t; \mu), \bar{X}_t \geq \mu) \leq \exp(-tI(x_t; \mu))$$

soit, en posant  $\delta = tI(x_t; \mu)$ ,

$$P(tI(\bar{X}_t; \mu) \geq \delta, \bar{X}_t \geq \mu) \leq \exp(-\delta)$$

Intervalles de confiance de risque  $\alpha$  :  $I$ -voisinage de  $\bar{X}_t$

$$[a_t, b_t] = \left\{ \mu : tI(\bar{X}_t; \mu) \leq \log \frac{2}{\alpha} \right\}$$

## Théorèmes [G. &amp; Leonardi '11]

## Borne générale

Pour tout  $\delta > 0$ ,

$$P(\exists t \in \{1, \dots, n\} : tI(\bar{X}_t; \mu) \geq \delta) \leq 2e^{\lceil \delta \log(n) \rceil} e^{-\delta}$$

## Cas log-concave

Si  $I(\cdot; \mu)$  est log-concave,

$$P(\exists t \in \{1, \dots, n\} : tI(\bar{X}_t; \mu) \geq \delta) \leq 2\sqrt{e} \left\lceil \frac{\sqrt{\delta}}{2} \log(n) \right\rceil e^{-\delta}$$

## Schéma de preuve

- Si  $t_k = \lfloor (1 + \eta)^k \rfloor$  et  $D = \lceil \log(n) / \log(1 + \eta) \rceil$ ,

$$P \left( \bigcup_{t=1}^n \{tI(\bar{X}_t; \mu) \geq \delta\} \right) \leq \sum_{k=1}^D P \left( \bigcup_{t=t_{k-1}+1}^{t_k} \{tI(\bar{X}_t; \mu) \geq \delta\} \right)$$

- Si  $\lambda_k$  tq  $I(x_{t_k}; \mu) = \lambda_k x_{t_k} - \phi(\lambda_k)$ , pour  $t_{k-1} < t \leq t_k$  :

$$tI(\bar{X}_t; \mu) \geq \delta \text{ et } \bar{X}_t \geq \mu \implies W_t^k \geq \exp \left( \frac{\delta}{1 + \eta} \right)$$

où  $W_t^k = \exp(\lambda_k S_t - t\phi(\lambda_k))$  est une sur-martingale

- Or par l'inégalité maximale

$$P \left( \bigcup_{t=t_{k-1}+1}^{t_k} \left\{ W_t^k \geq \exp \left( \frac{\delta}{1 + \eta} \right) \right\} \right) \leq \exp \left( -\frac{\delta}{1 + \eta} \right)$$

- On conclut en choisissant  $\eta = 1/(\delta - 1)$

## Version auto-normalisée pour observation optionnelle

Pour tout  $t \in \{1, \dots, n\}$ , supposons que  $\varepsilon_t \in \{0, 1\}$  soit  $\mathcal{F}_{t-1}$ -mesurables et telle que l'estimée courante au temps  $n$  de la moyenne soit

$$\bar{X}(n) = \frac{S(n)}{N(n)}, \quad \text{où } S(n) = \sum_{t=1}^n \varepsilon_t X_t \quad \text{et } N(n) = \sum_{t=1}^n \varepsilon_t$$

## Borne générale : version auto-normalisée

Pour tout  $\delta > 0$ ,

$$P \left( I(\bar{X}(n); \mu) \geq \frac{\delta}{N(n)} \right) \leq 2e^{\lceil \delta \log(n) \rceil} e^{-\delta}$$

## Observations non stationnaires [G. &amp; Moulines '11]

- $(X_t)_t$  indépendantes et bornées par  $B$ , d'espérances  $\mu_t$  ne variant pas trop vite (ou pas trop souvent).
- Estimateur escompté : pour  $\gamma \in ]0, 1[$ ,

$$\bar{X}_\gamma(n) = S_\gamma(n)/N_\gamma(n)$$

où  $S_\gamma(n) = \sum_{t=1}^n \gamma^{n-t} \varepsilon_t X_t$  et  $N_\gamma(n) = \sum_{t=1}^n \gamma^{n-t} \varepsilon_t$

- Décomposition biais-variance : si  $M_\gamma(n) = \sum_{t=1}^n \gamma^{n-t} \varepsilon_t \mu_t$ ,

$$\bar{X}_\gamma(n) - \mu_n = \underbrace{\bar{X}_\gamma(n) - \frac{M_\gamma(n)}{N_\gamma(n)}}_{\text{}} + \frac{M_\gamma(n)}{N_\gamma(n)} - \mu_n$$

- Contrôle du terme de variance : pour tout  $\eta > 0$ ,

$$P \left( \frac{S_\gamma(n) - M_\gamma(n)}{\sqrt{N_{\gamma^2}(n)}} \geq \delta \right) \leq \left\lceil \frac{\log \nu_\gamma(n)}{\log(1 + \eta)} \right\rceil \exp \left( -\frac{2\delta^2}{B^2} \left( 1 - \frac{\eta^2}{16} \right) \right)$$

où  $\nu_\gamma(n) = \sum_{t=1}^n \gamma^{n-t} < \min\{(1 - \gamma)^{-1}, n\}$ .

## Modèle exponentiel canonique [G. &amp; Cappé '11]

Modèle  $P_{\theta_0} \in \{P_{\theta} : \theta \in \Theta\}$ , où  $P_{\theta}$  admet la densité

$$p_{\theta}(x) = \exp(x\theta - b(\theta) + c(x)) .$$

et a pour espérance  $\mu(\theta) = \dot{b}(\theta)$

## Divergence

$$\text{KL}(P_{\beta}; P_{\theta}) = I(\mu(\beta); \mu(\theta)) = b(\theta) - b(\beta) - \dot{b}(\beta)(\theta - \beta)$$

Exemple 1 loi de Poisson :  $I(x, y) = y - x + x \log \frac{x}{y}$

Exemple 2 loi bornée  $X_t \in [0, 1]$  :

$$I(x, y) = \text{kl}(x, y) = x \log \frac{x}{y} + (1-x) \log \frac{1-x}{1-y} \geq 2(x-y)^2$$

## Intervalles de confiance

$$\begin{aligned} & \left\{ \theta \in \Theta : N(n) \text{KL} \left( P_{\mu^{-1}(\bar{X}(n))}; P_{\theta} \right) \leq \delta \right\} \\ & = \left\{ \theta \in \Theta : I(\bar{X}(n); \mu(\theta)) \leq \frac{\delta}{N(n)} \right\} . \end{aligned}$$

## Lois multinomiales [G. &amp; Leonardi '11]

Lemme: réduction aux lois de Bernoulli

Si  $P, Q \in \mathfrak{M}_1(\mathcal{A})$ ,

$$\text{KL}(P; Q) \leq \sum_{x \in \mathcal{A}} \text{kl}(P(x); Q(x))$$

Corollaire: Voisines KL pour multinomiales

Si  $X_1, \dots, X_n \sim P_0 \in \mathfrak{M}_1(\mathcal{A})$  iid, et  $\hat{P}_t(k) = \sum_{s=1}^t \mathbb{1}\{X_s = k\}/t$ 



$$P \left( \exists t \in \{1, \dots, n\} : \text{KL}(\hat{P}_t; P_0) \geq \frac{\delta}{t} \right) \\ \leq 2e (\delta \log(n) + |\mathcal{A}|) \exp \left( -\frac{\delta}{|\mathcal{A}|} \right)$$

## KL-balls [Filippi, G. & Cappé '10]

Suite  $(R_t)_{t \leq n}$  de régions de confiance “de type Sanov” pour  $P_0$  simultanément valides avec probabilité  $1 - \alpha$  en choisissant des voisinages de Kullback-Leibler du maximum de vraisemblance :

$$R_t = \left\{ Q \in \mathfrak{M}_1(\mathcal{A}) : \text{KL}(\hat{P}_t; Q) \leq \frac{\delta}{t} \right\},$$


avec  $\delta$  tel que  $2e(\delta \log(n) + |\mathcal{A}|) \exp(-\delta/|\mathcal{A}|) = \alpha$ .



# Plan de l'exposé

- 1 Arbres de contextes et mémoire variable
  - Noyaux, processus et simulation exacte
  - Estimation
- 2 Quelques inégalités auto-normalisées
- 3 Apprentissage par renforcements
  - Problèmes de bandits classique
  - Extensions du modèle

# Apprentissage par renforcement



dilemme  
exploration  
|  
exploitation

RL  $\neq$  apprentissage classique (notion de récompense)

RL  $\neq$  théorie des jeux (environnement indifférent)

# Essais cliniques séquentiels

On considère le cas de figure suivant :

- des patients atteints d'une certaine maladie sont diagnostiqués au fil du temps
- on dispose de plusieurs traitements mal dont l'efficacité est a priori inconnue
- on traite chaque patient avec un traitement, et on observe le résultat (binaire)
- *objectif* : soigner un maximum de patients (et pas connaître précisément l'efficacité de chaque traitement)

# Le "problème de bandits multibras"

**Environment** : ensemble de bras  $\mathcal{A}$ ; le choix du bras  $a \in \mathcal{A}$  à l'instant  $t$  donne la récompense

$$X_t = X_{a,t} \sim P_a \in \mathfrak{M}_1(\mathbb{R})$$

et la famille  $(X_{a,t})_{a \in \mathcal{A}, t \geq 1}$  est indépendante

**Règle d'allocation dynamique** :  $\pi = (\pi_1, \pi_2, \dots)$  telle que

$$A_t = \pi_t(X_1, \dots, X_{t-1})$$

**Nombre de tirages du bras**  $a \in \mathcal{A}$  à l'instant  $t \in \mathbb{N}$  :

$$N_a(t) = \sum_{s \leq t} \mathbb{1}\{A_s = a\}$$

## Performance, regret

- Récompense cumulée :  $S_n = X_1 + \dots + X_n$ ,  $n \geq 1$
- Objectif: choisir  $\pi$  de manière à maximiser

$$\begin{aligned} E[S_n] &= \sum_{t=1}^n \sum_{a \in \mathcal{A}} \mathbb{E}[\mathbb{E}[X_t \mathbb{1}\{A_t = a\} | X_1, \dots, X_{t-1}]] \\ &= \sum_{a \in \mathcal{A}} \mu_a \mathbb{E}[N_a(n)] \end{aligned}$$

où  $\mu_a = E[P_a]$

- Objectif équivalent : minimiser le *regret*

$$R_n = n\theta^* - E[S_n] = \sum_{a: \mu_a < \mu^*} (\mu^* - \mu_a) \mathbb{E}[N_a(n)]$$

où  $\mu^* = \max \{ \mu_a : a \in \mathcal{A} \}$

# Principe d'optimisme


Algorithmes **optimistes** : [Lai&Robins '85; Agrawal '95]

*Fais comme si tu te trouvais dans l'environnement qui t'est le plus favorable parmi tous ceux qui rendent les observations suffisamment vraisemblables*

De façon plutôt inattendue, les méthodes optimistes se révèlent pertinentes dans des cadres très différentes, efficaces, robustes et simples à mettre en oeuvre

## Stratégies "Upper Confidence Bound" [Auer&al '02; Audibert&al '07]

UCB (Upper Confidence Bound)  
 = établir une borne supérieure de  
 l'intérêt de chaque action, et choisir  
 celle qui est la plus prometteuse



- **Avantage** : comportement facilement interprétable et "acceptable"


⇒ le regret grandit comme  $C \log(n)$

où  $C$  dépend des  $P_a, a \in \mathcal{A}$

- *Politique d'indice* : on calcule un indice par bras et on choisit celui qui est le plus élevé, cf. [Gittins '79]

## Stratégies "Upper Confidence Bound" [Auer&al '02; Audibert&al '07]

UCB (Upper Confidence Bound)  
 = établir une borne supérieure de  
 l'intérêt de chaque action, et choisir  
 celle qui est la plus prometteuse




- **Avantage** : comportement facilement interprétable et "acceptable"

⇒ le regret grandit comme  $C \log(n)$


où  $C$  dépend des  $P_a, a \in \mathcal{A}$

- *Politique d'indice* : on calcule un indice par bras et on choisit celui qui est le plus élevé, cf. [Gittins '79]

## UCB en action



## UCB en action



# KL-UCB [Cappé, G., Maillard, Munos, & Stoltz]

Soit  $\hat{P}_a(t) \in \mathfrak{M}_1(\mathbb{R})$  la mesure empirique des observations du bras  $a$  à l'instant  $t$  :

$$\hat{P}_a(t) = \frac{1}{N_a(t)} \sum_{s \leq t: A_s = a} \delta_{X_{a,t}}$$

Soit  $\mathcal{F} \subset \mathfrak{M}_1(\mathbb{R})$  une classe de loi de probabilités, et soit  $\Pi : \mathfrak{M}_1(\mathbb{R}) \rightarrow \mathcal{F}$ . L'algorithme KL-UCB sur consiste à choisir

$$A_{t+1} = \arg \max_{a \in \mathcal{A}} U_a(t)$$

avec

$$U_a(t) = \max \left\{ E[P] : P \in \mathcal{F}, \text{KL} \left( \Pi_{\mathcal{F}} \left( \hat{P}_a(t) \right), P \right) \leq \frac{f(t)}{N_a(t)} \right\}$$

où, typiquement,  $f(t) \approx \log(t)$ .

# Borne de regret

Pour borner le nombre  $N_a(n)$  de tirages du bras sous-optimal  $a \in \mathcal{A}$ , on écrit pour tout  $t \leq n$  où il a été tiré :

Décomposition :

$$\{A_{t+1} = a\} \subset \{U_{a^*}(t) < \mu^*\} \cup \{U_a(t) \geq \mu^*\}$$

Premier terme : contrôlé par les inégalités auto-normalisées car

$$U_{a^*}(t) < \mu^* \implies \text{KL}\left(\Pi_{\mathcal{F}}\left(\hat{P}_{a^*}(t)\right), P_{a^*}\right) > \frac{f(t)}{N_{a^*}(t)}$$

Deuxième terme : implique avec grande proba que  $N_a(t)$  est petit car  $E[P_a] < \mu^*$ ,

# Exemple paramétrique : famille exponentielle canonique

Modèle  $\mathcal{F} = P_{\theta_0} \in \{P_{\theta} : \theta \in \Theta\}$ , où  $P_{\theta}$  admet la densité

$$p_{\theta}(x) = \exp(x\theta - b(\theta) + c(x)) .$$

et a pour espérance  $\mu(\theta) = \dot{b}(\theta)$

Projection  $\Pi_{\mathcal{F}}(Q) = P_{\mu^{-1}(E[Q])}$

Divergence

$$\text{KL}(P_{\beta}; P_{\theta}) = I(\mu(\beta); \mu(\theta)) = b(\theta) - b(\beta) - \dot{b}(\beta)(\theta - \beta)$$

Indice

$$U_a(t) = \max \left\{ \mu : I(\bar{X}_a(t); \mu) \leq \frac{f(t)}{N_a(t)} \right\}$$

Alternative bayésienne [Kaufmann, Cappé & Garivier] : quantiles des lois a posteriori

# Application : récompenses bornées [G. Cappé '11]

## Borne de regret

Pour tout  $\epsilon > 0$ , il existe  $C_1, C_2(\epsilon)$  et  $\beta(\epsilon)$  telles que pour n'importe que bras sous-optimal  $a$ , sous la politique KL-UCB,

$$\mathbb{E}[N_n(a)] \leq \frac{\log(n)}{\text{kl}(\mu_a, \mu^*)} (1 + \epsilon) + C_1 \log(\log(n)) + \frac{C_2(\epsilon)}{n^{\beta(\epsilon)}}$$

- kl-UCB meilleur qu'UCB pour le même cadre d'applications
- *asymptotiquement optimal* pour les variables de Bernoulli : cf borne inférieure de Lai&Robbins, Burnetas&Katehakis : dans le modèle  $\mathcal{F}$

$$N_a(n) \geq \left( \frac{1}{\inf_{P \in \mathcal{F}: E[P] > \mu^*} \text{KL}(P_a, P)} + o(1) \right) \log(n),$$

## Autre choix pour les récompenses bornées

Quand  $\text{Var}[P_a] \ll \mu_a(1 - \mu_a)$ , la borne de confiance utilisée est pessimiste.


**Estimation totalement non paramétrique** :  $\mathcal{F} = \mathfrak{M}_1([0, 1])$  et  $\Pi_{\mathcal{F}} = id$ .

$$U_a(t) = \max \left\{ E[P] : P \in \mathcal{F}, \text{KL}(\hat{P}_a(t), P) \leq \frac{f(t)}{N_a(t)} \right\}$$

- problème d'optimisation numériquement simple
- l'idée "intermédiaire" d'estimer la variance n'est pas facile à mettre en oeuvre efficacement, cf Bernstein et UCB-V :

$$U_a(t) = \bar{X}_a(t) + \sqrt{\frac{2\hat{V}_a(t) \log(t)}{N_a(t)}} + \frac{3 \log(t)}{N_a(t)}$$


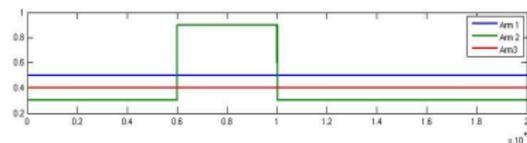
## Comparatif sur un exemple



$P_a = \mathcal{P}\left(\frac{1}{2} + \frac{a}{3}\right)$  pour  $1 \leq a \leq 6$  bras, tronquée à 10.

# Bandits non stationnaires [G. Moulines '11]

- **Changepoint** : les distributions des récompenses *variant brutalement*
- **Objectif** : *poursuivre le meilleur bras*
- **Application** : scanner à effet tunnel
- On étudie alors D-UCB et SW-UCB, variantes qui incluent un *oubli* (progressif) du passé
- On montre des bornes de regret en  $O(\sqrt{n \log n})$ , qui sont (presque) optimales



# Bandits linéaires / linéaires généralisés [Filippi, Cappé, G. & Szepesvári '10]

- Modèle de bandit avec information contextuelle :

$$\mathbb{E}[X_t|A_t] = \mu(m'_{A_t}\theta_*)$$

où  $\theta_* \in \mathbb{R}^d$  désigne un paramètre inconnu et où  $\mu : \mathbb{R} \rightarrow \mathbb{R}$  est la fonction de lien dans un modèle linéaire généralisé


- Exemple : pour des récompenses binaires

$$\mu(x) = \frac{\exp(x)}{1 + \exp(x)}$$

- Application : publicité ciblée sur internet
- GLM-UCB : borne de regret dépendant de  $d$  et pas du nombre d'actions possibles

# Optimisation stochastique [G. & Stoltz]

- Objectif : trouver le maximum (ou les quantiles) d'une fonction  $f : C \subset \mathbb{R}^d \rightarrow \mathbb{R}$  observée dans du bruit (ou pas)
- Application en cours : thèse de Marjorie Jalla sur l'exposition aux ondes électro-magnétiques (indice DAS = SAR)



- Modélisation :  $f$  est la réalisation d'un processus Gaussien, ou alors fonction de faible norme dans le RKHS associé au noyau de ce processus
- GP-UCB : évaluer  $f$  au point  $x \in C$  pour lequel l'intervalle de confiance pour  $f(x)$  est le plus haut

# Processus de Décision Markoviens

Le système est dans un état  $S_t$  qui évolue de façon markovienne :



$$S_{t+1} \sim P(\cdot; S_t, A_t) \text{ et } R_t = r(S_t, A_t) + \epsilon_t$$

Meilleur modèle pour les communications numériques, mais aussi pour :

- la robotique
- la commande d'une batterie d'ascenseurs
- le routage de paquets sur internet
- l'ordonnancement de tâches
- la maintenance de machines
- les jeux
- le contrôle des réseaux sociaux
- le yield management
- la prévision de charge...

# Optimisme pour les MDP [Filippi, Cappé & G. '10]

Le paradigme optimiste conduit à la recherche d'une matrice de transition "la plus avantageuse" dans un voisinage de son estimateur de maximum de vraisemblance.



L'utilisation de voisinages de Kullback-Leibler, autorisée par des inégalités de déviations semblables à celles montrées plus haut, conduisent à des algorithmes plus efficaces ayant de meilleures propriétés

# Exploration avec experts probabilistes

Espace de recherche :  $B \subset \Omega$  discret

Experts probabilistes :  $P_a \in \mathfrak{M}_1(\Omega)$  pour  $a \in \mathcal{A}$

Requêtes : à l'instant  $t$ , l'appel à l'expert  $A_t$  donne une réalisation  $X_t = X_{A_t,t}$  indépendante de  $P_a$

Objectif : trouver un maximum d'éléments distincts dans  $B$  en un minimum de requêtes :

$$F_n = \text{Card} (B \cap \{X_1, \dots, X_n\})$$

≠ bandit : trouver deux fois le même élément ne sert à rien !

Oracle : joue l'expert qui a la plus grande "masse manquante"

$$A_{t+1}^* = \arg \max_{a \in \mathcal{A}} P_a (B \setminus \{X_1, \dots, X_t\})$$

## Estimation de la masse manquante

- Notations :
- $X_t \stackrel{iid}{\sim} P \in \mathfrak{M}_1(\Omega)$ ,  $O_n(\omega) = \sum_{t=1}^n \mathbb{1}\{X_t = \omega\}$
  - $Z_n(x) = \mathbb{1}\{O_n(\omega) = 0\}$
  - $H_n(\omega) = \mathbb{1}\{O_n(\omega) = 1\}$ ,  $H_n = \sum_{\omega \in B} H_n(\omega)$

Problème : estimer la masse manquante

$$R_n = \sum_{\omega \in B} P(\omega) Z_n(\omega)$$

Good-Turing : “estimateur”  $\hat{R}_n = H_n/n$  tq  $\mathbb{E}[\hat{R}_n - R_n] \in [0, 1/n]$ .

Concentration : par l'inégalité de McDiarmid, avec proba  $1 - \delta$

$$\left| \hat{R}_n - E[\hat{R}_n] \right| \leq \sqrt{\frac{(2/n + p_{\max})^2 n \log(2/\delta)}{2}}$$

# L'algorithme Good-UCB [Bubeck, Ernst & G.]

Algorithme optimiste basé sur l'estimateur de Good-Turing :

$$A_{t+1} = \arg \max_{a \in \mathcal{A}} \left\{ \frac{H_a(t)}{N_a(t)} + c \sqrt{\frac{\log(t)}{N_a(t)}} \right\}$$

- $N_a(t)$  = nombre de tirages de  $P_a$  jusqu'à l'instant  $t$
- $H_a(t)$  = nombre d'éléments de  $B$  vus une seule fois (en tout) grâce à  $P_a$
- $c$  = constante à régler pour garantir l'estimation simultanée correcte avec grande probabilité

# Good-UCB en action

# Optimalité macroscopique

Hypothèses :

- $\Omega = \mathcal{A} \times \{1, \dots, N\}$
- $\forall a \in \mathcal{A}, \forall j \in \{1, \dots, N\}, P_a(\{(a, j)\}) = 1/N$





Limite macroscopique :

- $N \rightarrow \infty$
- $\forall a \in \mathcal{A}, \text{Card}(B \cap \{a\} \times \{1, \dots, N\}) / N \rightarrow q_a \in ]0, 1[$

## Optimalité macroscopique

Quand  $N$  tend vers l'infini, la performance de Good-UCB au cours du processus de découverte  $t \mapsto F([Nt])$  converge uniformément vers celle de l'oracle  $t \mapsto F^*([Nt])$  sur  $\mathbb{R}^+$ .

# Illustration numérique



Nombre d'objets intéressants trouvés par Good-UCB (trait plein), l'oracle (pointillés épais), et par échantillonnage uniforme (pointillé léger) en fonction du temps pour des tailles  $N = 128$ ,  $N = 500$ ,  $N = 1000$  et  $N = 10000$ , dans un environnement à 7 experts. ▶