



## Sur un théorème de limite conditionnelle

Adnan Aboulalaa

### ► To cite this version:

| Adnan Aboulalaa. Sur un théorème de limite conditionnelle. [Rapport de recherche] RR-2389, INRIA. 1994. inria-00074286

HAL Id: inria-00074286

<https://inria.hal.science/inria-00074286>

Submitted on 24 May 2006

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

INSTITUT NATIONAL DE RECHERCHE EN INFORMATIQUE ET EN AUTOMATIQUE

*Sur un théorème de limite conditionnelle.  
Application aux systèmes de capacités finies*

Adnan Aboulalaâ

N° 2389

Novembre 1994

PROGRAMME 1

Architectures parallèles,  
bases de données,  
réseaux et systèmes distribués





# Sur un théorème de limite conditionnelle. Application aux systèmes de capacités finies

Adnan Aboulalaâ\*

Programme 1 — Architectures parallèles, bases de données, réseaux  
et systèmes distribués

Projet MISTRAL

Rapport de recherche n° 2389 — Novembre 1994 — 28 pages

**Résumé :** Étant donné  $N$  copies indépendantes  $X_t^1, \dots, X_t^N$  d'un processus de sauts à valeurs dans un espace d'états fini, on étudie l'évolution d'un processus type conditionnellement à un événement du type  $\{1/N \sum_{i=1}^N f(X_t^i) \in U \subset R^k, \forall t \in [0, T]\}$  lorsque  $N$  tend vers l'infini (en fait on considérera des événements qui sont proches de ce dernier). Il s'agit d'une extension au cas du temps mobile du 'principe de conditionnement de Gibbs'. Ce principe est appliqué à l'étude d'un système disposant de  $k$  types de ressources, en quantités finies, partagées par  $N$  clients.

**Mots-clé :** Loi limite conditionnelle, grandes déviations, information de Kullback, physique statistique, processus de sauts contraints, systèmes à capacités finies.

(*Abstract: pto*)

\*. École Polytechnique et ENST. E-mail: aboulala@enst.fr

# On a conditional limit theorem and application to loss systems

**Abstract:** Consider  $N$  independant copies  $X_t^1, \dots, X_t^N$  of a Markov jump processes with finite state space, we study the limiting behavior of a typical process, say  $X_t^1$ , given a condition like  $\{1/N \sum_{i=1}^N f(X_t^i) \in U \subset R^k, \forall t \in [0, T]\}$  (in fact we will consider conditions which are close to the last one). This is a process version of a resulat which is called the Gibbs conditioning principle. This principle is applied to the analysis of a system which has several kinds of ressources shared by  $N$  traffic sources.

AMS 1991 Subject Classification: 60B12, 60F10, 60J75, 60K25

**Key-words:** Conditional limit law, large deviations, Kullback information, statistical physics, jump processes with constraints, loss systems.

# 1 Introduction

Le problème du conditionnement auquel on s'intéresse ici se pose de la manière suivante: on se donne une suite de variables i.i.d  $(X^i)_{i \in \mathbb{N}}$  à valeurs dans un espace  $\mathcal{S}$ , le plus général possible. Chaque  $X^i$  peut être vue comme représentant l'état d'une particule ( $i$ ) d'un gaz. On cherche alors la loi d'une de ces variables sous une contrainte du type

$$C(N, U) := \left\{ \frac{1}{N} \sum_{i=1}^N f(X^i) \in U \right\}$$

où  $f : \mathcal{S} \rightarrow V$ , ( $V$  espace localement convexe en général).  $f(X^i)$  peut s'interpréter comme l'énergie de la particule  $i$  et la condition correspond à une contrainte sur l'énergie globale du système. Autrement dit la question est de connaître la loi conditionnelle par rapport à  $C(N, U)$  de  $X^1$  (lorsque  $N$  tend vers l'infini). Ce problème a été traité par Vasicek (1980) [15] et Van Campenhout et Cover (1981) [14] dans des cas particuliers, puis par Csiszár (1984)[4] dans une grande généralité. Le résultat est que cette loi conditionnelle limite est obtenue en maximisant une certaine entropie (-l'information de Kullback d'une probabilité par rapport à la loi commune des  $X^i$ ) sur un ensemble de mesures adéquat. Le grand principe de maximisation d'entropie en physique statistique, ou en d'autres domaines, y trouve ainsi un certain<sup>1</sup> fondement.

Cependant les problèmes en temps mobile n'ont apparemment pas été considérés dans le passé. Le plus simple se pose de la manière suivante: les  $X^i \equiv X_t^i, t \in [0, T]$  sont des processus markoviens de sauts à espace d'états fini  $\Sigma$  indépendants et identiquement distribués et l'on s'intéresse au comportement de  $X_t^1, t \in [0, T]$  conditionnellement à un événement du type

$$C(N, U) = \left\{ \frac{1}{N} \sum_{i=1}^N f(X_t^i) \in U \quad \forall t \in [0, T] \right\}, f : \Sigma \rightarrow \mathbb{R}^k, k \geq 1$$

lorsque  $N$  devient grand; ( $U$  est un sous ensemble convenable de  $\mathbb{R}^k$  et  $T > 0$  est fixé). Ce problème est motivé par l'étude d'un modèle de système de communication( cf. *infra*); il a également la même interprétation en terme de physique statistique que celle décrite ci-dessus. Un des objectifs de ce travail est d'apporter des éléments de réponse à cette question.

Le résultat concernant la loi limite conditionnelle en temps fixe est connu sous le nom de principe de conditionnement de Gibbs. Il a trouvé des applications dans des domaines variés (traitement d'images, conception VLSI...). On en propose une dans le domaine des systèmes de communication.

\*\*

---

1. Il s'agit du cas particulier de la distribution microcanonique, voir aussi Stroock-Zeitouni(91)[13].

Les modèles classiques des systèmes tels que les réseaux de communication, e.g. les modèles de Jackson ou de Kelly, permettent d'obtenir le régime stationnaire -probabilité invariante d'un processus de Markov représentant l'état du système- sous une forme explicite. Cependant le calcul effectif et direct de cette probabilité stationnaire n'est possible que pour les 'petits' systèmes(nombre faible de noeuds et de liaisons), à cause de la compléxité combinatoire des formules.

Ce problème de compléxité se retrouve en des termes pareils en physique statistique où l'on cherche également la distribution de probabilité des états d'équilibre qui peuvent donner lieu là aussi à des problèmes de combinatoire pour calculer la fonction de partition. Vu ces analogies et les succès remportés par la physique statistique, il est assez naturel d'examiner l'éventuelle utilité des méthodes de la physique statistique dans l'étude des grands systèmes de communication. Un des premiers travaux allant dans ce sens (et qui en a inspiré d'autres par la suite cf. e.g. [7],[11],[12]) est celui de Beneš [1]. Il décrit les états du système par un ensemble  $S$  dont les éléments  $x$  représentent les ressources occupées à un instant donné en chaque 'point' du réseau. Alors en désignant par  $|x|$  la sommes de toutes les ressources occupées(ou le nombre total des appels en cours) lorsque le réseau est dans l'état  $x$ , et par  $q_x$  la probabilité d'un tel état, la distribution "d'équilibre" sur  $S$  est obtenue en maximisant l'entropie

$$H(q) = - \sum_{x \in S} q_x \log q_x$$

sous la contrainte que le trafic moyen dans le réseau est fixé:

$$\sum_{x \in S} |x| q_x = m$$

Moyenant ces postulats la distribution d'équilibre est donnée par

$$q_x = \frac{\lambda^{|x|}}{\Phi(\lambda)}, \quad \Phi(\xi) = \sum_{x \in S} \xi^{|x|}, \quad m = \lambda \frac{d \log \Phi(\lambda)}{d \lambda}$$

Et comme en physique statistique ou dans le modèle de Kelly le problème du calcul de la fonction de partition se retrouve dans ce cas cf. [1] pour plus de détails.

Le modèle que l'on propose ici est basé sur l'idée suivante: une manière d'évaluer les performances (ou les pertes ) dans un système de capacité finie est de comparer le comportement 'libre' des utilisateurs i.e. lorsque le système a une capacité infinie et le comportement conditionnel de ceux ci par rapport à la contrainte de capacité finie. Malgré quelques analogies entre ce modèle et celui de Beneš (on s'intéresse notamment au comportement macroscopique du système en faisant abstraction de sa topologie), ceux ci sont différents, outre du fait que les idées de base ne sont pas les mêmes, pour les raisons

suivantes:

- Le réseau n'est pas décrit par des variables représentant ses différents états, on s'intéresse plutôt au comportement des utilisateurs .
- On prend en compte effectivement la contrainte de limitation des ressources qui est réelle alors que V.Beneš prend comme contrainte un trafic moyen constant.
- la technique de maximisation d'entropie qui apparaît comme un principe dans la théorie de Benes, se retrouve dans le problème qu'on traitera comme un résultat (mais dans un contexte différent).

Enfin on peut dire, très schématiquement, que la démarche de V.Beneš correspond à l'ensemble canonique de la physique statistique alors que le modèle que l'on présente correspond à l'ensemble microcanonique (au sens de [13]).

★★

Le présent travail est organisé comme suit. Au §2. on présente le modèle adopté qui fait le lien entre la question du conditionnement et l'évaluation des performances des systèmes de capacités finies. Ceci est illustré par l'exemple des réseaux hiérarchiques. Le §3. est consacré aux "problèmes à temps fixe" où les v.a.  $X^i$  sont à valeurs dans un ensemble fini . On y rappelle le résultat sur la loi conditionnelle limite de  $X^1$  et on indique d'autres résultats de convergence. Ceux ci sont ensuite appliqués à l'exemple des systèmes hiérarchiques. Au §4. on étudie les problèmes à temps mobile : les  $X^i$  sont cette fois des fonctions aléatoires et l'on s'intéresse à la loi conditionnelle limite de  $X_t^1, t \in [0, T]$  sous une contrainte sur 'l'énergie moyenne' à chaque instant. Ce cas est bien entendu plus intéressant mais en contrepartie les résultats correspondant sont peu explicites. On traite d'abord le cas des chaînes de Markov §4.1 qui permet de deviner la forme de la loi conditionnelle limite éventuelle dans le cas temps continu; ce dernier cas est traité en modifiant légèrement la forme de l'événement  $C(N, U)$ , §4.2; on donnera les caractéristiques du processus  $X_t^1$  sous cette loi limite.

## 2 Le modèle

### 2.1 Modèle et problèmes

On considère un système qui possède  $k$  types de ressources et auquel peuvent accéder  $N$  clients. Ces ressources sont limitées en nombre de  $L_1, \dots, L_k$  unités respectivement.

Si les ressources étaient infinies un client évoluerait de manière aléatoire, identique (aux) et indépendante (des) autres utilisateurs, dans un espace d'état fini  $\Sigma = \{e_0, \dots, e_d\}$ . On suppose aussi que l'on dispose d'une fonction  $f : \Sigma \rightarrow \mathbb{R}^k$  qui à chaque état associe les quantités utilisées de chaque ressources. Le comportement réel des utilisateurs est

donné par leur comportement *a priori* conditionné par le fait que les ressources utilisées à chaque instant ne peuvent pas dépasser, en quantité, les ressources disponibles. On se pose alors les problèmes suivants :

### 2.1.1 Problèmes à temps fixe

On suppose que les utilisateurs sont représentés par des variables i.i.d.  $X^1, \dots, X^N$  à valeurs dans  $\Sigma$  et définies sur un espace de probabilité  $(\Omega, \mathcal{A}, \mathbb{P})$ . On pose

$$\mathbb{P}(X^i = e_h) = \mu_h$$

La condition de limitation des ressources s'écrit

$$\sum_{i=1}^N f(X^i) \in U_0, \quad U_0 = \prod_{j=1}^k [0, L_j] \subset \mathbb{R}^k$$

Le comportement réel des utilisateurs est donné par

$$\nu_h^N := \mathbb{P}(X^i = e_h \mid \sum_{i=1}^N f(X^i) \in U_0)$$

En particulier l'espérance de la quantité de ressources que demandent les utilisateurs est

$$E(\sum_{i=1}^N f(X^i)) = N \sum_{h=0}^N \mu_h f(e_h)$$

(on a même  $1/N \sum_{i=1}^N f(X^i) \rightarrow \sum_{h=0}^N \mu_h f(e_h)$   $\mathbb{P} - p.s.$ ) et l'espérance de la quantité de ressources réellement utilisée est

$$E(\sum_{i=1}^N f(X^i) \mid \sum_{i=1}^N f(X^i) \in U_0) = N \sum_{h=0}^N \nu_h^N f(e_h)$$

On établira un résultat de type convergence en probabilité(sous les contraintes)

$$\frac{1}{N} \sum_{i=1}^N f(X^i) \rightarrow \sum_{h=0}^d \nu_h f(e_h)$$

(prop. 3.1.3.) où  $\nu_h = \lim_N \nu_h^N$ , prop. 3.1.1. Donc la détermination des probabilités conditionnelles  $\nu_h$  donne des renseignements intéressants sur les performances du système. Ce cas peut s'appliquer en particulier aux problèmes des accès concurrents à un instant donné.

**Remarque 2.1.1** Dans toute la suite on posera  $L_i = Nl_i, i = 1, \dots, d$ ;  $\nu_h$  doit être vue comme une estimation asymptotique de  $\nu_h^N$  qui dépendra des  $l_i, \mu_h$ . Enfin l'événement par lequel on conditionne s'écrit désormais

$$C(N, U) = \left\{ \frac{1}{N} \sum_{i=1}^N f(X^i) \in U \right\}, \quad U = \prod_{j=1}^k [0, l_j] \subset \mathbb{R}^k$$

### 2.1.2 Problèmes à temps mobile

On fixe un intervalle de temps  $[0, T]$ . On suppose que l'évolution des utilisateurs est donnée par des processus  $X_t^1, \dots, X_t^N, t \in [0, T]$  indépendants et de même loi, dont l'espace des états est  $\Sigma$ , définis sur un même espace de probabilité  $(\Omega, \mathcal{A}, \mathbb{P})$ . Ici la condition de limitation des ressources s'écrit

$$C(N, U) = \left\{ \frac{1}{N} \sum_{i=1}^N f(X_t^i) \in U, \forall t \in [0, T] \right\} \quad U = \prod_{j=1}^k [0, l_j] \subset \mathbb{R}^k$$

et le comportement réel des utilisateurs est donné par la probabilité  $P^N$  sur  $\Omega$

$$P^N(\cdot) = \mathbb{P}(X^1 \in \cdot | C(N, U))$$

Le but étant d'obtenir des informations sur le comportement de  $X_t^1$  sous la probabilité  $P^N$  lorsque  $N$  tend vers l'infini. En ce qui concerne les ressources utilisées, le problème est le même qu'en temps fixe.

## 2.2 Exemple

- Temps mobile: On se donne un réseau hiérarchisé sur  $d$  niveaux. Par exemple le réseau téléphonique où l'on trouve les abonnés (en nombre  $N$  très grand) au niveau 0, les centres locaux au niveau 1, les centres à autonomie d'acheminement (CAA) au niveau 2, les centres de transit secondaires (CTS) au niveau 3, et enfin les centres de transit principaux (CTP).

Ici on fait abstraction de la topologie du réseau et on se donne seulement le nombre de ressources par niveau: un appel local nécessite seulement un canal disponible dans le commutateur de niveau 1, on suppose qu'il y en a  $l_1 N$  au total; un appel international nécessite l'utilisation d'un canal au niveau 1, un canal au niveau 2 etc... Bref on suppose qu'à une communication correspond un niveau  $i$  et qu'elle utilise une unité de ressource de chaque niveau  $j \leq i$ . Soit  $Nl_1, \dots, Nl_d$  les quantités globales de ressources de chaque niveau dont dispose le réseau.

Un abonné  $i$  disposant de toutes les ressources qu'il faut est représenté par un processus de sauts  $X_t^i$  à espaces d'états  $\Sigma = \{e_0, \dots, e_d\}$ ; ces processus sont indépendants et de même loi. Il occupe l'état de repos  $e_0$  (où il ne communique pas) pendant une durée  $\tau_0$  puis passe à l'état  $e_h, h \geq 1$  (l'abonné est en communication et utilise simultanément une unité de ressources des niveaux  $1, \dots, h$ ) où il reste une durée  $\tau_h$  puis revient à  $e_0$ ; ces durées sont des v.a. exponentielles ... On prend alors comme générateur de  $X_t^i$ :

$$A(e_0, e_h) = \alpha_h, \quad h \geq 1$$

$$A(e_h, e_0) = \beta_h, \quad h \geq 1$$

$$A(e_h, e_k) = 0 \text{ si } h \neq k \text{ dans les autres cas}$$

La contrainte de limitation des ressources à chaque niveau s'écrit :

$$\left\{ \begin{array}{l} \sum_1^N 1_{X_t^i = e_d} \leq Nl_d \\ \sum_1^N 1_{X_t^i \in \{e_{d-1}, e_d\}} \leq Nl_{d-1} \\ \dots \\ \sum_1^N 1_{X_t^i \in \{e_1, \dots, e_d\}} \leq Nl_1 \end{array} \right. \quad (1)$$

pour tout  $t \in [0, \infty[$  pour des raisons techniques on prendra plutôt  $\forall t \in [0, T], T < \infty$   
cf. §4. L'événement  $C(N, U)$  traduisant le fait que ces contraintes sont satisfaites s'écrit

$$C(N, U) = \left\{ \frac{1}{N} \sum_{i=1}^N f(X^i) \in U \forall t \in [0, T] \right\}, \quad U = \prod_0^d [0, l_i], \quad f : \Sigma \longrightarrow R^d$$

$$f(e_0) = (0, \dots, 0), f(e_1) = (1, 0, \dots, 0), f(e_2) = (1, 1, 0, \dots, 0), \dots, f(e_d) = (1, \dots, 1)$$

Notons que l'on a déjà

$$P(X_t^i = e_0 | C(N, U)) \geq P(X_t^i = e_0)$$

(vérification facile). Comme il se doit la probabilité pour qu'un abonné soit dans l'état de repos conditionnellement aux contraintes est plus grande que celle correspondant à des ressources infinies.

**Remarque 2.2.1** Une modélisation standard de la situation est la suivante. On considère  $d$  organes de services  $S_1, \dots, S_d$  (qui représentent les ressources des  $d$  niveaux). Le  $i$ -ème organe a une capacité de  $C_i$  serveurs. À l'entrée de  $S_1$  il y a des  $d$  type de flux d'arrivées poissonniennes d'intensités  $\lambda_1, \dots, \lambda_d$ . Lorsqu'un client de type  $k$  arrive à  $S_1$ , soit il trouve des serveurs libres simultanément dans  $S_1, \dots, S_k$  et alors il occupe un serveur de chaque niveau  $i, i \leq k$  pendant une durée v.a. exponentielle de paramètre  $\mu_k$  puis les libère ensuite, soit il trouve qu'un organe de service  $S_i, i \leq k$  est saturé et dans ce cas il est éjecté du système.

L'état du système peut alors être représenté par un  $(Y_t^1, \dots, Y_t^d) \in \mathbb{N}^d$  où  $Y_t^i$  est le nombre de client dans  $S_i$  à l'instant  $t$ . C'est un processus de sauts dont le générateur est donné par :

$$\left\{ \begin{array}{l} A((x_1, \dots, x_k, \dots, x_d), (x_1 + 1, \dots, x_k + 1, x_{k+1}, \dots)) = \lambda_k \text{ si } x_1 < C_1, \dots, x_k < C_k, \\ A((x_1, \dots, x_k, \dots, x_d), (x_1 - 1, \dots, x_k - 1, x_{k+1}, \dots)) = \mu_k x_k \text{ si } 0 < x_1 \leq C_1, \dots, 0 < x_k \leq C_k; \\ A(x, y) = 0 \text{ si } x \neq y \text{ dans les autres cas.} \end{array} \right. \quad (2)$$

Le problème serait alors de chercher la mesure invariante de ce processus.

Il faut noter que ce modèle est équivalent à celui qu'on a adopté sur le point suivant : les  $N$  processus  $X_t^i$  représentant les clients engendrent  $d$  flux d'arrivées poissonniennes avec des durées de services exponentielles. En effet si  $T_k^{i,h}$ ,  $k \in \mathbb{N}$  désignent les instants de sauts à l'état  $e_h$  de  $X_t^i$ , on obtient pour chaque  $i$  et  $h$  un processus de Poisson de paramètre  $-A(e_h, e_h)$  (puisque, pour un processus de sauts, les durées de séjour dans les états visités sont des v.a. exp. indépendantes, conditionnellement à la position de ces états). La superposition de ces instants pour les  $N$  processus donne le flux d'arrivée global de type  $h$  d'intensité  $\lambda_h = -NA(e_h, e_h)$  (les  $X^i$  sont indépendants). Par ailleurs on peut considérer que le flux des demandes qui ne seront pas rejetées correspond à l'évolution des  $X_t^i$  conditionnellement à la limitation de la capacité du système. C'est précisément à cette évolution que l'on s'intéressera.

- Temps fixe : C'est le même problème que précédemment sauf que les  $X^i$  sont simplement des v.a. à valeurs dans un ensemble fini; la condition  $C(N, U)$  est dans ce cas

$$\left\{ \begin{array}{l} \sum_1^N 1_{X^i=e_d} \leq Nl_d \\ \sum_1^N 1_{X^i \in \{e_{d-1}, e_d\}} \leq Nl_{d-1} \\ \dots \\ \sum_1^N 1_{X^i \in \{e_1, \dots, e_d\}} \leq Nl_1 \end{array} \right. \quad (3)$$

Ce problème sera traité au §3.2.

### 3 Problèmes à temps fixe

#### 3.1 Probabilités conditionnelles et convergence

Le cadre est celui du 2.1.1:  $\Sigma = \{e_0, \dots, e_d\}$ ,  $M_1(\Sigma) =$  l'ensemble des mesures de probabilité sur  $\Sigma$ . Pour une mesure  $\nu \in M_1(\Sigma)$  soit sa divergence (ou son information de Kullback) par rapport à  $\mu$

$$K(\nu|\mu) = \sum_{i=0}^d \nu_i \log \frac{\nu_i}{\mu_i}$$

et soit le sous-ensemble de  $M_1(\Sigma)$

$$\begin{aligned} \Gamma &= \{\nu \in M_1(\Sigma) : \int f d\nu \in U\} \\ &\equiv \{(\nu_0, \dots, \nu_d) \in \mathbb{R}_+^{d+1}, \sum_0^d \nu_i = 1, \sum_0^d \nu_i f(e_i) \in U\} \end{aligned} \quad (4)$$

La fonction  $K(\cdot|\mu)$  est strictement convexe sur  $\Gamma$ . Si  $U$  est un convexe fermé (ce qui est le cas au 2.1.1 et ce sera toujours le cas dans la suite)  $\Gamma$  l'est aussi (c'est même un compact) et  $K(\cdot|\mu)$  y admet un minimum unique que l'on notera  $\nu^*$ . Dans ces conditions:

**Proposition 3.1.1** *La suite des lois conditionnelles de  $X^1$  par rapport à  $C(N, U)$  soit  $\nu^N \in M_1(\Sigma)$  convergent en variation<sup>2</sup> vers  $\nu^*$  lorsque  $N$  tend vers l'infini.*

Preuve. Il s'agit d'une application immédiate du ‘principe de conditionnement de Gibbs’. cf. Dembo-Zeitouni[5] Th.3.3.3 ou Csiszár [4]  $\square$

**Remarque 3.1.2** On a par la loi des grands nombres

$$\frac{1}{N} \sum_{i=1}^N f(X_i) \longrightarrow \bar{f} := \sum_{h=0}^d \mu_h f(e_h) \text{ p.s.}$$

Donc la probabilité  $\mathbb{P}(C(N, U))$  tend vers 1 ou 0 selon que  $\bar{f}$  appartient ou non à  $U$ . Dans le premier cas on a directement  $\nu_h = \mu_h, h = 0, \dots, d$  sans utiliser le principe de Gibbs. Ce cas n'est pas très intéressant; il correspond à la situation où les ressources disponibles sont  $\geq$  aux ressources requises par les utilisateurs en moyenne.

Introduisons maintenant quelques notations. On prend  $\Omega = \Sigma^{\mathbb{N}}$ ,  $X^i : \Omega \rightarrow \Sigma$  les applications coordonnées,  $\mathcal{B}^n = \sigma(X^1, \dots, X^n)$ ; on se donne  $\mu \in M_1(\Sigma)$  et on pose  $\mathbb{P} = \mu^{\otimes \mathbb{N}} \in M_1(\Omega)$

Pour tout  $k \geq 1$  on considère  $P_n^{(k)} \in M_1(\Sigma^N, \mathcal{B}^k)$  telle que

$$P_n^{(k)}(\cdot) = \mathbb{P}(\cdot | C(n, U))|_{\mathcal{B}^k}$$

Les éléments de  $M_1(\Sigma^N, \mathcal{B}^k)$  seront identifiés aux éléments de  $M_1(\Sigma^k, \mathcal{B}^k)$ . D'après la proposition précédente, on dispose de  $P^{(1)} := \lim_{n \rightarrow \infty} P_n^{(1)}$ . Alors

**Proposition 3.1.3** 1/. Pour tout  $k$  fixé,  $X^1, \dots, X^k$  sont conditionnellement asymptotiquement indépendantes i.e.  $P_n^{(k)}(\cdot)$  converge en information (cf. §4.2) vers  $P^{(1) \otimes k}$   
2/. Pour toute application  $\phi : \Sigma \rightarrow \mathbb{R}^m, m \geq 0$  et tout fermé  $A \subset \mathbb{R}^m$  tel que  $E^{P^{(1)}}(\phi(X^1)) \notin A$  on a

$$P_n^{(n)}\left(\frac{1}{n} \sum_{i=1}^n \phi(X^i) \in A\right) \rightarrow 0$$

lorsque  $n$  tend vers l'infini, du moins si  $\inf_{x \in A} \Lambda_\mu^*(x) > 0$ ,  $\Lambda_\mu^*$  étant la transformée de Cramér associée à  $\mu$ .

---

2. Ici cela correspond tout simplement à la distance  $d(\nu, \nu') = \sup_{I \subset \Sigma} |\nu(I) - \nu'(I)| = \frac{1}{2} \sum_{e_i \in \Sigma} |\nu(e_i) - \nu'(e_i)|$

Preuve.

D'après un théorème de Csiszár [4] Th.4  $X^1, \dots, X^n$  sont “asymptotiquement quasi-indépendantes sous la condition  $C(n, U)$ ” (cf. la référence pour plus de précisions). Cela entraîne ([4] p. 772) 1/ d'une part et d'autre part que s'il existe un  $\alpha > 0$ ,  $\beta > 0$

$$\forall B_n \in \mathcal{B}^n P^{(1) \otimes n}(B_n) \leq \beta \exp(-\alpha n), n = 1, 2, \dots$$

alors

$$\lim_{n \rightarrow \infty} P_n^{(n)}(B_n) = 0$$

Or si  $A \subset \mathbb{R}^m$  est un fermé tel que  $E^{P^{(1)}}(\phi(X^1)) \notin A$ . Pour  $B_n = \{\frac{1}{n} \sum_{i=1}^n \phi(X^i) \in A\}$ , on a

$$P^{(1) \otimes n}(B_n) \leq 2 \exp(-\alpha n), n = 1, 2, \dots$$

pour  $\alpha = \inf_{x \in A} \Lambda_\mu^*(x)$  (cf. le théorème de Cramér-Chernov). 2/ s'en déduit.  $\square$

**Proposition 3.1.4** La suite  $\mathbb{P}_n(\cdot) = \mathbb{P}(\cdot | C(n, U))$  converge étroitement vers  $P^{(1) \otimes \mathbb{N}}$ .

Preuve.

On sait que les probabilités marginales de  $\mathbb{P}_n$  convergent étroitement vers celles de  $P^{(1) \otimes \mathbb{N}}$  (d'après le 1/ de la proposition précédente, la convergence en information entraînant la convergence en variation). D'autre part, en munissant  $\Sigma^{\mathbb{N}}$  de la métrique induite par la métrique usuelle de  $\mathbb{R}^{\mathbb{N}}$  (après avoir identifier  $\Sigma$  à  $\{0, 1, \dots, d\} \subset \mathbb{R}$  par exemple), c'est un compact cf. Billingsley [2] p.219. Il en résulte que la suite  $(P_n)_{n \geq 1}$  est tendue; on conclut en appliquant le théorème de Prohorov (cf.[2])  $\square$

### 3.2 Application : l'exemple des systèmes hiérarchiques

On se place dans le cadre du paragraphe 2.2 alinéa “temps fixe”. Pour calculer la probabilité conditionnelle limite, on est donc amené à résoudre le problème d'optimisation suivant

$$\left\{ \begin{array}{l} \inf_{\nu} K(\nu | \mu) = \sum_0^d \nu_h \log \frac{\nu_h}{\mu_h} \\ g(\nu) \in A \end{array} \right. \quad (5)$$

où

$$g(\nu_0, \dots, \nu_d) = \left( \sum_{h=0}^d \nu_h, \sum_{h=1}^d \nu_h, \dots, \nu_d \right)$$

$$A = \{1\} \times \{(x_1, \dots, x_d) \in R_+^d : x_i \leq l_i, i = 1, \dots, d\}$$

On peut réécrire ce problème sous la forme standard d'un problème d'optimisation convexe et on dispose de  $\lambda = (\lambda_0, \dots, \lambda_d)$ ,  $\lambda_i \geq 0$  si  $i \geq 1$  (multiplicateurs de Lagrange) tels que:

$$\begin{aligned}\nu_0^* &= \mu_0 e^{-\lambda_0 - 1} \\ \nu_i^* &= \mu_i e^{-\sum_{j=1}^i \lambda_j - 1}\end{aligned}$$

Avec

$$\lambda_i = 0 \quad \text{ou bien} \quad \sum_{j=1}^i \nu_j^* = 0 \quad i = 1, \dots, d.$$

En introduisant  $Z$  à la place de  $\lambda_0$ :

$$Z = e^{-\lambda_0 - 1}$$

("fonction de partition"), la solution vérifie:

$$\left\{ \begin{array}{l} \nu_0^* = \frac{\mu_0}{Z} \\ \nu_i^* = \frac{\mu_i}{Z} e^{-\sum_{j=1}^i \lambda_j} \\ \lambda_i = 0 \quad \text{ou bien} \quad \sum_{j=i}^d \nu_j^* = l_i \quad i = 1, \dots, d. \\ Z = \mu_0 + \sum_{i=1}^d \mu_i e^{-\sum_{j=1}^i \lambda_j} \end{array} \right. \quad (6)$$

- Intuitivement les probabilités  $\mu_i$  peuvent être interprétées comme étant les proportions des gens qui seraient en communication à un niveau  $i$  si les ressources étaient infinies; les probabilités  $\nu_i^*$  quant à elles peuvent être vues comme les proportions de gens qui sont en communication à un niveau  $i$  compte tenu des contraintes de limitation des ressources. On peut alors voir le rapport  $\nu_i^*/\mu_i \leq 1$  comme étant la proportion de gens ayant réussi à communiquer au niveau  $i$  et  $1 - \nu_i^*/\mu_i$  la proportion de gens n'ayant pas réussi à communiquer à ce niveau.

En effet, si l'on considère la fonction  $\phi_h : \Sigma \rightarrow R$   $e_i \rightarrow \delta_{hi}$  alors  $\frac{1}{n} \sum_{i=1}^n \phi_h(X^i)$  qui représente la proportion des ressources de type  $h$  utilisée tend, conditionnellement à la contrainte de limitation des ressources vers  $\nu_h^*$  au sens de la proposition 3.1.3. Ainsi la quantité  $\nu_h^*$  peut être interprétée comme la proportion des ressources de type  $h$  *effectivement* utilisée.

- Les ressources disponibles ne sont pas intégralement utilisées, bien qu'elles soient inférieures en quantité aux ressources requises. En effet elles seront utilisées dans leur intégralité si  $E^{\nu^*} f(X^1) := \sum_{h=1}^d \nu_h^* f(e_h) = (l_1, \dots, l_d)$  ce qui n'est pas vrai en général. Par contre on a  $E^{\nu^*} f(X^1) \in \partial U$ ,  $U = \prod_1^d [0, l_h]$  car  $K(\nu|\mu)$  est strictement convexe et son minimum absolu qui est atteint en  $\mu$  qui vérifie  $E^\mu(f(X^1)) \notin U$  comme on le suppose.

## 4 Problèmes à temps mobile

### 4.1 Cas des chaînes de Markov (temps discret)

Ce paragraphe peut être considéré comme une introduction heuristique au cas des processus de sauts à temps continu.

Soit  $T \in \mathbb{N}$ . Ici le temps  $t$  décrit les entiers  $\leq T$ . Soit  $X_t^i, i \in \mathbb{N}$  une suite de chaînes de Markov indépendantes de même loi (même matrice de transition  $Q$  et probabilité initiale  $\pi$ ) et dont l'espace des états est l'ensemble fini  $\Sigma = \{e_0, \dots, e_d\}$ . Ces chaînes sont définies sur un espace de probabilité  $(\Omega, \mathcal{A}, \mathbb{P})$

Soit enfin une fonction:

$$f : \Sigma \longrightarrow \mathbb{R}^k$$

et  $U$  un convexe de  $\mathbb{R}^k$ .

On considère l'événement

$$C(N, U) = \left\{ \frac{1}{N} \sum_{i=1}^N f(X_t^i) \in U, \forall t = 0, \dots, T \right\}$$

(qui représente la contrainte) et on s'intéresse à la limite de

$$P^N(\cdot) = \mathbb{P}(X \in \cdot | C(N, U))$$

lorsque  $N$  tend vers l'infini.

Dans ce cas on peut toujours appliquer le principe de Gibbs pour les mesures à support fini. Posons en effet:

$$X^i = (X_0^i, \dots, X_T^i)$$

les  $X^i$  sont alors i.i.d à valeurs dans  $\Sigma^{T+1}$  avec

$$\mathbb{P}(X^i = (x_0, \dots, x_T)) = \pi(x_0)Q(x_0, x_1)\dots Q(x_{T-1}, x_T)$$

et l'on peut écrire

$$C(N, U) = \left\{ \frac{1}{N} \sum_{i=1}^N F(X^i) \in U^{T+1} \right\}, \quad U^{T+1} \subset \mathbb{R}^{k(T+1)}$$

avec

$$F : \Sigma^k \longrightarrow \mathbb{R}^{k(T+1)} \quad F(x_0, \dots, x_T) = (f(x_0), \dots, f(x_T)), \quad x_i \in S_0$$

Notre but est d'obtenir une expression explicite de la limite de  $P^N(\cdot)$  qu'on notera  $P_T^*(\cdot)$ . La loi commune des  $X^i$  sera notée  $\mu \in M_1(\Sigma^{T+1})$ . La loi limite conditionnelle cherchée, soit  $\mu^* \in M_1(\Sigma^{T+1})$ , est donnée par

$$\mu^* = \arg \min_{\nu \in \Gamma} K(\nu | \mu)$$

$$\Gamma = \{\nu \in M_1(\Sigma^{T+1}) : \int F d\nu \in U^T \subset \mathbb{R}^{k(T+1)}\},$$

$$K(\nu|\mu) = \sum_{x \in \Sigma^{T+1}} \nu(x) \log \frac{\nu(x)}{\mu(x)}$$

Plus explicitement on a à résoudre le problème d'optimisation suivant:

$$\left\{ \begin{array}{l} \inf_{\nu \in M_1(\Sigma^{T+1})} \sum_{x_0, \dots, x_T} \nu(x_0, \dots, x_T) \log \frac{\nu(x_0, \dots, x_T)}{\mu(x_0, \dots, x_T)} \\ \sum_{x_0, \dots, x_T} f(x_0) \nu(x_0, \dots, x_T) \in U \subset \mathbb{R}^k \\ \sum_{x_0, \dots, x_T} f(x_1) \nu(x_0, \dots, x_T) \in U \subset \mathbb{R}^k \\ \quad \quad \quad \cdots \\ \sum_{x_0, \dots, x_T} f(x_T) \nu(x_0, \dots, x_T) \in U \subset \mathbb{R}^k \end{array} \right. \quad (7)$$

Ce problème d'optimisation admet une solution unique, la fonction à optimiser étant strictement convexe et le domaine est convexe. On dispose alors de multiplicateurs de Lagrange  $\lambda_0, \dots, \lambda_T \in \mathbb{R}^k$  tels que

$$\frac{\mu^*(x_0, \dots, x_T)}{\mu(x_0, \dots, x_T)} = \frac{e^{\sum_{t=0}^T \lambda_t \cdot f(x_t)}}{Z_T}$$

( $Z_T$  est un facteur de normalisation qui correspond à la contrainte  $\sum \nu(x_0, \dots, x_T) = 1$ ). En écrivant  $\mu(x_0, \dots, x_T)$  sous forme de produit des probabilités de transitions, il est facile de voir que  $\mu^*$  se factorise en un produit de probabilités de transitions  $Q_t^*(x_t, x_{t+1})$  qui dépendent donc du temps, de sorte que sous  $P_T^*, X_t^1$  est une chaîne de Markov non homogène.

**Remarque 4.1.1** On ne peut pas prendre  $T$  infini; l'événement par lequel on conditionnerait pourrait être de probabilité nulle. Une condition suffisante pour que les événements de type  $C(N, U)$  soient non négligeables est que  $f(X_t^1)$  reste dans  $U$  pour  $t = 0, \dots, T$  avec une probabilité non nulle; ce qui est vrai dans le cas typique où  $U = \prod_{h=1}^k [0, l_h]$  et  $f(e_0) = 0$

## 4.2 Cas des processus de sauts (temps continu)

On se donne cette fois un intervalle  $[0, T] \subset \mathbb{R}$  et une suite de processus markoviens de sauts  $X_t^i, t \in [0, T], i = 1, \dots$ , dont l'espace des états  $\Sigma = \{e_0, \dots, e_d\}$  est fini, définis sur un espace de probabilité  $(\Omega, \mathcal{A}, \mathbb{P})$ . On suppose que ces processus sont indépendants et

ont la même loi (générateur  $A$  et loi initiale  $\pi$ ). Comme au paragraphe précédent, on se donne un convexe  $U \subset \mathbb{R}^k$  et une application  $f : \Sigma \rightarrow \mathbb{R}^k$ , et on considère l'événement

$$C_0(N, U) = \left\{ \frac{1}{N} \sum_{i=1}^N f(X_t^i) \in U, \forall t \in [0, T] \right\}$$

On s'intéresse alors à la limite de

$$P^N(\cdot) = \mathbb{P}(X^1 \in \cdot | C_0(N, U))$$

lorsque  $N$  tend vers l'infini. Dans la suite on notera  $P_X$  la loi commune des  $X^i$  sous  $\mathbb{P}$ .

**Remarque 4.2.1** Ici encore on ne peut pas prendre  $T$  infini. En revanche une condition suffisante pour que  $C(N, U)$  soit non négligeable est  $P(f(X_t^1) \in U \forall t \in [0, T]) \neq 0$ . En particulier s'il existe un état  $e_i$  tel que  $f(e_i) \in U$  cette condition est réalisée puisque  $X_t^1$  reste  $= e_i$  pour tout  $t \in [0, T]$  avec une probabilité non nulle. On se placera dans ce cas dans toute la suite.

D'après l'expression de la probabilité limite pour les chaînes de Markov, on peut s'attendre à ce que cette limite en temps continu soit donnée par une formule du type

$$P^*(X^1 \in dx_\cdot) = \frac{e^{\int_0^T \lambda_t \cdot f(x_t) dt}}{Z} P_X(X^1 \in dx_\cdot)$$

Rappelons d'abord une définition. Soit  $P_n$  une suite de probabilités sur un espace  $(\mathcal{S}, \mathcal{B})$ . On dit que  $P_n$  converge en information (ou au sens de Csiszár) vers une probabilité  $Q \in M_1(\mathcal{S})$  si  $K(P_n|Q) \rightarrow 0$ . Avec

$$K(P|Q) = \int_{\mathcal{S}} \log \frac{dP}{dQ} dP \text{ si } P \ll Q, \text{ et } \infty \text{ sinon.}$$

Cette convergence entraîne la convergence en variation de  $P_n$  vers  $Q$ , et on a même (cf. [4]):

$$|P - Q| \leq \sqrt{2K(P, Q)} \quad \forall P, Q \in M_1(\mathcal{S})$$

On a alors le résultat général suivant sur les lois conditionnelles limites (cf. [4] Th.4.):

**Théorème 4.2.2 (Csiszár)** Soit  $\Psi$  une application mesurable d'un ensemble (mesurable)  $(S, \mathcal{S})$  vers un espace vectoriel topologique localement convexe (e.v.t.l.c.)  $V$ . Soient  $X^1, X^2, \dots$  une suite i.i.d de v.a. à valeur dans  $S$  de loi commune  $P_X$  et  $Q$  la probabilité

image de  $P_X$  par  $\Psi$ ;  $Q$  est supposée “convexe-tendue”<sup>3</sup>.

Alors pour tout  $C \subset V$ , convexe dont l'intérieur a une intersection non vide avec le support de  $Q$  la suite des probabilités conditionnelles

$$P_X^N(\cdot) = P(X^1 \in \cdot | \frac{1}{N} \sum_{i=1}^N \Psi(X^i) \in C)$$

converge en information vers la mesure de probabilité  $P^*$  définie par

$$\frac{dP^*}{dP_X}(\cdot) = \frac{1}{Z} \exp \mathcal{V}^*(\Psi(\cdot))$$

avec

$$\mathcal{V}^* = \arg \max_{v \in V'} [\inf_{v \in C} \mathcal{V}(v) - \text{Log} E^Q(\exp(\mathcal{V}(\cdot)))]$$

(ce maximum étant atteint)

Bien que ce résultat soit très général, les conditions imposées à  $C$  et à  $Q$  constituent des obstructions importantes à son utilisation dans le cas qui nous intéresse. On se place dans le cadre de ce théorème en prenant

$$S = \{\omega : [0, T] \longrightarrow \Sigma \text{ constante par morceaux}\}$$

$$\Psi : S \longrightarrow V \quad \Psi(\omega)(t) = f(\omega(t)), \quad C = \{\phi \in V : \phi(t) \in U \ \forall t \in [0, T]\}$$

où  $V$  est un e.v.t.l.c  $\subset (\mathbb{R}^k)^{[0, T]}$  à préciser. Les choix de  $V$  que l'on considère ici tournent autour des espaces  $L_{([0, T], R^k)}^p$ . Ils ont l'avantage d'avoir des espaces duals bien connus. Cependant, si on adopte  $V = L_{([0, T], R^k)}^p$  avec  $p < \infty$ , l'intérieur des ensembles  $C$  du type ci-dessus serait vide. D'autre part si on prenait  $V = L_{([0, T], R^k)}^\infty$ , il est facile de voir que la loi image  $Q$  du processus  $X_t^1$  n'est pas séparable (i.e. son support n'est pas séparable pour la topologie considérée) et donc non tendue<sup>4</sup> (cf. Billingsley[2] Appendice III). La solution retenue pour l'instant consiste à travailler sur un espace  $L^p$ , en modifiant légèrement la forme des contraintes  $C_0(N, U)$  par lesquelles on conditionne : on parlera de contraintes de type  $L^p$ ; étant entendu que notre problème initial est celui des contraintes de type  $L^\infty$ .

Pour simplifier la présentation, on se placera désormais dans le cas  $k = 1, T = 1$  avec  $U$  de la forme  $[0, E]$ ; la fonction  $f$  est généralement positive (à valeurs dans  $\mathbb{R}_+^k$  pour  $k \geq 1$ ): elle donne les quantités de ressources utilisées pour chaque état  $e_i$  ou l'énergie en physique statistique. L'hypothèse de l'existence d'un  $e_i \in \Sigma$  tel que  $f(e_i) \in U$  se traduit ici par  $f(e_i) \leq E$ . La traduction des résultats lorsque  $k > 1$  et  $U$  est un convexe de  $\mathbb{R}^k$  ne pose pas de difficulté.

---

3. i.e. il existe une suite d'ensembles  $K_1 \subset K_2, \dots$  convexes et compacts tels que  $\lim_{n \rightarrow \infty} Q(K_n) = 1$ . C'est toujours vrai si  $V$  est un espace de Banach séparable.

4. si  $Q$  était tendue on aurait  $\text{supp } Q \subset \bigcup K_n$  où  $K_n$  sont des compacts. Dans ce cas les  $K_n$  seraient séparables car ce sont des espaces compacts metrisables et donc  $\text{supp } Q$  le serait aussi.

#### 4.2.1 Cas des contraintes de type $L^p$ , $p < \infty$ .

Posons :

$$C(N, p) = \left\{ \frac{1}{N} \sum_{i=1}^N f \circ X^i \in B_p(E) \right\}$$

où  $B_p(E)$  est la boule fermée de rayon  $E$  de  $L_{([0,1], \mathbb{R})}^p$ . Notons que  $B_p(E) \subset B_{p'}(E)$  si  $p' \leq p$  (inégalité de Hölder), et donc  $C(N, p) \subset C(N, p')$  si  $p' \leq p$ . Remarquons aussi que  $C_0(N, U) = C(N, \infty)$  et il est facile de voir que  $\bigcap_p C(p, N) = C(N, \infty)$ . D'autre part on a

$$\forall \epsilon > 0 \exists p \in \mathbb{N} \forall \phi \in B_p(E) \exists I_\epsilon \subset [0, 1] : dt(I_\epsilon) < \epsilon, \phi(t) \leq E \forall t \in [0, 1] - I_\epsilon$$

(vérification facile). Ces considérations montrent que le fait de conditionner par des événements  $C(p, N)$  avec  $p$  suffisamment grand donnerait une idée sur la loi limite conditionnelle qu'on cherchait au départ (si elle existe). Pour  $p \in \mathbb{N}$  posons alors

$$P_p^N(\cdot) = \mathbb{P}(X^1 \in \cdot | C(N, p))$$

**Proposition 4.2.3** 1. La suite des probabilités  $P_p^N$  converge en information vers une probabilité  $P_p^*$  donnée par :

$$\frac{dP_p^*}{dP_X}(\omega) = \frac{e^{\int_0^1 f(\omega(t))\lambda_p(t)dt}}{Z_p}, Z_p = E^{P_X}(e^{\int_0^1 f(X_t^1)\lambda_p(t)dt}) \quad (8)$$

où  $\lambda_p \in L^q([0, 1])$ ,  $(1/p + 1/q = 1)$  est l'unique solution du problème d'optimisation suivant :

$$\lambda_p = \arg \max_{\lambda \in L^q([0, 1])} \left[ \inf_{\phi \in B_p(E)} \int_0^1 \phi(t)\lambda(t)dt - \log E^{P_X}(\exp(\int_0^1 f(X_t^1)\lambda(t)dt)) \right] \quad (9)$$

2. Le processus  $X_t^1$ ,  $t \in [0, T]$  est markovien (non homogène) sous la probabilité  $P_p^*$ .

Preuve.

1. La première partie est une application du théorème de Csiszár avec ici  $V = L_{([0,1])}^p$  qui est un espace de Banach séparable,  $C = B_p(E)$  dont l'intérieur a une intersection non vide avec le support de la loi image de  $X^1$  par  $\Psi$  si on suppose qu'il existe un  $e_i \in \Sigma$  :  $f(e_i) \leq E$  par exemple. Les conditions du théorème sont vérifiées dans ce cas.

2. Rappelons que si  $P$  et  $Q$  sont deux probabilités sur un même espace  $(\Omega, \mathcal{A})$  telles que  $dQ/dP = M$  alors pour toute sous tribu  $\mathcal{B}$  de  $\mathcal{A}$  et toute v.a.  $\Phi$  on a

$$E^Q(\Phi|\mathcal{B}) = \frac{E^P(\Phi M|\mathcal{B})}{E^P(M|\mathcal{B})} \quad (10)$$

Pour  $t \in [0, T]$  désignons par  $\mathcal{F}_{\leq t} = \sigma(X_s^1, s \leq t)$ ,  $\mathcal{F}_{\geq t} = \sigma(X_s^1, s \geq t)$  et posons

$$M_T(x.) = \frac{e^{\int_0^T f(x_s) \lambda_p(s) ds}}{Z_p}, \quad M_{\leq t}(x.) = e^{\int_0^t f(x_s) \lambda_p(s) ds}, \quad M_{\geq t}(x.) = e^{\int_t^T f(x_s) \lambda_p(s) ds}$$

Soit  $Y_{\leq t}, Y_{\geq t}$  deux variables aléatoires mesurables par rapport à  $\mathcal{F}_{\leq t}$  et  $\mathcal{F}_{\geq t}$  respectivement. Alors en désignant par  $E(\cdot)$  et  $E^*(\cdot)$  les espérances par rapport aux probabilités  $P_X$  et  $P_X^*$  respectivement, on a grâce à la formule rappelée ci-dessus (remarquer qu'on a simplifier par  $Z_p$  dans la deuxième égalité)

$$E^*(Y_{\leq t} Y_{\geq t} | X_t^1) = \frac{E(Y_{\leq t} Y_{\geq t} M_T | X_t^1)}{E(M_T | X_t)} \quad (11)$$

$$= \frac{E(Y_{\leq t} Y_{\geq t} M_{\leq t} M_{\geq t} | X_t^1)}{E(M_{\leq t} M_{\geq t} | X_t^1)} \quad (12)$$

et puisque  $X_t^1$  est markovien sous  $P_X$  et compte tenu de ce que  $M_{\leq t}$  et  $M_{\geq t}$  sont mesurables resp. par rapport  $\mathcal{F}_{\leq t}$  et  $\mathcal{F}_{\geq t}$ , cette dernière quantité est

$$= \frac{E(Y_{\leq t} M_{\leq t} | X_t^1) E(M_{\geq t} Y_{\geq t} | X_t^1)}{E(M_{\leq t} | X_t^1) E(M_{\geq t}^1 | X_t^1)} \quad (13)$$

$$= \frac{E(Y_{\leq t} M_{\leq t} | X_t^1) E(M_{\geq t} | X_t^1)}{E(M_{\leq t} | X_t^1) E(M_{\geq t} | X_t^1)} \frac{E(Y_{\geq t} M_{\geq t} | X_t^1) E(M_{\leq t} | X_t^1)}{E(M_{\geq t} | X_t^1) E(M_{\leq t} | X_t^1)} \quad (14)$$

$$= \frac{E(Y_{\leq t} M_T | X_t^1)}{E(M_T | X_t^1)} \frac{E(Y_{\geq t} M_T | X_t^1)}{E(M_T | X_t^1)} \quad (15)$$

où dans le dernier passage on a utilisé encore une fois la propriété markovienne de  $X_t^1$  sous  $P_X$  et divisé les numérateurs et dénominateurs des deux fractions par  $Z_p$ .

On applique une deuxième fois 10 et l'on obtient

$$E^*(Y_{\leq t} Y_{\geq t} | X_t^1) = E^*(Y_{\leq t} | X_t^1) E^*(Y_{\geq t} | X_t^1) \square$$

Dans la suite de ce paragraphe on fixe  $p$  et on pose  $V_p = L_{([0, T])}^p$ ,  $P^* := P_p^*$ ,  $\lambda := \lambda_p$

**Proposition 4.2.4** *Si  $f$  est à valeurs dans  $\mathbb{R}_+$  (ce qui est le cas aussi bien pour l'application qui nous intéresse qu'en physique statistique) alors*

$$\lambda(t) \leq 0 \text{ } dt - p.p. \text{ sur } [0, T]$$

La signification physique de cette proposition est claire : la probabilité d'une trajectoire est d'autant plus faible que les états occupés dans cette trajectoire ont des énergies élevées.

Preuve.

Pour  $\beta \in V'_p$  notons

$$H(\beta) = \inf_{\phi \in C} \int_0^T \phi(t)\beta(t)dt - \text{Log}E^{P_X} \exp \int_0^T f(X^1(t)\beta(t)dt$$

où  $C = B_p(E)$ . Par définition on a

$$\lambda = \arg \max_{\beta \in V'_p} H(\beta)$$

On va montrer que  $\forall \beta \in V'_p$  il existe  $\beta_1 \in V'_p$  négative telle que  $H(\beta_1) \geq H(\beta)$ . Soit donc  $\beta \in V'_p$  et soit  $\text{supp}_\beta^-$  (resp.  $\text{supp}_\beta^+$ ) le plus grand sous ensemble de  $[0, T]$  sur lequel  $\beta$  est négative (resp. positive) i.e.  $\forall \phi \in V_p \text{ supp}(\phi) \subset \text{supp}_\beta^- \implies \beta(\phi) \leq 0$  (resp.  $\forall \phi \in V_p \text{ supp}(\phi) \subset \text{supp}_\beta^+ \implies \beta(\phi) \geq 0$ ). Soit  $\beta_1 \in V'_p$  définie par

$$\int_0^T \phi(t)\beta_1(t)dt = \int_0^T 1_{\text{supp}_\beta^-} \phi(t)\beta(t)dt - \int_0^T 1_{\text{supp}_\beta^+} \phi(t)\beta(t)dt.$$

Il est clair que  $\beta_1$  est négative. Alors

$$\inf_{\phi \in C} \int_0^T \phi(t)\beta(t)dt = \inf_{\phi \in C} \int_0^T \phi(t)\beta_1(t)dt \quad (16)$$

En effet,  $\forall \phi \in C$  il existe  $\phi_1 \in C$  définie par  $\phi_1(t) = \phi(t)$  si  $t \in \text{supp}_\beta^-$  et  $\phi_1(t) = -\phi(t)$  si  $t \in \text{supp}_\beta^+$  telle que

$$\int_0^T \phi(t)\beta(t)dt = \int_0^T \phi_1(t)\beta_1(t)dt.$$

D'autre part compte tenu de ce que  $f$  est positive on a

$$\text{Log}E^{P_X} \exp \int_0^T f(X_t^1)\beta(t)dt \geq \text{Log}E^{P_X} \exp \int_0^T f(X_t^1)\beta_1(t)dt \quad (17)$$

16 et 17 entraînent bien que  $H(\beta_1) \geq H(\beta)$ .  $\square$

### •Semi-groupe et générateurs de $X_t^1$ sous $P^*$

Les démonstrations des deux propositions qui suivent sont données en Appendice.

**Proposition 4.2.5** *Les générateur  $A_t^*$  du processus  $X_t^1$  sous  $P_X^*$  sont donnés par*

$$A_t^*(x, y) = A(x, y) \frac{E(e^{\int_t^T f(X_s^1)\lambda(s)ds} | X_t^1 = y)}{E(e^{\int_t^T f(X_s^1)\lambda(s)ds} | X_t^1 = x)} \text{ pour } x \neq y$$

- Semi-groupe de  $X_t^1$  sous  $P^*$ : Il suffit de calculer les probabilités  $P^*(X_t^1 = x)$ . On a

$$\begin{aligned}
P^*(X_t = x) &= \frac{E(1_{X_t=x} e^{\int_0^T \lambda(s).f(X_s)ds})}{E(e^{\int_0^T \lambda(s).f(X_s)ds})} \\
&= \frac{E(e^{\int_0^T \lambda(s).f(X_s)dt} | X_t = x) P_X(X_s = x)}{E(e^{\int_0^T \lambda(s).f(X_s)ds})} \\
&= \frac{E(e^{\int_0^t \lambda(s).f(X_s)ds} | X_t = x) E(e^{\int_t^T \lambda(s).f(X_s)ds} | X_t = x)}{E(e^{\int_0^T \lambda(s).f(X_s)ds})} \times P_X(X_t = x)
\end{aligned} \tag{18}$$

La proposition suivante fournit un moyen pour le calcul des termes intervenant dans l'expression du semi-groupe ou des générateurs.

**Proposition 4.2.6** En tout point  $t \in [0, T]$  où  $\lambda$  est continue, les fonctions  $h_x(t) = E^{P_X}(e^{\int_t^T f(X_s^1)\lambda(s)ds} | X_t^1 = x)$  et  $k_x(t) := E^{P_X}(e^{\int_0^t f(X_s^1)\lambda(s)ds} | X_t^1 = x)$  satisfont les équations suivantes :

$$\begin{aligned}
\frac{dh_x(t)}{dt} &= -f(x).\lambda(t)h_x(t) - \sum_y A(x, y)h_y(t) \\
\frac{dk_x(t)}{dt} &= \left(-\frac{P'(t, x)}{P(t, x)} - \lambda(t).f(x)\right)k_x(t) + \frac{1}{P(t, x)} \sum_y A(y, x)P(t, y)k_y(t)
\end{aligned}$$

avec  $P(t, x) = P_X(X_t^1 = x)$ .

Enfin la (moyenne de la) quantité des ressources réellement utilisées à un instant  $t \in [0, T]$  est donnée par

$$E^*(f(X_t^1)) = \sum_{h=0}^d f(e_h)P^*(X_t^1 = e_h)$$

#### 4.2.2 Quelques remarques sur le cas des contraintes $L^\infty$

Ici on suppose que  $f$  est à valeurs positives. On prend  $E = 1$  (il suffit de poser  $f := f/E$ ) et on suppose qu'il existe  $e_i \in \Sigma$  tel que  $f(e_i) < E = 1$ . On notera aussi  $V = L_{([0,1], \mathbb{R})}^\infty$  et  $B_1$  la boule fermé unité de  $V$  et  $V_p = L_{([0,1], \mathbb{R})}^p$ .

**Remarque 4.2.7** Pour tout  $p$  fixé  $P_p^n$  converge en variation vers  $P_p^* \in M_1(S)$  lorsque  $n$  tend vers l'infini. D'autre part puisque  $\bigcap_p C(n, p) = C(n, U)$ , on a la convergence en variation de  $P_p^n$  vers  $P^n$  lorsque  $p \rightarrow \infty$  pour tout  $n$  fixé. Compte tenu de ce que  $M_1(S)$  est complet pour la distance variationnelle (cf. Neveu[9]), si on arrive à montrer que l'une des convergences est uniforme, on conclura à l'existence de la limite de  $P^n$  qu'on cherchait au départ (théorème de la double limite). La question reste ouverte.

Si la limite de  $P^n(.) = \mathbb{P}(.|C(n, U))$  existe (ce qui est parfaitement plausible), d'après la proposition 4.2.3 on peut s'attendre à ce qu'elle soit donnée par une formule du type 8 :

$$\frac{dP^*}{dP_X}(\omega) = \frac{e^{\int_0^1 f(\omega(t))d\lambda(t)}}{Z}$$

où  $\lambda \in V'$  (mesure de Radon) est donnée par

$$\lambda = \arg \max_{\alpha \in V'} H(\alpha) = [\inf_{\phi \in B_1} \int_0^1 \phi(t)d\alpha(t) - \text{Log}E e^{\int_0^1 f(X_t)d\alpha(t)}]$$

Les éléments de  $V'$  s'expriment sous la forme d'une intégrale (de Radon, cf. Dunford-Schwartz[6] ou Yosida[16]):  $\alpha(\phi) = \int_0^1 \phi(t)d\alpha(t)$ ,  $\phi \in V$ ; elles s'identifient aux mesures sur  $[0, 1]$  (additives seulement!) et absolument continues par rapport à la mesure de Lebesgue; on notera aussi  $\alpha(I) := \int_0^1 1_I d\alpha(t)$  pour un borélien  $I \subset [0, 1]$ . On a alors le résultat suivant:

**Remarque 4.2.8** *La fonctionnelle*

$$J(\alpha) = -H(\alpha) = -\inf_{\phi \in B_1} \int_0^1 \phi(t)d\alpha(t) + \text{Log}E e^{\int_0^1 f(X_t)d\alpha(t)}$$

admet un minimum unique sur  $V'$ .

Preuve.

$J$  est définie sur  $V'$  qui sera muni de la topologie faible usuelle.

• Existence:

(i)  $J$  est semi-continue inférieurement (s.c.i.): en effet on a d'une part  $\alpha \rightarrow -\int_0^1 \phi(t)d\alpha(t)$  est continue pour toute  $\phi \in V$ , ce qui entraîne que  $\alpha \rightarrow \sup_{\phi \in V} -\int_0^1 \phi(t)d\alpha(t)$  est s.c.i. (l'enveloppe supérieure d'une famille de fonctions continues est s.c.i.). D'autre part il faut noter que  $\inf_{\alpha \in V'} J(\alpha) = \inf_{\alpha \in K} J(\alpha)$  où  $K$  est l'ensemble des formes linéaires continues sur  $V$  qui sont négatives i.e.  $\alpha(\phi) \leq 0$  si  $\phi \geq 0$  (cf. la proposition 4.3.2 dont la vérification s'applique également au cas présent) et alors il est facile de voir que  $\alpha \rightarrow \text{Log}E e^{\int_0^1 f(X_t)d\alpha(t)}$  est continue sur  $K$  (en utilisant le théorème de convergence dominée, ici  $f$  est positive). D'où le résultat.

(ii)  $J(\alpha) \rightarrow +\infty$  si  $\|\alpha\| \rightarrow \infty$  avec  $\|\alpha\| = \sup_{\|\phi\|_\infty=1} \int_0^1 \phi(t)d\alpha(t)$ . En effet

$$\begin{aligned} J(\alpha) &= \sup_{\phi \in B_1} (-\int_0^1 \phi(t)d\alpha(t)) + \text{Log}E e^{\int_0^1 f(X_t)d\alpha(t)} \\ &= \|\alpha\| (1 + \frac{\text{Log}E e^{\int_0^1 f(X_t)d\alpha(t)}}{\|\alpha\|}) \end{aligned}$$

Par hypothèse, on a  $f(e_0) < E = 1$ . Soit  $\epsilon = \mathbb{P}(X_t^1 = e_0, \forall t \in [0, 1])$ ; on sait que  $\epsilon > 0$  et on a

$$\text{Log}E e^{\int_0^1 f(X_t)d\alpha(t)} \geq \text{Log}\epsilon e^{\int_0^1 f(e_0)d\alpha(t)}$$

et donc

$$\begin{aligned} J(\alpha) &\geq \|\alpha\|(1 + \frac{\text{Log}\epsilon + f(e_0) \int_0^1 d\alpha(t)}{\|\alpha\|}) \\ &\geq \|\alpha\|(1 + \frac{\text{Log}\epsilon}{\|\alpha\|} - f(e_0)) \end{aligned}$$

Comme  $f(e_0) < 1$  on en déduit que  $J(\alpha)$  tend vers  $+\infty$  lorsque  $\|\alpha\| \rightarrow \infty$ .

(iii) Soit  $\alpha_n$  une suite minimisante de  $J$  i.e.  $J(\alpha_n) \rightarrow \inf_{\alpha \in V'} J(\alpha)$ . D'après (ii)  $\alpha_n$  est bornée; on dispose alors d'une valeur d'adhérence  $\lambda$  pour cette suite (théorème d'Alaoglu-Bourbaki). Comme  $J$  est s.c.i. (pour la topologie faible), on a  $\forall \epsilon > 0$  il existe un voisinage  $A$  de  $\lambda$  tel que

$$J(\alpha) \geq J(\lambda) - \epsilon \quad \forall \alpha \in A.$$

$\lambda$  étant une valeur d'adhérence de  $(\alpha_n)$ ,  $A$  contient une infinité d'éléments de la suite et on en déduit que

$$\limsup_n J(\alpha_n) \geq J(\lambda) - \epsilon,$$

et comme  $\epsilon > 0$  est arbitraire

$$\limsup_n J(\alpha_n) \geq J(\lambda),$$

mais  $\limsup_n J(\alpha_n) = \lim_n J(\alpha_n) = \inf_{\beta \in V'} J(\beta)$ , ce qui entraîne que  $J(\lambda) \leq \inf_{\beta \in V'} J(\beta)$  et par conséquent  $J(\lambda) = \inf_{\beta \in V'} J(\beta)$ . Le minimum est donc atteint<sup>5</sup> en  $\lambda$ .

• Unicité :  $J$  est strictement convexe: on a d'abord la convexité de  $\alpha \mapsto \sup_{\phi \in V} - \int_0^1 \phi(t) d\alpha(t)$  (enveloppe supérieure de fonctions convexes) puis  $\alpha \mapsto \text{Log}E e^{\int_0^1 f(X_t) d\alpha(t)}$  est strictement convexe; en effet Soient  $\lambda \in ]0, 1[$  et  $\alpha_1, \alpha_2 \in V'$ . Par l'inégalité de Hölder on vérifie aisément que

$$E[e^{\lambda \int_0^1 f(X_t) d\alpha_1(t)} e^{(1-\lambda) \int_0^1 f(X_t) d\alpha_2(t)}] \leq Ee^{\lambda \int_0^1 f(X_t) d\alpha_1(t)} Ee^{(1-\lambda) \int_0^1 f(X_t) d\alpha_2(t)} \quad (19)$$

en composant par  $\text{Log}$ , on obtient la convexité de  $\alpha \mapsto \text{Log}E e^{\int_0^1 f(X_t) d\alpha(t)}$ . La stricte convexité tient à ce que l'égalité dans 19 n'est possible que si  $e^{\int_0^1 f(X_t) d\alpha_1(t)} = \delta e^{\int_0^1 f(X_t) d\alpha_2(t)}$  p.s., soit  $\int_0^1 f(X_t) d\alpha_1(t) = \int_0^1 f(X_t) d\alpha_2(t) + \text{Log}\delta$   $P_X$ -p.s.; ce qui entraîne d'abord que  $\delta = 1$  puis que  $\alpha_1 = \alpha_2$ . En effet si pour  $\beta \in V'$  on a  $\int_0^1 f(X_t) d\beta(t) = 0$   $P_X$ -p.s., il est facile de vérifier que pour tout intervalle  $I \subset [0, 1]$  on a  $\beta(I) = 0$  (on suppose évidemment qu'il existe un  $e_i \in \Sigma$  tel que  $f(e_i) \neq 0$ ), puis en utilisant le fait que  $\beta$  est absolument continue par rapport à la mesure de Lebesgue,  $\beta(B) = 0$  pour tout borélien  $B \subset [0, 1]$ ; et donc  $\beta \equiv 0$ . Ceci achève la démonstration.  $\square$

---

5. Ici on a un problème d'optimisation sur un espace dual ( $V'$ ); on n'a pas besoin de l'hypothèse de réflexivité de l'espace (non vérifiée dans ce cas) qui est généralement requise par les théorèmes d'existence des minima. D'autre part on a évité le passage par l'extraction d'une sous suite de  $\alpha_n$  qui n'est pas nécessairement licite dans  $V'$ .

**Remarque 4.2.9** La suite des  $\lambda_p \in V'_p \subset V'$  solutions de  $\vartheta$  est bornée dans  $V' = (L_{([0,1])}^\infty)'$  (qui est muni de la norme usuelle:  $\|\lambda\| = \sup_{\|\phi\|_\infty \leq 1} \lambda(\phi)$ ).

Preuve.

Posons  $V_p = L_{([0,1])}^p$  et

$$J_p(\lambda) = \|\lambda\|_q + \text{Log} E e^{\int_0^1 f(X_t) \lambda(t) dt}, \quad \lambda \in V_p, \quad 1/p + 1/q = 1$$

Par définition  $\lambda_p = \inf_{\lambda \in V'_p} J_p(\lambda)$ . Supposons que  $\lambda_p$  n'est pas bornée pour la norme  $\|\cdot\|$  de  $V'$ ; il existe alors une suite  $p_n$  telle que  $\|\lambda_{p_n}\| \rightarrow \infty$ , ce qui entraîne que  $\|\lambda_{p_n}\|_{q_n} \rightarrow \infty$  (puisque  $\|\lambda\|_q \geq \|\lambda\| \forall q \geq 1, \lambda \in V_p$ ). Et alors il est facile de voir que  $J_{p_n}(\lambda_{p_n}) \rightarrow \infty$ . En effet, comme au (ii) de la remarque précédente on a

$$\begin{aligned} J_{p_n}(\lambda_{p_n}) &\geq \|\lambda_{p_n}\|_{q_n} \left( 1 + \frac{\text{Log} \epsilon + f(e_0) \int_0^1 \lambda_{p_n}(t) dt}{\|\lambda_{p_n}\|_{q_n}} \right) \\ &\geq \|\lambda_{p_n}\|_{q_n} \left( 1 + \frac{\text{Log} \epsilon}{\|\lambda_{p_n}\|_{q_n}} - f(e_0) \right) \end{aligned}$$

qui tend vers l'infini lorsque  $\|\lambda_{p_n}\|_{q_n}$  tend vers l'infini ( $\epsilon = \mathbb{P}(X_t^1 = e_0, \forall t \in [0, 1]) > 0$ ). Mais

$$J_{p_n}(\lambda_{p_n}) = \inf_{\lambda \in V'_{p_n}} J_{p_n}(\lambda) \leq J_{p_n}(0) = 0$$

On arrive ainsi à une contradiction.  $\square$

La suite  $\lambda_p$  admet donc une valeur d'adhérence  $\lambda_\infty$  (pour la topologie faible); malheureusement  $V'$  (et  $V$ ) n'a pas les "bonnes" propriétés permettant d'affirmer l'existence d'une sous-suite de  $\lambda_p$  qui converge. La question est alors de savoir si cette valeur d'adhérence est unique, si oui a-t-on  $\lambda_\infty = \lambda$  (le point minimum de la remarque précédente) et enfin si cette forme linéaire correspond à la limite  $P^*$  cherchée.

## 5 Appendice

- Preuve de la proposition 4.2.5.

On va faire la preuve pour  $t = 0$ . Il s'agit de calculer pour  $x, y \in \Sigma$

$$\lim_{t \rightarrow 0} \frac{P_t^*(x, y)}{t} = \lim_{t \rightarrow 0} \frac{E_x^*(1_{X_t^1=y})}{t} = \lim_{t \rightarrow 0} \frac{E_x(1_{X_t^1=y} e^{\int_0^T f(X_s^1) \lambda(s) ds})}{E_x(e^{\int_0^T f(X_s^1) \lambda(s) ds})}$$

$(E_x(\cdot) := E(\cdot | X_0^1 = x), E_x^*(\cdot) := E^*(\cdot | X_0^1 = x))$ . Or on a

$$E_x(1_{X_t^1=y} e^{\int_0^T f(X_s^1) \lambda(s) ds}) = E_x(1_{X_t^1=y} e^{\int_0^T f(X_s^1) \lambda(s) ds} | X_t = y) P_x(X_t^1 = y)$$

et en utilisant la propriété de Markov

$$E_x(e^{\int_0^T f(X_s^1) \lambda(s) ds} | X_t^1 = y) = E_x(e^{\int_0^t f(X_s^1) \lambda(s) ds} | X_t^1 = y) E_x(e^{\int_t^T f(X_s^1) \lambda(s) ds} | X_t^1 = y)$$

Par ailleurs on a  $E_x(e^{\int_0^t f(X_s^1) \lambda(s) ds} | X_t^1 = y) \rightarrow 1$  quand  $t$  tend vers 0 (en effet  $E_x(|e^{\int_0^t f(X_s^1) \lambda(s) ds} - 1| | X_t^1 = y) = O(t)$ ). D'autre part grâce à l'homogénéité de  $X^1$  sous  $P_X$  on a

$$E_x(e^{\int_t^T f(X_s^1) \lambda(s) ds} | X_t^1 = y) = E_y(e^{\int_t^T f(X_{s-t}^1) \lambda(s) ds})$$

Il suffit de montrer maintenant que cette quantité tend vers  $E_y(e^{\int_0^T f(X_s^1) \lambda(s) ds})$  lorsque  $t$  tend vers 0. Ceci découle du théorème de convergence dominée appliqué à  $\int_t^T f(X_{s-t}) \lambda(s) ds = \int_0^T 1_{s \geq t} f(X_{s-t}) \lambda(s) ds$  en remarquant que pour  $P_X$ -presque toute trajectoire  $X_s^1, f(X_{s-t})^1 \rightarrow f(X_s^1)$  lorsque  $t$  tend vers 0 sauf pour un nombre fini de points. Bien entendu le théorème de convergence dominée est appliqué ensuite pour le passage à la limite sous  $E_y$ . Ceci achève la démonstration.  $\square$

- Preuve de la proposition 4.2.6.

On va calculer la dérivée à droite de  $h_x(t)$ ; la dérivée à gauche se calcule de manière analogue. Dans la suite les symboles  $d/d\epsilon$  désigneront des dérivées à droite ( $\epsilon > 0$ ) et  $X_t^1$  sera noté  $X_t$ .

1/ Écrivons

$$\begin{aligned} h_x(t) &= \sum_y E(1_{X_{t+\epsilon}=y} e^{\int_t^T f(X_s) \lambda(s) ds} | X_t = x) \\ &= \sum_y E(e^{\int_t^T f(X_s) \lambda(s) ds} | X_t = x, X_{t+\epsilon} = y) P_X(X_{t+\epsilon} = y | X_t = x) \end{aligned}$$

Pour  $y \neq x$ , d'après la démonstration de la proposition précédente on a  $E(e^{\int_t^T f(X_s) \lambda(s) ds} | X_t = x, X_{t+\epsilon} = y) \rightarrow E(e^{\int_0^T f(X_s) \lambda(s) ds} | X_t = y)$  et par conséquent il est facile de voir que

$$\frac{d[E(e^{\int_t^T f(X_s) \lambda(s) ds} | X_t = x, X_{t+\epsilon} = y) P_X(X_{t+\epsilon} = y | X_t = x)]}{d\epsilon} = \\ E(e^{\int_0^T f(X_s) \lambda(s) ds} | X_t = y) A(x, y)$$

De même pour  $y = x$  on a

$$\frac{d[E(e^{\int_t^T f(X_s) \lambda(s) ds} | X_t = x, X_{t+\epsilon} = x) P_X(X_{t+\epsilon} = x | X_t = x)]}{d\epsilon} = \\ E(e^{\int_0^T f(X_s) \lambda(s) ds} | X_t = x) A(x, x) + \frac{d[E(e^{\int_t^T f(X_s) \lambda(s) ds} | X_t = x, X_{t+\epsilon} = x)]}{d\epsilon}$$

Pour calculer le dernier terme, on écrit encore une fois par la propriété de Markov

$$E(e^{\int_t^T f(X_s) \lambda(s) ds} | X_t = x, X_{t+\epsilon} = x) = E(e^{\int_t^{t+\epsilon} f(X_s) \lambda(s) ds} | X_t = x, X_{t+\epsilon} = x) \times \\ E(e^{\int_{t+\epsilon}^T f(X_s) \lambda(s) ds} | X_{t+\epsilon} = x) \quad (20)$$

le deuxième terme du second membre tend vers  $h_x(t)$  lorsque  $\epsilon$  tend vers 0 et sa dérivée par rapport à  $\epsilon$  n'est autre que  $dh_x/dt$ . Regardons maintenant la dérivée de l'autre terme à savoir

$$E(e^{\int_t^{t+\epsilon} f(X_s) \lambda(s) ds} | X_t = x, X_{t+\epsilon} = x) = \frac{E(1_{X_{t+\epsilon}=x} e^{\int_t^{t+\epsilon} f(X_s) \lambda(s) ds})}{P(X_{t+\epsilon} = x | X_t = x)}$$

Il faut noter qu'il tend vers 1 quand  $\epsilon$  tend vers 0. Calculons maintenant la dérivée du numérateur. On a

$$E(1_{X_{t+\epsilon}=x} e^{\int_t^{t+\epsilon} f(X_s) \lambda(s) ds} | X_t = x) = E(1_{X_{t+\epsilon}=x} (1 + \int_t^{t+\epsilon} f(X_s) \lambda(s) ds + o(\epsilon)) | X_t = x) \\ = E(1_{X_{t+\epsilon}=x} | X_t = x) + E(1_{X_{t+\epsilon}=x} e^{\int_t^{t+\epsilon} f(X_s) \lambda(s) ds} | X_t = x) + o(\epsilon) \quad (21)$$

On en déduit que la dérivée cherchée est

$$\frac{d[E(1_{X_{t+\epsilon}=x} e^{\int_t^{t+\epsilon} f(X_s) \lambda(s) ds} | X_t = x)]}{d\epsilon} = A(x, x) + f(x)\lambda(t)$$

(on a utilisé le fait que  $E(1_{X_{t+\epsilon}=x} - 1_{\{X_s=x, t \leq s \leq t+\epsilon\}} | X_t = x)$  tend vers 0 lorsque  $\epsilon$  tend vers 0.) Par conséquent

$$\frac{d}{d\epsilon} \left[ \frac{E(1_{X_{t+\epsilon}=x} e^{\int_t^{t+\epsilon} f(X_s) \lambda(s) ds})}{P_X(X_{t+\epsilon}^1 = x | X_t = x)} \right] = -A(x, x) + A(x, x) + f(x)\lambda(t) \quad (22)$$

$$= f(x)\lambda(t) \quad (23)$$

Finalement

$$\frac{d[E(e^{\int_t^T f(X_s) \cdot \lambda(s) ds} | X_t = x, X_{t+\epsilon} = x) P_X(X_{t+\epsilon} = y | X_t = x)]}{d\epsilon} = h_x(t)(A(x, x) + f(x)\lambda(t)) + \frac{dh_x(t)}{dt}$$

et

$$\sum_y A(x, y)h_y(t) + h_x(t)f(x)\lambda(t) + \frac{dh_x(t)}{dt} = 0 \quad \square$$

2/Venons en maintenant à  $k_x(t)$ . La preuve est analogue à la précédente :

$$k_x(t) = \sum_y E(1_{X_{t-\epsilon}=y} e^{\int_0^t f(X_s) \cdot \lambda(s) ds} | X_t = x) \quad (24)$$

$$= \sum_y E(1_{X_t=x} 1_{X_{t-\epsilon}=y} e^{\int_0^t f(X_s) \cdot \lambda(s) ds}) \times \frac{1}{P(t, x)} \quad (25)$$

et l'on regardera la dérivée de  $g(\epsilon, t, x, y) = E(1_{X_t=x} 1_{X_{t-\epsilon}=y} e^{\int_0^t f(X_s) \cdot \lambda(s) ds})$  par rapport à  $\epsilon$ . Par la propriété de Markov on a

$$g(\epsilon, t, x, y) = E(e^{\int_0^{t-\epsilon} f(X_s) \cdot \lambda(s) ds} | X_{t-\epsilon} = y) E(1_{X_t=x} e^{\int_{t-\epsilon}^t f(X_s) \cdot \lambda(s) ds} | X_{t-\epsilon} = y)$$

La dérivée (par rapport à  $\epsilon$ ) du premier terme du second membre n'est autre que  $-dk_y(t)/dt$ ; Pour l'autre terme on a

$$\begin{aligned} E(1_{X_t=x} e^{\int_{t-\epsilon}^t f(X_s) \cdot \lambda(s) ds} | X_{t-\epsilon} = y) &= E(1_{X_t=x} (1 + \int_{t-\epsilon}^t f(X_s) \cdot \lambda(s) ds + o(\epsilon)) | X_{t-\epsilon} = y) \\ &= E(X_t = x | X_{t-\epsilon} = y) \\ &+ E(1_{X_t=x} \int_{t-\epsilon}^t f(X_s) \cdot \lambda(s) ds | X_{t-\epsilon} = y) + o(\epsilon) \end{aligned}$$

ce qui montre que ce terme tend vers 0 lorsque  $\epsilon \rightarrow 0$  si  $y \neq x$  et vers 1 si  $y = x$  et que sa dérivée vaut

$$A(y, x) - f(x) \cdot \lambda(t) \delta_{xy}$$

En somme on a

$$\frac{dE(1_{X_t=x} e^{\int_{t-\epsilon}^t f(X_s) \cdot \lambda(s) ds} | X_{t-\epsilon} = y)}{d\epsilon} = -\frac{dk_x(t)}{dt} \delta_{xy} + k_x(t)(A(y, x) - f(x) \cdot \lambda(t) \delta_{xy})$$

et

$$\begin{aligned} \frac{dg(\epsilon, t, x, y)}{d\epsilon} &= P(t, x) \left( -\frac{dk_x(t)}{dt} \delta_{xy} + k_x(t)(A(y, x) - f(x) \cdot \lambda(t) \delta_{xy}) \right) \\ &+ -P'(t, x) k_x(t) \end{aligned}$$

L'équation régissant  $k_x(t)$  se déduit du fait que

$$\sum_y \frac{dg(\epsilon, t, x, y)}{d\epsilon} = 0 \quad \square\square$$

**Remarque.** Lorsque  $\lambda \equiv 0$  l'équation à laquelle satisfait  $k_x(t)$  donne

$$\sum_y A(y, x)P(t, y) = P'(t, x)$$

On retrouve ainsi l'équation de Kolmogorov ('forward').

★

★ ★

### Remerciements

Ce travail a été effectué au sein du projet Mistral; il m'est agréable de remercier Monsieur F.Baccelli pour la qualité de son accueil, ses encouragements et pour l'intérêt qu'il a porté à ce sujet. D'autre part, je suis redevable à S.A.Zuyev d'avoir posé un problème de performances de réseaux hiérarchiques qui a été à l'origine de la méthode considérée ci-dessus; je le remercie pour son aide et les longues discussions que nous avons eu sur ce problème.

## Références

- [1] Beneš V.E. (1963) A Thermodynamic theory of traffic in connecting networks. *Bell. Syst. Tech. J.* 567-607
- [2] Billingsley P.(1968) *Convergence of Probability Measures* . Wiley
- [3] Csiszár I. (1975) I-divergence geometry of probability distributions and minimization problems. *Ann. of Prob.* 3, 146-158
- [4] Csiszár I. (1984) Sanov property, generalized I-projection and a conditional limit theorem. *Ann. of Prob.* 12, 768-793
- [5] Dembo A., Zeitouni O.(1993) *Large Deviation Techniques and Applications*. Jones and Bart. Pub.
- [6] Dunford N., Schwartz J.T.(1988) *Linear operators*. Vol 1. Wiley
- [7] Kouvatsos D.D., Xenios N.P. (1989) Maximum entropy analysis of general networks with blocking. In H.G.Perros, T.Altiok (eds) *Workshop on queuing networks with blocking*. North Holland.
- [8] Lanford O.E. (1973) Entropy and equilibrium states in classical statistical mechanics and mathematical problems. *Lect. N. In Phy.* 20, 1-113. Springer-Verlag.
- [9] Neveu J.(1970) *Bases mathématiques du calcul des probabilités*. 2ème éd. Masson.
- [10] Pinsker M.S. (1964) *Information and information stability of random variables and processes*. Holden-Day, San Francisco.
- [11] Pinsky E., Yemini Y.(1984) A statistical mechanics of some interconnection networks. In E.Gelenbe(ed) *Performace '84*. North-Holland.
- [12] Pinsky E., Yemini Y.(1986) The canonical approximation in performance analysis. In T.Hasegawa et al. (eds) *Computer Networking and Performance Evaluation* . North-Holland.
- [13] Stroock D.W., Zeitouni O.(1991) Microcanonical distributions, Gibbs states, and the equivalence of ensembles. In Durrett and Kesten eds. *Festchrift in honour of F.Spitzer*. Birkhäuser.
- [14] Van Campenhout J.M., Cover T.M. (1981) Maximum entropy and conditional probability. *IEEE Trans. Inf. Th.* IT 27 483-489
- [15] Vasicek O.A. (1980) A conditional law of large numbers. *Ann. of Prob.* 8 142-147
- [16] Yosida K. (1980 ) *Functional Analysis*, 6th ed. Springer-Verlag.



---

Unité de recherche INRIA Lorraine, Technopôle de Nancy-Brabois, Campus scientifique,  
615 rue du Jardin Botanique, BP 101, 54600 VILLERS LÈS NANCY  
Unité de recherche INRIA Rennes, Irisa, Campus universitaire de Beaulieu, 35042 RENNES Cedex  
Unité de recherche INRIA Rhône-Alpes, 46 avenue Félix Viallet, 38031 GRENOBLE Cedex 1  
Unité de recherche INRIA Rocquencourt, Domaine de Voluceau, Rocquencourt, BP 105, 78153 LE CHESNAY Cedex  
Unité de recherche INRIA Sophia-Antipolis, 2004 route des Lucioles, BP 93, 06902 SOPHIA-ANTIPOLIS Cedex

---

Éditeur

INRIA, Domaine de Voluceau, Rocquencourt, BP 105, 78153 LE CHESNAY Cedex (France)

ISSN 0249-6399