

# Feuille 4, Chaînes de Markov et modèles spatiaux

**Exercice 1:**

**Un modèle de migration.**

On considère un modèle très simple d'une population animale dans un habitat ouvert. A chaque génération  $n \in \mathbb{N}$ , chaque animal  $y$  vivant le quitte, indépendamment des autres, avec une probabilité  $p$ , et  $y$  demeure avec une probabilité  $1 - p$ .

Simultanément et indépendamment, un nombre poissonnien (de paramètre  $a > 0$ ) d'animaux immigrent depuis le monde extérieur dans cet habitat.

On rappelle qu'une loi de Poisson  $N$  de paramètre  $a$  est définie par :

$$\forall k \in \mathbb{N}, \quad \mathbb{P}(N = k) = e^{-a} a^k / k!.$$

1. Expliquer pourquoi une loi d'immigration suivant une loi de Poisson peut être pertinente (par exemple en utilisant la limite de lois binomiales).
2. Décrire le nombre  $X_n$  d'animaux vivant dans l'habitat par une formule de récurrence, puis donner la matrice de transition  $P$  de cette chaîne de Markov.
3. Déterminer  $\mathbb{E}(X_n)$ .
4. Calculer la loi de  $X_n$  quand la loi initiale est une loi de Poisson de paramètre  $\lambda > 0$ .

**Exercice 2:**

**Chaîne de naissance et mort.**

On considère une chaîne de naissance et mort  $(X_n : n \in \mathbb{N})$  sur  $\mathbb{N}$ , c'est à dire une chaîne de Markov dont la matrice de transition  $Q$  est définie par

$$Q(0, 0) = r_0, \quad Q(0, 1) = p_0 > 0, \quad p_0 + r_0 = 1$$

et pour tout  $i \geq 1$

$$Q(i, i-1) = q_i > 0, \quad Q(i, i) = r_i, \quad Q(i, i+1) = p_i > 0, \quad q_i + r_i + p_i = 1.$$

On définit  $\tau_i := \inf\{n \in \mathbb{N} : X_n = i\}$  (on pose  $\inf \emptyset = \infty$ ) comme le temps d'atteinte de l'état  $i$  par la chaîne.

On définit également

$$\gamma_0 = 1, \quad \forall i \geq 1, \quad \gamma_i = \frac{q_1 \dots q_i}{p_1 \dots p_i}.$$

et pour  $a, b \in \mathbb{N}$  tels que  $a + 1 < b$ , on considère  $\tau = \min(\tau_a, \tau_b)$ .

1. Soit  $u$  une fonction telle que  $Qu(i) = u(i)$  pour tout  $a + 1 \leq i \leq b - 1$ , où l'on rappelle que  $Qu(i) = \sum_j Q(i, j)u(j)$ .  
Montrer que

$$u(i) = u(a) + (u(a+1) - u(a)) \gamma_a^{-1} \sum_{k=a}^{i-1} \gamma_k$$

pour tout  $a \leq i \leq b$  et que  $u$  est monotone sur cet intervalle.

2. Montrer que pour tout  $a \leq i \leq b$ ,  $\mathbb{P}_i(\tau < \infty) = 1$  et que

$$\mathbb{P}_i(X_\tau = b) = \frac{\sum_{k=a}^{i-1} \gamma_k}{\sum_{k=a}^{b-1} \gamma_k}.$$

3. Calculer  $\mathbb{P}_1(\tau_0 = \infty)$  et déterminer quand la chaîne est récurrente. Que fait-elle sinon ?

4. Exemples : étudier la récurrence de la chaîne dans les cas suivants :

(a) Le cas homogène :  $\forall i \geq 1, p_i = p, q_i = q, r_i = r$ .

(b)  $p_i = \frac{i+2}{2i+3}, q_i = \frac{i+1}{2i+3}$ .

(c)  $p_i = \frac{i+3}{2i+3}, q_i = \frac{i}{2i+3}$ .

### Exercice 3:

#### Grandes déviations

On considère une suite de variables aléatoires  $(X_i : i \in \mathbb{N})$  i.i.d de même loi que la v.a.  $X$ . On suppose que  $X$  admet des moments exponentiels de tout ordre et on définit pour  $\lambda, x \in \mathbb{R}$  :

$$m := \mathbb{E}(X), \quad \Lambda(\lambda) := \log(\mathbb{E}(e^{\lambda X})), \quad \Psi(x) := \sup_{\lambda \in \mathbb{R}} \{\lambda x - \Lambda(\lambda)\} = \sup_{\lambda \geq 0} \{\lambda x - \Lambda(\lambda)\}.$$

On veut montrer que pour tout  $x \geq m$ ,

$$\lim_{n \rightarrow \infty} -\frac{1}{n} \log \mathbb{P} \left( \sum_{i=1}^n X_i \geq nx \right) = \Psi(x).$$

a) Montrer la borne inférieure en utilisant l'inégalité de Markov  $\mathbb{P}(X \geq 0) \leq \mathbb{E}(e^X)$ .

b) En utilisant le réel  $\tau$  et le changement de loi associés à  $x$  par

$$x = \Lambda'(\tau) = \frac{\mathbb{E}(X e^{\tau X})}{\mathbb{E}(e^{\tau X})}, \quad \mathbb{P}(\tilde{X} \in du) = \frac{e^{\tau u}}{\mathbb{E}(e^{\tau X})} \mathbb{P}(X \in du),$$

montrer que pour tout  $m \leq x < y$ ,

$$\limsup_{n \rightarrow \infty} -\frac{1}{n} \log \mathbb{P} \left( nx \leq \sum_{i=1}^n X_i \leq ny \right) \leq \tau y - \Lambda(\tau).$$

c) Conclure.

#### Exercice 3.I. Application au branchement (ramification) spatial.

On considère le modèle de reproduction spatial suivant. À chaque génération  $n \in \mathbb{N}$ , chaque individu meurt après avoir donné naissance indépendamment à un nombre aléatoire  $N$  d'enfants qui se dispersent, indépendamment les uns des autres et indépendamment du passé. Le déplacement est donné par la variable  $X$ , c'est à dire que si la mère est à la position  $x$ , la position d'un enfant est distribuée comme la variable  $x + X$ .

On note  $Z_n$  la taille de la population à la génération  $n$ ,  $(X_n^i : 1 \leq i \leq Z_n)$  les positions des individus à la génération  $n$  et

$$u_n(I) = \mathbb{E}(\#\{i : X_n^i \in I\})$$

le nombre moyen d'individus dans l'intervalle  $I$  à la génération  $n$ .

a) Où les individus se trouvent-t-ils en majorité au temps  $n$  ?

b) Montrer que pour tout  $x \geq \mathbb{E}(X)$ ,

$$\lim_{n \rightarrow \infty} -\frac{1}{n} \log(u_n([nx, \infty])) = -\log(\mathbb{E}(N)) + \Psi(x).$$

où  $\Psi$  est la transformée de Fenchel Legendre de  $X$  définie à l'exercice précédent.

### Exercice 3.II. Application à la stochasticité environnementale.

On regarde une population se reproduisant en environnement aléatoire. C'est à dire qu'à chaque génération  $n \in \mathbb{N}$ , on tire un environnement (noté  $\mathcal{E}_n$ ) de manière i.i.d. On note  $N(e)$  la v.a. de reproduction dans l'environnement  $e$  et  $m(e) = \mathbb{E}(N(e))$  le nombre moyen d'enfants par individu dans cet environnement. On note  $Z_n$  la taille de la population à l'instant  $n$  : on part d'un individu ( $Z_0 = 1$ ) et à chaque génération, conditionnellement au fait que l'environnement soit égal à  $e$ , les individus se reproduisent indépendamment suivant la v.a.  $N(e)$ .

a) Rappeler pourquoi le modèle est décrit par la récurrence suivante : Pour tout  $n \in \mathbb{N}$

$$Z_{n+1} = \sum_{i=1}^{Z_n} N_n(i),$$

où conditionnellement à  $\mathcal{E}_n = e$ , les  $N_n(i)$  sont des v.a. i.i.d. distribuées comme  $N(e)$  et indépendantes de  $Z_n$ .

Retrouver également que

$$m(\mathcal{E}_0, \dots, \mathcal{E}_{n-1}) = \mathbb{E}(Z_n | \mathcal{E}_0, \dots, \mathcal{E}_{n-1}) = \exp(S_n)$$

où  $S_n = \sum_{i=0}^{n-1} \log(m(\mathcal{E}_i))$  ( $S_0 = 0$ ).

b) Montrer que pour tout  $x \geq \mathbb{E}(\log(m(\mathcal{E})))$ ,

$$\lim_{n \rightarrow \infty} -\frac{1}{n} \log \mathbb{P}(m(\mathcal{E}_0, \dots, \mathcal{E}_{n-1}) \geq \exp(nx)) = \Psi(x).$$

où  $\Psi$  est la transformée de Fenchel Legendre de  $X$  définie à l'exercice précédent.

c) Interprétez d'un point de vue de la modélisation en écologie ce résultat.

### Exercice 4:

**Modèle "faucon-colombe"** On considère le modèle "faucon-colombe" suivant, où deux espèces sont réparties en des communautés discrètes dans lesquelles les interactions sont dictées par la proportion de chacune des espèces. Ces modèles correspondent plutôt à des stratégies de coopération/tricherie et nous renvoyons à un bon ouvrage sur la théorie des jeux pour plus de détails. On appelle  $F_t(x)$  (resp  $C_t(x)$ ) le nombre de faucons (resp. colombes) au temps  $t$  à l'emplacement  $x$  et

$$P_t(x) = \frac{F_t(x)}{F_t(x) + C_t(x)}$$

la fraction de faucons au temps  $t$  à l'emplacement  $x$ . Le modèle est décrit de la manière suivante :

- Migration : chaque individu migre au taux  $m$  vers l'un de ses plus proches voisins (choisi uniformément au hasard) ;
- Mort : chaque individu du site  $x$  meurt au taux  $\kappa(F_t(x) + C_t(x))$  ;
- De surcroît, pour chaque individu, le taux de naissance (ou de mort, si le paramètre correspondant est négatif) des faucons est de la forme  $aP_t(x) + b(1 - P_t(x))$  et celui des colombes s'écrit  $cP_t(x) + d(1 - P_t(x))$ .

1) Commenter le modèle en expliquant les différents termes.

2) Expliquer pourquoi l'analogie déterministe est donné par

$$\begin{cases} u' = u(a \frac{u}{u+v} + b \frac{v}{u+v} - \kappa(u+v)) \\ v' = v(c \frac{u}{u+v} + d \frac{v}{u+v} - \kappa(u+v)), \end{cases}$$

Dans quel cadre le modèle déterministe serait-il une bonne approximation du modèle précédent ?

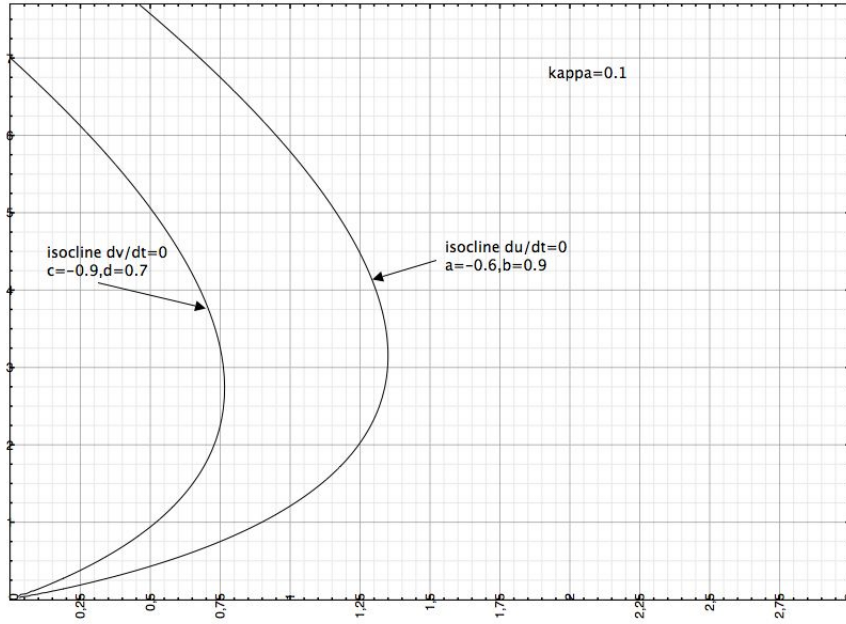


FIG. 1 – Isoclines du modèle faucon colombe quand  $\kappa = 0, 1$ ,  $a = -0.6, b = 0.9, c = -0.9, d = 0.7$ .

3) Dans le cas où  $\kappa = 0, 1$ ,  $a = -0.6, b = 0.9, c = -0.9, d = 0.7$ , prédire le comportement des solutions du modèle déterministe, en utilisant les isoclines tracées ci-dessous.

**Exercice 5:**

**Marquage de territoire.**

Le but de cet exercice est de modéliser le déplacement et ainsi la répartition d’animaux, en particulier de carnivores comme les loups, coyotes ou lynx (en dimension 1 ici, la dimension 2 étant plus technique).

1) Commençons par établir des EDP qui apparaissent naturellement pour modéliser le mouvement d’individus.

On note  $u(x, t)$  la densité de présence à la position  $x$  au temps  $t$ . Si l’on note  $X_t$  la position aléatoire d’un animal au temps  $t$ , on a ainsi

$$\mathbb{P}(a \leq X_t < b) = \int_a^b u(x, t) dx.$$

On note  $L_h(x, t)$  (resp.  $R_h(x, t)$ ) la probabilité d’aller de  $x$  en  $x - h$  (resp.  $x + h$ ) entre le temps  $t$  et le temps  $t + h^2$ .

a) Justifier que la densité  $u$  est solution de

$$\frac{\partial}{\partial t} u = -\frac{\partial}{\partial x} (cu) + \frac{\partial^2}{\partial x^2} (du)$$

où  $(x, t) \in \mathbb{R}^2 \rightarrow c(x, t), d(x, t)$  sont les coefficients d’advection et de diffusion à préciser.

b) Déterminer la solution stationnaire dans le cas où  $c(x, t) = -c \cdot \text{sign}(x)$  et  $d(x, t) = d$ , où  $c, d \in \mathbb{R}^+$ , en précisant pourquoi ce cas est naturel pour la modélisation.

Note : Ici  $\text{sign}(x) = -1, 0, 1$  suivant que  $x$  est strictement négatif, nul ou strictement positif.

c) Critiquer le modèle.

2) Nous considérons maintenant le cas où il y a deux groupes d’animaux qui ont chacun un territoire, avec un coefficient de diffusion commun constant  $d \in \mathbb{R}_+$ . La région considérée est le

segment  $[0, 1]$ , le premier groupe a son foyer en 0 et sa densité de présence en  $x$  au temps  $t$  est donnée par  $u(x, t)$ , tandis que le deuxième a son foyer en 1 et sa densité de présence est donnée par  $v(x, t)$ .

Chaque groupe marque le territoire et réagit aux marques de l'autre espèce en tendant à revenir vers son foyer quand il les rencontre. On note  $p(x, t)$  (resp.  $q(x, t)$ ) la densité de marques en  $x$  au temps  $t$  du premier (resp. deuxième) groupe. Les animaux produisent des marques à taux 1 en l'absence de l'autre groupe, et le marquage croît linéairement en fonction des marques de l'autre groupe. Enfin les marques disparaissent à taux 1.

a) Justifiez que le modèle peut maintenant être décrit par

$$\begin{aligned}\frac{\partial}{\partial t}u &= -c\frac{\partial}{\partial x}(qu) + d\frac{\partial^2}{\partial x^2}u \\ \frac{\partial}{\partial t}v &= c\frac{\partial}{\partial x}(pv) + d\frac{\partial^2}{\partial x^2}v \\ \frac{\partial}{\partial t}p &= u(1 + mq) - p \\ \frac{\partial}{\partial t}q &= v(1 + mp) - q\end{aligned}$$

avec les conditions aux bords pour  $x = 0, 1$

$$\frac{\partial}{\partial t}u = -cqu + d\frac{\partial}{\partial x}u, \quad \frac{\partial}{\partial t}v = cqv + d\frac{\partial}{\partial x}v$$

b) Déterminer la solution stationnaire quand  $m = 0$  et tracer les courbes.

c) On suppose maintenant  $m > 0$ . En utilisant les conditions de conservation pour les densités, prouver que pour la solution stationnaire

$$(1 + mu)(1 + mv) = k$$

où  $k$  est un réel positif.

Expliquer alors la méthode pour trouver la solution stationnaire, conjecturer les courbes et faire les calculs pour  $k = 2$ .

Pour aller plus loin (avec des données...), *Mechanistic Home Range Analysis*, de Paul R. Moorcroft et Maura A. Lewis.

## Pour s'entraîner

### Exercice 6:

#### Modèle de Wright Fisher

Nous décrivons ici un modèle haploïde de reproduction aléatoire, sans mutation ni sélection ni immigration. On s'intéresse à une population génétique de  $2N$  gènes pouvant être de deux types  $A$  et  $a$ . Le type de chaque gène à la génération  $n + 1$  est obtenu en prenant le type d'un individu pris au hasard (uniformément et avec remise) dans la population de gènes à la génération  $n$ .

On note  $X_n$  le nombre de gènes de type  $A$  à la génération  $n$  et on suppose  $0 < X_0 < 2N$ .

1) Donner la matrice de transition de la chaîne de Markov  $(X_n)_{n \in \mathbb{N}}$ .

2) Calculer l'espérance et la variance de  $X_n$ .

3) Montrer que p.s.  $(X_n)_{n \in \mathbb{N}}$  est absorbée en 0 ou en  $2N$  et calculer la probabilité de chacun de ces deux événements.

### Exercice 7:

**Marche aléatoire sur un polygone.** On indexe par  $i = 1 \dots N$  les sommets d'un polygone (dans

le sens des aiguilles d'une montre par exemple) et on considère la chaîne de Markov correspondant à la marche aléatoire sur ces sommets avec une probabilité  $p$  de sauter au sommet suivant,  $q$  de sauter au sommet précédent et  $r$  de ne pas bouger, avec  $p + q + r = 1$ .

1. Quand la chaîne est-elle irréductible? Quelle est alors sa loi invariante?
2. On suppose  $p, q > 0$ . On rappelle que la période d'un état  $i$  est

$$\text{PGCD}(n \in \mathbb{N} : P^n(i, i) > 0),$$

où  $P$  est la matrice de transition de la chaîne.

- (a) Retrouver le fait qu'ici la période ne dépend pas de l'état : on l'appelle la période de la chaîne. Pourquoi est-ce le cas pour une chaîne irréductible en général?
- (b) Montrer que si  $r > 0$ , la chaîne est de période 1 (apériodique).
- (c) Montrer que si  $r = 0$ , la chaîne est de période 2 quand  $N$  pair et 1 quand  $N$  impair, sauf dans les cas dégérés où  $p$  ou  $q$  sont également nuls.
- (d) Discuter alors de la convergence en distribution de la chaîne.

### Exercice 8:

#### La domestication du millet

On considère trois variétés de millet qui se différencient par un couple d'allèles : la variété domestique correspond à  $(a, a)$ , la variété sauvage à  $(A, A)$  et la variété hybride à  $(A, a)$ . Les variétés cultivées sont les variétés domestiques et hybrides qui sont sélectionnées par les cultivateurs car leurs grains restent mieux accrochés aux plants.

On cherche à comprendre comment cette caractéristique peut se fixer dans la population cultivée malgré les croisements constants avec la variété sauvage.

On note  $X_n$  la proportion de la variété domestique dans le champ et  $Y_n$  la proportion de la variété hybride.

1. La méthode de culture est la suivante. D'une part, afin d'éviter les reproductions entre hybrides pouvant conduire à la création de millet de type  $(A, A)$  (indésirable), le cultivateur ne tente de reproduire que des fleurs de type domestique  $(a, a)$ . Pour ce qui est du pollen utilisé, le cultivateur commence par éliminer avant la floraison une proportion  $v \in [0, 1]$  d'hybrides, puis il récolte le pollen des plants de millet (domestiques et hybrides) restants. Ensuite,
  - (a) une proportion  $\alpha$  des fleurs à reproduire sont choisies dans les domestiques et subissent une auto-fécondation (elles se reproduisent avec du pollen issu de leur propre plant)
  - (b) pour les autres, la reproduction se fait par allo-fécondation :
    - (b.1) pour une proportion  $m$  avec la population sauvage
    - (b.2) pour les autres, par panmixie parmi les plantes cultivées (c-à-d qu'on choisit au hasard une plante dans le champ).

Montrer que

$$\begin{aligned} X_{n+1} &= \alpha + (1 - \alpha)(1 - m) \left( \frac{X_n}{1 - vY_n} + \frac{1}{2} \frac{(1 - v)Y_n}{1 - vY_n} \right) \\ Y_{n+1} &= (1 - \alpha)m + (1 - \alpha)(1 - m) \frac{1}{2} \frac{(1 - v)Y_n}{1 - vY_n}. \end{aligned}$$

En déduire que  $Y_n$  converge vers l'unique point fixe donné par

$$Y_\infty = F(m, v, \alpha, Y_\infty)$$

où

$$F(m, v, \alpha, y) := (1 - \alpha) \left( m + \frac{(1 - v)(1 - m)y}{2(1 - vy)} \right).$$

Vérifier que  $Y_\infty$  est une fonction décroissante de  $\alpha$  et de  $v$ , et une fonction croissante de  $m$ .

2. La population est maintenant supposée d'effectif constant égal à  $N$  et on est amené à introduire le modèle stochastique suivant. La composition des variétés de millet à partir d'une population contenant  $i$  hybrides est obtenue par échantillonnage aléatoire (avec remise). En procédant comme dans 1) aléatoirement pour chaque reproduction, on est amené à introduire la fréquence (probabilité)

$$p_i = p_i(N) = F\left(m, v, \alpha, \frac{i}{N}\right)$$

qui donne la probabilité d'obtenir un hybride pour chaque reproduction à chaque échantillonnage.

- a) On note  $U_n^N := NY_n^N$  le nombre d'hybrides à la génération  $n$ . Déterminer la matrice de transition de la chaîne de Markov  $(U_n^N)$ .

- b) Montrer que

$$\mathbb{E}(U_n^N | U_{n-1}^N = i) = Np_i.$$

En moyenne, on retrouve donc le modèle déterministe.

- c) Montrer qu'indépendamment de l'état initial, la chaîne de Markov  $(U_n^N)$  converge vers une unique loi stationnaire.

- d) Montrer que  $\text{Var}(Y_{n+1}^N - Y_n^N | Y_n^N = y)$  tend vers zéro quand  $N \rightarrow \infty$ .

- e) En déduire que  $Y_n^N$  converge quand  $N \rightarrow \infty$  vers la suite déterministe  $Y_n$  de la première partie.

- f) Afin d'étudier les fluctuations de  $Y^N$  autour de sa limite  $Y$ , introduisons la quantité

$$V_n^N := \sqrt{N} (Y_n^N - Y_n).$$

Montrer que

$$\lim_{N \rightarrow \infty} \mathbb{E}(V_{n+1}^N - V_n^N | V_n^N = v) = -(1 - F'(Y_n))v$$

et que

$$\lim_{N \rightarrow \infty} \text{Var}(V_{n+1}^N - V_n^N | V_n^N = v) = F(Y_n)(1 - F(Y_n)).$$

Ceci permet de montrer que le processus  $V_n^N$  est approximé quand  $N \rightarrow \infty$  par la chaîne de Markov autorégressive  $(V_n, n \geq 0)$  définie par

$$V_{n+1} = -(1 - F'(Y_n))V_n + E_n,$$

où  $E_n$  est indépendante de  $V_n$  et de loi normale  $\mathcal{N}(0, F(Y_n)(1 - F(Y_n)))$ .