

# INTRODUCTION AUX PROBABILITES XII-XIII-XIV-XV

Support du cours donné en 1<sup>re</sup> année  
par Marietta Manolessou  
EISTI - Département Mathématiques

Année 2010-2011



# Table des matières

	<b>Probabilités</b>	<b>1</b>
<b>12 Vecteurs aléatoires</b>		<b>1</b>
1 Vecteurs aléatoires (ou de probabilités) . . . . .		1
1 Vecteurs aléatoires de dimension 2 . . . . .		1
2 Distributions Conditionnelles . . . . .		4
1 Fonction de masse conditionnelle . . . . .		4
2 Fonction de densité conditionnelle (cas continu) . . . . .		4
3 Moments conditionnels (cas général-vectoriel) . . . . .		4
1 . . . . .		4
2 Moments Conditionnels d'ordre $p$ . . . . .		5
3 Variance conditionnelle . . . . .		5
4 Transformations de vecteurs aléatoires (à densité) . . . . .		5
<b>13 Introduction aux Processus Stochastiques</b>		<b>7</b>
1 Définition d'un processus stochastique . . . . .		7
1 Processus Stoch. et sa Trajectoire . . . . .		7
2 Processus à accroissements indépendants . . . . .		8
3 Processus à accroissements stationnaires . . . . .		8
4 Filtration . . . . .		8
5 Filtration naturelle . . . . .		8
<b>14 Introduction aux Processus Stochastiques Chaînes de Markov</b>		
<b>A</b>		<b>9</b>
1 Processus Markoviens-Chaînes de Markov . . . . .		9
1 Références . . . . .		9
2 Processus de Markov- Chaînes de Markov . . . . .		9
3 Matrices de Transition . . . . .		10
4 Propriétés de la matrice de transition $P$ . . . . .		11
5 Graphe associé à une chaîne de Markov . . . . .		11
<b>15 Introduction aux Processus Stochastiques Chaînes de Markov</b>		
<b>B</b>		<b>13</b>
1 Régimes d'une chaîne de Markov		
Ergodicité - Classes d'équivalence . . . . .		13
1 Résumé . . . . .		13
2 Régimes d'une chaîne de Markov . . . . .		13

3	Ergodicité . . . . .	14
4	Caractérisation des états . . . . .	14
5	Etats et Classes d'équivalence . . . . .	15

# Table des figures

15.1 Une chaîne de Markov irréductible . . . . .	15
--	----



# Chapitre 12

## Vecteurs aléatoires

### 1 Vecteurs aléatoires (ou de probabilités)


#### 1 Vecteurs aléatoires de dimension 2

a)

$$\begin{aligned} X &: (\Omega, \mathcal{A}, P) \rightarrow \mathbb{R} \\ Y &: (\Omega, \mathcal{A}, P) \rightarrow \mathbb{R} \end{aligned}$$

$\vec{V}(\omega) \in \mathbb{R}^2$  (vect. aléatoire)

**Exemple 1.1** Événement :  $A(D) \equiv \vec{V} \in D, \quad D \subset \mathbb{R}^2$



On associe l'ens. des pts  $\omega$  t.q.

$$A(x, y) = \{\omega | X(\omega) \leq x ; Y(\omega) \leq y\}$$

#### b) Mesure de Probabilité - Fonction de répartition jointe

$$F(x, y) \equiv P[\{X \leq x\} \cap \{Y \leq y\}]$$

\* Cas continu :

(i) La mesure de probabilité définie par :

$$P(x, y) = \frac{\partial^2 F}{\partial x \partial y}$$

si elle existe on l'appelle **fonction de densité jointe** (notée " $f(x, y)$ ") d'un vecteur aléatoire continu et inversement :

$$F(x, y) = \int_{-\infty}^x \int_{-\infty}^y P(x', y') dx' dy'$$

$$\Downarrow$$

$$(f(x', y'))$$

**(ii) Fonction de répartition marginale**

$$F_X(x) = \int_{-\infty}^x \int_{-\infty}^{+\infty} f(x', y') dx' dy'$$

et fonction de densité marginale  $\Leftrightarrow$  (dériv. par rapport à  $x$ )

$$f_X(x) = \int_{-\infty}^{+\infty} f(x, y) dy$$

**\* Cas discret - fonction de masse jointe :**

(i)

$$P[x_i, y_j] \equiv P[\{X = x_i\} \cap \{Y = y_j\}]$$

et  $\forall D \in \mathbb{R}^2$  fonction de répartition

$$P[D] = \sum_{(x_i, y_j) \in D} P[x_i, y_j]$$

(ii)

- Fonction de masse marginale

$$Px_i = \sum_{y_j} P(x_i y_j)$$

- Fonction de répartition marginale

$$F_X(x_i) = F[x_i, +\infty]$$

$$\downarrow$$

$$y_j \in ] - \infty, +\infty[$$

**c) Espérance mathématique (cas général :  $h(X, Y)$ )**

**\* Cas continu :**

$$E[h[X, Y]] = \iint h(x, y) f(x, y) dx dy$$

**\* Cas discret :**

$$E[h[X, Y]] = \sum_{x_i, y_j} h(x_i, y_j) P(x_i, y_j)$$

Propriétés

(a) Si  $h(x, y) = x + y$

$$E[h(X, Y)] = E[X] + E[Y]$$



(b) Si  $h(x, y) = xy \Rightarrow$  en général

$$E[(X \cdot Y)] \neq E[X]E[Y]$$

(c) (Rappel) Déf : Variables aléatoires indépendantes

$$\Leftrightarrow F(x, y) = F_X(x)F_Y(y).$$

$$f(x, y) = f_X(x)f_Y(y)$$

(d)

$$P(x, y) = P_X(x)P_Y(y)$$

### Remarque importante

*Cette factorisation peut se produire même si  $X, Y$  ne sont pas indépendantes (liées).*

#### d) Covariance (définition)

$$\text{Cov}(X, Y) \equiv E[(X - \mu_X)(Y - \mu_Y)]$$

ou  $\Rightarrow$

$$\text{Cov}[X, Y] = E[XY] - \mu_X\mu_Y$$

(i) Corollaire

$$\text{Cov}(X, Y) = 0$$

si  $X, Y$  sont non corrélées

(ii) "Inégalité de Schwartz"

$$\text{Cov}^2(X, Y) \leq \sigma_X^2\sigma_Y^2$$

$\Leftrightarrow$

$$\text{Cov}(X, Y) \leq \sigma_X\sigma_Y$$

e) Coefficient de corrélation (de  $X, Y$ ) déf.

$$C \equiv \frac{\text{Cov}(X, Y)}{\sigma_X\sigma_Y}$$

en général

$$|C| \leq 1$$

\* Si  $C = 0 \Leftrightarrow$  var. al.  $X, Y$  non corrélées.

\* Si  $|C| = 1$  ( $C$  peut être aussi  $< 0$ )  $\Leftrightarrow X, Y$  **complètement corrélées**.

## 2 Distributions Conditionnelles

### 1 Fonction de masse conditionnelle

(cas discret)

#### Définition 2.1

$$P_{x_i|y_j} \stackrel{\text{notation}}{\equiv} P[\{X = x_i\}|\{Y = y_j\}] \stackrel{\text{def}}{\equiv} \frac{P[\{X = x_i\} \cap \{Y = y_j\}]}{P[Y = y_j]}$$

où

$$P[Y = y_j] = \sum_{x_i} P_{x_i y_j}$$

### 2 Fonction de densité conditionnelle (cas continu)

#### i) Cas scalaire

##### Définition 2.2

$$f_X[x|y] \stackrel{\text{def}}{\equiv} \frac{f(x, y)}{f_Y(y)}$$

##### Proposition 2.1

$$\int f_X[x|y] dx = 1,$$

#### ii) Cas vectoriel (sur $\mathbb{R}$ )

##### Définition 2.3

$$f_X[\vec{x}|y] \stackrel{\text{def}}{\equiv} \frac{f(x, y)}{f_Y(\vec{y})}$$

et aussi :

##### Proposition 2.2

$$i) \quad \int f_X[x|y] dx_1 \dots dx_n = 1$$

$$ii) \quad \int f_X[x|y] f_Y(y) dy_1 \dots dy_n = f_X(x)$$

**Exercice 2.1** Montrer les propositions 2.1 et 2.2

## 3 Moments conditionnels (cas général-vectoriel)

### 1

Soit une fonction - var. aléatoire  $h(X)$ , avec,

$$X \text{ vect. de probabilité ; } X : (\Omega, \mathcal{A}, P) \rightarrow \mathbb{R}^n$$

$$Y \text{ vect. de probabilité ; } Y : (\Omega, \mathcal{A}, P) \rightarrow \mathbb{R}^n$$

**Définition 3.1** *Espérance Conditionnelle*

$$E_X[h(X)|y] = \int h(x)f_X[x|y]dx$$

Propriété importante !

**Proposition 3.1**

$$E_Y[E_X[h(X)|y]] = E_X[h(X)]$$

**Exercice 3.1** *Montrer la proposition 3.1*

## 2 Moments Conditionnels d'ordre $p$

**Définition 3.2**

$$E_X[X^p|y] = \int x^p f[x|y]dx$$

(Définition analogue pour le cas discret)

## 3 Variance conditionnelle

**Définition 3.3**

$$\begin{aligned} E_X[(X - \mu_X)^2|y] &= \int (X - \mu_X)^2 f[x|y]dx \\ &= E[X^2|y] + \mu_X^2 - 2\mu_X E_X[X|y] \end{aligned}$$

## 4 Transformations de vecteurs aléatoires (à densité)

**Théorème 3.1** *Soit  $(\Omega, \mathcal{F}, P)$  un espace de probabilité et soit*

$$X = \{X_1, X_2, \dots, X_n\} : (\Omega, \mathcal{F}, P) \rightarrow \mathbb{R}^n$$

*un vecteur aléatoire.*

*Soit  $Y = \phi(X)$  un vecteur aléatoire - transformation biunivoque du vecteur aléatoire  $X$ .*

$\Rightarrow$

*la densité de probabilité du vecteur  $Y$  est obtenue par la formule suivante :*

$$g(y) = \frac{f((\phi)^{-1}(y))}{|\det J|}$$

*où  $J$  est la matrice -**Jacobien** de la transformation.*



# Chapitre 13

## Introduction aux Processus Stochastiques

### 1 Définition d'un processus stochastique

#### 1 Processus Stoch. et sa Trajectoire

##### Définition 1.1

Soit  $(\Omega, \mathcal{F}, P)$  un espace de probabilité, et soit  $Y$  une variable aléatoire définie sur  $\Omega$  (donc  $\mathcal{F}$ -mesurable).

On appelle **tribu engendrée par  $Y$**  ou  $Y$ -tribu, la plus petite des tribus (formée par des sous ensembles de  $\Omega$ ) par rapport à laquelle la var. al.  $Y$  est **mesurable** et on note :

$$\mathcal{F}(Y) \text{ ou } \sigma(Y)$$

##### Définition 1.2 Soient :

- $(\Omega, \mathcal{F}, P)$  un espace de probabilité
- $T$  un ensemble quelconque
- $(E, \mathcal{E})$  esp. mesurable

On appelle **processus stochastique** défini sur  $\Omega$ , avec  $T$  ensemble des temps et  $E$  espace des états, toute famille  $\{X(t)\}_{t \in T}$  de var. al. à valeurs dans  $E$ .

- La variable aléatoire  $X(t)$  est appelée : état à l'instant  $t$ .
- Autre notation :  $\{X_t\}_{t \in T}$

##### Définition 1.3 Trajectoire

$\forall \omega \in \Omega$  l'application :

$$\begin{aligned} T &\rightarrow E \\ t &\mapsto X(t, \omega) \quad \text{ou } t \mapsto X_t(\omega) \end{aligned}$$

est appelée : **la trajectoire associée à  $\omega$**

On étudiera 2 cas

- $T \in \mathbb{N}$  cas en temps discret
  - $T = \{t \in [0, t_0]\}$  (intervalle de  $\mathbb{R}$ )  $\Leftrightarrow$  cas en temps continu
- Par la suite, on considérera que  $E \subset \mathbb{R}$  ou  $E \subset \mathbb{R}^N$  (cas général) (fini ou infini)

## 2 Processus à accroissements indépendants

**Définition 1.4** Soit  $\{X(t)\}_{t \in T}$  un **processus stochastique** défini sur  $\Omega$ ; il est à **accroissements indépendants** ssi

$$\forall t_1 < t_2 < t_3 \dots < t_n \quad (t_i \in T)$$

les var. aléatoires :

$$X(t_1), X(t_2) - X(t_1), \dots, X(t_n) - X(t_{n-1})$$

sont indépendantes

## 3 Processus à accroissements stationnaires

**Définition 1.5** Un **processus stochastique**  $\{X(t)\}_{t \in T}$ , défini sur  $\Omega$ , est à **accroissements stationnaires** ssi les var. aléatoires.  $X(h)$  et  $X(t+h) - X(t)$  sont équidistribuées.

## 4 Filtration

**Définition 1.6** Soit  $(\Omega, \mathcal{F}, P)$  un espace de probabilité.

On appelle **filtration**, une famille de sous tribus

$$(\mathcal{F}_t)_{t \in T}$$

t.q.  $\mathcal{F}_s \subset \mathcal{F}_t$  pour  $s \leq t$  (**famille croissante de sous tribus de  $\mathcal{F}$** ).

### Interprétation

$\mathcal{F}_t$  (appelée **tribu des événements antérieurs à  $t$** ) modélise les informations disponibles à temps  $t$ .

## 5 Filtration naturelle

**Remarque 1.1** Tout processus stochastique  $X$  génère une “filtration naturelle”

$$\mathcal{F}_t = \mathcal{F}(X(s); s \leq t)$$

$\Leftrightarrow$  **filtration engendrée par les variables aléatoires antérieures à l’instant  $t$ .**

**Définition 1.7** **Processus stochastique adapté une filtration  $\{\mathcal{F}_t\}$**

(i) **Cas continu** : Un processus stochastique  $X(t)_{t \in T}$  est adapté à une filtration  $\{\mathcal{F}_t\}$  si  $\forall t \in T$   $X_t$  est  $\mathcal{F}_t$ -mesurable

(ii) **Cas discret** :  $X_n$  adapté à  $\mathcal{F}_n$   $\Leftrightarrow \forall n \in \mathbb{N}$ , ( $T = \mathbb{N}$ ),  $X_n$  est  $\mathcal{F}_n$  - mesurable

**Définition 1.8** **Processus stochastique prévisible par rapport à  $\{\mathcal{F}_n\}$**

**Cas discret** :  $X_n$  prévisible, par rapport à  $\{\mathcal{F}_n\}$

$\Leftrightarrow X_n$  est adapté à  $\mathcal{F}_n$  et  $\forall n \in \mathbb{N}$ , ( $T = \mathbb{N}$ ),  $X_n$  est  $\mathcal{F}_{n-1}$  - mesurable.

# Chapitre 14

## Introduction aux Processus Stochastiques Chaînes de Markov A

### 1 Processus Markoviens-Chaînes de Markov

#### 1 Références

- (i) P. BREMAUD  
"Introduction aux probabilités" par P. Bremaud  
Edition : Springer et Verlag
- (ii) R. Faure, "Recherche Opérationnelle" (Masson)
- (iii) J.-M. Helary - R. Pedrono, "Recherche Opérationnelle"
- (iv) P. Gordon, "Théorie des chaînes de Markov" (Dunod)
- (v) S.M.Ross, "Initiation aux Probabilités"  
(Presses Polytechniques et Universitaires Romandes)
- (vi) S. Lipschutz, "Probabilités (Série SCHAUM)" (Mc Graw Hill - Ediscience)

#### 2 Processus de Markov- Chaînes de Markov

**Définition 1.1** Données  $(\Omega, \mathcal{F}, \{F_t\}, P)$ ,  $\{X_t\}$  processus stochastique sur  $\Omega$

$\Rightarrow \{X_t\}$  est Markovien (ou processus de Markov)

ssi :  $\forall t_1 \leq t_2$

$$P[\{X(t_2) \in \mathcal{B}\} | \mathcal{F}_{t_1}] = P[\{X(t_2) \in \mathcal{B}\} | X(t_1)]$$

ou ssi

$$E[f[X(t_2)] | \mathcal{F}_{t_1}] = E[f[X(t_2)] | X(t_1)]$$

pour toute fonction  $f$  continue et bornée.

$\Leftrightarrow$  la loi de  $X(t_2)$  conditionnellement à  $\mathcal{F}_{t_1}$  est égale à la loi de  $X(t_2)$  conditionnellement à  $X(t_1)$ .

**Autrement dit :**

A la date  $t_1$  toute l'information pertinente sur les réalisations futures sont contenues dans  $X(t_1)$  (v. aussi cas particulier les Chaînes de Markov).

**Définition 1.2 (Chaîne de Markov)**

Un processus stochastique  $\{X(t)\}_{t \in T}$  défini sur un espace de probabilité  $(\Omega, \mathcal{F}, P)$  avec :  
 $E =$  Ensemble fini ou dénombrable -**ensemble des états du système**  
 $T =$  Sous-ensemble de  $\mathbb{R}^+$ , **ensemble des paramètres du temps**  
 est appelé Chaîne de Markov à “temps”  $\in T$  à valeurs dans  $E$ , si :

$$\forall n \in \mathbb{N}, 0 < t_0 \leq t_1 \leq \dots \leq t_n \leq t (\in T); s \in T; i_0, i_1, \dots, i_n, i, j \in E$$

si l'égalité suivante entre probabilités conditionnelles est bien vérifiée :

$$P[X_{t+s} = j | X_{t_0} = i_0, X_{t_1} = i_1, \dots, X_{t_n} = i_n, X_t = i] = P[X_{t+s} = j | X_t = i]$$

**Remarque 1.1** Souvent on utilise la notation  $\{X_n\}_{n \in \mathbb{N}}$  pour le temps discret.

**Remarque Importante**

Une chaîne de Markov est complètement déterminée : **(a)** par ses **probabilités de transition** :

$$p_{i,j}(t, s) = P[X_{t+s} = j | X_t = i] \\ \forall t \in T, s \in T \\ i \in E, j \in E.$$

et **(b)** par sa **loi de probabilité de l'état initial** :

$$\Pi_i^{(0)} = P[X_0 = i] \quad (i \in E)$$

**Définition 1.3** Les chaînes **homogènes** de Markov.

Ce sont les chaînes pour lesquelles les probabilités de transition  $p_{i,j}(t, s)$  ne dépendent pas de l'instant  $t$  mais seulement de l'accroissement de temps  $s$ .

\* On étudiera surtout les chaînes homogènes à temps discret. ( $t = n \in \mathbb{N}$ )

**3 Matrices de Transition****Matrice Stochastique****Définition 1.4****a) Vecteur de probabilité**

$u = \{u_1, u_2, \dots, u_n\} \in \mathbb{R}^n$  est un vecteur de probabilité

$$\text{ssi} \begin{cases} 0 \leq u_i \leq 1 & \forall i = 1, \dots, n \\ \sum_{i=1}^n u_i = 1 \end{cases}$$

**Exemples :**

$$u = \{\frac{1}{4}; \frac{1}{4}; 0; \frac{1}{2}\} \quad \text{oui (vecteur de probabilité)}$$

$$v = \{\frac{3}{4}; 0; -\frac{1}{4}; \frac{1}{2}\} \quad \text{non}$$

$$w = \{\frac{3}{4}; \frac{1}{2}; 0; \frac{1}{4}\} \quad \text{non}$$

**b) Matrice Stochastique**

Une matrice carrée  $P = \{p_{ij}\} \in \mathcal{M}_n(\mathbb{R})$  est une matrice stochastique si chacune de ses lignes est un vecteur de probabilité :

$$\Rightarrow \\ 0 \leq p_{ij} \leq 1 \quad \text{et} \quad \sum_{j=1}^n p_{ij} = 1 \quad (\forall i = 1, \dots, n)$$



**Exemples 1.1**

$$P_1 = \begin{pmatrix} \frac{1}{4} & \frac{3}{4} \\ \frac{1}{3} & \frac{1}{3} \end{pmatrix} \quad (Non); \quad P_2 = \begin{pmatrix} \frac{1}{3} & 0 & \frac{2}{3} \\ \frac{3}{4} & \frac{1}{2} & -\frac{1}{4} \\ \frac{1}{2} & \frac{1}{3} & \frac{1}{3} \end{pmatrix} \quad (Non); \quad P_3 = \begin{pmatrix} 0 & 1 & 0 \\ \frac{1}{2} & \frac{1}{6} & \frac{1}{3} \\ \frac{1}{3} & \frac{2}{3} & 0 \end{pmatrix} \quad (Oui).$$

**Proposition 1.1** Si  $A$  et  $B$  sont deux matrices stochastiques

$$\Rightarrow \begin{cases} (i) & AB \text{ est une matrice stochastique} \\ (ii) & A^m \text{ est une matrice stochastique} \end{cases}$$

**Remarque 1.2** Les probabilités  $p_{ij}$  de transition d'une chaîne de Markov finie (qui est un processus stochastique) peuvent être rangées sous la forme d'une matrice  $P$  qu'on appelle matrice de transition.

**Proposition 1.2** La matrice de transition  $P$  d'une chaîne de Markov est une matrice stochastique.

**Matrice de Transition**

**Cas discret : matrice de transition**

$$\begin{aligned} P &= \{p_{ij}\}_{i,j \in E} \\ p_{ij} &= P\{X_{n+1} = j | X_n = i\} \\ &= P\{X_1 = j | X_0 = i\} \end{aligned}$$

**Cas continu :**

Famille de matrices de transition.

$$\begin{aligned} P &= \{p_{ij}(t)\}_{i,j \in E} \\ p_{ij}(t) &= P\{X_{t_0+t} = j | X_{t_0} = i\} \\ &= P\{X_t = j | X_0 = i\} \end{aligned}$$

**4 Propriétés de la matrice de transition  $P$**

et loi de probabilité d'état.

**Proposition 1.3 Cas discret**

$$\begin{aligned} i) & P^{n+m} = P^n \cdot P^m && \forall n, m \in \mathbb{N} \\ ii) & P^n = \{p_{ij}^{(n)}\}; && p_{ij}^{(n)} = P[X_{n_0+n} = j | X_{n_0} = i] = P[X_n = j | X_0 = i] \\ iii) & \text{Soit } \Pi^{(n)} \equiv (\Pi_i^{(n)})_{i \in E} && (\text{vecteur de prob des états du système à } t = n) \\ & \text{avec } \Pi_i^{(n)} = P[X_n = i] && \\ \Rightarrow & && \Pi^{(n+m)} = \Pi^{(n)} P^m \end{aligned}$$

**5 Graphe associé à une chaîne de Markov**

**Définition 1.5 (Graphe orienté d'une chaîne de Markov discrète)**

Le graphe associé à une chaîne de Markov (et à sa matrice de transition  $P$ ) est défini par :

(a) Ses **sommets** qui représentent les états du système ( $i \in E$ )

(b) Ses **arêtes** ( $i \rightarrow j$ ) associées aux probabilités de transition :  $p_{ij} > 0$

Utilité d'un graphe

- (i) On voit directement si le système peut passer d'un état à un autre (dans un temps  $n$  fini)
- (ii) On étudie plus facilement les propriétés des états du système
- (iii) On classe plus facilement les états du système (Classes d'équivalence)

**Exemple 1.1** *exercice*

Faire le graphe associé à la chaîne de Markov dont  $P$  est :

$$P = \begin{pmatrix} 1/2 & 1/4 & 1/4 \\ 1/2 & 0 & 1/2 \\ 0 & 1 & 0 \end{pmatrix}$$

**Proposition 1.4** *Cas continu*

(i)  $\forall t, s \in T, P(t+s) = P(t) \cdot P(s)$

(ii)  $P(t) = \{P_{ij}(t)\}$  où

$$\begin{aligned} P_{ij}(t) &= P[X_{t+s} = j | X_t = i] \\ &= P[X_s = j | X_0 = i] \end{aligned}$$

(iii) Si  $\Pi(t) = \{\Pi_i(t)\}_{i \in E}$  avec

$$\Pi_i(t) = P[X_t = i]$$

$$\Rightarrow \underline{\Pi(t+s) = \Pi(t) \cdot P(s)}$$

# Chapitre 15

## Introduction aux Processus Stochastiques Chaînes de Markov B

### 1 Régimes d'une chaîne de Markov Ergodicité - Classes d'équivalence

#### 1 Résumé

- \* Régimes d'une chaîne de Markov - stationnarité
- \* Ergodicité
- \* Caractérisation des états
- \* Classes d'équivalence

**Remarque 1.1** *Par la suite on étudiera toujours : les cas discrets*

### 2 Régimes d'une chaîne de Markov

#### Définitions :

- \* Régimes d'une chaîne de Markov
- \* Régime stationnaire (Point fixe de P)
- \* Ergodicité

#### Définition 1.1

Le vecteur de probabilité des états du système à l'instant  $t = n$  (ligne de  $P$  à l'instant  $n$ ),  $\Pi^{(n)}$  est appelé régime du système à l'instant  $n$ .

#### Définition 1.2

Un régime  $\Pi$  est stationnaire ssi

$$\Pi P = \Pi \quad \text{avec : } \left\{ \begin{array}{l} \sum_{i \in E} \Pi_i = 1 \\ \Pi_i \geq 0 \quad \forall i \in E \end{array} \right\}$$

**Remarque 1.2**

- (a) le vecteur  $\Pi$  est un vecteur propre (à gauche) de  $P$  associé à la valeur propre  $\underline{1}$  de  $P$   
 (b)  $\Leftrightarrow \Pi$  est un **point fixe** de la matrice de transition  $P$  considérée comme transformation des probabilités des différents états du système quand le temps **varie** :  $n \rightarrow n + m$   
 (c)  $\Leftrightarrow \Pi =$  *vecteur constant*.

**Exemple 1.1 Exercice**

On considère une chaîne de Markov dont la matrice de transition  $P$  est la suivante ; trouver (si il en existe) le régime stationnaire :

$$\begin{bmatrix} 1/2 & 1/4 & 1/4 \\ 1/2 & 0 & 1/2 \\ 0 & 1 & 0 \end{bmatrix}$$

- (d) (*Important!*) La stationnarité du régime :

$$\Pi^{(n)} P = \Pi^{(n)}$$

$\Leftrightarrow$

$$\forall m > n : \Pi^{(m)} = \Pi^{(n)}$$

$\Leftrightarrow$

*La probabilité pour que le système se trouve à un certain état reste la même pour tout instant  $m$  après  $n$ .*

**Définition 1.3**

On appelle régime **permanent** le vecteur de probabilité :

$$\begin{aligned} \Pi \text{ t.q. } & \Pi = \lim_{n \rightarrow \infty} \Pi^{(n)} \\ \text{ou} & \lim_{n \rightarrow \infty} \Pi^{(0)} P^{(n)} = \Pi \end{aligned}$$

**Remarque 1.3**

*Si il existe un régime permanent alors il est nécessairement stationnaire.*

**3 Ergodicité****Définition 1.4**

On dit qu'une chaîne de Markov est **ergodique**

*ssi*

$$\exists \Pi \quad \text{avec} \quad \Pi = \lim_{n \rightarrow \infty} \Pi^{(n)}$$

pour tout régime initial  $\Pi^{(0)}$

*Autrement dit : l'ergodicité caractérise les systèmes qui possèdent un régime permanent indépendamment du régime initial  $\Pi^{(0)}$*

**4 Caractérisation des états****Définition 1.5** (*Propriétés des états*)




FIG. 15.1 – Une chaîne de Markov irréductible

1) On considère l'application suivante  $f_i$  de l'ensemble des états  $E$  vers l'intervalle  $I = [0, 1]$

$$\begin{aligned} E &\rightarrow [0, 1] \\ f_i : i &\rightarrow f_i \end{aligned}$$

$$f_i = P[\exists n > 0 | P(X_n = i | X_0 = i)]$$

Alors : a)  $i$  est un **état transitoire** si

$$f_i < 1$$

b)  $i$  est un **état récurrent** si

$$f_i = 1$$

2) Soit  $d_i = \text{pgcd}$  des longueurs de chemins partant de  $i$  et arrivant en  $i$

Si  $d_i = 1$

$\Rightarrow$  L'état  $i$  est dit **apériodique**

Si  $d_i \neq 1$

$\Rightarrow$  L'état  $i$  est dit **périodique** de **période**  $d_i$

3) Quand le système se trouve à l'état  $i \in E$  et il ne peut plus en sortir

$$\Leftrightarrow P_{ii}^{(n)} = 1 \quad (\forall n)$$

Cet état est appelé **absorbant**.

(Il est forcément récurrent et apériodique)

## 5 Etats et Classes d'équivalence

**Définition 1.6** Classes d'équivalence d'une chaîne de Markov.

On définit une relation d'équivalence sur  $E$  :

$$i \sim j \Leftrightarrow \left\{ \begin{array}{l} (i = j) \text{ ou} \\ \left( \begin{array}{l} \exists n \geq 1 \text{ t.q. } P_{ij}^{(n)} > 0 \\ \text{et } \exists m \geq 1 \text{ t.q. } P_{ji}^{(m)} > 0 \end{array} \right) \end{array} \right.$$

On dit alors que les deux états  $i$  et  $j$  appartiennent à la même classe d'équivalence.

**Remarque 1.4** Les états d'une même classe ont les mêmes propriétés d'où les trois possibilités :

- **Classe Récurrente**
- **Classe Transitoire**
- **Classe Absorbante** ( $\Leftrightarrow 1$  seul état  $\in E$ )

**Définition 1.7** Chaîne de Markov **irréductible**

- $\Leftrightarrow G$  fortement connexe
- $\Leftrightarrow \exists 1$  seule classe récurrente