

# Chaînes de Markov, Processus de décision markoviens et Apprentissage par renforcement


Jean-Philippe Gayon

ISIMA, filières F3 et F4 (2ème et 3ème année)

23 octobre 2024

- 1 Introduction
- 2 Chaînes de Markov à temps discret
- 3 Chaînes de Markov avec récompenses (évaluer une politique)
  - Distributions connues
  - Distributions inconnues
- 4 Processus de décision markovien (déterminer la politique optimale)
  - Horizon infini
  - Horizon fini
- 5 Apprentissage par renforcement (environnement inconnu)
  - Bandit manchot
  - Processus de décision markovien
- 6 Chaîne de Markov à temps continu

# Apprentissage par renforcement <sup>1</sup>



- Etat  $\rightarrow$  Action  $\rightarrow$  Récompense  $\rightarrow$  Etat  $\rightarrow$  Action  $\rightarrow$  Récompense  $\rightarrow$  ...

$$S_0, A_0, R_1, S_1, A_1, R_2, S_2 \dots$$

- Récompenses et probabilités de transitions inconnues
- Objectif : maximiser les récompenses

1. Sutton et Barto (2018). Reinforcement Learning

# Exemples

- Gym : API pour l'apprentissage par renforcement
  - ▶ <https://gymnasium.farama.org/>
- Cart-pole
  - ▶ <https://towardsdatascience.com/reinforcement-learning-concept-on-cart-pole-with-dqn-79910>
- Jeux Atari
- Faire marcher un robot humanoïde
- Frozen lake

# Programme

- Chaînes de Markov :  $S_0, S_1, S_2, \dots$
- Chaînes de Markov avec récompenses (évaluer une politique)

$$S_0, R_0, S_1, R_1, S_2, R_2 \dots$$

- Processus de décision markovien (trouver la politique optimale)


$$S_0, A_0, R_0, S_1, A_1, R_1, \dots$$

- Apprentissage par renforcement (environnement incertain)
  - ▶ Récompenses inconnues
  - ▶ Distributions inconnues


# Pour aller plus loin sur l'apprentissage par renforcement

- Présentations et vidéos par David Silver  
<https://www.davidsilver.uk/teaching/>


Baynat



Bertsekas



Sutton and Barto



- Extraits à lire au fur et à mesure du cours

- 1 Introduction
- 2 Chaînes de Markov à temps discret
- 3 Chaînes de Markov avec récompenses (évaluer une politique)
  - Distributions connues
  - Distributions inconnues
- 4 Processus de décision markovien (déterminer la politique optimale)
  - Horizon infini
  - Horizon fini
- 5 Apprentissage par renforcement (environnement inconnu)
  - Bandit manchot
  - Processus de décision markovien
- 6 Chaîne de Markov à temps continu

# Historique : Andreï Andreïevitch Markov (1822-1856)

- Fondateur de la théorie des processus stochastiques
- Chaînes de Markov : phénomènes aléatoires à mémoire courte
- 1913 : Analyse d'un texte de 20 000 lettres d'Alexandre Pouchkine
  - ▶ Observation : L'apparition des lettres dépend des précédentes
  - ▶ Modèle de Markov d'ordre 0 : chaque lettre apparaît indépendamment des autres
  - ▶ Modèle de Markov d'ordre 1 : la  $n$ -ième lettre ne dépend que de la  $n - 1$ -ème lettre
  - ▶ Modèle de Markov d'ordre  $k$  : la  $n$ -ième lettre ne dépend que des  $k$  lettres précédentes ( $n - 1, n - 2, \dots, n - k$ )
  - ▶ On peut faire la même chose avec des mots => générateur parodique
- Générateur de texte markovien : Modèle simple d'IA générative !

# Processus aléatoire

- Processus aléatoire : suite de variables aléatoires  $X_0, X_1, X_2, \dots$
- De très nombreux phénomènes sont décrits par des suites de variables aléatoires inter-dépendantes
  - ▶ Cours d'une action
  - ▶ Évolution d'un stock
  - ▶ Nombre d'étudiants en retard
  - ▶ Évolution du nombre de requêtes serveur en attente d'être traitées
  - ▶ ...
- Remarque : aléatoire = stochastique

# Evolution du CAC 40 sur un an<sup>2</sup>




- $X_t$  : valeur de l'action le jour  $t$
- Espace des temps discret :  $t = 1, 2, \dots, 365$  (en jours)
- Espace d'état discret :  $X_t \in \{0, 0.01, 0.02, \dots\}$  (en euros)

---

2. Boursorama, 10 sept. 2019

# Marche aléatoire 1D<sup>3</sup>

- Un pas en avant (+1) avec probabilité 1/2, un pas en arrière (-1) avec probabilité 1/2
- $X_t$  : position à la  $t$ -ième étape
- 3 exemples de **trajectoires** aléatoires en partant de 0




3. Wikipedia, 10 sept. 2019

# Quelques questions que nous chercherons à étudier

- Distribution après  $n$  étapes :  $P(X_t = k) = ?$
- Probabilité de retour à l'origine ?
  - ▶ Proba = 1
  - ▶ On dit que l'état initial est récurrent
- Temps moyen avant de revenir à l'origine ?
  - ▶ Infini
  - ▶ On dit que l'état initial est récurrent nul

# Marche aléatoire 2D<sup>4</sup>


- Avant, arrière, droite, gauche avec probabilité 1/4
- $V_t = (X_t, Y_t)$  : position à la  $t$ -ième étape



4. Wikipedia, 10 sept. 2019

# Marche aléatoire 3D<sup>5</sup>

- avant, arrière, droite, gauche, haut, bas avec probabilité 1/6
- $V_t = (X_t, Y_t, Z_t)$  : position à la  $t$ -ième étape
- Probabilité de revenir à l'origine  $< 1$  (marche transitoire)



5. Wikipedia, 10 sept. 2019

# Processus aléatoire (= Processus stochastique)

- Processus stochastique à temps discret : suite de variables aléatoires  $\{X_n, n = 0, 1, 2, \dots\}$
- Espace d'état  $E : X_n \in E$
- Espace d'état fini (ou dénombrable)


# Chaîne de Markov à Temps Discret (CMTD)

- CMTD = Processus stochastique à temps discret sans mémoire

$$P(X_{n+1} = j | X_n = i, X_{n-1} = i_{n-1}, \dots, X_0 = i_0) = P(X_{n+1} = j | X_n = i)$$

- L'état suivant ne dépend que de l'état courant
- Exemple : Marche aléatoire
- $p_{ij}(n) = P(X_{n+1} = j | X_n = i) =$  probabilité de transition de l'état  $i$  à l'état  $j$  à l'instant  $n$
- CMTD homogène :  $p_{ij}(n) = p_{ij}$

# Dynamique




- Homogène si  $p_{ij}(n) = p_{ij}$

# Graphe d'une CMTD homogène

- Graphe orienté
  - ▶ État = sommet
  - ▶ Arc orienté de  $i$  à  $j$  si  $p_{ij} > 0$
  - ▶ Pondération  $p_{ij}$  sur l'arc orienté  $(i, j)$


## Exemple : CMTD à 2 états



# Matrice de transition pour une CMTD fini et homogène

- **Matrice de transition** :  $P = (p_{ij})$

## Exemple : CMTD à 2 états



$$P = \begin{pmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{pmatrix}$$

- Une matrice de transition est une **matrice stochastique** : la somme des éléments de chaque ligne vaut 1

$$\sum_j p_{ij} = 1, \forall i$$

# Propriétés d'une matrice stochastique

- Le produit de 2 matrices stochastiques est stochastique
- Corollaire : si  $P$  stochastique alors  $P^n$  stochastique.
- 1 est valeur propre
- Le rayon spectral vaut 1 : les valeurs propres sont inférieures ou égales à 1 en module

# Pile ou face jusqu'à la faillite

## Principe du jeu

- Les joueurs A et B possèdent respectivement  $\alpha$  et  $\beta$  euros
- A chaque tour, ils misent un euro et jouent à pile ou face
- Le jeu s'arrête quand l'un des deux est ruiné
- Durée du jeu = nombre de tours joués



## Questions

- Quelle est la probabilité pour chacun des joueurs d'être ruiné ?
- Quelle est la durée moyenne du jeu ?

# Épisodes

- Épisode :  $X_0, X_1, \dots, X_T$
- $T$  : instant final (potentiellement une variable aléatoire)


## Example




- L'épisode se termine quand on atteint l'état absorbant 3.
- Sur cette réalisation,  $T = 5$ .

# Épisode sans fin

## Exemple





# Exemple : Souris dans un labyrinthe




- La souris est amnésique et choisit un des couloirs de façon équiprobable
- On s'intéresse à la succession des pièces visitées (et pas au temps passé dans chaque pièce)
- Modéliser ce système par une CMTD, donner son graphe et sa matrice de transition

# Souris dans un labyrinthe : CMTD et graphe

- $X_n$  : position après le  $n$ -ième couloir emprunté
- $X_0 = 2$




# Souris dans un labyrinthe : matrice de transition



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

# Régime transitoire



- $\pi_j(n) = P(X_n = j)$  : probabilité d'être dans l'état  $j$  à l'instant  $n$

$$\pi_j(n + 1) = \sum_{i \in E} p_{ij} \pi_i(n)$$


# Régime transitoire (forme matricielle)

- $\pi(n) = (\pi_1(n), \pi_2(n), \dots, \pi_{|E|}(n))$  : distribution à l'instant  $n$

$$\pi(n+1) = \pi(n)P$$


$$\pi(n) = \pi(0)P^n$$

## Exemple : CMTD à 2 états



- Avec  $\pi(0) = (1, 0)$ , calculer  $\pi(1), \pi(2), \pi(3)$ .

## Exemple : CMTD à 2 états



$$P = \begin{pmatrix} 0.5 & 0.5 \\ 1 & 0 \end{pmatrix}$$

$$\pi(0) = (1, 0)$$

$$\pi(1) = \pi(0)P = (1/2, 1/2)$$


$$\pi(2) = \pi(1)P = (3/4, 1/4)$$

$$\pi(3) = \pi(2)P = (5/8, 3/8),$$

$$\pi(10) = (0.666015625, 0.333984375)$$

$$\pi(\infty) = (2/3, 1/3)$$

# Souris dans un labyrinthe : régime transitoire



- Supposons que  $X_0 = 2$ , calculer  $\pi(0), \pi(1), \pi(2), \pi(3)$  et  $\lim_{n \rightarrow \infty} \pi(n)$ .

# Souris dans un labyrinthe : régime transitoire (réponse)

$$\pi(0) = (0, 1, 0, 0, 0, 0)$$

$$\pi(1) = \left( \frac{1}{2}, 0, 0, \frac{1}{2}, 0, 0 \right)$$

$$\pi(2) = \left( \frac{1}{4}, \frac{1}{4}, \frac{1}{2}, 0, 0, 0 \right)$$

$$\pi(3) = \left( \frac{3}{8}, \frac{1}{4}, 0, \frac{1}{8}, \frac{1}{8}, \frac{1}{8} \right)$$

$$\pi(\infty) = (0, 0, 0, 0, 1/2, 1/2)$$

# Probabilité d'aller de $i$ à $j$ en $n$ étapes

- $p_{ij}^{(n)}$  : Probabilité, commençant en  $i$ , d'être en  $j$  après  $n$  transitions

$$p_{ij}^{(n)} = P(X_{t+n} = j | X_t = i)$$

$$P_{ij}^{(n)} = P^n$$

- Equations de Chapman-Kolmogorov


$$p_{ij}^{(n+m)} = \sum_{k \in \mathcal{S}} p_{ik}^{(n)} p_{kj}^{(m)}$$

$$P^{n+m} = P^n P^m$$

# Travail à la maison

- Lire chapitre 3.1, pages 55 à 62
- Exercice 1 (téléphone arabe)
- Exercice 4 (matrices stochastiques)


# Convergence vers une distribution limite : un exemple



$$\begin{cases} \pi_1(n+1) = \frac{1}{4}\pi_2(n) \\ \pi_2(n+1) = \pi_n(1) + \frac{3}{4}\pi_2(n) \end{cases}$$

$n$	$\pi_1(n)$	$\pi_2(n)$
0	1	0
1	0	1
2	0.25	0.75
3	0.1875	0.8125
4	0.203125	0.796875
...	...	...
13	0.2	0.8
14	0.2	0.8

# Exemple de non convergence



$$\begin{cases} \pi_1(n+1) = \pi_2(n) \\ \pi_2(n+1) = \pi_1(n) \end{cases}$$

$n$	$\pi_1(n)$	$\pi_2(n)$
0	1	0
1	0	1
2	1	0
3	0	1
4	1	0
...	...	...

- En revanche, convergence au sens de Césarò

$$\underbrace{\frac{1}{n} \sum_{k=1}^n \pi_1(k)}_{\text{Proportion de temps passé en 1 au cours des } n \text{ premières étapes}} \xrightarrow{n \rightarrow +\infty} 0.5$$

Proportion de temps passé en 1  
au cours des  $n$  premières étapes

# Si convergence, alors ...

- Supposons que  $\pi(n) = (\pi_1(n), \pi_2(n), \dots)$  converge vers  $\pi = (\pi_1, \pi_2, \dots)$
- Alors

$$\begin{aligned}\pi(n+1) &= \pi(n)P \\ \Downarrow n \rightarrow \infty \\ \pi &= \pi P\end{aligned}$$

- Questions
  - ▶ Quels sont les critères de convergence ?
  - ▶ La distribution limite dépend-elle de l'état initial ?

# Distribution stationnaire

- "Stationnaire" signifie "qui ne dépend pas du temps"

$$\pi(n) = \pi$$

$$\pi(n+1) = \pi(n)P \Rightarrow \pi = \pi P$$

- Une distribution de probabilité  $\pi$  est dite **stationnaire** si et seulement si


$$\begin{cases} \pi = \pi P \\ \sum_i \pi_i = 1 \end{cases}$$

# Lien entre distribution stationnaire et distribution limite

## Propriété

*La distribution limite est la distribution stationnaire.*


## La réciproque est fausse



$$\begin{cases} \pi = \pi P \\ \sum_i \pi_i = 1 \end{cases} \Leftrightarrow \pi_1 = \pi_2 = 0.5$$

# La distribution stationnaire est-elle toujours unique ?


La réponse est non



$$\begin{cases} \pi = \pi P \\ \sum_i \pi_i = 1 \end{cases} \Leftrightarrow \begin{cases} \pi_2 = 0 \\ \pi_1 + \pi_3 = 1 \end{cases}$$

# Existe-il toujours une distribution stationnaire ?

La réponse est non




$$\begin{cases} \pi = \pi P \\ \sum_i \pi_i = 1 \end{cases} \Leftrightarrow \begin{cases} \pi_i = 0, \forall i \\ \sum_i \pi_i = 1 \end{cases}$$

# Classification des états

- État **absorbant** :  $p_{jj} = 1$

## Exemple




- État **périodique** ou **apériodique**
- État **récurrent** ou **transitoire**

# État périodique versus état apériodique

- État **périodique**  $j$  : il existe  $k > 1$  tel qu'on ne puisse retourner en  $j$  qu'après un nombre d'étapes multiple de  $k$
- État **apériodique** : un état n'étant pas périodique


## Exemple : CMTD périodiques



# État récurrent versus état transitoire

- $f_{jj}^{(n)}$  : probabilité que le premier retour en  $j$ , en partant de  $j$ , ait lieu en  $n$  étapes
- $f_{jj} = \sum_{n=1}^{\infty} f_{jj}^{(n)}$  : probabilité, en partant de  $j$ , de revenir un jour en  $j$
- Etat **récurrent** :  $f_{jj} = 1$
- Etat **transitoire** :  $f_{jj} < 1$

## Exemple : CMTD fini



- 1 et 2 sont récurrents
- 3 et 4 sont transitoires


# Récurrent nul versus récurrent non nul

- $M_j$  : temps moyen entre 2 visites de  $j$
- État récurrent **non nul** :  $M_j < +\infty$
- État récurrent **nul** :  $M_j = +\infty$

## Proposition


Soit  $E$  un espace d'état fini. Alors tout état récurrent est récurrent non nul.

## Déterminer $f_{22}$ et $M_2$



$$f_{22} = \sum_{i=1}^{\infty} \left(\frac{1}{2}\right)^i = 1, \quad M_2 = \sum_{i=2}^{\infty} \left(\frac{1}{2}\right)^{i-1} = 3$$

# Un exemple de CMTD infini



- $p > 1/2$  : tous les états sont transitoires
- $p = 1/2$  : tous les états sont récurrents nuls
- $0 < p < 1/2$  : tous les états sont récurrents non nuls

# CMTD irréductible versus irréductible

- Une CMTD est **irréductible** si son graphe est fortement connexe

$$\forall i, j \in E, \exists m > 1, p_{ij}^{(m)} > 0$$

- CMTD **réductible** = CMTD qui n'est pas irréductible

# Nature des états d'une CMTD irréductible

## Théorème (Admis)

*Tous les états d'une CMTD irréductible sont de même nature :*


- *Tous transitoires, ou tous récurrents non nuls, ou tous récurrents nuls*
- *Tous périodiques ou tous apériodiques*

## Corollaire (Nombre d'états fini)


*Tous les états d'une CMTD irréductible finie sont récurrents non nuls.*

# Exercice 5 : classification des états


a)




b)



c)



d)



# Travail à la maison

- Lire chapitre 3.1, pages 62 à 68
- Exercice 5 (classification des états)
- Exercice 3 (marche aléatoire symétrique)

# Distribution limite pour une CMTD irréductible et apériodique

## Théorème (admis)

*Pour une CMTD irréductible et apériodique, la distribution limite  $\pi = (\pi_1, \pi_2, \dots)$  existe et est indépendante de la distribution initiale  $\pi(0)$  :*


- *Si les états sont tous transitoires ou tous récurrents nuls, alors*

$$\forall j \in E, \pi_j = 0$$

- *Si les états sont tous récurrents non nuls, alors les  $\pi_j$  satisfont*

$$(S) : \begin{cases} \pi_j = \sum_{i \in E} \pi_i P_{ij}, \forall j \in E \\ \sum_{j \in E} \pi_j = 1 \end{cases}$$

# Exemple : Téléphone arabe



- La CMTD est irréductible et apériodique
- Tous les états sont récurrents non nuls
- La distribution limite existe et satisfait

$$\begin{cases} \pi_1 = p\pi_1 + q\pi_2 \\ \pi_2 = p\pi_2 + q\pi_1 \\ \pi_1 + \pi_2 = 1 \end{cases} \Rightarrow \pi_1 = \pi_2 = 0.5$$

# Interprétation de la distribution limite

## Théorème (Césaro)

Soit  $(u_n)$  une suite de nombres réels convergeant vers  $L$ , alors la moyenne de Césaro

$$c_n = \frac{1}{n} \sum_{k=1}^n u_k$$

converge également vers  $L$ .

## La réciproque est fausse

- $u_n = (-1)^n$  ne converge pas
- Mais  $c_n$  converge vers 0

# Interprétation de la distribution limite

- Supposons que  $\pi_i(n) \xrightarrow{n \rightarrow +\infty} \pi_i$
- Alors, d'après le théorème de Césaro

$$\underbrace{\frac{1}{n} \sum_{k=1}^n \pi_i(k)}_{\text{Proportion de temps passé en } i \text{ au cours des } n \text{ premières étapes}} \xrightarrow{n \rightarrow +\infty} \pi_i$$

- Interprétation de  $\pi_i$  : proportion de temps passé en  $i$  sur un horizon infini


# CMTD irréductible et périodique (finie)

- $\pi(n)$  n'a pas de limite

$$(S) : \begin{cases} \pi_j = \sum_{i \in E} \pi_i p_{ij}, \forall j \in E \\ \sum_{j \in E} \pi_j = 1 \end{cases}$$

- (S) admet une solution unique où  $\pi_j$  représente la proportion de temps passé dans l'état  $j$  sur un horizon infini

## Exemple




$$\begin{cases} \pi_1 = \pi_2 \\ \pi_1 + \pi_2 = 1 \end{cases} \implies \pi_1 = \pi_2 = 0.5$$

# Temps moyen entre deux visites d'un état

- $M_j$  : temps moyen entre deux visites d'un état  $j$

$$M_j = \frac{1}{\pi_j}$$

## Exemple



Calculer  $M_1$  et  $M_2$  par deux méthodes (avec ou sans le résultat ci-dessus).

# Résolution de $(S)$ pour une CMTD à $m$ états (facultatif)

- Soit  $\mathbf{1} = (1, \dots, 1)$

$$(S) \begin{cases} \pi = \pi P \\ \pi \mathbf{1}^T = 1 \end{cases}$$

- $A$  : matrice  $m \times m$  avec toutes les entrées à 1 ( $a_{ij} = 1$ )

$$\pi A = \mathbf{1}$$

- Il suit avec  $I$  la matrice identité  $m \times m$

$$I\pi + \pi A = \pi P + \mathbf{1}$$


- Propriété :  $I - P + A$  est inversible pour une CMTD apériodique et irréductible

$$\pi = \mathbf{1}(I - P + A)^{-1}$$


# Conservation des flux

- $\pi_i p_{ij}$  : Nombre de transitions de  $i$  vers  $j$  par unité de temps
- Partition des états :  $E = E_1 \cup E_2$

$$\overbrace{\sum_{i \in E_1} \sum_{j \in E_2} \pi_i p_{ij}}^{\text{Flux de } E_1 \text{ vers } E_2} = \overbrace{\sum_{i \in E_2} \sum_{j \in E_1} \pi_i p_{ij}}^{\text{Flux de } E_2 \text{ vers } E_1}$$




# Exemple 1



- Flux de 0 vers 1 = Flux de 1 vers 0
- Flux de 1 vers 2 = Flux de 2 vers 1

$$\begin{cases} \frac{2}{3}\pi_0 = \frac{1}{2}\pi_1 \\ \frac{1}{2}\pi_1 = \frac{1}{2}\pi_2 \\ \pi_0 + \pi_1 + \pi_2 = 1 \end{cases} \Rightarrow \begin{cases} \pi_1 = \frac{4}{3}\pi_0 \\ \pi_2 = \pi_1 = \frac{4}{3}\pi_0 \\ \pi_0\left(1 + \frac{4}{3} + \frac{4}{3}\right) = 1 \end{cases} \Rightarrow \begin{cases} \pi_0 = \frac{3}{11} \\ \pi_1 = \frac{4}{11} \\ \pi_2 = \frac{4}{11} \end{cases}$$

## Exemple 2



- Flux de  $E_1$  vers  $E_2 =$  Flux de  $E_2$  vers  $E_1 \Rightarrow p\pi_i = q\pi_{i+1}$
- Soit  $\rho = \frac{p}{q}$ . Alors  $\pi_i = \rho^i \pi_0$ .
- Si  $\rho < 1$ , alors  $\sum_{i=0}^{\infty} \pi_i = 1 \Rightarrow \pi_0 = 1 - \rho$


$$\pi_i = (1 - \rho)\rho^i$$

# Travail à la maison

- Finir lecture du chapitre 3.1 (pages 55 à 73)
- Exercices 6 et 7
- TP sur les marches aléatoires (évaluation lors de l'examen terminal)


# Partition d'une CMTD

- Une CMTD peut être partitionnée en sous-chaînes irréductibles, plus un ensemble d'états transitoires
  - ▶  $E_T$  : Ensemble d'états transitoires
  - ▶  $E_i$  : Ensemble d'états de la  $i$ -ème sous-chaîne irréductible
- Sous-chaîne irréductible = Sous-chaîne absorbante




- Peut-on encore appliquer le théorème valable pour une chaîne irréductible ?
- Probabilité d'absorption par une sous-chaîne ?
- Temps moyen avant absorption par une sous-chaîne ?

## Uni-chaîne : Une seule sous-chaîne irréductible



- Les résultats pour une CMTD irréductible s'appliquent encore.

## Multi-chaîne : Plusieurs sous-chaîne irréductibles



- La distribution limite dépend de l'état initial
- La solution de  $(S)$  n'est pas unique

# Forme canonique de la matrice de transition (facultatif)

- $P_T$  : transitions entre les états transitoires  $E_T$
- $P_i$  : transitions entre les états récurrents  $E_i$  de la sous-chaîne irréductible  $i$
- $R_i$  : transitions des états transitoires  $E_T$  vers les états  $E_i$  de la sous-chaîne irréductible  $i$


$$P = \begin{pmatrix} P_1 & & 0 & 0 \\ & \ddots & & \vdots \\ 0 & & P_k & 0 \\ R_1 & \dots & R_k & P_T \end{pmatrix}$$

# Temps moyen avant absorption par une sous-chaîne

- $e_i$  : Temps moyen avant absorption par une sous-chaîne irréductible, en partant de l'état transitoire  $i$

$$e_i = 1 + \sum_{j \in E_T} p_{ij} e_j$$

## Exemple




$$\begin{cases} e_1 = 1 + 1/4 e_2 \\ e_2 = 1 + 1/3 e_1 \end{cases} \Rightarrow \begin{cases} e_1 = 15/11 \\ e_2 = 16/11 \end{cases}$$

# Probabilité d'absorption par une sous-chaîne

- $a_{ij}$  : probabilité, en partant de l'état transitoire  $i$ , d'être absorbé par la sous-chaîne  $j$

$$a_{ij} = \sum_{k \in E_j} p_{ik} + \sum_{k \in E_T} p_{ik} a_{kj}$$

## Exemple



$$\begin{cases} a_{11} = 3/4 + 1/4 a_{21} \\ a_{21} = 1/3 a_{11} \end{cases} \Rightarrow \begin{cases} a_{12} = 9/11 \\ a_{21} = 3/11 \end{cases}$$


# Temps moyen passé dans un état transitoire

- $s_{ij}$  : Temps moyen passé dans  $j$ , en partant de  $i \in S_T$

$$s_{ij} = \delta_{ij} + \sum_{k \in S_T} p_{ik} s_{kj}$$

avec  $\delta_{ij} = 1$  si  $i = j$  and 0 autrement

## Exemple



$$\begin{cases} s_{11} = 1 + 1/4 s_{21} \\ s_{21} = 1/3 s_{11} \end{cases} \Rightarrow \begin{cases} s_{11} = 12/11 \\ s_{21} = 4/11 \end{cases}$$

- ▶ Vérifier que  $e_1 = s_{11} + s_{12}$  et  $e_2 = s_{21} + s_{22}$

# Exercice 8 : roulette




# Roulette française versus roulette américaine



## Temps de séjour dans un état (voir exercice 2)

- $T_j$  : nombres d'étapes passées dans l'état  $j$  avant d'en sortir
- Supposons que  $p_{jj} < 1$  (autrement  $T_j = +\infty$ )



- $T_j =$  nombre d'expérience de Bernoulli pour obtenir un succès, avec proba de succès  $(1 - p_{jj})$
- $T_j$  distribué suivant une loi géométrique de paramètre  $(1 - p_{jj})$

$$P(T_j = k) = (1 - p_{jj})p_{jj}^{k-1} \quad \text{pour } k = 1, 2, \dots$$


# Propriété sans mémoire (ou propriété de Markov)

- Une variable aléatoire  $T$  est dite sans mémoire si

$$\forall t, x, \quad P(T > t + x | T > t) = P(T > x)$$

- La loi géométrique est sans mémoire (voir exercice 10)
- Le temps passé dans un état d'une CTMD suit donc une loi sans mémoire

# Chaîne de Markov ergodique



- Hypothèse ergodique : les performances stationnaires sont égales à la performance moyenne de n'importe quelle trajectoire  $(X_0, X_1, X_2, \dots)$

$$\frac{1}{N} \sum_{n=1}^N f(X_n) \xrightarrow{N \rightarrow +\infty} \sum_{i \in E} f(i) \pi_i$$

- Propriété : Une CMTD irréductible (ou uni-chaîne) est ergodique
- Implication : on peut simuler le comportement d'un système ergodique avec une seule trajectoire


# Pourcentage de temps passé dans un état

- Prenons  $f(x) = 1$  si  $x = j$ , 0 sinon
- Alors

$$\underbrace{\frac{1}{N} \sum_{n=1}^N f(X_n = j)}_{\text{Proportion de temps passé en } j \text{ sur la trajectoire } X_1, X_2, \dots, X_N} \xrightarrow{N \rightarrow \infty} \pi_j$$

- Conclusion : pour une CMTD ergodique, le % de temps passé dans l'état  $j$  pour une trajectoire vaut  $\pi_j$ , quelle que soit la trajectoire

# Un exemple de chaîne non ergodique



- Si l'on part de l'état 2, il faut plusieurs simulations (en repartant de l'état 2) pour étudier les performances (par exemple estimer la probabilité d'absorption par 1)


# Travail à la maison

- Programme de l'évaluation bonus
  - ▶ Exercices 1 à 8
  - ▶ Exercice "Pile ou face jusqu'à la ruine" (cas particulier de l'exercice 8)
  - ▶ Chapitre 3.1
- Savoir (entre autres) :
  - ▶ Donner le graphe et la matrice de transition
  - ▶ Classer les états
  - ▶ Calculer la distribution en régime transitoire  $\pi(n)$
  - ▶ Calculer la distribution limite  $\pi$
  - ▶ Interpréter la distribution limite / stationnaire
  - ▶ Calculer le temps moyen avant absorption par une sous-chaîne irréductible
  - ▶ Calculer la probabilité d'absorption par une sous-chaîne irréductible

- 1 Introduction
- 2 Chaînes de Markov à temps discret
- 3 Chaînes de Markov avec récompenses (évaluer une politique)
  - Distributions connues
  - Distributions inconnues
- 4 Processus de décision markovien (déterminer la politique optimale)
  - Horizon infini
  - Horizon fini
- 5 Apprentissage par renforcement (environnement inconnu)
  - Bandit manchot
  - Processus de décision markovien
- 6 Chaîne de Markov à temps continu

# Chaîne de Markov avec récompenses

- $\mathcal{S}$  : espace d'états
- $p_{ij}$  : probabilité d'aller d'un état  $i$  à un état  $j$
- $r_i$  : récompense (en espérance) à chaque visite de l'état  $i$
- $\gamma$  : Taux d'actualisation




## Exemple

La récompense obtenue à chaque visite de l'état  $i$  est une variable aléatoire d'espérance  $\mu_i$  et d'écart-type  $\sigma_i$ .

$$r_i = \mu_i$$


# Récompenses sur les arcs / sommets

## Récompenses sur les arcs



- $r_{ij}$  : récompense si une transition de  $i$  à  $j$  se produit

## Récompenses sur les sommets



- $r_i$  : récompense à chaque visite de l'état  $i$

- On peut passer des  $r_{ij}$  aux  $r_i$  sans modifier la récompense totale


$$r_i = \sum_{j \in \mathcal{S}} p_{ij} r_{ij}$$

- Dans la suite, nous écrivons les équations avec les récompenses sur les sommets


# Représentation graphique

- Récompenses et coûts en rouge :
  - ▶ + R pour une Récompense
  - ▶ - C pour un Coût

## Récompenses sur les arcs




## Récompenses sur les sommets



# Différentes fonctions objectif (horizon infini)

- Récompense totale =  $\mathbb{E}(R_0 + R_1 + R_2 + R_3 + \dots)$
- $\gamma \in ]0, 1[$  : taux d'actualisation
- Récompense totale **actualisée** =  $\mathbb{E}(R_0 + \gamma R_1 + \gamma^2 R_2 + \gamma^3 R_3 + \dots)$
- Gain moyen =  $\lim_{T \rightarrow \infty} \mathbb{E} \left( \frac{R_0 + R_1 + \dots + R_{T-1}}{T} \right)$

## Exemple



$$\text{Récompense totale} = 5 + 5 + 5 + \dots = +\infty$$

$$\text{Récompense totale actualisé} = 5 + 5\gamma + 5\gamma^2 + 5\gamma^3 + \dots = \frac{5}{1 - \gamma}$$

$$\text{Gain moyen (par periode)} = 5$$

# Fonctions de valeur

## Récompense totale

$$v(i) = \mathbb{E} \left[ \sum_{t=0}^{\infty} R_t \mid S_0 = i \right]$$

## Récompense totale actualisée ( $\gamma < 1$ )

$$v(i) = \mathbb{E} \left[ \sum_{t=0}^{\infty} \gamma^t R_t \mid S_0 = i \right]$$

## Gain moyen

$$g(i) = \lim_{T \rightarrow \infty} E \left[ \frac{1}{T} \sum_{t=0}^T R_t \mid S_0 = i \right]$$

# Gain à partir de $t$

## Definition

Le gain  $G_t$  est la récompense total actualisée à partir de  $t$ .

$$G_t = R_t + \gamma R_{t+1} + \gamma^2 R_{t+2} + \dots$$

$$v(i) = \mathbb{E}[G_t | S_t = i]$$

# Récompense totale - Équations de Bellman

## Définition

Un *état terminal*  $s$  est un état absorbant ( $p_{ss} = 1$ ) avec récompense nulle ( $r_s = 0$ ).

## Hypothèse

Il existe un état terminal  $s$  atteint avec probabilité 1.

- La fonction de valeur est solution des équations de Bellman


$$v(s) = 0$$

$$v(i) = r_i + \sum_{j \in \mathcal{S}} p_{ij} v(j) \quad \text{pour } i \neq s$$

- Version avec les  $r_{ij}$

$$v(i) = \sum_{j \in \mathcal{S}} p_{ij} (r_{ij} + v(j))$$

## Exemple 1




$$\begin{cases} v(1) = 10 + v(2) \\ v(2) = \frac{1}{2}v(1) + \frac{1}{2}v(3) \\ v(3) = 0 \end{cases} \Rightarrow \begin{cases} v(1) = 20 \\ v(2) = 10 \\ v(3) = 0 \end{cases}$$

## Exemple 2 : Roulette (exercice 8)

Écrire un système linéaire permettant d'obtenir  $v(i)$  en partant d'un état  $i$ .

# Travail pour la prochaine fois



- Obtenir  $v$  par deux méthodes :
  - ▶ En résolvant un système linéaire
  - ▶ En implémentant l'algorithme d'itération sur la valeur
- Tester votre algorithme avec différents vecteurs initiaux  $v_0$  et différents critères d'arrêt  $\epsilon$
- Devrait donner  $v = [15 \ 7 \ 0]^\top$
- Roulette (exercice 8) : résoudre les équations de Bellman de manière exacte et par itération sur la valeur. Vérifier que la récompense obtenue est cohérent avec les résultats de l'exercice 8.

# Récompense actualisé

- Soit  $r_{max} = \max_{i \in \mathcal{S}} |r_i|$
- La fonction de valeur est alors bornée

$$|v(i)| \leq \sum_{t=0}^{\infty} \gamma^t r_{max} = \frac{r_{max}}{1 - \gamma}$$


- La fonction de valeur est alors solution des équations de Bellman suivantes

$$\forall i \in \mathcal{S}, \quad v(i) = r_i + \gamma \sum_{j \in \mathcal{S}} p_{ij} v(j)$$

# Pourquoi actualiser ?

- Si les récompenses sont financières, les récompenses immédiates ont plus de valeur
- Les êtres vivants préfèrent les récompenses immédiates
- Évite de cycler
- Lorsqu'il n'y a pas d'état terminal

## Exemple avec $\gamma = 0.8$



$$\begin{cases} v(1) = 5 + \gamma \times v(2) \\ v(2) = \gamma \times \left[ \frac{1}{4}v(1) + \frac{3}{4}v(2) \right] \end{cases} \Rightarrow \begin{cases} v(1) = \frac{25}{3} \\ v(2) = \frac{25}{6} \end{cases}$$

# Version matricielle des équations de Bellman

- Notons  $1, \dots, n$  les états **non terminaux**
- $P = (p_{ij})$  : matrice de transition excluant les états terminaux
- Cette matrice n'est pas stochastique

$$\begin{bmatrix} v(1) \\ \vdots \\ v(n) \end{bmatrix} = \begin{bmatrix} r_1 \\ \vdots \\ r_n \end{bmatrix} + \gamma \begin{bmatrix} p_{11} & \cdots & p_{1n} \\ \vdots & \ddots & \vdots \\ p_{n1} & \cdots & p_{nn} \end{bmatrix} \begin{bmatrix} v(1) \\ \vdots \\ v(n) \end{bmatrix}$$

$$v = r + \gamma P v$$

$$v = (I - \gamma P)^{-1} r$$

# Algorithme d'itération sur la valeur

- Distance entre deux fonctions de valeur  $u$  and  $w$  avec la norme  $\infty$

$$\|u - w\| = \max_{i \in \mathcal{S}} |u(i) - w(i)|$$

## Algorithme d'itération sur la valeur

- $v_0$  arbitraire ( $v_0 \in \mathbb{R}^n$ )
  - $v_{k+1} = r + \gamma P v_k$
  - Critère d'arrêt :  $\|v_{k+1} - v_k\|_\infty < \epsilon$
- 
- Si  $\gamma < 1$  ou si il existe un état terminal, alors la suite  $(v_k)$  converge vers l'unique solution de

$$v = r + \gamma P v$$

- A quelle distance est-on de  $v$  pour un  $\epsilon$  donné ?  $\|v_k - v\|_\infty \leq ?$

# Preuve de la convergence si $\gamma < 1$

- Opérateur  $L(v) = r + \gamma P v$
- Les équations de Bellman s'écrivent

$$v = L(v)$$

- L'opérateur  $L$  est  $\gamma$ -contractant


$$\|L(u) - L(w)\| \leq \gamma \|u - w\|$$

- $L^k(u)$  : applique  $k$  fois l'opérateur  $L$  à  $u$
- Par le théorème du point fixe de Banach, la suite  $(v_k)$  converge vers l'unique solution de  $v = L(v)$  avec une vitesse de convergence linéaire

$\gamma$


$$\|v_k - v\| = \|L^k(v_0) - L^k(v)\| \leq \gamma^k \|v_0 - v\|$$

## Exemple with $\gamma = 1$ and $v_0 = 0$



$k$	$v_k(1)$	$v_k(2)$	$v_k(3)$
0	0	0	0
1	10	0	0
2	10	5	0
3	15	5	0
4	15	7.5	0
...	...	...	...
10	19.375	9.688	0
...	...	...	...
50	20.000	10.000	0

Exemple with  $\gamma = 0.8$  and  $v_0 = 0$



$k$	$v_k(1)$	$v_k(2)$
0	0	0
1	5	0
2	5	1
3	5.8	1.6
4	6.28	2.12
...	...	...
10	7.796	3.630
...	...	...
50	8.333	4.167
...	...	...
100	8.333	4.167

# Itération sur la valeur "In-place"

- L'itération sur la valeur **Synchrone** stocke deux copies de la fonction de valeur

$$\forall i \in \mathcal{S}, \quad v_{new}(i) \leftarrow r_i + \sum_{j \in \mathcal{S}} p_{ij} v_{old}(j)$$

- La version **In-place** stocke une seule copie

$$\forall i \in \mathcal{S}, \quad v(i) \leftarrow r_i + \sum_{j \in \mathcal{S}} p_{ij} v(j)$$

- La version in-place est plus efficace car tient compte de la dernière mise à jour
- Son efficacité dépend de l'ordre de parcours des états

# Lien entre récompense non actualisée (avec état terminal) et récompense actualisée

- Récompense totale actualisée avec probabilités de transition ( $p_{ij}$ )

$$v(i) = r_i + \gamma \sum_{j \in \mathcal{S}} p_{ij} v(j)$$


- Récompense totale avec espace d'état  $\mathcal{S} \cup t$  avec  $t$  l'état terminal et les probabilités de transition suivantes  $p'_{ij} = \gamma p_{ij}, \forall i, j \in \mathcal{S}$  and  $p'_{it} = 1 - \gamma, \forall i \in \mathcal{S}$

$$\begin{aligned} v(i) &= r_i + \sum_{j \in \mathcal{S} \cup t} p'_{ij} v(j) \\ &= r_i + \gamma \sum_{j \in \mathcal{S}} p_{ij} v(j) \end{aligned}$$


- Les équations étant les mêmes, la fonction de valeur est identique
- Récompense totale actualisée = cas particulier de la récompense totale avec état terminal

# Exemple

Récompense totale actualisée avec  $\gamma \in ]0, 1[$



Récompense totale (non actualisée) équivalente, avec un état terminal



# Gain moyen


- $g$  : gain moyen

$$g = \lim_{T \rightarrow \infty} E \left[ \frac{1}{T} \sum_{t=0}^T R_t \right]$$

- Le gain moyen est indépendant de l'état initial si la chaîne de Markov est irréductible (ou uni-chaîne)

$$g = \sum_{i \in \mathcal{S}} \pi_i r_i$$

## Exemple




$$\begin{aligned} g &= \pi_1 r_1 + \pi_2 r_2 \\ &= 0.2 \times 5 + 0.8 \times 10 \\ &= 9 \end{aligned}$$

# Lien entre gain moyen et récompense actualisée

- Hypothèse : chaîne de Markov uni-chain

$$\forall i, \quad g = \lim_{\gamma \rightarrow 1^-} (1 - \gamma)v(i)$$

## Exemple



$$g = 1$$

$$v(2) = 1 + \gamma + \gamma^2 + \dots = \frac{1}{1 - \gamma}$$

$$v(1) = 2 + \gamma v(2) = 2 + \frac{\gamma}{1 - \gamma}$$

- 1 Introduction
- 2 Chaînes de Markov à temps discret
- 3 Chaînes de Markov avec récompenses (évaluer une politique)
  - Distributions connues
  - Distributions inconnues
- 4 Processus de décision markovien (déterminer la politique optimale)
  - Horizon infini
  - Horizon fini
- 5 Apprentissage par renforcement (environnement inconnu)
  - Bandit manchot
  - Processus de décision markovien
- 6 Chaîne de Markov à temps continu

# Récompenses et distributions inconnues

- Probabilités  $p_{ij}$  inconnues
- Récompenses  $r_{ij}$  inconnues
- Épisode =  $S_0, R_0, S_1, R_1, \dots, S_T, R_T$
- On peut simuler un grand nombre d'épisodes

# Loi des grands nombres

- $X$  : variable aléatoire d'espérance  $\mu$  et d'écart-tupe  $\sigma$  (ex : la récompense obtenue lors d'un épisode)
- $X_1, X_2, \dots, X_n$  : variables aléatoires i.i.d. de mêmes distribution que  $X$
- Moyenne empirique

$$\mu_n = \frac{X_1 + \dots + X_n}{n}$$

- Elle converge vers  $\mu = E(X)$

$$\mu_n \xrightarrow[n \rightarrow \infty]{} \mu$$

# Moyenne incrémentale et taux d'apprentissage


- $\mu_k$  : moyenne de  $(X_1, \dots, X_k)$
- $\mu_0 = 0$

$$\underbrace{\mu_k}_{\text{Nouvelle estimation}} = \left(1 - \frac{1}{k}\right) \cdot \underbrace{\mu_{k-1}}_{\text{Ancienne estimation}} + \underbrace{\frac{1}{k}}_{\text{Taux apprentissage}} \cdot \underbrace{X_k}_{\text{Nouvelle valeur}}$$

$$\mu_k = \mu_{k-1} + \frac{1}{k}(X_k - \mu_{k-1})$$

# Exemple

- $X$  est distribuée suivant une loi normale ( $\mu = 100$  and  $\sigma = 10$ )
- On trace  $\mu_k$  pour  $k = 1, \dots, 1000$  pour deux épisodes



# Autres taux d'apprentissage

$$\underbrace{\mu_k}_{\text{Nouvelle estimation}} = (1 - \alpha_k) \cdot \underbrace{\mu_{k-1}}_{\text{Ancienne estimation}} + \underbrace{\alpha_k}_{\text{Taux d'apprentissage}} \cdot \underbrace{X_k}_{\text{Ancienne valeur}}$$
$$= \mu_{k-1} + \alpha_k (X_k - \mu_{k-1})$$

- Si  $\alpha_k = \frac{1}{k}$ , on obtient la moyenne empirique
- Condition de convergence vers  $\mu$  (Robbins-Monro) :
  - ▶  $\sum_k \alpha_k = +\infty$
  - ▶  $\sum_k \alpha_k^2 < \infty$
- If  $\alpha_k = \alpha$ 
  - ▶ Ne converge pas vers  $\mu$
  - ▶ Préférable pour un environnement non stationnaire

# Travail à la maison

- $X$  distribuée suivant une loi normale ( $\mu = 100$  et  $\sigma = 20$ )
- Tracer  $\mu_k$  pour  $k = 1$  à  $k = n$
- Tester plusieurs taux d'apprentissage
  - ▶  $\alpha_k = \frac{1}{k}$
  - ▶  $\alpha_k = \alpha$  (faire varier  $\alpha$  dans  $[0, 1]$ )
  - ▶  $\alpha_k = \frac{1}{k^a}$  (faire varier  $a$ )
- Faire varier  $n$  (e.g.  $n = 10^2, 10^3, 10^4, \dots$ )
- Faire varier  $\mu_0$  (e.g.  $\mu_0 = 0, 50, 100, 150$ )
- Commenter

# Simulation de Monte-Carlo




- Hypothèse : Tous les épisodes terminent
- Épisode :  $S_0, R_0, S_1, R_1, \dots$
- Récompense à partir de  $t$  :

$$G_t = R_t + \gamma R_{t+1} + \gamma^2 R_{t+2} + \dots$$

$$v(s) = E(G_t | S_t = s)$$

- $V(s)$  : estimation de  $v(s)$




# Monte-Carlo First-Visit



$$V(1) = \frac{1}{2} [(2 + 5\gamma) + (-3 + 4\gamma + 6\gamma^2 + 3\gamma^3)]$$

$$V(2) = \frac{1}{2} [5 + (4 + 6\gamma + 3\gamma^2)]$$

# Monte-Carlo Every Visit



$$V(1) = \frac{1}{4} [(2 + 5\gamma) + (-3 + 4\gamma + 6\gamma^2 + 3\gamma^3) + (6 + 3\gamma) + 3]$$

# Monte-Carlo Every-Visit : algorithme

- $V(s)$  : estimation de  $v(s)$
- $Gains(s)$  : liste vide

## Boucle (pour chaque épisode)

- Générer un épisode  $S_0, R_0, S_1, R_1, \dots, S_T$
- $G \leftarrow 0$
- Pour  $t = T - 1, T - 2, \dots, 0$ 
  - 1  $G \leftarrow G + \gamma R_t$
  - 2 Ajouter  $G$  à  $Gains(S_t)$
  - 3  $V(S_t) \leftarrow \text{moyenne}(Gains(S_t))$
- $V$  converge vers  $v$  (loi des grands nombres)

# Monte-Carlo Every-Visit : version incrémentale

- $V(s)$  : estimation de  $v(s)$ , initialisée à 0 par exemple
- $Gains(s)$  : liste vide
- $N(s) \leftarrow 0$  : compteur du nombre de visites

## Boucle (pour chaque épisode)

- Générer un épisode  $S_0, R_0, S_1, R_1, \dots, S_T$
- $G \leftarrow 0$
- Pour  $t = T - 1, T - 2, \dots, 0$ 
  - 1  $G \leftarrow G + \gamma R_t$
  - 2  $N(S_t) \leftarrow N(S_t) + 1$
  - 3  $V(S_t) \leftarrow V(S_t) + \frac{1}{N(S_t)}(G - V(S_t))$

- Pour des problèmes non stationnaires, il est utile d'oublier les anciens épisodes

$$V(S_t) \leftarrow V(S_t) + \alpha(G - V(S_t))$$

# Temporal-Difference learning : TD(0)

- $V(s)$  : estimation de  $v(s)$
- Initialiser par exemple avec  $V(s) = 0, \forall s$  (doit être égal à 0 pour un état terminal)

## Boucle (pour chaque épisode)

- Initialiser l'état  $S$
- Tant que  $S$  n'est pas terminal
  - 1 Observer  $R$  et  $S'$  (récompense et état suivant)
  - 2 Mettre à jour  $V$


$$\underbrace{V(S)}_{\text{Nouvelle estimation}} \leftarrow (1 - \alpha) \underbrace{V(S)}_{\text{Ancienne estimation}} + \underbrace{\alpha}_{\text{Taux d'apprentissage}} [R + \gamma \underbrace{V(S')}_{\text{Estimation du gain futur}}]$$

- 3  $S \leftarrow S'$

- $V$  converge vers  $v$  sous les conditions de Robbins-Monro

- 1 Introduction
- 2 Chaînes de Markov à temps discret
- 3 Chaînes de Markov avec récompenses (évaluer une politique)
  - Distributions connues
  - Distributions inconnues
- 4 Processus de décision markovien (déterminer la politique optimale)
  - Horizon infini
  - Horizon fini
- 5 Apprentissage par renforcement (environnement inconnu)
  - Bandit manchot
  - Processus de décision markovien
- 6 Chaîne de Markov à temps continu

# Plus court chemin déterministe




- $d_{ij}$  : distance du sommet  $i$  au sommet  $j$  ( $d_{12} = 5$ )
- $s$  : source ( $s = 1$ )
- $t$  : destination ( $t = 7$ )
- Objectif : trouver le plus court chemin de  $s$  to  $t$

# Fonction de valeur


- $v^*(i)$  : distance minimale entre le sommet  $i$  et la destination
- $Succ(i)$  : ensemble des successeurs de  $i$  ( $Succ(1) = \{2, 3\}$ )
- Équations d'optimalité

$$v^*(i) = \min_{j \in Succ(i)} d_{ij} + v^*(j)$$




# Plus court chemin stochastique

- Trouver la distance minimale (en espérance) de la source  $s$  à la  $t$



# Fonctions de valeur

- $v^*(i)$  : distance minimale (en espérance) de  $i$  à la destination finale
- $q^*(i, a)$  : distance minimale (en espérance) de  $(i, a)$  à la destination finale




- $q^*(1, a) = \frac{1}{2}[3 + v^*(2)] + \frac{1}{2}[4 + v^*(3)] = 5$
- $q^*(1, a') = 2 + v^*(3) = 4$
- $v^*(1) = \min[q^*(1, a), q^*(1, a')] = 4$

# Processus de décision markovien (=MDP)

- 5 ingrédients
  - ▶  $\mathcal{S}$  : Espace d'états (que nous supposerons fini)
  - ▶  $\mathcal{A}$  : Espace d'actions (que nous supposerons fini)
  - ▶  $p_{ij}(a)$  : Probabilité d'aller de l'état  $i$  vers l'état  $j$  si l'action  $a$  est choisie
  - ▶  $r_i(a)$  : Récompense si l'action  $a$  est choisie dans l'état  $i$
  - ▶ Objectif : Déterminer la politique qui maximise l'espérance du gain total (taux d'actualisation  $\gamma$ )
  
- Une **politique** spécifie l'action à prendre à chaque instant (quel que soit l'état, l'instant, l'historique des états et des actions, ...)

# Récompenses sur les arcs ou les sommets



- On peut passer des récompenses sur les arcs à des récompenses sur les sommets sans changer le gain total


$$r_i(a) = \sum_{j \in \mathcal{S}} p_{ij}(a) r_{ij}(a)$$

# Dynamique

État à l'instant  $t$

Actions

États à  $t + 1$



# Politiques de décision

- On peut montrer qu'il existe une politique optimale avec les propriétés suivantes :
  - ▶ markovienne (la décision ne dépend que de l'état courant)
  - ▶ déterministe (non aléatoire)
  - ▶ stationnaire (quel que soit l'instant  $t$ , la même décision est prise dans l'état  $i$ )

- Dans la suite, nous considérerons des politiques avec ces trois propriétés

- On notera  $\pi$  une politique

- $a(i)$  : action prise dans l'état  $i$

- Une telle politique peut être décrite simplement

État $i$		1	2	3	...
Action $a(i)$		Up	Down	Left	...


- $|\mathcal{A}|^{|\mathcal{S}|}$  politiques possibles

# Fonction de valeur optimale

- $v^*(i)$  : Récompense optimale (en espérance) en partant de l'état  $i$
- $q^*(i, a)$  : Récompense optimale (en espérance) en prenant l'action  $a$  dans l'état  $i$  et en appliquant ensuite la politique optimale

$$v^*(i) = \max_{a \in \mathcal{A}} q^*(i, a)$$

# Équations d'optimalité pour $v^*$




$$q^*(i, a) = \sum_j p_{ij}(a) [r_{ij}(a) + \gamma v^*(j)]$$

$$v^*(i) = \max_a q^*(i, a)$$

$$v^*(i) = \max_a r_i(a) + \gamma \sum_j p_{ij}(a) v^*(j)$$

# Équations d'optimalité pour $q^*$




$$q^*(i, a) = r_i(a) + \gamma \sum_j p_{ij}(a) v^*(j)$$

$$v^*(j) = \max_{a'} q^*(j, a')$$

$$q^*(i, a) = r_i(a) + \gamma \sum_j p_{ij}(a) \max_{a'} q^*(j, a')$$

# Comment aller à son travail ?



- Objectif : minimiser le temps (en espérance) pour aller à son travail
- Écrire les équations d'optimalité

# Algorithme d'itération sur la valeur

- Les équations de Bellman sont des équations au point fixe

$$v^*(i) = \max_a r_i(a) + \gamma \sum_j p_{ij}(a) v^*(j)$$

- Soit la suite de fonctions de valeur  $v_k$  définie par

$$v_{k+1}(i) = \max_a r_i(a) + \gamma \sum_j p_{ij}(a) v_k(j)$$

- Si  $v_k$  converge, alors elle converge vers  $v^*$

# Algorithme d'itération sur la valeur

- Soit l'opérateur  $T$  tel que


$$v^*(i) = \underbrace{\max_a r_i(a) + \gamma \sum_j p_{ij}(a) v^*(j)}_{Tv^*(i)}$$

- Point fixe :  $v^* = Tv^*$
- On peut montrer que l'opérateur  $T$  est  $\gamma$ -contractant

## Algorithme d'itération sur la valeur

- ▶  $v_0$  arbitraire
- ▶  $v_{k+1} = Tv_k$
- ▶ Critère d'arrêt :  $\|v_{k+1} - v_k\|_\infty < \epsilon$
- La suite  $v_k$  converge vers  $v^*$ 
  - ▶ si  $\gamma < 1$
  - ▶ si  $\gamma = 1$  et qu'il existe un état terminal atteint avec probabilité 1 quelle que soit la politique

# Comment aller à son travail ?



- Écrire deux itérations de l'algorithme d'itération sur la valeur, en prenant  $v_0 = 0$

# Comment obtenir la politique optimale à la fin de l'algorithme ?


- A la fin de l'algorithme, nous avons  $v^*$  (ou du moins une bonne approximation)
- L'action optimale  $a^*(i)$  dans l'état  $i$  est alors

$$a^*(i) = \arg \max_a q^*(i, a)$$

où


$$q^*(i, a) = r_i(a) + \gamma \sum_{j \in \mathcal{S}} p_{ij}(a) v^*(j)$$

# La politique optimale peut dépendre du taux d'actualisation




- Quel est le chemin de 0 à  $(n + 1)$  ayant le plus grand gain ?
- Le chemin du bas procure un gain de 1
- Le chemin du haut procure un gain de  $2\gamma^n$
- Si  $\gamma = 1$ , il vaut mieux toujours passer par en haut
- If  $\gamma < 1$ , il peut être plus intéressant de passer par en bas (par exemple si  $\gamma = 0.9$  et  $n = 10$ )

# Le taux d'actualisation permet d'éviter des cycles



- De manière évidente, nous avons  $v^*(1) = v^*(2) = 1$  et  $v^*(0) = 0$
- Dans l'état 1,
  - ▶ si  $\gamma = 1$ , il est équivalent d'aller en 2 ou en 3 depuis l'état 1
  - ▶ si  $\gamma < 1$ , il vaut mieux toujours aller dans l'état 3

# Algorithme d'itération sur la politique



## Algorithme d'itération sur la politique

- Choisir une politique  $\pi$  arbitrairement et prendre  $\pi' = \emptyset$
- Tant que  $\pi'$  différent de  $\pi$ 
  - 1 Évaluation de la politique : déterminer  $v^\pi$
  - 2 Amélioration de la politique : obtenir une politique  $\pi'$  meilleure que  $\pi$

$$\forall i, v^{\pi'}(i) \geq v^\pi(i)$$

# Algorithme d'itération sur la politique : Evaluation de la politique

- $\pi$  : politique à l'itération  $k$  de l'algorithme
- $a(i)$  : action prise dans l'état  $i$
- Déterminer  $v^\pi$  en résolvant les équations de Bellman

$$v^\pi(i) = r_i(a(i)) + \gamma \sum_j p_{ij}(a(i)) v^\pi(j)$$

# Itération sur la politique : Amélioration de la politique

- $\pi$  : politique à l'itération  $k$  de l'algorithme
- $\pi'$  : politique à l'itération  $k$  de l'algorithme
- Dans l'état  $i$ , la politique  $\pi'$  sélectionne l'action  $a$  qui maximise

$$r_i(a) + \gamma \sum_j p_{ij}(a) v^\pi(j) \quad (1)$$

- On peut montrer que la politique obtenue est de récompense supérieure

$$v^{\pi'} \geq v^\pi$$

# Frozen lake (lac gelé)




- Objectif : atteindre le cadeau (récompense de +1 si on l'atteint)

# Frozen lake - États

S <sup>0</sup>	F <sup>1</sup>	F <sup>2</sup>	F <sup>3</sup>
F <sup>4</sup>	H <sup>5</sup>	F <sup>6</sup>	H <sup>7</sup>
F <sup>8</sup>	F <sup>9</sup>	F <sup>10</sup>	H <sup>11</sup>
H <sup>12</sup>	F <sup>13</sup>	F <sup>14</sup>	G <sup>15</sup>


- S = Start, F = Frozen, H = Hole, G = Goal
- États :  $\mathcal{S} = \{0, 1, 2, \dots, 15\}$

# Version déterministe - Actions




- Actions :  $\mathcal{A} = \{0, 1, 2, 3\}$  (left, down, right, up)
- Dans un trou H, n'importe quelle action vous laisse dans H (idem pour G)
- Aux bords, un mouvement vers l'extérieur vous laisse dans le même état

# Version déterministe - Une politique optimale




Etat $i$	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Action $a(i)$	2	2	1	0	1	-	1	-	2	2	1	-	-	2	2	-

# Version stochastique - Probabilités de transition




- Aux bords, un mouvement vers l'extérieur vous laisse dans le même état

# Version stochastique - Une politique optimale



État $i$	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Action $a(i)$	0	3	3	3	0	-	0	-	3	1	0	-	-	2	1	-

# Chaîne de Markov si on applique la politique optimale



- On peut montrer que la probabilité d'absorption par le sommet 15 est de  $\frac{14}{17}$

# Frozen lake - Notations et politiques considérées

- $P$  = Pourcentage de fois où l'on atteint le sommet  $G$
- $N$  = nombre d'étapes nécessaires pour atteindre le but  $G$ , quand il est atteint
- Politique aléatoire : politique qui choisit l'action  $a \in \{0, 1, 2, 3\}$  avec probabilité  $1/4$
- Politique optimale : politique qui maximise le gain total (en espérance), c'est-à-dire qui maximise la probabilité d'atteindre le cadeau

# Travail à la maison concernant Frozen lake

- On considère la version déterministe dans un premier temps
  - ▶ Écrire les équations d'optimalité avec un taux d'actualisation  $\gamma$
  - ▶ Implémenter un algorithme d'itération sur la valeur qui retourne la fonction de valeur optimale ainsi que la politique optimale
  - ▶ Tester votre algorithme pour  $\gamma = 1$  et  $\gamma = 0.99$
  - ▶ Utiliser une simulation de Monte-Carlo avec 10 000 épisodes (ou plus) pour estimer P et N
    - ★ Avec la politique optimale
    - ★ Avec la politique aléatoire
  - ▶ Commenter
- Mêmes questions pour la version stochastique

- 1 Introduction
- 2 Chaînes de Markov à temps discret
- 3 Chaînes de Markov avec récompenses (évaluer une politique)
  - Distributions connues
  - Distributions inconnues
- 4 Processus de décision markovien (déterminer la politique optimale)
  - Horizon infini
  - Horizon fini
- 5 Apprentissage par renforcement (environnement inconnu)
  - Bandit manchot
  - Processus de décision markovien
- 6 Chaîne de Markov à temps continu

# Horizon fini

- Horizon de temps  $\{0, \dots, T\}$
- $R_t$  : récompense à la période  $t$
- $v^*(i)$  : Récompense optimale en partant de l'état  $i$

$$v^*(i) = \mathbb{E}[R_0 + \gamma R_1 + \dots + \gamma^{T-1} R_{T-1} | S_0 = i]$$


- Sous-problème de  $t$  à  $T$
- $v_t^*(i)$  : Récompense optimale de  $t$  à  $T$  en partant de l'état  $i$  à l'instant  $t$

$$v_t^*(i) = \mathbb{E}[R_t + \gamma R_{t+1} + \dots + \gamma^{T-1-t} R_{T-1} | S_t = i]$$

# Politiques de décision

- On peut montrer qu'il existe une politique optimale avec les propriétés suivantes :
  - ▶ markovienne (la décision ne dépend que de l'état courant)
  - ▶ déterministe (non aléatoire)
- Dans la suite, nous considérerons des politiques avec ces deux propriétés
- On notera  $\pi$  une politique
- $a(i, t)$  : action prise dans l'état  $i$  à l'instant  $t$
- $|\mathcal{A}|^{T|S|}$  politiques possibles

# Relation entre $v_t^*$ et $v_{t+1}^*$



$$\begin{aligned}v_t^*(i) &= \max_a r_i(a) + \gamma \sum_{j \in \mathcal{S}} p_{ij} v_{t+1}^*(j) \\ &= \max_a q_t^*(i, a)\end{aligned}$$


# Programme dynamique en $O(|A| \times |\mathcal{S}|^2 \times T)$

## Programme dynamique



- Initialisation :  $v_T^*(i) = 0$  pour  $i \in \mathcal{S}$
- Pour  $t = T - 1, \dots, 0$ 
  - ▶ Pour  $i \in \mathcal{S}$

$$v_t^*(i) = \max_a r_i(a) + \gamma \sum_{j \in \mathcal{S}} p_{ij}(a) v_{t+1}^*(j)$$

- $v^* = v_0^*$



- Calculer  $v_t^*(i)$  pour chaque état  $i$  et chaque instant  $t$
- Calcul  $q_t^*(i, a)$  pour chaque paire d'état-action  $(i, a)$  et chaque instant  $t$
- Donner une politique optimale



- 1 Introduction
- 2 Chaînes de Markov à temps discret
- 3 Chaînes de Markov avec récompenses (évaluer une politique)
  - Distributions connues
  - Distributions inconnues
- 4 Processus de décision markovien (déterminer la politique optimale)
  - Horizon infini
  - Horizon fini
- 5 Apprentissage par renforcement (environnement inconnu)
  - Bandit manchot
  - Processus de décision markovien
- 6 Chaîne de Markov à temps continu

- 1 Introduction
- 2 Chaînes de Markov à temps discret
- 3 Chaînes de Markov avec récompenses (évaluer une politique)
  - Distributions connues
  - Distributions inconnues
- 4 Processus de décision markovien (déterminer la politique optimale)
  - Horizon infini
  - Horizon fini
- 5 Apprentissage par renforcement (environnement inconnu)
  - Bandit manchot
  - Processus de décision markovien
- 6 Chaîne de Markov à temps continu

# Problème du bandit manchot




- $N$  machines à sous
- La machine  $i$  offre une récompense  $X_i$  de loi inconnue
- $\mu_i = E(X_i)$  : récompense moyenne de la machine  $i$
- Objectif : Maximiser le gain total (en espérance) après  $T$  essais

## Exemple

<https://cse442-17f.github.io/LinUCB/>

# Problème du bandit manchot = MDP à 1 état

- Exemple avec deux machines



- Objectif : maximiser l'espérance du gain total (ou moyen) sur  $T$  périodes

## 2 algorithmes naifs

### RANDOM

- Choisir une machine au hasard

### GREEDY (= glouton)

- $\bar{x}_i$  : Récompense moyenne obtenue par la machine  $i$  jusqu'à présent
- Jouer la machine de plus grand  $\bar{x}_i$

### Exprimer le gain moyen des 3 politiques suivantes

- RANDOM
- GREEDY après une phase d'initialisation avec un essai par machine
- Politique optimale

# Politique optimale et regret

## Politique optimale

- Sélectionner la machine ayant la plus grande espérance de récompense

$$\mu^* = \max_i \mu_i$$

- Espérance du gain :  $T\mu^*$


## Politique d'apprentissage $\pi$

- $R_t^\pi$  : récompense obtenue à l'étape  $t$  par la politique  $\pi$
- Regret

$$\text{Regret}_T^\pi = \underbrace{T\mu^*}_{\text{récompense optimale}} - \underbrace{E\left(\sum_{t=1}^T R_t^\pi\right)}_{\text{récompense de } \pi}$$

# Exemple avec deux machines

- Récompenses :  $X_1 \sim \mathcal{N}(\mu_1, 1)$  et  $X_2 \sim \mathcal{N}(\mu_2, 1)$
- MDP avec un état et 2 actions



- Après 100 étapes,  $\pi$  a choisi 75 fois l'action 1 et 25 fois l'action 2

$$t_1 = 75$$

$$t_2 = 25$$

- Les récompenses moyennes empiriques sont

$$\bar{x}_1 = 10.1$$

$$\bar{x}_2 = 9.2$$

- Quelle machine choisir à l'étape suivante ?

# Exploration versus exploitation

- **Exploration** : Essayer d'obtenir plus d'information sur l'environnement
- **Exploitation** : Exploiter l'information connue pour maximiser sa récompense
- Il est important à la fois d'explorer et d'exploiter

## Exemple du bandit manchot à 2 machines

- Exploitation : choisir la machine 1 qui est le meilleur choix avec l'information dont je dispose
- Exploration : choisir la machine 2

## 2 algorithmes fondateurs

### $\epsilon$ -greedy

- Explorer avec probabilité  $\epsilon$
- Exploiter avec probabilité  $(1 - \epsilon)$

### UCB : Upper Confidence Bound

- Optimisme face à l'incertitude
  - Intervalles de confiance sur les  $\mu_i$  :  $\mu_i \in [\mu_i^{min}, \mu_i^{max}]$
  - Choisir la machine  $i$  de plus grand  $\mu_i^{max}$
- 
- Les idées de ces algorithmes sont applicables à des MDP à plusieurs états

# Algorithme $\epsilon$ -greedy

- $\bar{x}_i$  : Récompense moyenne obtenue par la machine  $i$  jusqu'à présent

## Algorithme $\epsilon$ -greedy

- Avec probabilité  $\epsilon$ , jouer une machine au hasard (exploration)
- Avec probabilité  $1 - \epsilon$ , jouer la machine de plus grand  $\bar{x}_i$  (exploitation)

- Le regret est linéaire

$$\text{Regret}_T^\epsilon = O(T)$$

- Si  $\epsilon_t = \frac{a}{t}$ , le regret est logarithmique

$$\text{Regret}_T^{\epsilon_t} = O(\log T)$$

# Algorithme UCB<sup>6</sup>

- $\bar{x}_i$  : Récompense moyenne obtenue par la machine  $i$  jusqu'à présent
- $t_i$  : nombre de fois où la machine  $i$  à été jouée
- $T$  : nombre total d'étapes ( $= \sum_i t_i$ )
- $c$  : paramètre contrôlant le degré d'exploration

## Algo UCB

- Initialisation : Jouer une fois chaque machine

- Jouer la machine  $i$  qui maximise  $\bar{x}_i + c \sqrt{\frac{\ln T}{t_i}}$

- Le regret est logarithmique si les récompenses sont bornées
- L'intervalle de confiance vient de l'inégalité de Hoeffding

---

6. Auer, Cesa-Bianchi and Fischer (2002). Finite-time analysis of the multiarmed bandit problem. Machine learning, 47

# Inégalité de Hoeffding

- $X_1, \dots, X_n$  : v.a. indépendantes telles que

$$a_k \leq X_k \leq b_k$$

- $S_n = X_1 + \dots + X_n$
- Alors, pour tout  $\alpha > 0$

$$P(S_n \geq E[S_n] + \alpha) \leq \exp\left(-\frac{2\alpha^2}{\sum_{i=1}^n (b_i - a_i)^2}\right)$$

# Idée pour obtenir la borne supérieure de UCB

- Soit  $X_1, \dots, X_t$  i.i.d. avec  $a_k = 0, b_k = 1, E(X_k) = \mu$
- En posant  $u = \alpha/t$ , il vient

$$P(\bar{X}_t \geq \mu + u) \leq \exp(-2ut^2)$$

- Solving  $P(\bar{X}_t \geq \mu + u) = p$  gives



$$u = \sqrt{\frac{-\ln p}{2t}}$$

- Diminuer  $p$  avec le nombre total de parties  $T$ , e.g.  $p = \frac{1}{T^4}$

$$u = \sqrt{\frac{2 \ln T}{t}}$$

# Exemple de résultats numériques <sup>7</sup>


- 2 machines
- Récompenses distribuées suivant des lois de Bernoulli (paramètres 0.9 et 0.8)



7. Auer, Cesa-Bianchi and Fischer (2002). Finite-time analysis of the multiarmed bandit problem. Machine learning, 47


# Jeu d'instances de Sutton et Barto (2018)

- 10 machines à sous
- Récompense du bras  $i$  :  $X_i \sim \mathcal{N}(\mu_i, 1)$  où  $\mu_i \sim \mathcal{N}(0, 1)$
- 2000 instances générées. Un exemple ci-dessous.




# Performances de $\epsilon$ -greedy

- Initialisation :  $Q(a) = 0$  pour chaque machine  $a$




# Estimation initiale optimiste

- Initialisation :  $Q(a) = +5$  pour chaque machine  $a$




# Le paramétrage est un art [Sutton et Barto, 2018]



- Chaque point représente la récompense moyenne pour un algorithme donné avec un paramétrage donné

- 1 Introduction
- 2 Chaînes de Markov à temps discret
- 3 Chaînes de Markov avec récompenses (évaluer une politique)
  - Distributions connues
  - Distributions inconnues
- 4 Processus de décision markovien (déterminer la politique optimale)
  - Horizon infini
  - Horizon fini
- 5 Apprentissage par renforcement (environnement inconnu)
  - Bandit manchot
  - Processus de décision markovien
- 6 Chaîne de Markov à temps continu

# Apprentissage par renforcement



- Etat  $\rightarrow$  Action  $\rightarrow$  Récompense  $\rightarrow$  Etat  $\rightarrow$  Action  $\rightarrow$  Récompense  $\rightarrow$  ...
- Récompenses et probabilités de transitions inconnues
- Objectif : maximiser le gain total
- Apprentissage par renforcement = Reinforcement learning = RL

# Apprentissage par renforcement dans un MDP

On considère un processus de décision markovien (MDP = Markov decision process)

- $\mathcal{S}$  et  $\mathcal{A}$  : Espace d'états et d'actions
- $p_{ij}(a)$  : Probabilités de transition **inconnues**
- $r_i(a)$  : Récompenses **inconnues**
- Objectif : Déterminer la politique qui minimise l'espérance du gain total (taux d'actualisation  $\gamma$ )

# Le MDP est une boîte noire

## Modèle avec simulateur

- Choisir un état  $S$  et une action  $A$
- Observer la récompense  $R$  et l'état suivant  $S'$

## Modèle navigant

- Initialiser l'état  $S$
- Tant que  $S$  n'est pas terminal
  - 1 Choisir une action  $A$
  - 2 Observer la récompense  $R$  et l'état suivant  $S'$
  - 3  $S \leftarrow S'$

# Regret d'une politique

- $\pi^*$  : politique optimale
- $\pi$  : une politique
- $R_t^\pi$  : récompense obtenue en période  $t$  par la politique  $\pi$
- Récompense totale (en espérance) de la politique  $\pi$  sur  $T$  périodes

$$v_T^\pi = E \left[ \sum_{t=1}^T R_t^\pi \right]$$

## Définition

Le **regret** de la politique  $\pi$  est la différence entre les récompenses de  $\pi^*$  et  $\pi$ .

$$\text{Regret}_T^\pi = v_T^* - v_T^\pi$$

# Politique no-regret

## Définition

Une politique  $\pi$  est dite **no-regret** si son regret est sous-linéaire.

$$\frac{\text{Regret}_T^\pi}{T} \xrightarrow{T \rightarrow +\infty} 0$$

- Si la politique est no-regret, le ratio de compétitivité tend vers 1

$$\frac{v_T^\pi}{v_T^*} \xrightarrow{T \rightarrow +\infty} 1$$

# Politique $\epsilon$ -greedy

- $Q(s, a)$  : estimation de  $q^*(s, a)$
- Politique gloutonne

$$\operatorname{argmax}_a Q(s, a)$$

- Politique  $\epsilon$ -greedy

$$a \leftarrow \begin{cases} \operatorname{argmax}_a Q(s, a) & \text{avec proba } 1 - \epsilon \quad (\text{exploitation}) \\ \text{random action} & \text{avec proba } \epsilon \quad (\text{exploration}) \end{cases}$$

# Algorithme de Q-learning

- Initialiser arbitrairement  $Q(s, a)$  pour tout  $s, a$  (doit valoir 0 pour les états terminaux)

## Pour chaque épisode

- Initialiser l'état  $S$
- Tant que  $S$  n'est pas terminal
  - 1 Choisir une action  $A$  selon la politique  $\epsilon$ -greedy
  - 2 Observer la récompense  $R$  et l'état suivant  $S'$
  - 3 Mettre à jour  $Q$

$$\underbrace{Q(S, A)}_{\text{Nouvelle estimation}} \leftarrow (1 - \alpha) \underbrace{Q(S, A)}_{\text{Ancienne estimation}} + \underbrace{\alpha}_{\text{Taux d'apprentissage}} [R + \gamma \underbrace{\max_{a'} Q(S', a')}_{\text{Estimation des récompenses futures}}]$$

- 4  $S \leftarrow S'$

# Q-learning : quelques remarques


- Mélange intelligent de simulation et de programmation dynamique
- On-line : propose une heuristique à tout instant

$$\operatorname{argmax}_a Q(s, a)$$


- Converge (doucelement) vers la politique optimale sous certaines conditions
- Peut fonctionner en environnement stationnaire
- "Deep Q-learning" : Lorsque l'espace d'états devient grand, on doit approcher la fonction  $Q(s, a)$  en utilisant par exemple des réseaux de neurones

# Pour aller plus loin


Puterman



Bertsekas



Sutton and Barto




Présentations et vidéos par David Silver sur le RL :  
<https://www.davidsilver.uk/teaching/>

# Programme de l'examen


- 1/3 sur les TP
- 1/3 tiré du polycopié d'exercices
- 1/3 surprise

- 1 Introduction
- 2 Chaînes de Markov à temps discret
- 3 Chaînes de Markov avec récompenses (évaluer une politique)
  - Distributions connues
  - Distributions inconnues
- 4 Processus de décision markovien (déterminer la politique optimale)
  - Horizon infini
  - Horizon fini
- 5 Apprentissage par renforcement (environnement inconnu)
  - Bandit manchot
  - Processus de décision markovien
- 6 Chaîne de Markov à temps continu

# Classification des processus aléatoires



# Chaîne de Markov à Temps Continu (CMTC)




## Définition

Le processus  $(X(t))_{t>0}$  est une CMTC si,  $\forall t_0 < t_1 < \dots < t_n$ ,

$$P[X(t_n) = i_n \mid X(t_{n-1}) = i_{n-1}, X(t_{n-2}) = i_{n-2}, \dots, X(t_0) = i_0] \\ = P[X(t_n) = i_n \mid X(t_{n-1}) = i_{n-1}]$$

- Une information détaillée du passé ne fournit pas plus d'info sur l'évolution future que la connaissance de la dernière observation

# Exemple : file d'attente (supermarché, serveur, ...)



# CMTC homogène


## Définition

*Une CMTC est dite homogène si les probabilités de transition ne dépendent que de la durée entre 2 observations*

$$P[X(t + s) = j | X(s) = i] = P[X(t) = j | X(0) = i]$$

- Par la suite, uniquement des CMTC homogènes

# Temps de séjour dans un état




## Propriété

Le temps de séjour  $T_i$  dans l'état  $i$  d'une CMTC homogène suit une loi exponentielle de taux  $\mu_i$ .

$$T_i \sim \exp(\mu_i)$$


# 1ère caractérisation d'une CMTC homogène

- $T_i \sim \exp(\mu_i)$  : temps de séjour dans l'état  $i$
- $p_{ij}$  : probabilité de transition de  $i$  à  $j$ , lorsqu'on quitte  $i$



# 1ère caractérisation d'une CMTC homogène

- Une CMTC homogène est entièrement définie par les  $\{\mu_i\}$  et les  $\{p_{ij}\}$



# Lois exponentielles

- Soit  $T \sim \exp(\lambda)$ .
- Densité

$$f(t) = \begin{cases} \lambda e^{-\lambda t} & \text{si } t \geq 0 \\ 0 & \text{sinon} \end{cases}$$

- Interprétation de la densité

$$f(t)dt \simeq P(t < T \leq t + dt)$$

- Fonction de répartition

$$F(t) = P(T \leq t) = \begin{cases} 1 - e^{-\lambda t} & \text{si } t \geq 0 \\ 0 & \text{sinon} \end{cases}$$

# Lois exponentielles (suite)

- Espérance, écart-type et coefficient de variation

$$E(T) = \sigma(T) = \frac{1}{\lambda}$$

$$cv(T) = \frac{\sigma(T)}{E(T)} = 1$$

- Le coefficient de variation est sans dimension et permet de comparer la variabilité de variables aléatoires dans des unités différentes

# Lois exponentielles (suite)

## Propriété

Soit deux v.a. indépendantes  $X_1 \sim \exp(\lambda_1)$  et  $X_2 \sim \exp(\lambda_2)$ . Alors :

- $\min(X_1, X_2) \sim \exp(\lambda_1 + \lambda_2)$

- $P(X_1 < X_2) = \frac{\lambda_1}{\lambda_1 + \lambda_2}$

- Généralisation à  $n$  lois exponentielles indépendantes :

$$\min(X_1, \dots, X_n) \sim \exp(\lambda_1 + \dots + \lambda_n)$$

$$P(X_1 < \min(X_2, \dots, X_n)) = \frac{\lambda_1}{\lambda_1 + \dots + \lambda_n}$$

# Taux de panne

## Définition

Le taux de panne d'une v.a. de densité  $f$  et de fonction de répartition  $F$  est la fonction

$$\tau(t) = \frac{f(t)}{1 - F(t)}.$$

- Interprétation en fiabilité : soit  $T$  la durée de vie d'un appareil.

$\tau(t)dt \simeq$  proba qu'une panne se produise entre  $t$  et  $t + dt$   
sachant que l'appareil fonctionne encore à  $t$

- Interprétation pour les CMTC : soit  $T$  le temps de séjour dans un état.

$\tau(t)dt \simeq$  proba de quitter l'état entre  $t$  et  $t + dt$   
sachant que l'on est encore dans cet état à  $t$

# Taux de panne d'une loi exponentielle

## Propriété

*Pour une loi exponentielle de taux  $\lambda$ , le taux de panne est constant :*

$$\tau(t) = \lambda$$

## Propriété

*La loi exponentielle est sans mémoire :*


$$P(T > s + t | T > s) = P(T > t)$$

# Travail à la maison

- Lire le chapitre 3.2 jusqu'à la page 75
- Exercices 9, 10, 11


## 2ème caractérisation d'une CMTC homogène (la plus couramment utilisée)

- $T_{ij} \sim \exp(\mu_{ij})$  : temps au bout duquel on passe de l'état  $i$  à l'état  $j$



- Si  $T_{ij} < T_{ik}$  pour tout  $k \neq j$ , aller dans l'état  $j$

## 2ème caractérisation d'une CMTC homogène




- $\mu_{ij}$  : taux de transition de  $i$  vers  $j$

$$\mu_{ij} = \frac{1}{E(T_{ij})}$$

- Unité des taux de transition :  $[s^{-1}]$


# Equivalence entre les 2 caractérisations



# Exemple : Nombre d'étudiants dans la salle

- Hypothèses et notations
  - ▶  $N(t)$  : nombre d'étudiants dans la salle à l'instant  $t$
  - ▶  $N(0) = 40$
  - ▶ Le  $i$ -ième étudiant de la salle sort après un temps  $T_i$  exponentiel de taux  $\mu$
  - ▶ Les dates de départ  $T_1, \dots, T_{40}$  sont supposées indépendantes les unes des autres
- Pourquoi  $N(t)$  est une CMTC ?
- Donner son graphe pour la 2-ème caractérisation.



# Exemple : Nombre d'étudiants dans la salle



# Exemple : téléphone portable

- Panne après un temps exponentiel de taux  $\gamma_1$
- Réparation après un temps exponentiel de taux  $\lambda_1$
- Déchargement de batterie après un temps exponentiel de taux  $\gamma_2$
- Chargement après un temps exponentiel de taux  $\lambda_2$
  
- Donner son graphe (suivant les 2 caractérisations)

# Exemple : téléphone portable



# Analyse en régime transitoire

- $t \in \mathbb{R}^+$
- $\pi_i(t)$  : probabilité d'être dans l'état  $i$  à l'instant  $t$

$$\pi(t) = (\pi_1(t), \pi_2(t), \dots)$$


# Générateur infinitésimal

- Soit une CMTC de taux de transition  $(\mu_{ij})$
- La matrice  $Q = (q_{ij})$  avec

$$\begin{cases} q_{ij} = \mu_{ij} \text{ si } i \neq j \\ q_{ii} = -\mu_i = -\sum_{j \neq i} \mu_{ij} \end{cases}$$

est appelé le générateur infinitésimal de la CMTC

## Exemple : Téléphone portable



$$Q = \begin{pmatrix} -\lambda_1 & \lambda_1 & 0 \\ \gamma_1 & -(\gamma_1 + \gamma_2) & \gamma_2 \\ 0 & \lambda_2 & -\lambda_2 \end{pmatrix}$$

# Equations en régime transitoire


- Cf poly pour la démonstration :

$$\forall j \in E, \quad \frac{d\pi_j(t)}{dt} = \sum_i q_{ij} \pi_i(t)$$


- Sous forme matricielle

$$\frac{d\pi(t)}{dt} = \pi(t)Q$$

## Exemple



Exprimer  $\pi_1(t)$  et  $\pi_2(t)$  en fonction de  $\lambda, \mu$  et  $t$



$$Q = \begin{pmatrix} -\lambda & \lambda \\ \mu & -\mu \end{pmatrix}$$

$$\pi_1(0) = 0$$

$$\pi_2(0) = 1$$

$$\begin{cases} \pi_1'(t) = -\lambda \pi_1(t) + \mu \pi_2(t) \\ \pi_2'(t) = \lambda \pi_1(t) - \mu \pi_2(t) \\ \pi_1(t) + \pi_2(t) = 1 \end{cases}$$

$$\Rightarrow \pi_1'(t) = -\lambda \pi_1(t) + \mu (1 - \pi_2(t)) \Leftrightarrow \pi_1'(t) + (\lambda + \mu) \pi_1(t) = \mu$$

Solution sans 2<sup>nd</sup> membre =  ~~$Ae^{-(\lambda+\mu)t}$~~  =  $Ae^{-(\lambda+\mu)t}$

Sol. part. avec  $\frac{\mu}{\lambda + \mu}$


$$D'au \left\{ \begin{aligned} \pi_1(t) &= \frac{\mu}{\lambda + \mu} (1 - e^{-(\lambda + \mu)t}) \xrightarrow{t \rightarrow \infty} \frac{\mu}{\lambda + \mu} \\ \pi_2(t) &= \frac{\lambda}{\lambda + \mu} e^{-(\lambda + \mu)t} \end{aligned} \right. \left( \begin{aligned} \pi_1(t) &= Ae^{-(\lambda + \mu)t} + \frac{\mu}{\lambda + \mu} \\ + \pi_1(0) &= 0 \end{aligned} \right)$$

$\xrightarrow{t \rightarrow \infty} \frac{\lambda}{\lambda + \mu}$


# Travail à la maison

- Polycopié : lire jusqu'à la page 81
- Exercices 12 et 13

## 2ème caractérisation d'une CMTC (rappel)




# 1ère caractérisation d'une CMTC (rappel)



# CMTD incluse associée à une CMTC

- CMTD incluse : CMTD de matrice de transition  $(p_{ij})$



# Classification des états d'une CMTC

- La nature d'un état est défini de la même manière que pour une CMTD
  - ▶  $f_{jj} < 1$  : état transitoire
  - ▶  $f_{jj} = 1, M_j < \infty$  : état récurrent non nul
  - ▶  $f_{jj} = 1, M_j = \infty$  : état récurrent nul
- Pas de notion de périodicité dans une CMTC
- Une CMTC est dite irréductible si sa CMTD incluse est irréductible

## Proposition

- *Un état  $i$  d'une CMTC est transitoire (respectivement récurrent) ssi l'état  $i$  de la CMTD incluse est transitoire (respectivement récurrent)*
- *Les états d'une CMTC irréductible sont de même nature : transitoires / récurrents nuls / récurrents non nuls*
- *Les états d'une CMTC finie et irréductible sont récurrents non nuls*

# Distribution limite

- $\pi(t) = (\pi_1(t), \pi_2(t), \dots)$
- Equations en régime transitoire pour une CMTC finie

$$\frac{d\pi(t)}{dt} = \pi(t)Q$$

- Supposons que  $\pi(t)$  converge vers  $\pi$  quand  $t$  tend vers l'infini, alors

$$\pi Q = 0$$

# Distribution limite pour une CMTC irréductible

## Théorème (admis)

Pour une CMTC irréductible, la distribution limite  $\pi = (\pi_1, \pi_2, \dots)$  existe et est indépendante de la distribution initiale  $\pi(0)$  :

- Si les états sont tous transitoires ou tous récurrents nuls, alors

$$\forall j \in E, \pi_j = 0$$

- Si les états sont tous récurrents non nuls, alors les  $\pi_j$  satisfont

$$(S) : \begin{cases} \sum_{i \in E} \pi_i q_{ij} = 0, \forall j \in E \\ \sum_{j \in E} \pi_j = 1 \end{cases}$$

- Pour une CMTC finie

$$\sum_{i \in E} \pi_i q_{ij} = 0 \Leftrightarrow \pi Q = 0$$

# Flux sortant d'un état = flux entrant dans cet état


- L'équation  $\sum_{i \in E} \pi_i q_{ij} = 0$  peut s'écrire aussi

$$\overbrace{\pi_i \sum_{j \neq i} \mu_{ij}}^{\text{Flux sortant de } i} = \overbrace{\sum_{j \neq i} \mu_{ji} \pi_j}^{\text{Flux entrant en } i}$$

- $\mu_{ji} \pi_j$  : nombre de transitions par unité de temps de  $j$  vers  $i$

## Exemple : Marche / Panne


- Un appareil tombe en panne après un temps  $\sim \exp(\lambda)$
- En cas de panne, l'appareil est réparé au bout d'un temps  $\sim \exp(\mu)$
- Quelle est la probabilité que l'appareil fonctionne ?



$$(S) : \begin{cases} \lambda\pi_1 = \mu\pi_2 & (\text{flux sortant de 1} = \text{flux entrant en 1}) \\ \mu\pi_2 = \lambda\pi_1 & (\text{flux sortant de 2} = \text{flux entrant en 2}) \\ \pi_1 + \pi_2 = 1 \end{cases}$$

$$\Rightarrow \pi_1 = \frac{\mu}{\lambda + \mu}, \pi_2 = \frac{\lambda}{\lambda + \mu}$$

## Exemple : Téléphone portable



Déterminer  $\pi_1, \pi_2$  et  $\pi_3$ .

Il faut résoudre le système linéaire suivant :


$$(S) : \begin{cases} \lambda_1 \pi_1 = \gamma_1 \pi_2 & (\text{flux sortant de 1} = \text{flux entrant en 1}) \\ (\gamma_1 + \gamma_2) \pi_2 = \lambda \pi_1 + \lambda_2 \pi_3 & (\text{flux sortant de 2} = \text{flux entrant en 2}) \\ \lambda_2 \pi_3 = \gamma_2 \pi_2 & (\text{flux sortant de 3} = \text{flux entrant en 3}) \\ \pi_1 + \pi_2 + \pi_3 = 1 \end{cases}$$

$$\Rightarrow \dots \Rightarrow \pi_1 = ?, \pi_2 = ?, \pi_3 = ?$$


# Conservation des flux

- Partition des états :  $E = E_1 \cup E_2$

$$\overbrace{\sum_{i \in E_1} \sum_{j \in E_2} \pi_i \mu_{ij}}^{\text{Flux de } E_1 \text{ vers } E_2} = \overbrace{\sum_{i \in E_2} \sum_{j \in E_1} \pi_i \mu_{ij}}^{\text{Flux de } E_2 \text{ vers } E_1}$$



# Exemple : file d'attente $M/M/1$



- $T_s$  : temps pour servir un client


$$T_s \sim \exp(\mu)$$

- $T_a$  : temps entre 2 arrivées de clients

$$T_a \sim \exp(\lambda)$$

- $N(t)$  : nombre de clients dans le système (en attente + en service)


$N(t)$  est une CMTC



• Cette CMTC est irréductible

- ▶  $\mu < \lambda$  : états tous transitoires et les  $\pi_i = 0$
- ▶  $\mu = \lambda$  : états tous récurrents nuls et les  $\pi_i = 0$
- ▶  $\mu > \lambda$  : états tous récurrents non nuls et les  $\pi_i$  sont solution de (S)

# Distribution limite pour $\mu > \lambda$



- Flux de  $E_1$  vers  $E_2$  = Flux de  $E_2$  vers  $E_1 \Rightarrow \lambda\pi_i = \mu\pi_{i+1}$
- Soit  $\rho = \frac{\lambda}{\mu}$  le taux d'utilisation de la file d'attente. Alors

$$\pi_i = \rho^i \pi_0$$

- Si  $\rho < 1$ , alors  $\sum_{i=0}^{+\infty} \pi_i = 1$  donne  $\pi_0 = 1 - \rho$  puis

$$\pi_i = (1 - \rho)\rho^i$$


# Travail à la maison

- Finir chapitre 3.2 sur les CMTC
- Exercices 14 et 15
- TP file d'attente

# Récapitulatif

	CMTD	CMTC
Transitions	$p_{ij}$	$\mu_{ij}$
Régime transitoire	$\pi(n+1) = \pi(n)P$	$\frac{d\pi(t)}{dt} = \pi Q$
Régime permanent	$\pi = \pi P$	$0 = \pi Q$
Flux de $i$ vers $j$	$\pi_i p_{ij}$	$\pi_i \mu_{ij}$
Temps passé dans un état	géométrique	exponentiel

# Convergence rate : An exemple (facultatif)



$$\pi(0) = (1, 0), P = \begin{pmatrix} 1 - \alpha & \alpha \\ \beta & 1 - \beta \end{pmatrix}$$

- Give  $\pi$  :  $\pi_1 = \frac{\beta}{\alpha + \beta}$
- Give  $\pi_1(n)$  :  $\pi_1(n) = \frac{\beta}{\alpha + \beta} + \frac{\alpha}{\alpha + \beta}(1 - \alpha - \beta)^n$
- Give  $|\pi_1(n) - \pi_1|$  :  $|\pi_1(n) - \pi_1| = \frac{\alpha}{\alpha + \beta}|1 - \alpha - \beta|^n$
- Study the rate of convergence : converge geometrically but very slowly when  $\alpha \simeq \beta \simeq 1$  (quasi-periodic) or if  $\alpha \simeq \beta \simeq 0$  (quasi not connected).
- Compute eigenvalues of  $P$  : 1 and  $1 - \alpha - \beta$  ( $\lambda_1 = 1$  and  $\lambda_1 + \lambda_2 = \text{Tr}(P) = 2 - \alpha - \beta$ ).

# Upper bound on the convergence rate (facultatif)

- Eigenvalues of  $P$  :  $\lambda_1 = 1 \geq |\lambda_2| \geq \dots \geq |\lambda_S|$
- For an aperiodic and irreducible Markov chain

$$|\lambda_2| < 1$$

- ▶ The convergence to the stationary distribution is geometric in the second eigenvalue. There exists  $C > 0$  such that

$$|\pi_j(n) - \pi_j| \leq C|\lambda_2|^n$$

- Previous result is trivial when  $P$  is diagonalisable :  $P^k = AD^kA^{-1}$

# Convergence rate : Birth death process (facultatif)

$p = 1 - q$ ,  $|\mathcal{S}|$  states

$$P = \begin{pmatrix} q & p & 0 & \dots & 0 \\ q & 0 & p & \dots & 0 \\ 0 & \ddots & \ddots & \ddots & 0 \\ 0 & \dots & q & 0 & p \\ 0 & \dots & 0 & q & p \end{pmatrix}$$

$$\lambda_1 = 1, \lambda_j = 2\sqrt{pq} \cos\left(\frac{(j-1)\pi}{|\mathcal{S}|}\right)$$

$\lambda_2$  is maximal for  $p = q = 0.5$  and goes to 1 when  $|\mathcal{S}|$  goes to infinity.  
Will be an issue for queuing systems close to instability.