

Complexité, Approximation et Hasard
Optimisation et Vérification
en univers incertain

Richard Lassaigne
IMJ/Logique mathématique
CNRS-Université Paris Diderot

- Problèmes de **planning** et **vérification** pour les systèmes avec **non déterminisme** et **probabilités**
- Méthodes classiques : algorithmes en temps **polynomial** ?
- Problème : la **modélisation** donne un modèle dont la **représentation** peut ne pas tenir en mémoire
- La complexité en **espace** est primordiale dans un problème comme la **vérification**
- Peut-on utiliser des méthodes d'**approximation** et des algorithmes **probabilistes** ?

Pb \	SAT	VC	CLIQUE	TSP	KNAPSACK
Déci.	NP-com.	NP-com.	NP-com.	NP-com.	NP-com.
Opt.	MaxSAT	MinVC	MaxCLIQ.	MinTSP	Pseudo-Poly
Approx.	$\varepsilon = 1/2$	$\varepsilon = 1/2$			FPTAS
Non Approx.	FPTAS $\Rightarrow P=NP$		ε -approx. $\Rightarrow P=NP$	ε -approx. $\Rightarrow P=NP$	

Fully Polynomial-Time Approximation Scheme

(FPTAS) : $\text{poly}(|x|, 1/\varepsilon)$

- Processus de décision markoviens (**MDP**)
Problème de décision markovien (**planning**)
- Méthodes classiques :
Itération sur la fonction de valeur (**Value Iteration**)
Itération sur la stratégie (**Policy Iteration**)
- Vérification **probabiliste**
Schémas probabilistes d'**approximation**
- Approximation pour le **planning** et la **vérification**

Quelques acteurs majeurs



Richard Bellman Ronald Howard



Christos Papadimitriou Michael Kearns

Modèles dynamiques :

- Processus **stochastiques** bien connus
- Critères de **performance** utilisés en recherche opérationnelle, économie, optimisation combinatoire, théorie du contrôle...

Applications (parmi beaucoup d'autres) :

- Modélisation de **protocoles** de communication
- Modélisation du contrôle dans les réseaux
- Optimisation dans les **réseaux de capteurs** sans fil
- Contrôle dans les systèmes **embarqués**

Modèle de décision :


- à chaque étape, un agent (ou un contrôleur) observe l'**état** du système et choisit une **action** (non déterminisme)
- il reçoit une **récompense** (ou subit un **coût**) et le système évolue vers un nouvel **état** en suivant une **distribution de probabilités** déterminée par le choix

Problème de décision markovien :

- Processus de décision markovien
- Critère de **performance**

Stratégie :

- Fonction associant une **action** à chaque **état**
- Détermine une suite de transitions dont la **valeur** est la **récompense** totale ou le **coût** total



$$P_a = \begin{pmatrix} 0.6 & 0.4 \\ 0.6 & 0.4 \end{pmatrix}$$

$$P_b = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

s	act	R(s,act)
s_1	a	1
s_1	b	0
s_2	a	0
s_2	b	1

$$\mathcal{M} = (S, s_0, A, P, R)$$

- S ensemble fini d'**états** ($|S| = n$)
- s_0 état initial (ou μ distribution de probabilités sur les états)
- A ensemble d'**actions** ($|A| = m$)
- $P : S \times A \longrightarrow \text{Distr}(S)$ Relation de **transition**
 $\text{Distr}(S)$ ensemble des **distributions de probabilités** sur S
- $R : S \times A \longrightarrow \mathcal{R}^+$ Fonction de **récompense** (ou de **coût**)

Pour chaque couple état-action $(s, a) \in S \times A$:

- $P_{s,a}(\cdot)$ **distribution de probabilités** sur les états
- $R_{s,a}$ **récompense** (ou **coût**) associée à l'action a
à partir de l'état s

Stratégie (stationnaire) :

- **déterministe** et sans mémoire $\pi : S \longrightarrow A$
- **probabiliste** et sans mémoire $\pi : S \longrightarrow Distr(A)$

Arbre des **trajectoires** :

Chaque branche correspond à l'application d'une stratégie

Remarque :

- Si l'on se restreint à une stratégie π , on obtient la **chaîne de Markov** induite par la stratégie π
- On peut alors faire une étape de **vérification** de propriétés intéressantes (accessibilité, sûreté)

Problème de décision markovien :

trouver une stratégie **optimale** suivant un critère de **performance**

- Horizon H **fini** : récompense totale **espérée**

$$V^\pi(s) = \mathbb{E}_s^\pi \left(\sum_{i=1}^H R(s_i, \pi(s_i)) \right)$$

s_i étant l'état résultant à l'étape i suivant la chaîne de Markov induite par la stratégie π

- Horizon **infini** : récompense totale **espérée** avec taux de discount $0 < \gamma < 1$

$$V^\pi(s) = \mathbb{E}_s^\pi \left(\sum_{i=1}^{\infty} \gamma^{i-1} R(s_i, \pi(s_i)) \right)$$

- Horizon **infini** : récompense **espérée moyenne**

$$V^\pi(s) = \lim_{T \rightarrow +\infty} \frac{1}{T} \mathbb{E}_s^\pi \left(\sum_{i=1}^T R(s_i, \pi(s_i)) \right)$$

Problème de décision markovien : Horizon **infini**, avec **discount**

Fonction **auxiliaire** (Q -fonction) :

$$Q^\pi(s, a) = R_{s,a} + \mathbb{E}_s^\pi \left(\sum_{s' \in S} \gamma P_{s,a}(s') V^\pi(s') \right)$$

Fonction de récompense **optimale** (ou coût optimal) :

$$V^*(s) = \max_\pi V^\pi(s) \text{ et } Q^*(s, a) = \max_\pi Q^\pi(s, a) \text{ pour tout } (s, a) \in S \times A$$

Stratégie **optimale** π^* : $\pi^*(s) = \operatorname{argmax}_a Q^*(s, a)$ pour tout $s \in S$

Equation de **Bellman** :

$$V^*(s) = \max_{a \in A} \left(R(s, a) + \gamma \sum_{s' \in S} P_{s,a}(s') \cdot V^*(s') \right)$$

Résolution :

- Méthodes itératives (value iteration, policy iteration)
- Programmation linéaire

Algorithme :

- Pour chaque $s \in S$, initialiser $V_0(s)$
- $h := 1$
- Tant que $n < \text{nb maximum d'itérations}$
 pour chaque $(s, a) \in S \times A$,

$$Q_h(s, a) := R(s, a) + \gamma \sum_{s' \in S} P_{s,a}(s') \cdot V_{h-1}(s')$$

$$V_h(s) := \max_{a \in A} Q_h(s, a)$$

$$h := h + 1$$
- Pour chaque $s \in S$, $\pi^*(s) := \operatorname{argmax}_{a \in A} Q_h(s, a)$
- Retourner π^*

Nombre maximum d'itérations :

- soit l'horizon **fini** H
- soit déterminé par un **critère d'arrêt** (horizon infini)

$$\max_{s \in S} |V_h(s) - V_{h-1}(s)| \leq \varepsilon' = \varepsilon \frac{(1-\gamma)}{2\gamma}$$

Ce critère garantit que la stratégie résultante π^* est **ε -optimale**

Le temps de calcul pour chaque itération est $O(mn^2)$

Algorithme :

- Soit π_0 une stratégie stationnaire déterministe
- Boucle :

$$\pi := \pi_0$$

Déterminer, pour chaque $s \in S$, $V^\pi(s)$ par résolution de l'équation de **Bellman** (à n inconnues)

Pour chaque $s \in S$, s'il existe $a \in A$ t.q.

$$(R(s, a) + \gamma \sum_{s' \in S} P_{s,a}(s') \cdot V^\pi(s')) < V^\pi(s),$$

alors $\pi_0(s) := a$, sinon $\pi_0(s) := \pi(s)$

Répéter la boucle si $\pi \neq \pi_0$

- Retourner π

Remarque :

- Il existe au plus m^n stratégies distinctes
- Comme chaque stratégie améliore la précédente (Puterman, 1994) l'algorithme termine en au plus un nombre **exponentiel** d'étapes

Algorithme en 2 phases :

- Détermination de la fonction **valeur** (résolution d'un système d'équations linéaires) en $O(n^3)$ étapes
- Amélioration (éventuelle) de la **stratégie** en $O(mn^2)$ étapes

Complexité :

- Le nombre d'itérations est en $O(\frac{mn}{1-\gamma} \log(\frac{n}{1-\gamma}))$
(Ye, 2010)
- Le nombre d'itérations est en $O(\frac{m}{1-\gamma} \log(\frac{n}{1-\gamma}))$
(Hansen, Miltersen et Zwick, 2011)
- Borne **exponentielle** pour le problème sans discount, ou lorsque le taux de discount fait partie de l'entrée
(Friedmann, 2009, Fearnley, 2010)

Théorème (C. Papadimitriou, J.N. Tsitsiklis, 1987) :

Le problème de décision markovien est **P-complet** dans les 3 cas (horizon fini, horizon infini avec discount ou coût moyen)

Idée de la preuve :


Réduction du "Circuit Value Problem" (CVP) au problème de décision markovien

Remarque : Cas "déterministe" (les probas sont égales à 0 ou 1)

Les trois problèmes correspondants sont dans la classe **NC**

(problèmes décidables en temps polynomial sur une RAM parallèle avec un nombre de processeurs polynomial)

Problème : **P** \neq **NC** ?



Entrée :

- Modèle $\mathcal{M} = (S, R)$ $R \subseteq S^2$ (relation de transition)
- Etat initial s_0
- Formule φ (Logique Temporelle Linéaire : **LTL**)


Sortie :

- **OUI** si $(\mathcal{M}, s_0) \models \varphi$
- **NON** avec trace d'erreur si $(\mathcal{M}, s_0) \not\models \varphi$

Chaînes de Markov

Entrée :

- Modèle $\mathcal{M} = (S, P, L)$ et état initial s_0
- $P : S^2 \rightarrow [0, 1]$ Fonction de probabilité
- $L : S \rightarrow 2^{AP}$ (étiquetage des états)
- Formula ψ (**LTL**)

Sortie : $Prob_{\Omega}[\psi]$ Exemple : $\psi \equiv transmission \text{ Until } success$ $(\Omega$ espace probabiliste des chemins d'exécution d'origine s_0)

Complexité : (Courcoubetis et Yannakakis, 1995)

Vérification qualitative (i.e. $prob > 0$?)

Même **complexité** que **model checking pour LTL**

$$O(|M|.2^{|\psi|})$$

Vérification Quantitative (i.e. $prob = ?$)

$$O(poly(|M|).2^{|\psi|})$$

Problème :

- Phénomène d'explosion combinatoire (dû à la **modélisation**)
- Le problème n'est pas le temps, mais l'**espace** utilisé pour la représentation **explicite** du modèle

Exemple : **PRISM** (Probabilistic Model Checker)

Protocole (probabiliste) du diner des philosophes

Une solution :

- Méthode d'**approximation probabiliste**
- Utilisation d'une représentation **succincte** du modèle

Algorithme probabiliste A

- Entrée : instance x d'un problème de comptage, $\varepsilon, \delta > 0$
- Sortie : valeur $A(x, \varepsilon, \delta)$ telle que

$$Pr[(1 - \varepsilon)\#(x) \leq A(x, \varepsilon, \delta) \leq (1 + \varepsilon)\#(x)] \geq 1 - \delta$$

Schéma probabiliste d'approximation polynomial : FPRAS

Le temps de calcul est $poly(|x|, (1/\varepsilon), \log(1/\delta))$

Théorème (LP08) :

L'existence d'un FPRAS pour calculer $Prob_{\Omega}(\psi)$ ($\psi \in LTL$) entrainerait $RP = NP$

Restrictions sur l'approximation probabiliste :

- approximation absolue
- propriétés monotones (ex : accessibilité)
ou anti-monotones (ex : sûreté)

Schéma probabiliste d'approximation en espace logarithmique

Classe *RP* (Randomised Polynomial Time) :

Problèmes P pour lesquels il existe un algorithme probabiliste A fonctionnant en temps polynomial t.q. pour toute entrée x

- si $P(x)$, alors $Prob_{\Omega}(A \text{ accepte } x) \geq \frac{1}{2}$
- si $\neg P(x)$, alors $Prob_{\Omega}(A \text{ accepte } x) = 0$

Ω est l' espace probabiliste des tirages de la machine

Exemple : Le problème de primalité est dans *coRP*

Algorithmes de Monte-Carlo (avec erreur d'1 seul côté) :

$$Prob_{\Omega}(P(x) \text{ et } A \text{ rejette } x) < \frac{1}{2}$$

Réduction exponentielle de la probabilité d'erreur
avec un nombre linéaire d'itérations de l'algorithme

Méthode :

Estimation (Monte-Carlo) + borne de Chernoff-Hoeffding

X variable de Bernoulli $(0, 1)$ avec probabilité de succès p

- Faire N tirages aléatoires indépendants X_1, X_2, \dots, X_N
- Estimer p par $\mu = \sum_{i=1}^N X_i / N$ avec erreur absolue ε
- La taille de l'échantillon N est telle que la probabilité d'erreur (de l'algorithme) $< \delta$

Borne de Chernoff-Hoeffding :

$$Pr[\mu < p - \varepsilon] + Pr[\mu > p + \varepsilon] < 2e^{-2N\varepsilon^2}$$

Si $N \geq \ln(\frac{2}{\delta}) / 2\varepsilon^2$, alors

$$Pr[p - \varepsilon \leq \mu \leq p + \varepsilon] \geq 1 - \delta$$

Algorithme générique d'approximation \mathcal{GAA}

entrée : générateur, $\phi, \varepsilon, \delta$

sortie : ε -approximation de $Prob_k(\psi)$

$A := 0$

$N := \log\left(\frac{2}{\delta}\right) / 2\varepsilon^2$

Pour $i := 1$ à N

- Engendrer de manière aléatoire un chemin σ de longueur k
- Si ψ est vraie sur σ alors $A := A + 1$

Retourner (A/N)

Algorithme basé sur une estimation de type Monte-Carlo et la borne de **Chernoff-Hoeffding**

Générateur : représentation **succincte** du système
(par exemple programme dans le langage d'entrée de **PRISM**)

Théorème :

\mathcal{GAA} est un FPRAS pour $Prob_k(\psi)$

Méthodologie : Pour approximer $Prob_\Omega(\psi)$

- Choisir $k \approx \log|M| \cdot \ln(1/\varepsilon)$
- Itérer l'approximation de $Prob_k(\psi)$

Corollaire :

L'algorithme de point fixe obtenu en itérant \mathcal{GAA} est un schéma probabiliste d'approximation en **espace logarithmique** pour $Prob(\psi)$

Remarque :

- La **complexité en espace** est **logarithmique**...
- La vitesse de **convergence** est régie par l'ordre de multiplicité de la 2e valeur propre (théorème de Perron-Frobenius)

Idée :


Etant donné un **générateur** (probabiliste) pour MDP \mathcal{M}

- déterminer une **stratégie** π^* ε -optimale
- construire une **chaîne de Markov** \mathcal{M} par restriction du MDP \mathcal{M} à la stratégie π^*

Générateur **probabiliste** :

Algorithme probabiliste qui pour chaque entrée $(s, a) \in S \times A$ fournit

- un état t engendré suivant la **distribution de probabilités** $P_{s,a}$
- la **récompense** (ou coût) associée $P_{s,a}$



Construction (inspirée de Kearns, 2001) :

Arbre des trajectoires d'un "plus petit" MDP \mathcal{M}' de **profondeur H'**

- Arbre **peu dense** construit (look-ahead) à partir de l'état initial

- Chaque transition à partir d'un état s et d'une action a est restreinte à **C successeurs** suivant la distribution $P_{s,a}$

Remarque : $H' = 2H$ (H déterminé plus tard...)

Objectif :

Estimer la récompense espérée (avec discount) à l'horizon H

$$V_H^*(s) = \mathbb{E}_s^{\pi^*} \left(\sum_{i=1}^H \gamma^{i-1} R(s_i, \pi^*(s_i)) \right)$$

Récompense espérée (avec discount) à l'horizon $h \geq 1$:

$$V_h^*(s) = R_{s,a^*} + \gamma \sum_{s' \in S} P_{s,a^*}(s') \cdot V_{h-1}^*(s') \text{ et } V_0^*(s) = 0$$

a^* est l'action choisie par la stratégie optimale à partir de s

Estimation $\hat{V}_h^*(s)$ de $V_h^*(s)$:

- pour chaque $a \in A$, utiliser le **générateur** pour obtenir $R_{s,a}$ et un **échantillon** $S_{s,a}$ de C états suivant la distribution $P_{s,a}$
- calculer $\hat{V}_{h-1}^*(s')$ pour chaque état s' dans les $S_{s,a}$
- l'estimation de $V_h^*(s)$ est donnée par

$$\hat{V}_h^*(s) = \max_{a \in A} \left(R(s, a) + \gamma \frac{1}{C} \sum_{s' \in S_a} \hat{V}_{h-1}^*(s') \right)$$

Structure intermédiaire $\widehat{\mathcal{M}}$:

- pour chaque noeud s dans l'arbre, pour chaque action a
on stocke les ensembles $S_{s,a}$ des C successeurs de s
- on étiquette l'action a correspondant à la valeur \max par a^*
on obtient ainsi une stratégie presque optimale $\hat{\pi}^*$

Arbre des trajectoires de la chaîne de Markov \mathcal{M}^* :

- on supprime les noeuds et les transitions correspondant
à des actions non étiquetées
- on élague les branches à la profondeur H

Propriété :

pour chaque état s du MDP \mathcal{M}' à profondeur $\leq H = \frac{H'}{2}$,
l'action optimale dans \mathcal{M}' à partir de s est une action
presque optimale dans \mathcal{M}

Objectif :

Montrer que la stratégie π^* est ε -optimale à l'horizon infini

i.e. que pour tout état s de \mathcal{M}^* , $|V^*(s) - \hat{V}_H^*(s)| \leq \varepsilon$

Borne de Chernoff-Hoeffding :

Soit $\lambda > 0$. Pour tout état s et toute action a ,

$$\text{Prob}\left(\left| \mathbb{E}_s^{\pi^*}(V^*(s)) - \frac{1}{C} \sum_{i=1}^C V^*(s_i) \right| \leq \lambda \right) \geq 1 - e^{-\lambda^2 \cdot C / V_{max}^2}$$

La probabilité d'une mauvaise estimation à l'issue de H étapes est bornée par $(mC)^H e^{-\lambda^2 \cdot C / V_{max}^2}$.

On choisit H pour que l'erreur soit $\leq 2\lambda / (1 - \gamma)$

$$H = \log_{\gamma} \left(\frac{\lambda}{V_{max}} \right) \text{ où } V_{max} = \frac{R_{max}}{1 - \gamma}$$

Il est possible de choisir $C = \tilde{O}\left(\frac{R_{max}^2}{\varepsilon^2(1-\gamma)^6}\right)$ tel que :

la probabilité d'une mauvaise estimation soit $\leq \delta = \lambda / R_{max}$

Dernière étape (Kearns, d'après Singh et Yee, 1994) :

Soit π une stratégie **probabiliste** t. q. pour tout état s ,

$$\text{Prob}(|Q^*(s, \pi^*(s)) - Q^*(s, \pi(s))| < \lambda) \geq (1 - \delta)$$

Alors pour tout état s ,

$$|V^*(s) - V^\pi(s)| \leq (\lambda + 2\delta V_{max}) / (1 - \gamma)$$

Il reste à choisir λ pour obtenir l' ε -approximation :

$$\lambda = \varepsilon(1 - \gamma)^2 / 4$$

Ouf!

- Les méthodes classiques d'optimisation et de vérification pour les problèmes de décision markoviens sont polynomiales dans la taille du modèle
- Les méthodes d'approximation probabiliste ont permis d'éliminer la complexité en espace sur les chaînes de Markov et ont montré leur efficacité pratique (APMC dans le model-checker probabiliste PRISM)
- Les méthodes d'optimisation par génération probabiliste dans les MDPs sont indépendantes de la taille du modèle
- Cependant la complexité est exponentielle dans l' ε -horizon
- Il reste à montrer leur efficacité dans la pratique...

- [B57] R. Bellman. *Dynamic Programming*. Princeton University Press, 1957
- [CY95] C. Courcoubetis and M. Yannakakis. *The complexity of probabilistic verification*. JACM, 24(4), p. 857-907, 1995
- [HMZ11] T.D. Hansen, P.B. Miltersen and U. Zwick. *Strategy iteration is strongly polynomial*. Proc. Innovations in Computer Science, p.253-263, 2011
- [H63] W. Hoeffding. *Probability inequalities for sums of bounded random variables*. Journal of the American Statistical Association, 58(301), p.13-30, 1963
- [H60] R.A. Howard. *Dynamic programming and Markov process*. MIT Press, 1960
- [KMN02] M. Kearns, Y. Mansour and A.Y. Ng. *A sparse sampling algorithm for near-optimal planning in large Markov decision processes*. Machine Learning, 49(2-3), p. 193-208, 2002

- [LDK95] M. Littman, T. Dean and L. Kaelbling. *On the complexity of solving markov decision problems*. Proc. of the 11th UAI, p. 394-402, 1995
- [LP08] R. Lassaigne et S. Peyronnet. *Probabilistic Verification and Approximation*. Journal of Pure and Applied Logic, vol. 152 (1-3), p. 122-131, 2008
- [LP12] R. Lassaigne et S. Peyronnet. *Approximate planning and verification for large Markov decision processes*. Proc. ACM Symposium on Applied Computing, p. 1314-1319, 2012
- [PT87] C.H. Papadimitriou and J.N. Tsitsiklis. *The complexity of Markov decision processes*. Mathematics of Operations Research, 12(3), p. 441-450
- [P94] M. Puterman. *Markov Decision Processes*. John Wiley and Sons, 1994