Utilisation de croyances heuristiques pour la planification multi-agent dans le cadre des Dec-POMDP

Soutenance de thèse

Gabriel Corona

Loria

Équipe MAIA

11 avril 2011

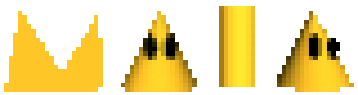

Contrôle décentralisé

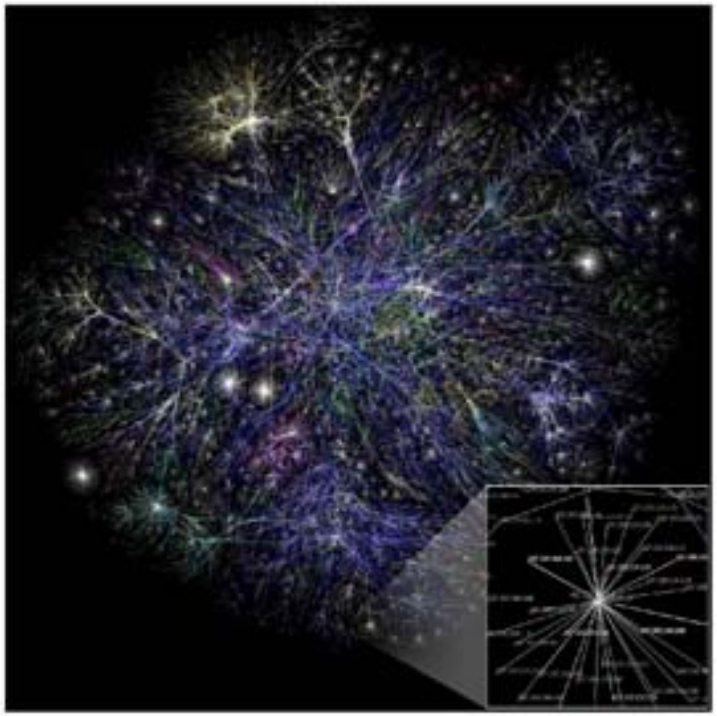

Contrôle décentralisé

Contrôle décentralisé

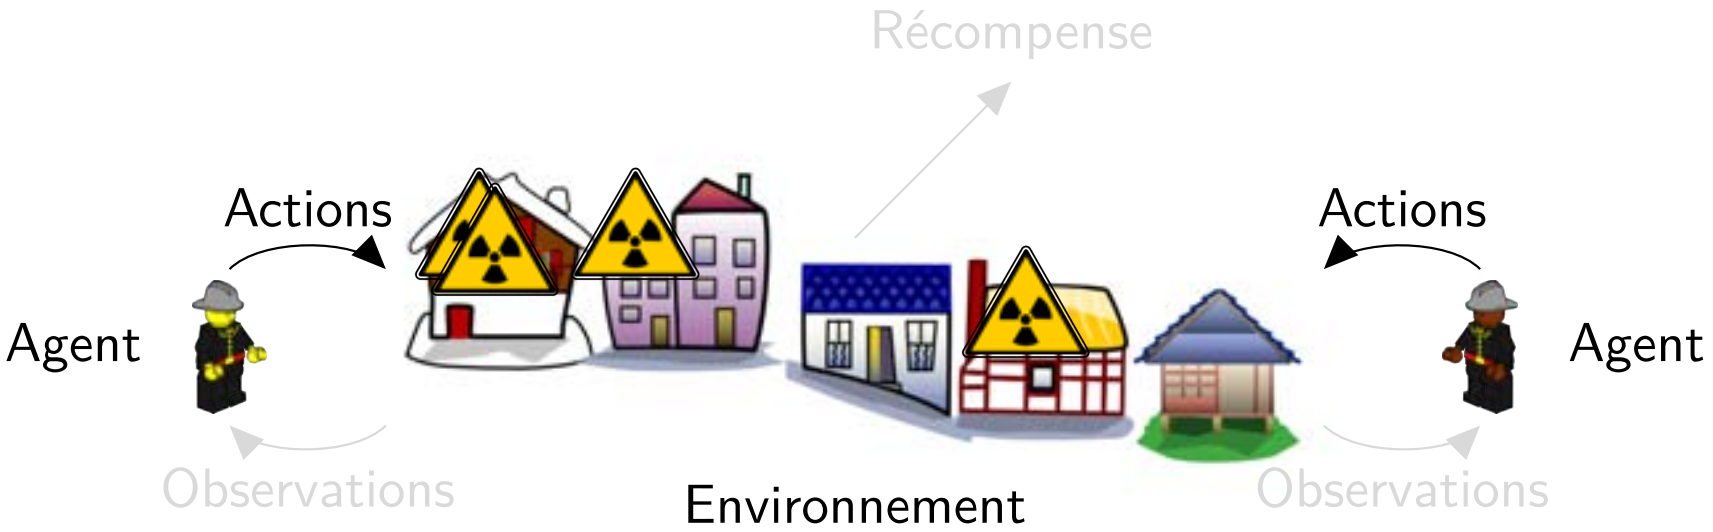

Contrôle décentralisé

Contrôle décentralisé

Contrôle décentralisé

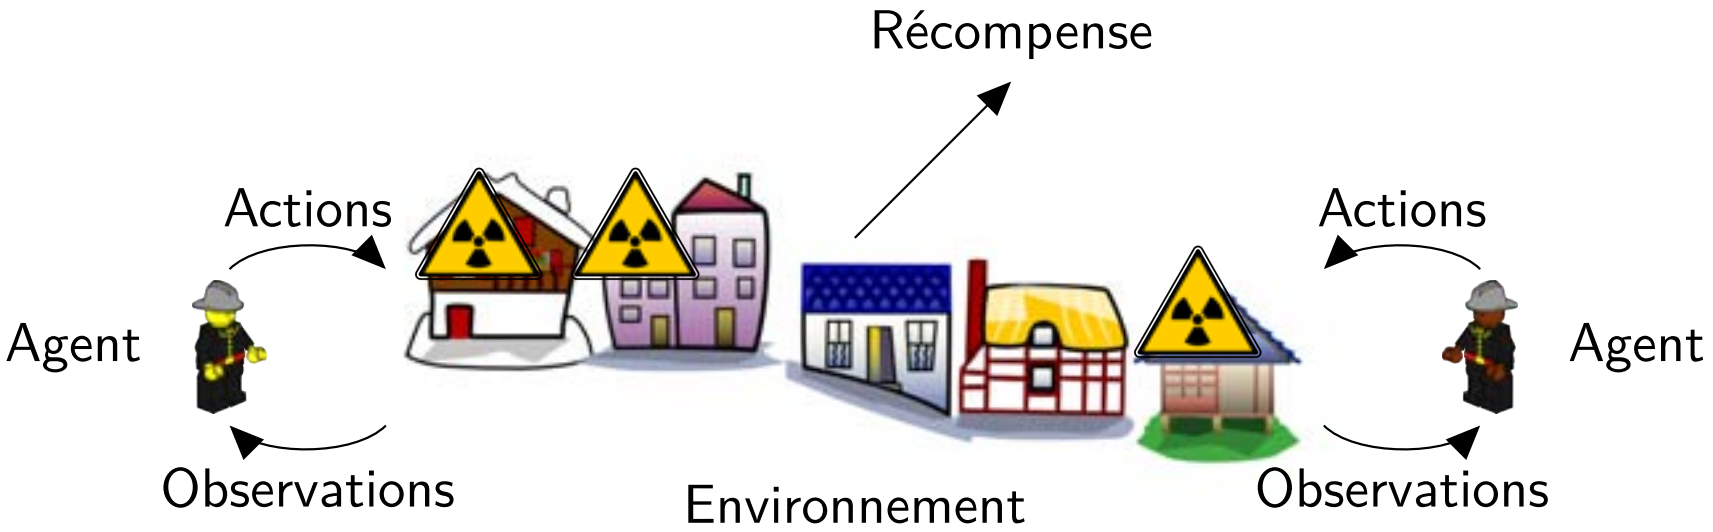

Modèle Dec-POMDP

Decentralized Partially Observable Markov Decision Process [bernstein2000]
$\mathcal{M} = \langle \mathcal{I}, \mathcal{S}, (\mathcal{A}_i)_{i\in\mathcal{I}}, \mathcal{T}, \mathcal{R}, (\Omega_i)_{i\in\mathcal{I}}, \mathcal{O} \rangle$

- $\mathcal{S}$, ensemble des états
- $\mathcal{I}$, ensemble des agents
- $\forall i \in \mathcal{I}, \mathcal{A}_i$, ensemble des actions
- $\forall i \in \mathcal{I}, \Omega_i$, ensemble des observations
- $\mathcal{T}(s'|s,a)$, loi de transition
- $\mathcal{R}(s,a)$ récompenses immédiates
- $\mathcal{O}(o|s,a,s')$ loi d'observation

Problème : planification, horizon T fini
Objectif : maximiser les récompenses

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

NEXP-difficile [bernstein2000]

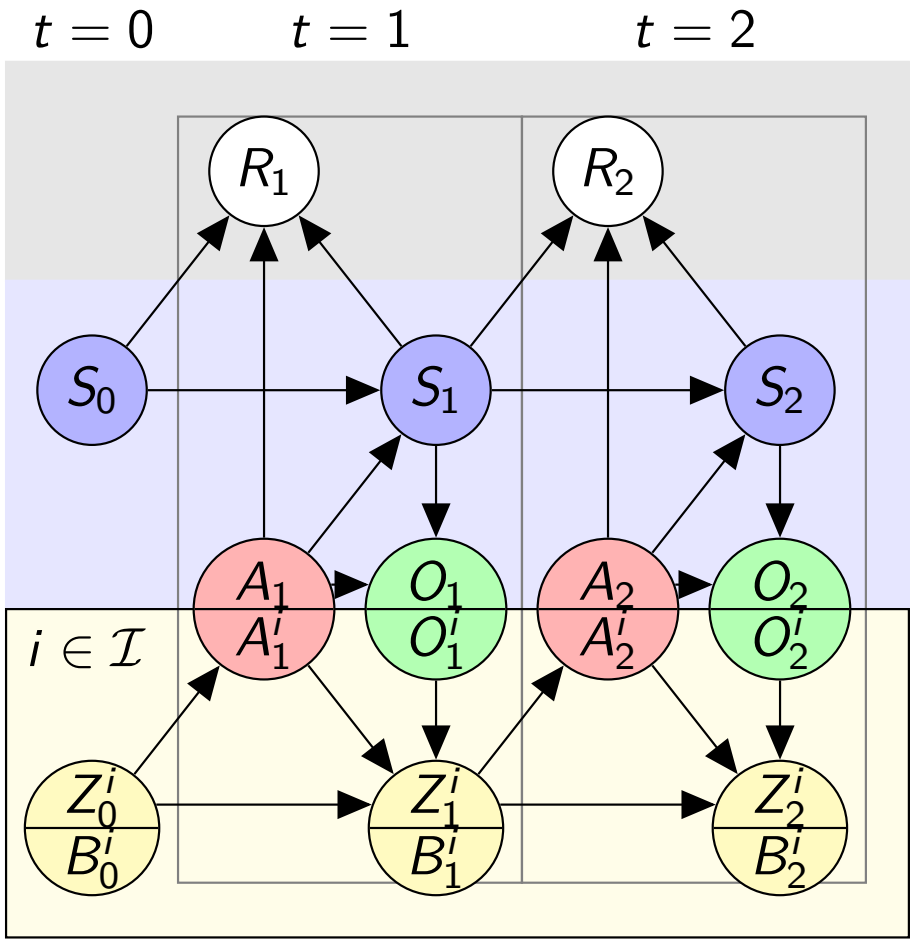

Croyance

Connaissance (bayésienne) de l'agent sur l'état du système

Mono-agent

$$B_t(s) = Pr(S_t = s | B_O, A_1, O_1, \ldots A_t, O_t)$$

Multi-agent

$$B^i_t(s, z_{-i}) = Pr(S_t = s, Z^{-i}_t = z_{-i} | B^i_O, A^i_1, O^i_1, \ldots A^i_t, O^i_t)$$

Raisonnement récursif : « je pense qu'il pense que je pense qu'il pense que je pense qu'il pense que ... »

Croyance

Connaissance (bayésienne) de l'agent sur l'état du système

Mono-agent

$$B_t(s) = Pr(S_t = s | B_O, A_1, O_1, \ldots A_t, O_t)$$

Multi-agent

$$B^i_t(s, z_{-i}) = Pr(S_t = s, Z^{-i}_t = z_{-i} | B^i_O, A^i_1, O^i_1, \ldots A^i_t, O^i_t)$$

Raisonnement récursif : « je pense qu'il pense que je pense qu'il pense que je pense qu'il pense que ... »

Arbres de politique

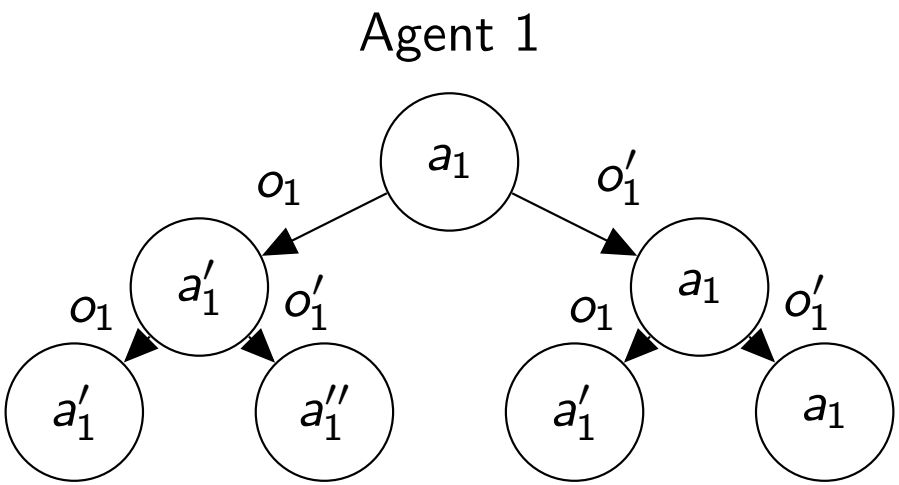

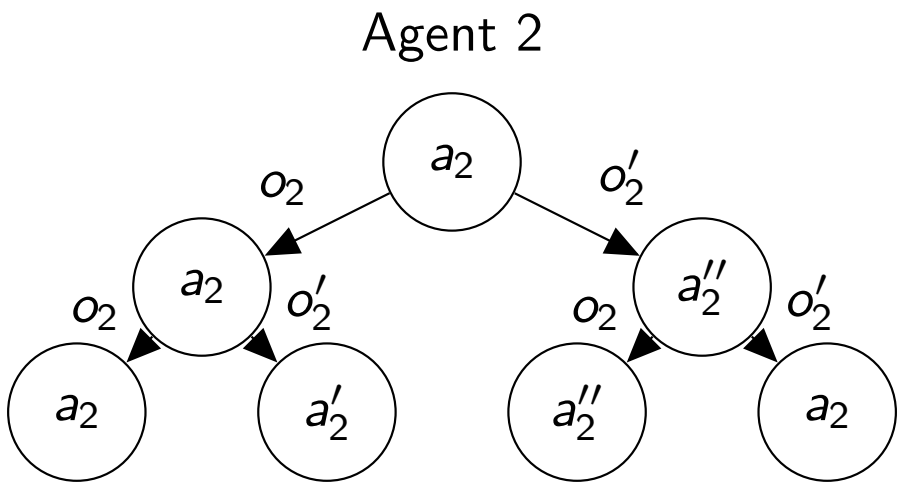

Évaluation des politiques jointes

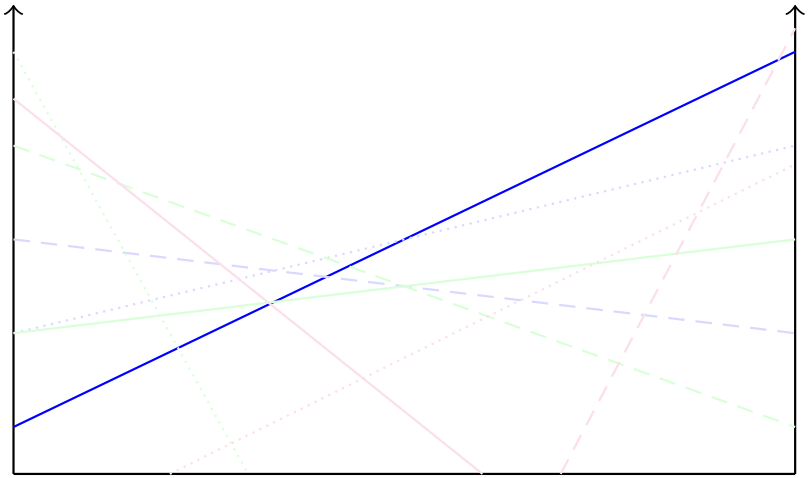

s_1
$\Pr(s_1) = 1$
$\Pr(s_2) = 0$

s_2
$\Pr(s_1) = 0$
$\Pr(s_2) = 1$

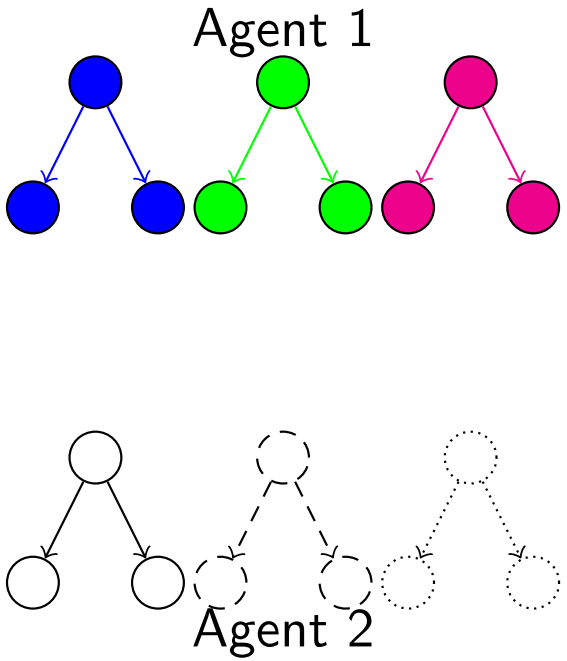

$$V_z(b) = \mathrm{E}[\sum_{t'=t}^{T} R_t | z, b] = \sum_s V_z(s) b(s)$$

$$V_{z_i}(b_i) = \mathrm{E}[\sum_{t'=t}^{T} R_t | z_i, b_i] = \sum_{s, z_{-i}} V_{(z_i, z_{-i})}(s) b(s, z_{-i})$$

Évaluation des politiques jointes

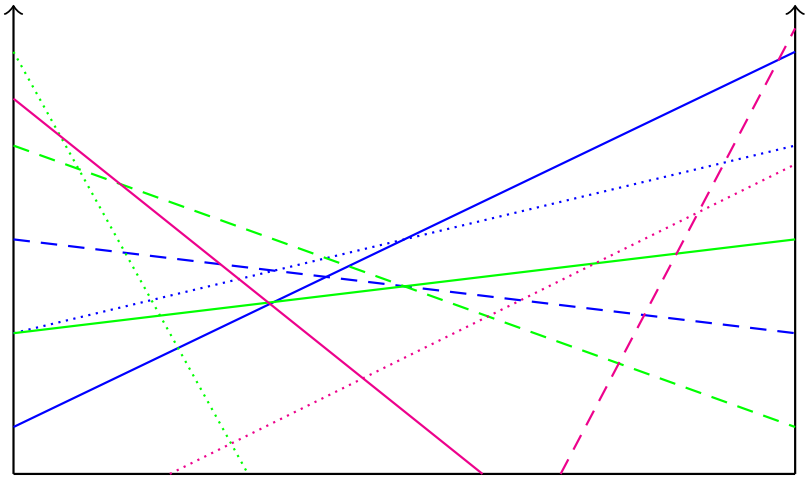

s_1
$\Pr(s_1) = 1$
$\Pr(s_2) = 0$

s_2
$\Pr(s_1) = 0$
$\Pr(s_2) = 1$

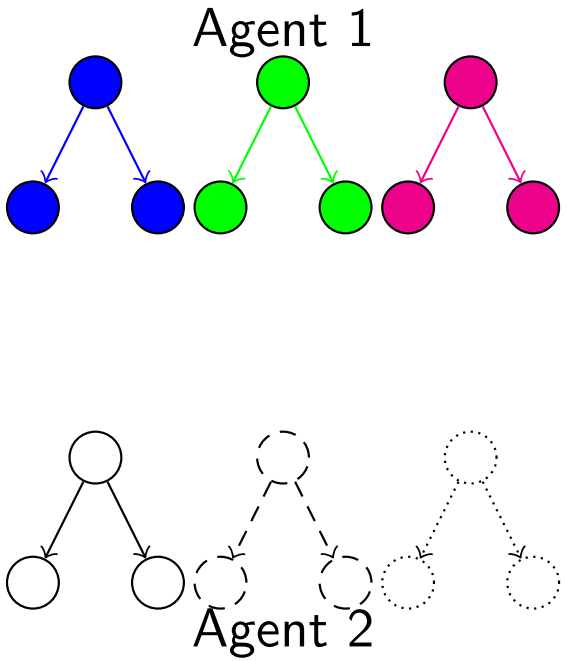

$$V_z(b) = \mathrm{E}[\sum_{t'=t}^{T} R_t | z, b] = \sum_s V_z(s) b(s)$$

$$V_{z_i}(b_i) = \mathrm{E}[\sum_{t'=t}^{T} R_t | z_i, b_i] = \sum_{s, z_{-i}} V_{(z_i, z_{-i})}(s) b(s, z_{-i})$$

Programmation dynamique

[hansen2004]

Chaînage arrière

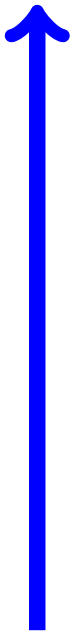

Chaînage avant

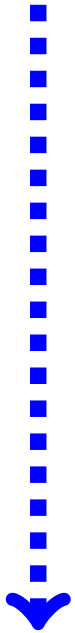

Programmation dynamique

$\mathcal{A}_i = \{a_i, a'_i\}$, $\Omega_i = \{o_i, o'_i\}$

Énumération des politiques
Évaluation des politiques jointes
[hansen2004]

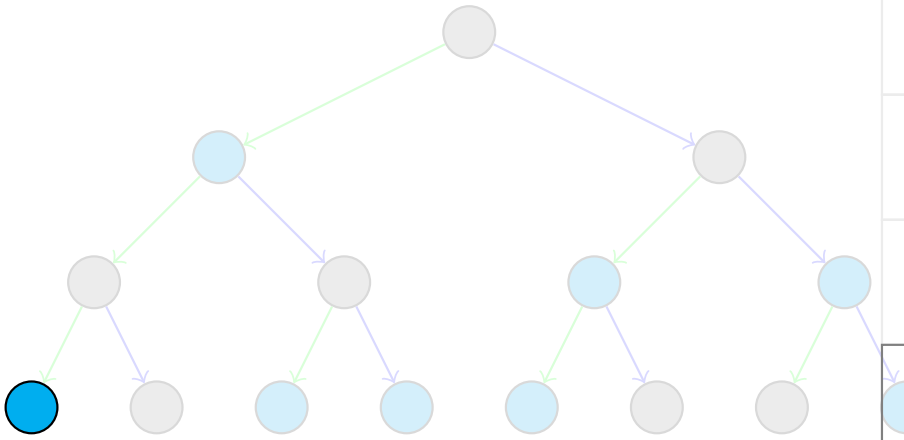

$|\mathcal{A}_i|^{|\Omega_i|^T}$

2×18^{38}
9×10^9
2×10^9
32768
128
8
2

Mise à jour exhaustive

Programmation dynamique

$\mathcal{A}_i = \{a_i, a'_i\}$, $\Omega_i = \{o_i, o'_i\}$

Énumération des politiques
Évaluation des politiques jointes
[hansen2004]

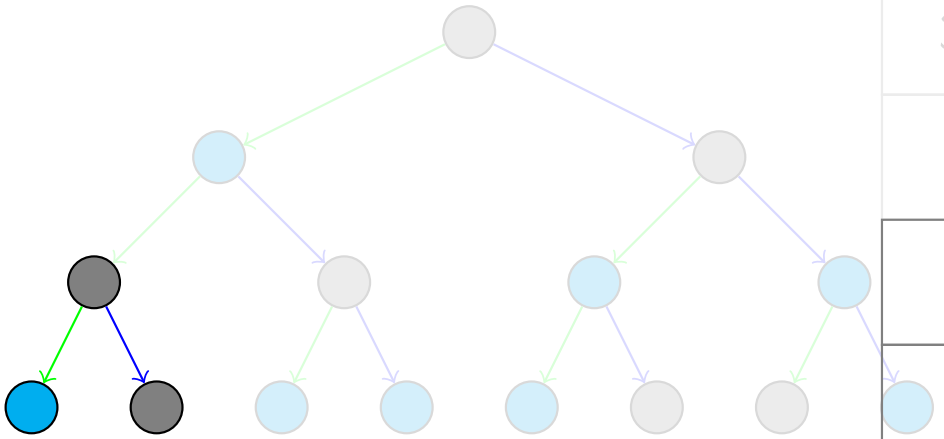

$|\mathcal{A}_i|^{|\Omega_i|^T}$

2×18^{38}
9×10^9
2×10^9
32768
128
8
2

Mise à jour exhaustive

Programmation dynamique

$\mathcal{A}_i = \{a_i, a'_i\}$, $\Omega_i = \{o_i, o'_i\}$

Énumération des politiques
Évaluation des politiques jointes
[hansen2004]

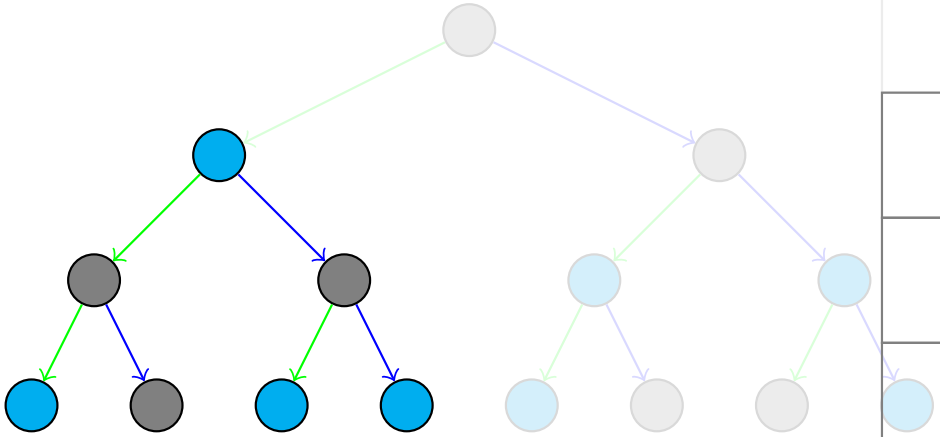

$|\mathcal{A}_i|^{|\Omega_i|^T}$

2×18^{38}

9×10^9

2×10^9

32768

128

8

2

Mise à jour exhaustive

Programmation dynamique

$\mathcal{A}_i = \{a_i, a'_i\}$, $\Omega_i = \{o_i, o'_i\}$

Énumération des politiques
Évaluation des politiques jointes
[hansen2004]

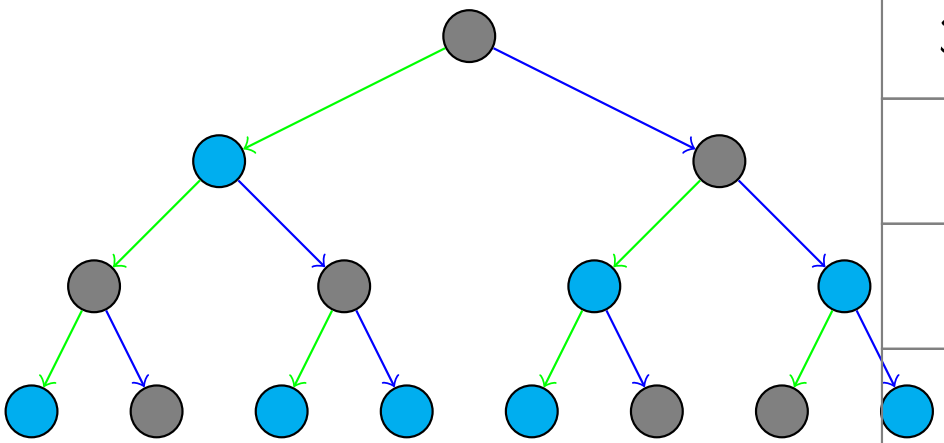

$|\mathcal{A}_i|^{|\Omega_i|^T}$

2×18^{38}
9×10^9
2×10^9
32768
128
8
2

Mise à jour exhaustive

Programmation dynamique

$\mathcal{A}_i = \{a_i, a'_i\}$, $\Omega_i = \{o_i, o'_i\}$

$|\mathcal{A}_i|^{|\Omega_i|^T}$

Énumération des politiques
Évaluation des politiques jointes
[hansen2004]

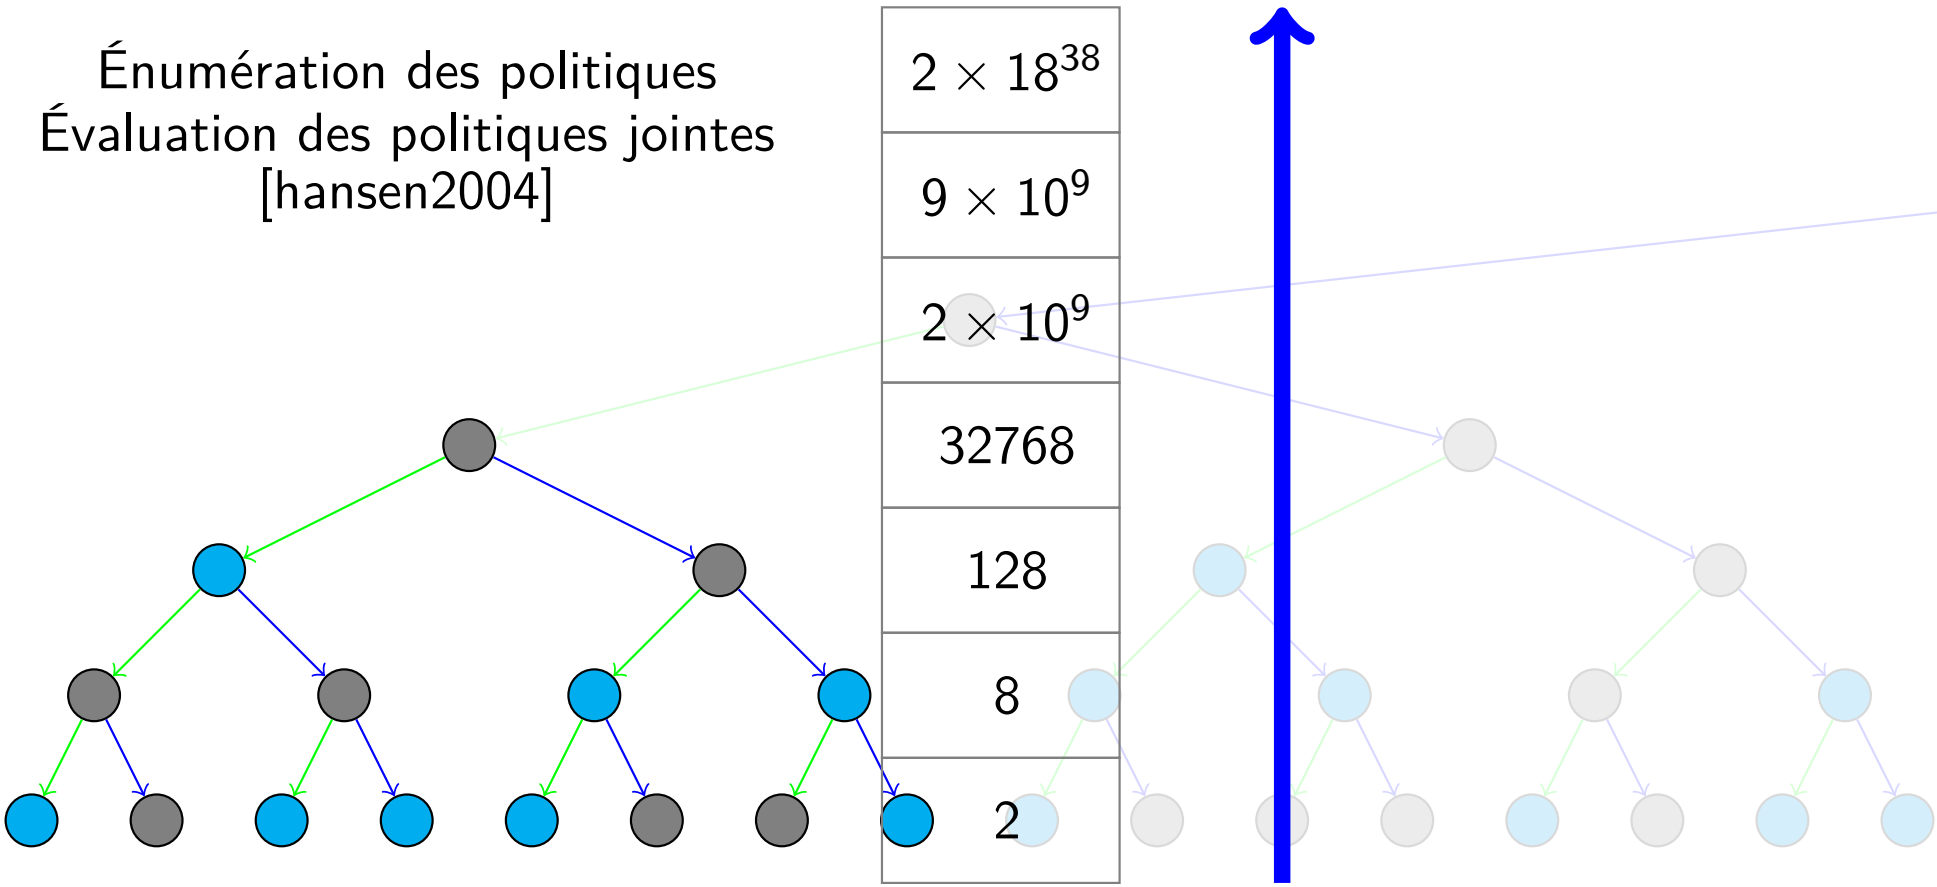

Mise à jour exhaustive

Élagage

$\mathcal{A}_i = \{a_i, a'_i\}$, $\Omega_i = \{o_i, o'_i\}$

Supprimer les politiques inutiles
$\forall b_i, \exists z'_i \neq z_i, V_{z'_i}(b_i) \geq V_{z_i}(b_i)$
[hansen2004]

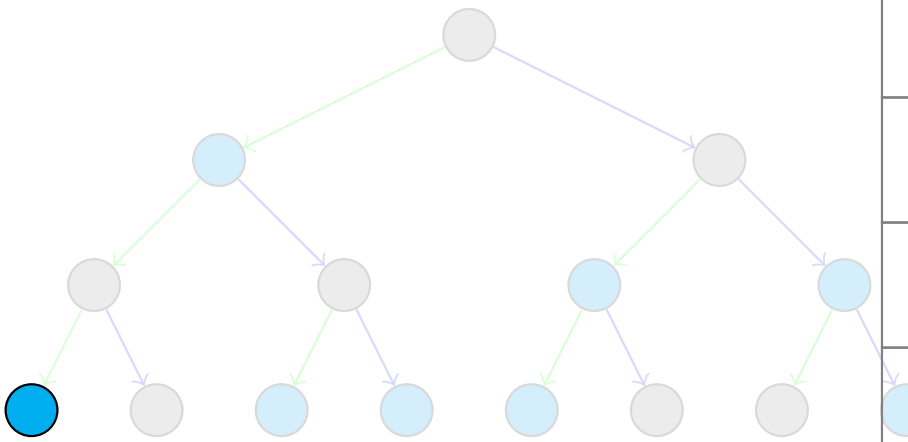

$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^T}$	$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^T}$
2×18^{38}	2×10^{19} ~~4×10^{19}~~
9×10^9	4×10^9 ~~8×10^9~~
2×10^9	65536 ~~131072~~
32768	256 ~~1024~~
128	16 ~~32~~
8	4 ~~8~~
2	2

Mise à jour exhaustive

Élagage (exemple)

Élagage

$\mathcal{A}_i = \{a_i, a'_i\}$, $\Omega_i = \{o_i, o'_i\}$

Supprimer les politiques inutiles
$\forall b_i, \exists z'_i \neq z_i, V_{z'_i}(b_i) \geq V_{z_i}(b_i)$
[hansen2004]

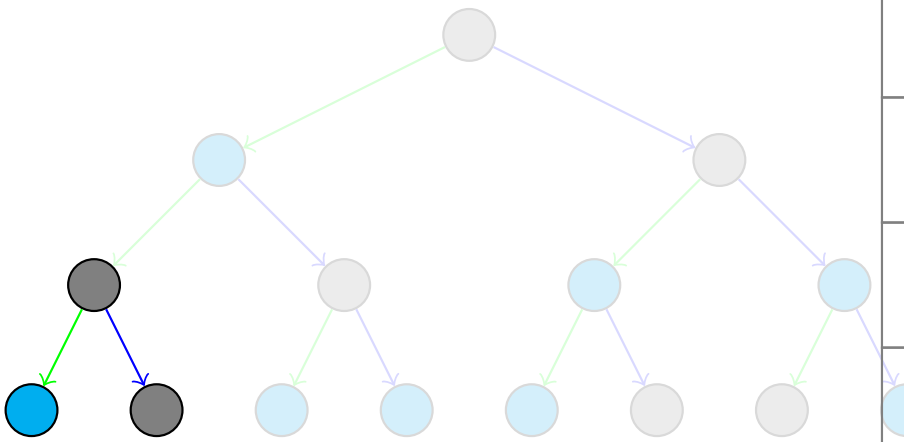

$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^T}$	
2×18^{38}	2×10^{19} ~~4×10^{19}~~
9×10^9	4×10^9 ~~8×10^9~~
2×10^9	65536 ~~131072~~
32768	256 ~~1024~~
128	16 ~~32~~
8	4 ~~8~~
2	2

Mise à jour exhaustive

Élagage (exemple)

Élagage

$\mathcal{A}_i = \{a_i, a'_i\}$, $\Omega_i = \{o_i, o'_i\}$

Supprimer les politiques inutiles
$\forall b_i, \exists z'_i \neq z_i, V_{z'_i}(b_i) \geq V_{z_i}(b_i)$
[hansen2004]

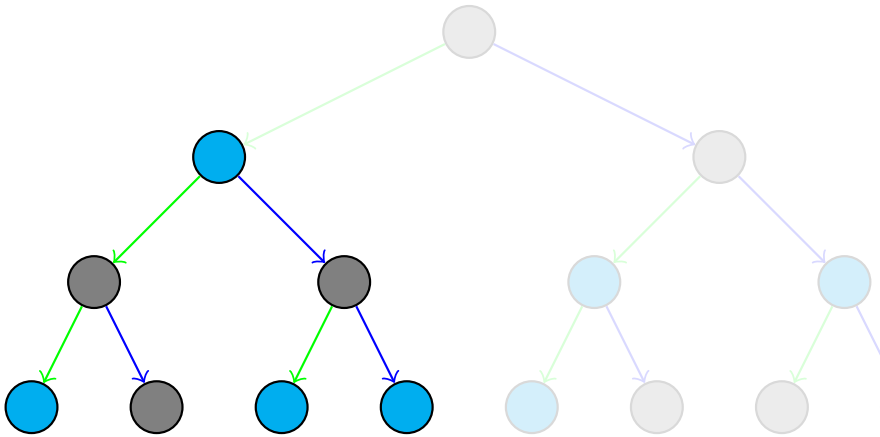

$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^T}$	$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^T}$
2×18^{38}	2×10^{19} ~~4×10^{19}~~
9×10^9	4×10^9 ~~8×10^9~~
2×10^9	65536 ~~131072~~
32768	256 ~~1024~~
128	16 ~~32~~
8	4 ~~8~~
2	2
Mise à jour exhaustive	Élagage (exemple)

Élagage

$\mathcal{A}_i = \{a_i, a'_i\}$, $\Omega_i = \{o_i, o'_i\}$

Supprimer les politiques inutiles
$\forall b_i, \exists z'_i \neq z_i, V_{z'_i}(b_i) \geq V_{z_i}(b_i)$
[hansen2004]

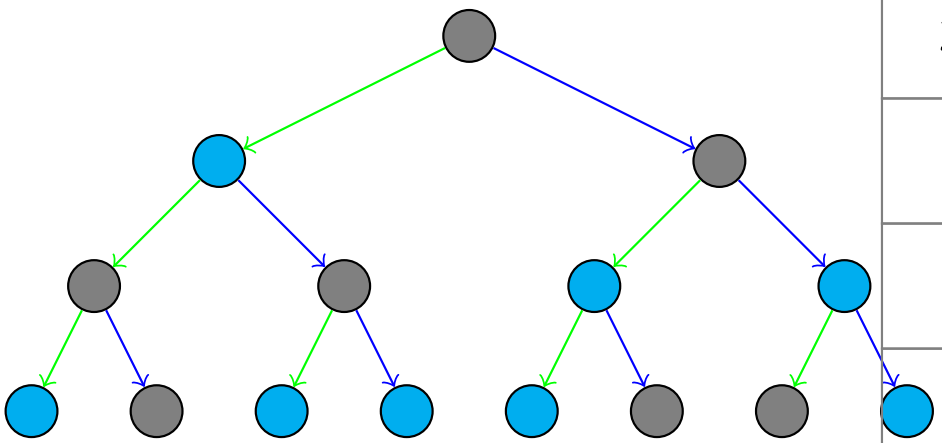

$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^T}$	
2×18^{38}	2×10^{19} ~~4×10^{19}~~
9×10^9	4×10^9 ~~8×10^9~~
2×10^9	65536 ~~131072~~
32768	256 ~~1024~~
128	16 ~~32~~
8	4 ~~8~~
2	2

Mise à jour exhaustive

Élagage (exemple)

Élagage

$\mathcal{A}_i = \{a_i, a'_i\}$, $\Omega_i = \{o_i, o'_i\}$

Supprimer les politiques inutiles
$\forall b_i, \exists z'_i \neq z_i, V_{z'_i}(b_i) \geq V_{z_i}(b_i)$
[hansen2004]

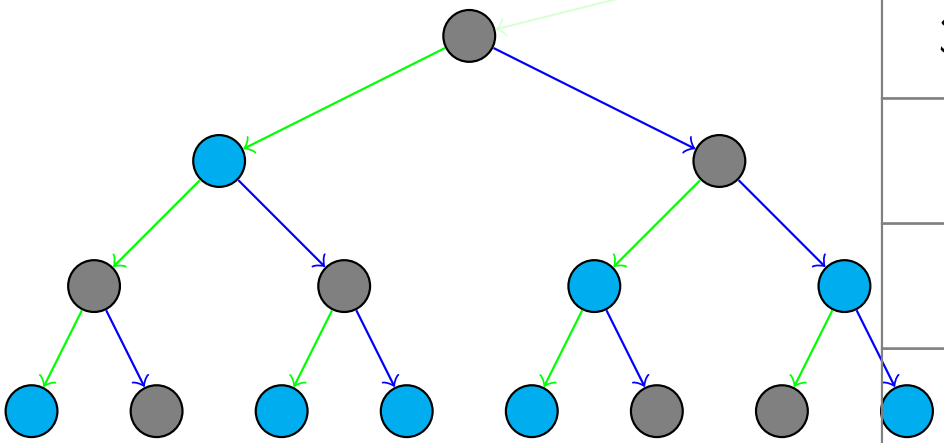

$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^T}$	$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^T}$
2×18^{38}	2×10^{19} ~~4×10^{19}~~
9×10^9	4×10^9 ~~8×10^9~~
2×10^9	65536 ~~131072~~
32768	256 ~~1024~~
128	16 ~~32~~
8	4 ~~8~~
2	2
Mise à jour exhaustive	Élagage (exemple)

Accessibilité

Élagage de z_i :

$$\forall b_i, \exists z_i' \neq z_i, V_{z_i'}(b_i) \geq V_{z_i}(b_i)$$

Prendre en compte l'accessibilité [szer2006c] [seuken2007a] [dibangoye2008]

Dépend de la politique π de 0 à t (inconnue)

PBDP [szer2006c] (*Point Based Dynamic Programming*) :

- échantillonner π
- échantilonner b_i

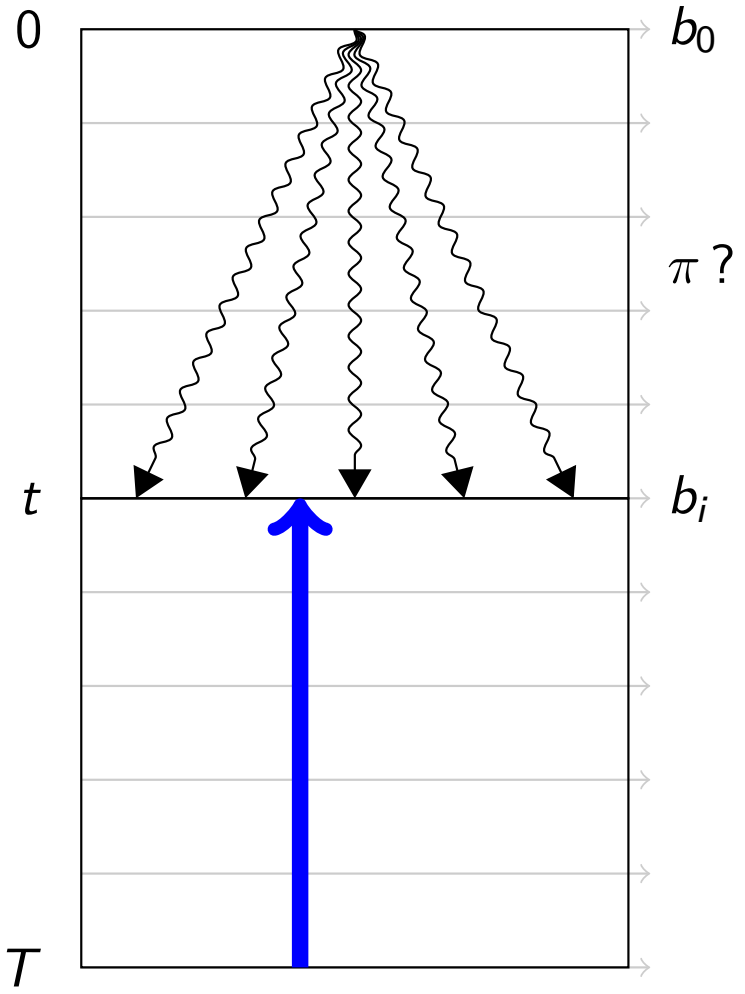

Mémoire bornée

MBDP (*Memory Bounded Dynamic Programming*) [seuken2007a]

$\mathcal{A}_i = \{a_i, a'_i\}$, $\Omega_i = \{o_i, o'_i\}$

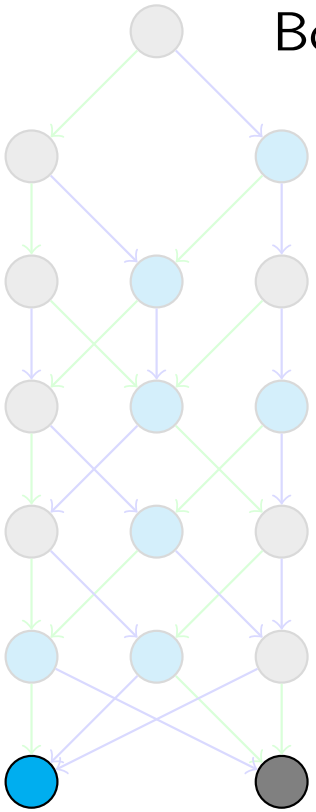

Borner le nombre d'arbres
(Structure de trellis)

Complexité contrôlée
N'est plus optimal

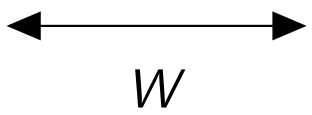

$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^T}$	$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^t}$	$\lvert\mathcal{A}_i\rvert W^{\lvert\Omega_i\rvert}$
2×18^{38}	2×10^{19} ~~4×10^{19}~~	3 ~~18~~
9×18^9	4×10^9 ~~8×10^9~~	3 ~~18~~
2×10^9	65536 ~~131072~~	3 ~~18~~
32768	256 ~~1024~~	3 ~~18~~
128	16 ~~32~~	3 ~~18~~
8	4 ~~8~~	3 ~~8~~
2	2	2
Mise à jour exhaustive	Élagage (exemple)	MBDP ($W = 3$)

Mémoire bornée

MBDP (*Memory Bounded Dynamic Programming*) [seuken2007a]

$\mathcal{A}_i = \{a_i, a'_i\}$, $\Omega_i = \{o_i, o'_i\}$

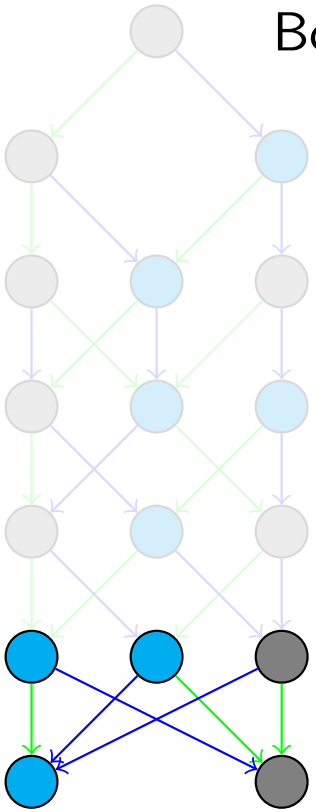

Borner le nombre d'arbres (Structure de trellis)

Complexité contrôlée
N'est plus optimal

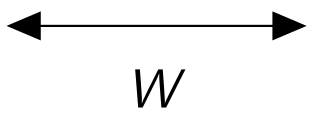

$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^T}$	$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^t}$	$\lvert\mathcal{A}_i\rvert W^{\lvert\Omega_i\rvert}$
2×18^{38}	2×10^{19} ~~4×10^{19}~~	3 ~~18~~
9×18^9	4×10^9 ~~8×10^9~~	3 ~~18~~
2×10^9	65536 ~~131072~~	3 ~~18~~
32768	256 ~~1024~~	3 ~~18~~
128	16 ~~32~~	3 ~~18~~
8	4 ~~8~~	3 ~~8~~
2	2	2
Mise à jour exhaustive	Élagage (exemple)	MBDP ($W = 3$)

Mémoire bornée

MBDP (*Memory Bounded Dynamic Programming*) [seuken2007a]

$\mathcal{A}_i = \{a_i, a'_i\}$, $\Omega_i = \{o_i, o'_i\}$

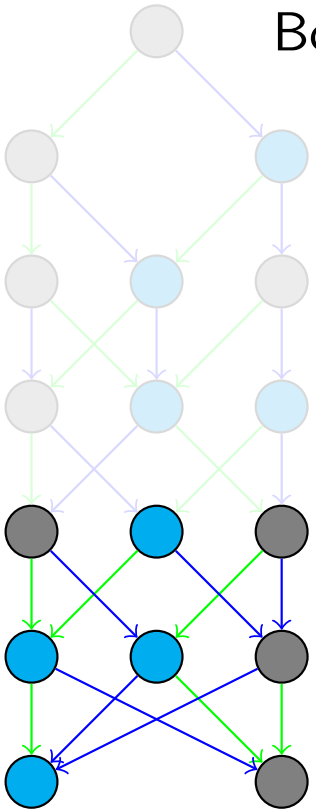

Borner le nombre d'arbres
(Structure de trellis)

Complexité contrôlée
N'est plus optimal

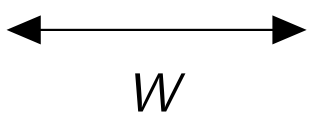

$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^T}$	$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^t}$	$\lvert\mathcal{A}_i\rvert W^{\lvert\Omega_i\rvert}$
2×18^{38}	2×10^{19} ~~4×10^{19}~~	3 ~~18~~
9×18^9	4×10^9 ~~8×10^9~~	3 ~~18~~
2×10^9	65536 ~~131072~~	3 ~~18~~
32768	256 ~~1024~~	3 ~~18~~
128	16 ~~32~~	3 ~~18~~
8	4 ~~8~~	3 ~~8~~
2	2	2
Mise à jour exhaustive	Élagage (exemple)	MBDP ($W = 3$)

Mémoire bornée

MBDP (*Memory Bounded Dynamic Programming*) [seuken2007a]

$\mathcal{A}_i = \{a_i, a'_i\}$, $\Omega_i = \{o_i, o'_i\}$

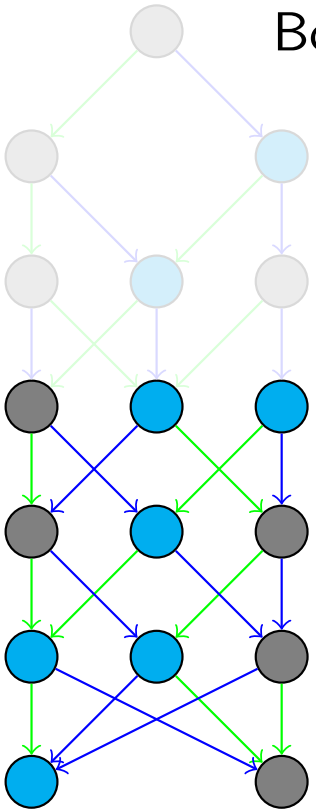

Borner le nombre d'arbres
(Structure de trellis)

Complexité contrôlée
N'est plus optimal

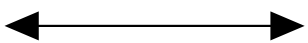

W

$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^T}$	$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^t}$	$\lvert\mathcal{A}_i\rvert W^{\lvert\Omega_i\rvert}$
2×18^{38}	2×10^{19} ~~4×10^{19}~~	3 ~~18~~
9×18^9	4×10^9 ~~8×10^9~~	3 ~~18~~
2×10^9	65536 ~~131072~~	3 ~~18~~
32768	256 ~~1024~~	3 ~~18~~
128	16 ~~32~~	3 ~~18~~
8	4 ~~8~~	3 ~~8~~
2	2	2
Mise à jour exhaustive	Élagage (exemple)	MBDP ($W = 3$)

Mémoire bornée

MBDP (*Memory Bounded Dynamic Programming*) [seuken2007a]

$\mathcal{A}_i = \{a_i, a'_i\}$, $\Omega_i = \{o_i, o'_i\}$

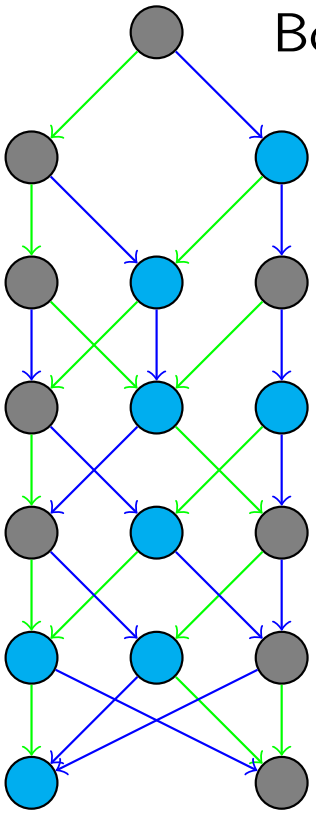

W

Borner le nombre d'arbres (Structure de trellis)

Complexité contrôlée
N'est plus optimal

$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^T}$	$\lvert\mathcal{A}_i\rvert^{\lvert\Omega_i\rvert^t}$	$\lvert\mathcal{A}_i\rvert W^{\lvert\Omega_i\rvert}$
2×18^{38}	2×10^{19} ~~4×10^{19}~~	3 ~~18~~
9×18^9	4×10^9 ~~8×10^9~~	3 ~~18~~
2×10^9	65536 ~~131072~~	3 ~~18~~
32768	256 ~~1024~~	3 ~~18~~
128	16 ~~32~~	3 ~~18~~
8	4 ~~8~~	3 ~~8~~
2	2	2
Mise à jour exhaustive	Élagage (exemple)	MBDP ($W = 3$)

Heuristique

Utilise la croyance centralisée :

$B_t(s) = \Pr(S_t = s | B_O = b_0, A_1, O_1, \ldots A_t, O_t)$

Politique(s) heuristique(s) $\hat{\pi}$

Sélectionne W points

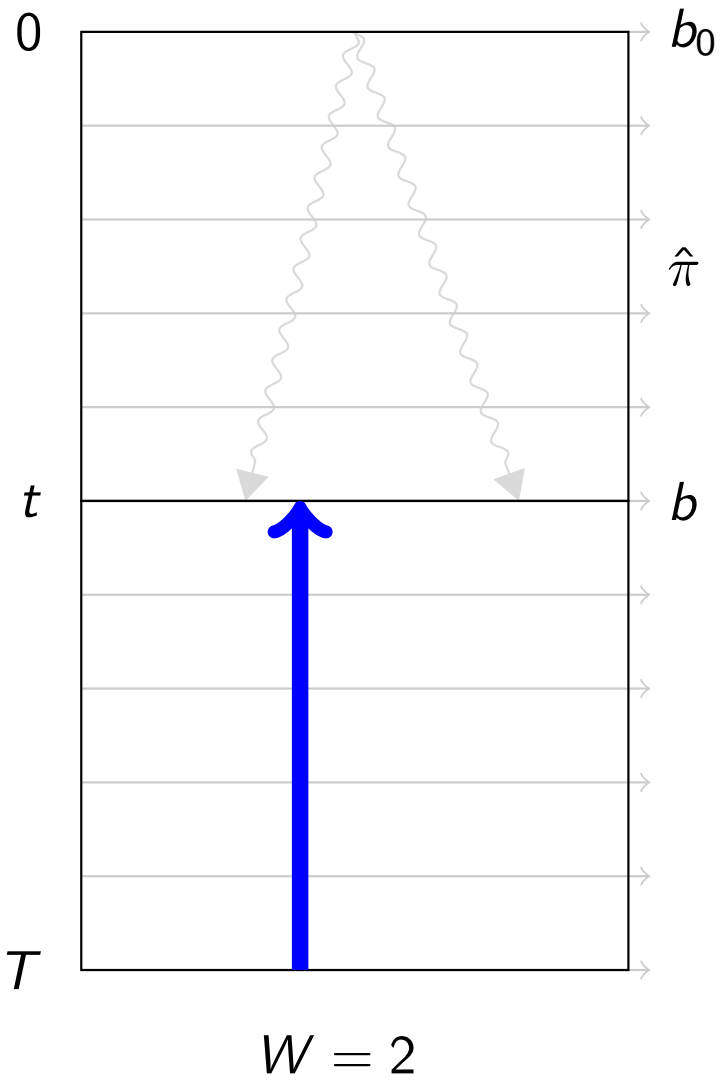

Heuristique

Utilise la croyance centralisée :

$B_t(s) = \Pr(S_t = s | B_O = b_0, A_1, O_1, \ldots A_t, O_t)$

Politique(s) heuristique(s) $\hat{\pi}$

Sélectionne W points

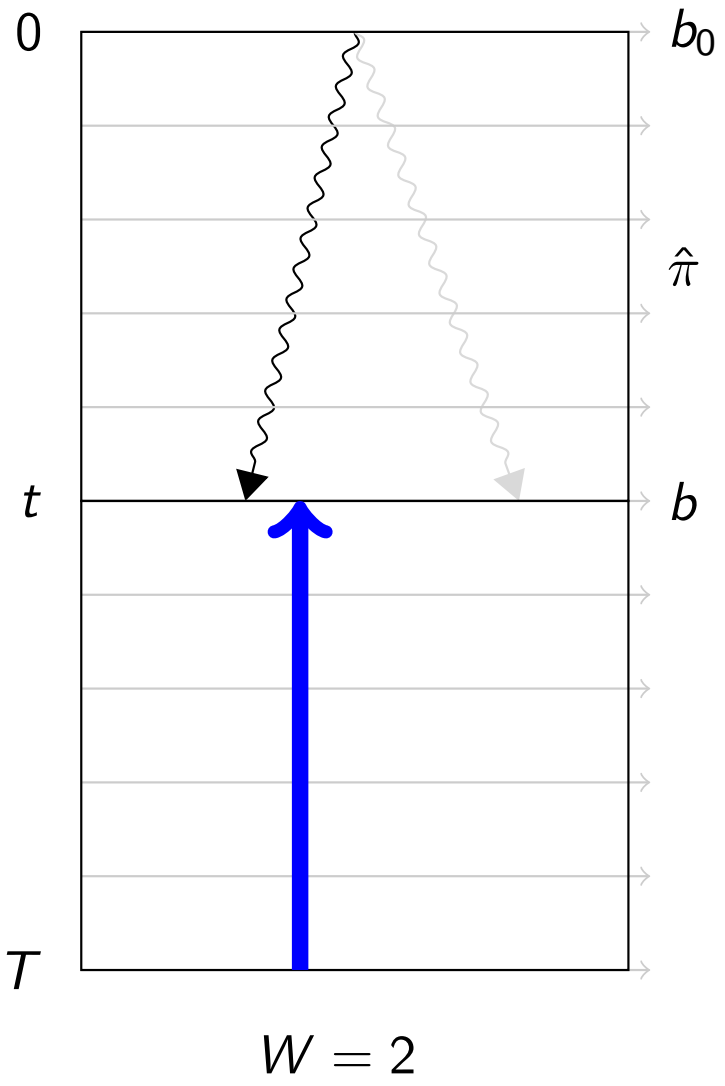

Heuristique

Utilise la croyance centralisée :

$B_t(s) = \Pr(S_t = s | B_O = b_0, A_1, O_1, \ldots A_t, O_t)$

Politique(s) heuristique(s) $\hat{\pi}$

Sélectionne W points

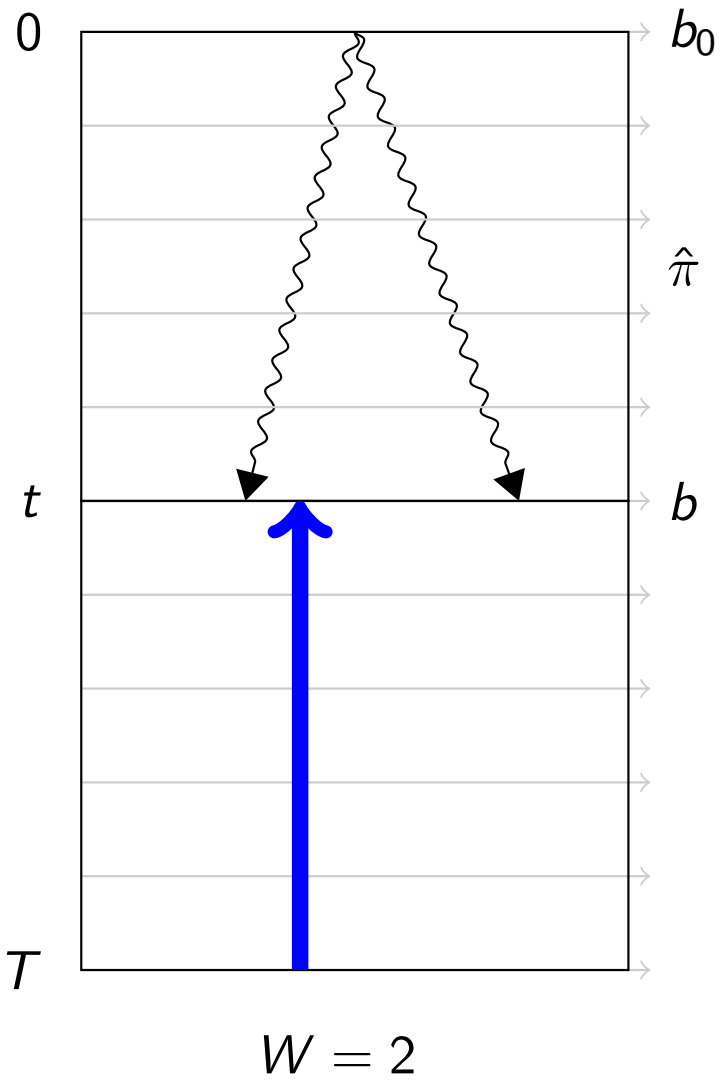

Sélection des arbres de politique

Optimisation indépendamment en W points (problème de *lookahead*)

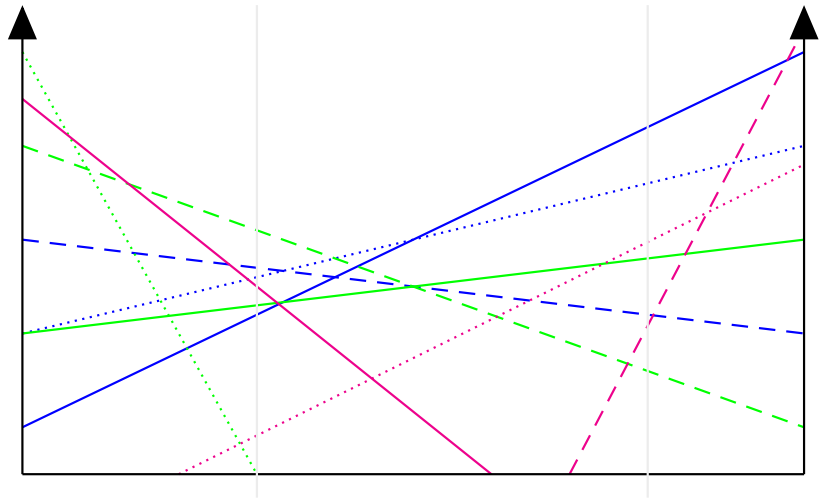

s_1
$\Pr(s_1) = 1$
$\Pr(s_2) = 0$

s_2
$\Pr(s_1) = 0$
$\Pr(s_2) = 1$

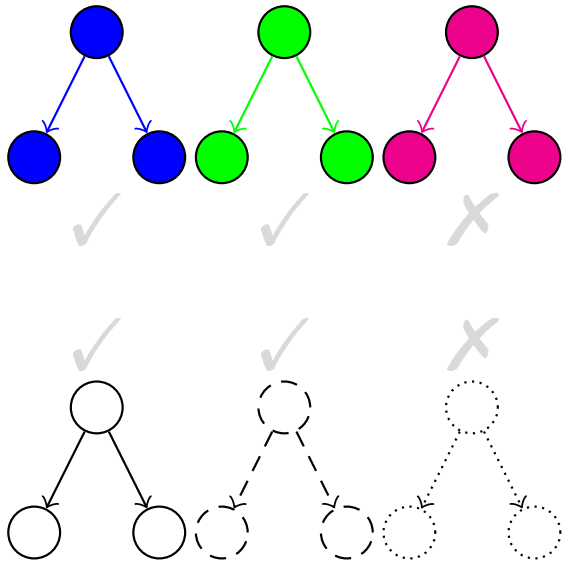

$W = 2$

Décomposé en W sous-problèmes indépendants

Sélection des arbres de politique

Optimisation indépendamment en W points (problème de *lookahead*)

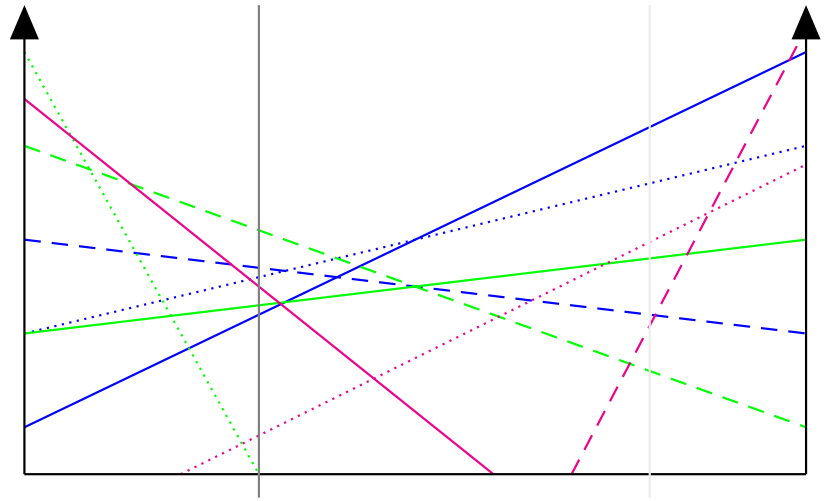

s_1
$\Pr(s_1) = 1$
$\Pr(s_2) = 0$

s_2
$\Pr(s_1) = 0$
$\Pr(s_2) = 1$

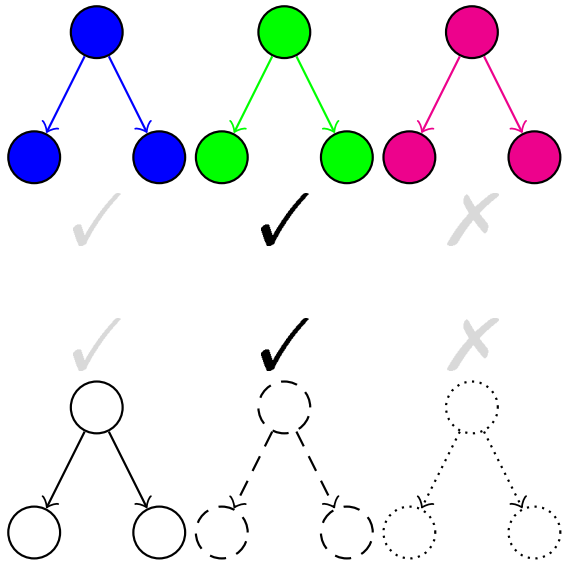

$W = 2$

Décomposé en W sous-problèmes indépendants

Sélection des arbres de politique

Optimisation indépendamment en W points (problème de *lookahead*)

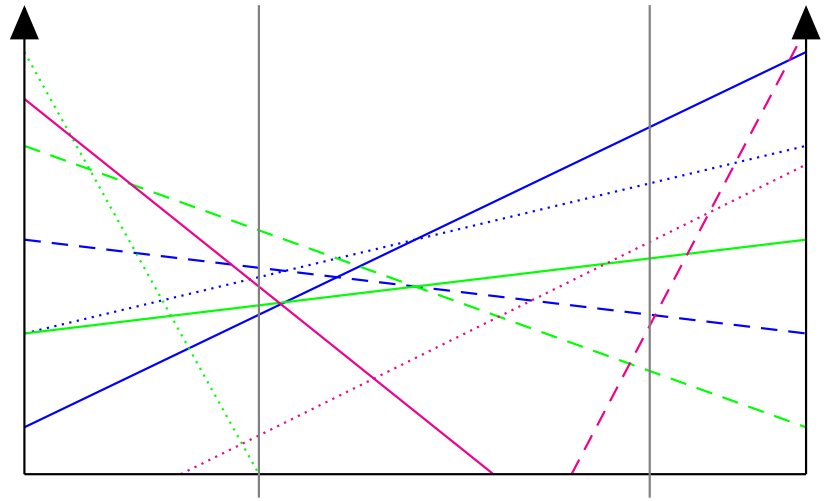

s_1
$\Pr(s_1) = 1$
$\Pr(s_2) = 0$

s_2
$\Pr(s_1) = 0$
$\Pr(s_2) = 1$

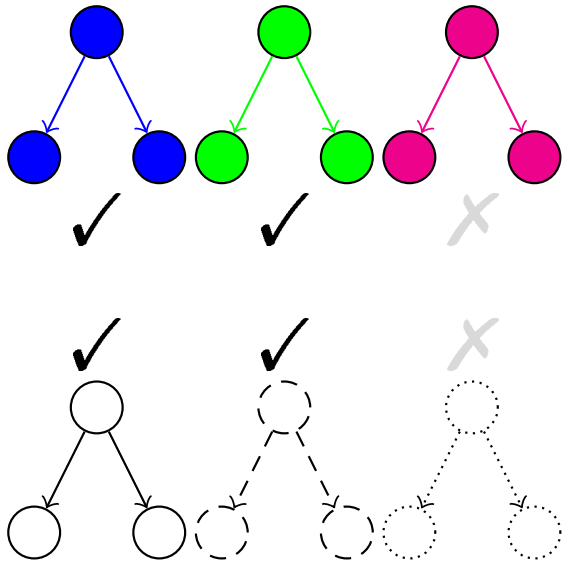

$W = 2$

Décomposé en W sous-problèmes indépendants

Sélection des arbres de politique

Optimisation indépendamment en W points (problème de *lookahead*)

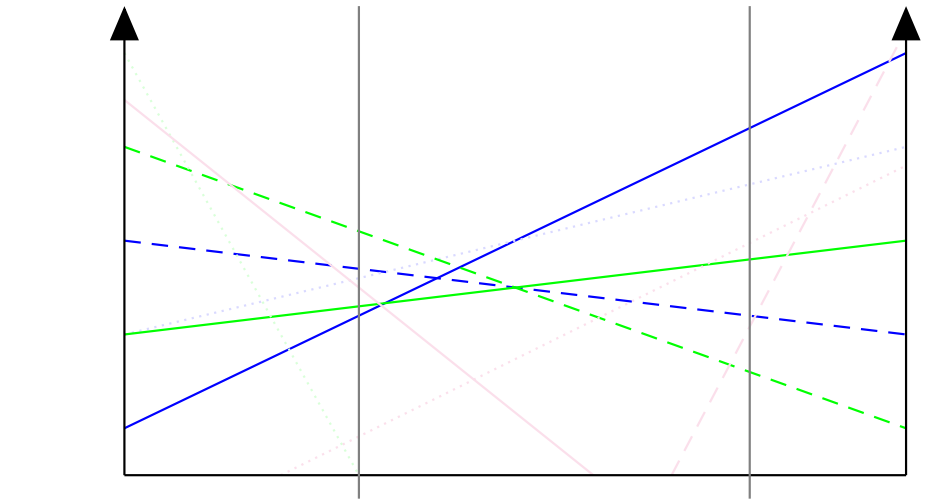

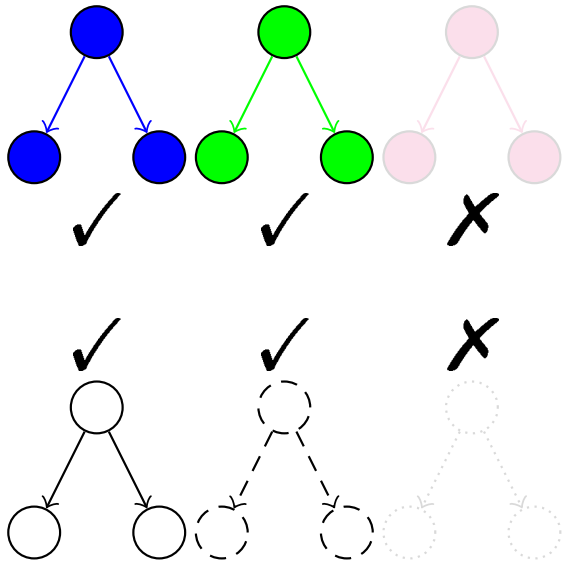

$W = 2$

Décomposé en W sous-problèmes indépendants

Opération de *Lookahead*

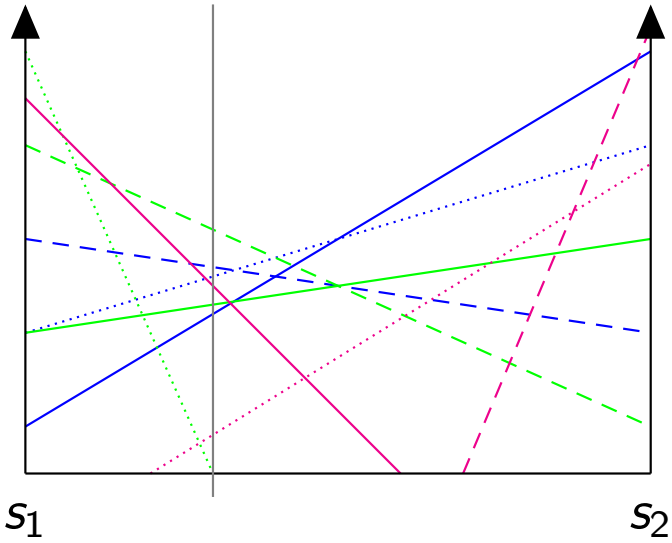

MBDP [seuken2007a]

Memory Bounded Dynamic Programming
Recherche exhaustive

$$\prod_{i \in \mathcal{I}} |\mathcal{A}_i| W^{|\Omega_i|}$$

Problème d'optimisation combinatoire

PBIP [dibangoye2008]

Point Based Incremental Pruning
Recherche *branch-and-bound* :

- plus rapide
- même complexité de manière générale

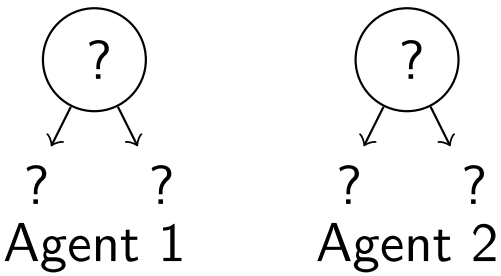

Contributions

Résolution approchée des problèmes de *lookahead*

« plus rapide (au risque d'être moins bon) »

Connaissance heuristique sur le problème pour guider la planification

« meilleure qualité (au risque d'être plus lent) »

Résumé de l'état de l'art

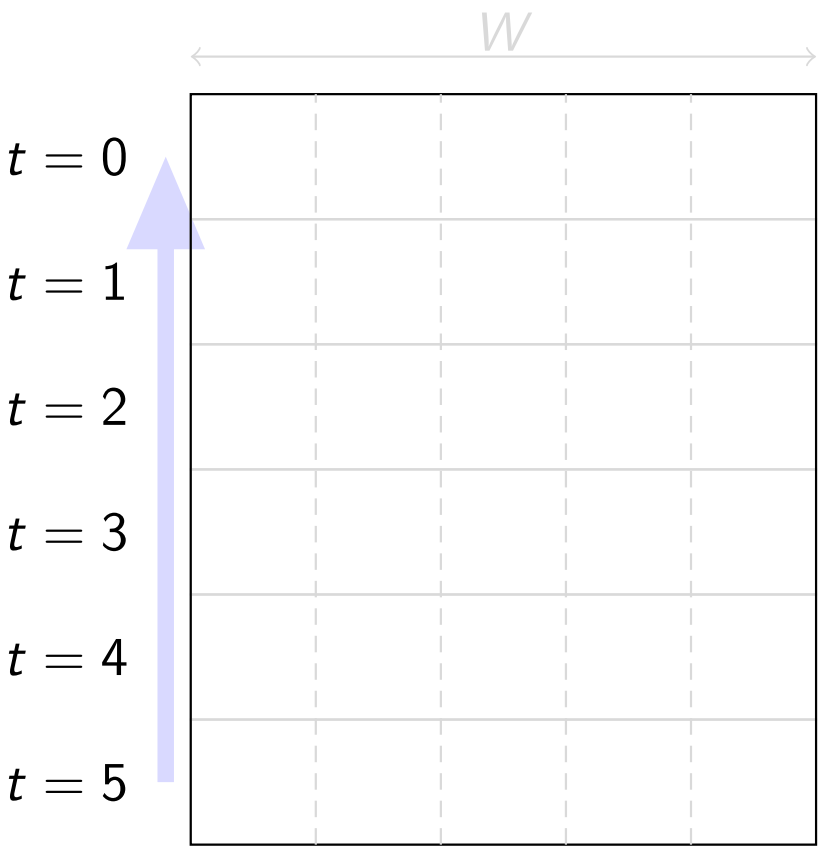

1. décomposition DP rétrograde
2. politiques bornées (W)
3. W *lookaheads* indépendants

Limites :

- espace de recherche, $\prod_{i \in \mathcal{I}} |\mathcal{A}_i| W^{|\Omega_i|}$
- W très petit

Résolution exacte d'un sous-problème obtenu par de nombreuses approximations

Résumé de l'état de l'art

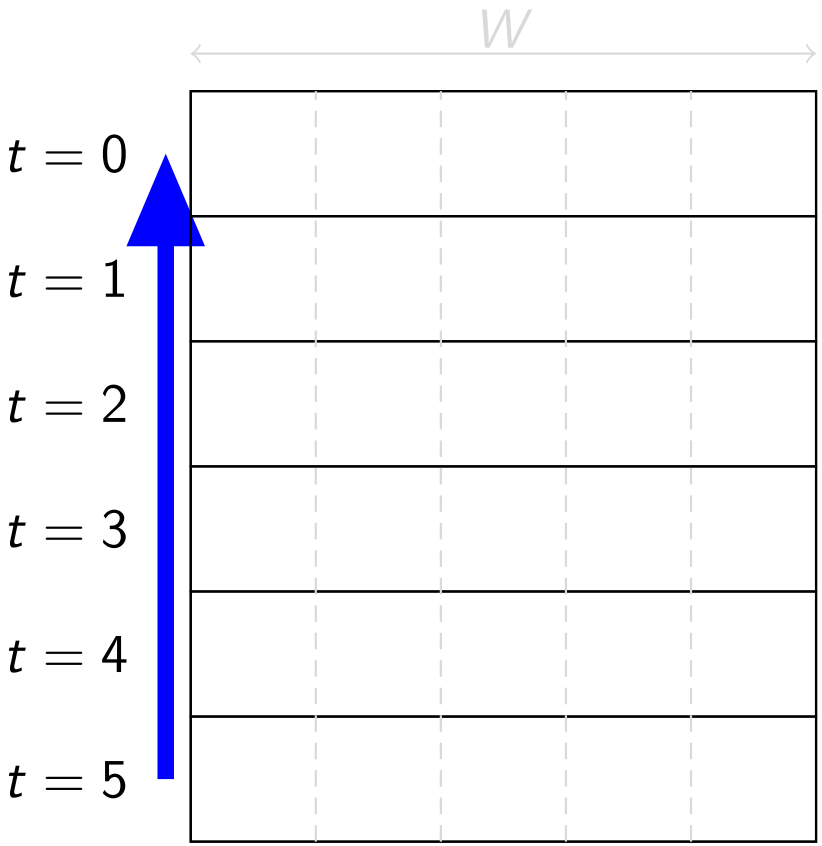

1. décomposition DP rétrograde
2. politiques bornées (W)
3. W *lookaheads* indépendants

Limites :

- espace de recherche, $\prod_{i \in \mathcal{I}} |\mathcal{A}_i| W^{|\Omega_i|}$
- W très petit

Résolution exacte d'un sous-problème obtenu par de nombreuses approximations

Résumé de l'état de l'art

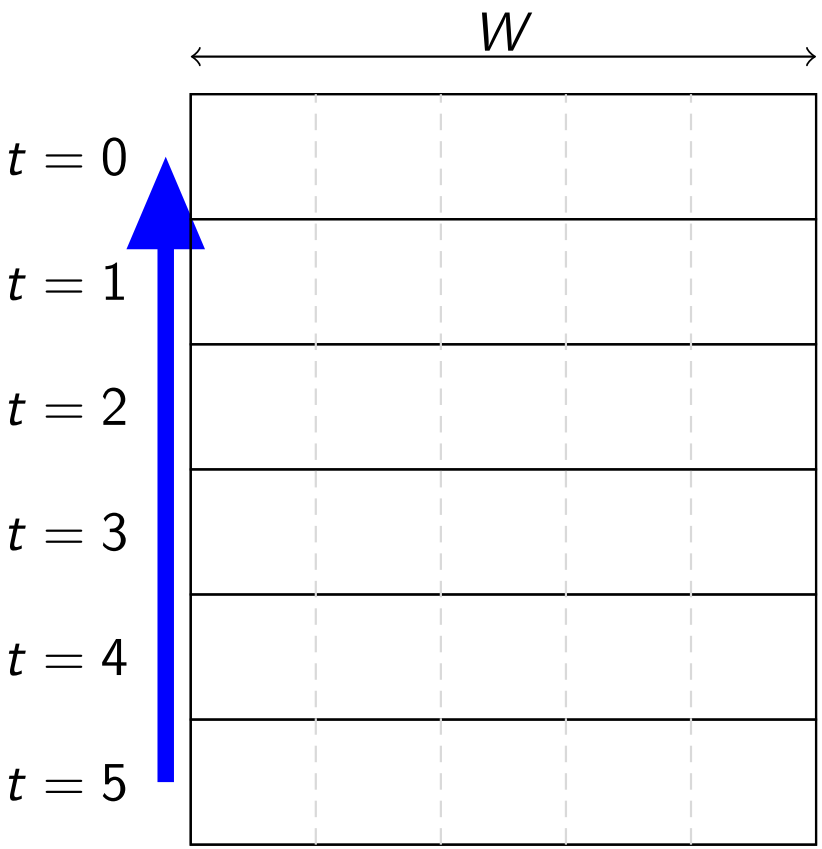

1. décomposition DP rétrograde
2. politiques bornées (W)
3. W *lookaheads* indépendants

Limites :

- espace de recherche, $\prod_{i \in \mathcal{I}} |\mathcal{A}_i| W^{|\Omega_i|}$
- W très petit

Résolution exacte d'un sous-problème obtenu par de nombreuses approximations

Résumé de l'état de l'art

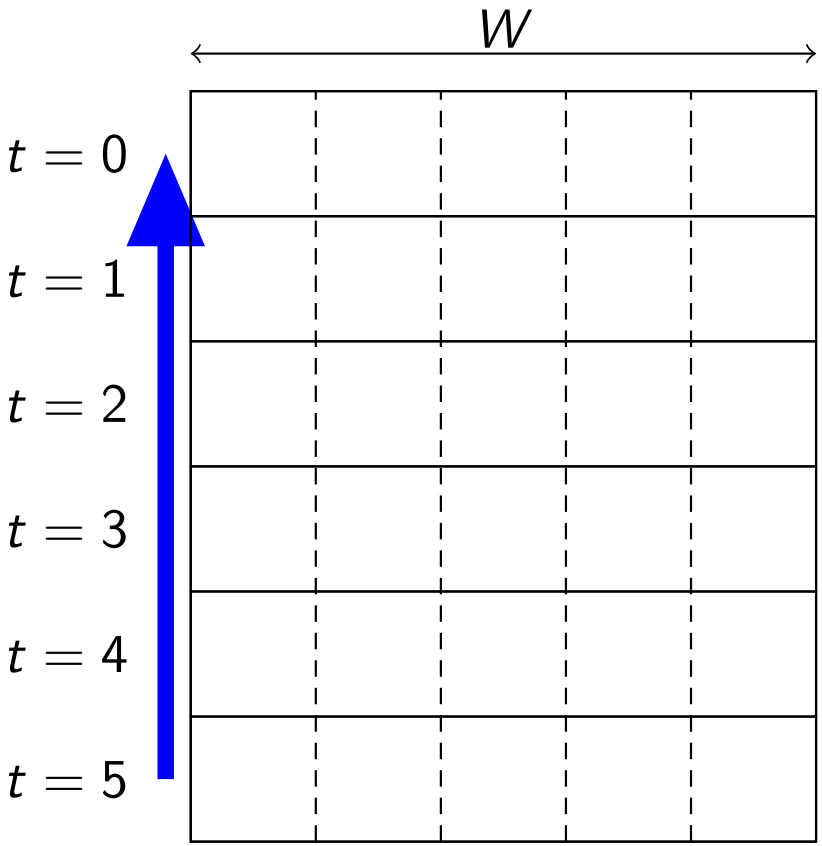

1. décomposition DP rétrograde
2. politiques bornées (W)
3. W *lookaheads* indépendants

Limites :

- espace de recherche, $\prod_{i \in \mathcal{I}} |\mathcal{A}_i| W^{|\Omega_i|}$
- W très petit

Résolution exacte d'un sous-problème obtenu par de nombreuses approximations

Résumé de l'état de l'art

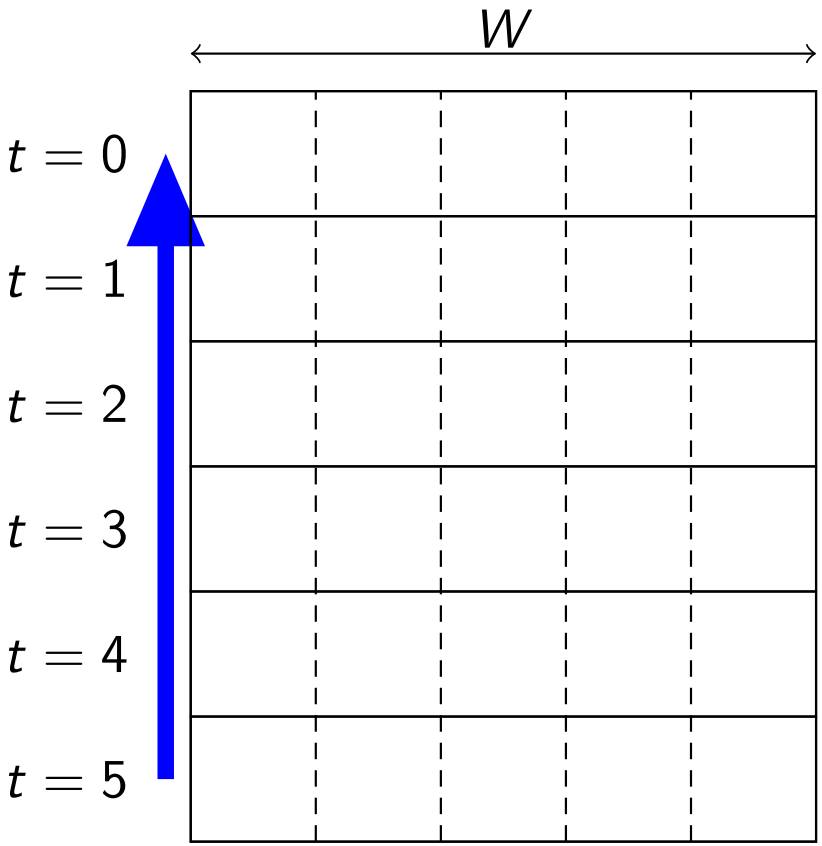

1. décomposition DP rétrograde
2. politiques bornées (W)
3. W *lookaheads* indépendants

Limites :

- espace de recherche, $\prod_{i \in \mathcal{I}} |\mathcal{A}_i| W^{|\Omega_i|}$
- W très petit

Résolution exacte d'un sous-problème obtenu par de nombreuses approximations

Lookahead approché

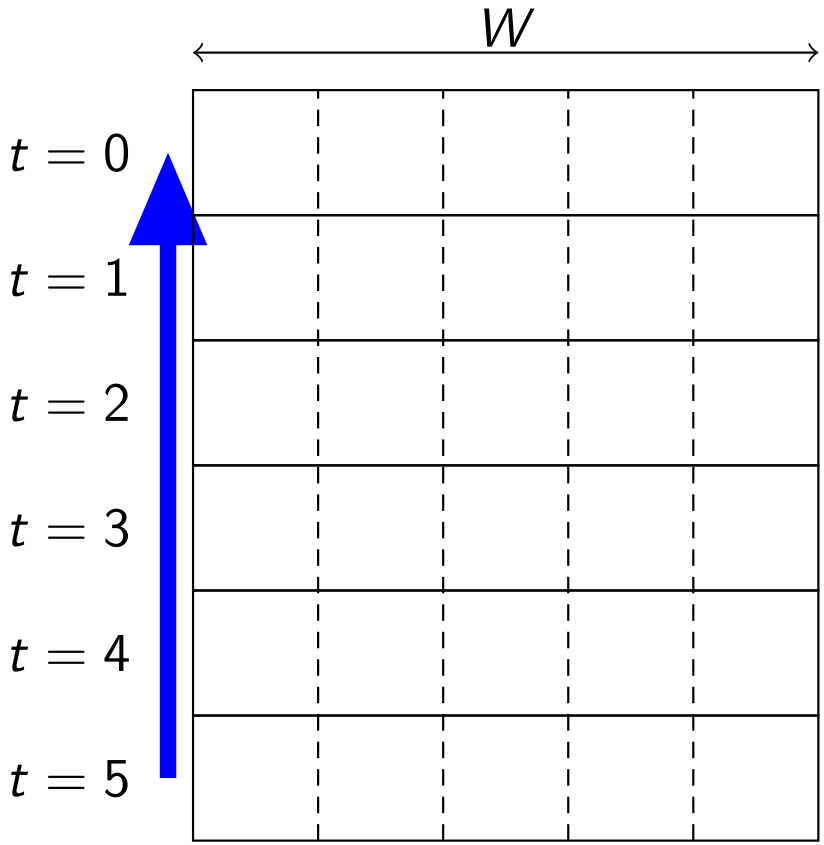

Résolution approchée, méta-heuristiques :

- ↘ complexité
- ↘ temps de calcul (à W constant)
- qualité attendue similaire (à W constant)
- ↗ arbres de politiques, qualité

Compromis W/résolution exacte

Optimisation locale

Recherche d'un maximum local : équilibre de Nash

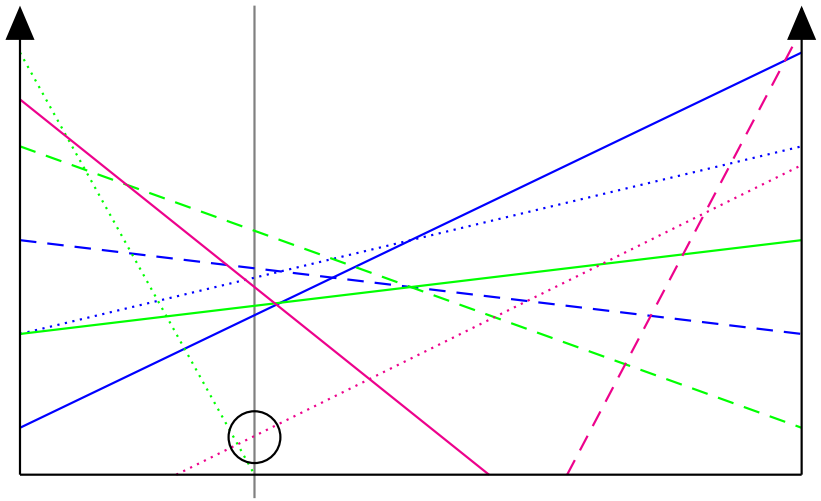

s_1
$\Pr(s_1) = 1$
$\Pr(s_2) = 0$

s_2
$\Pr(s_1) = 0$
$\Pr(s_2) = 1$

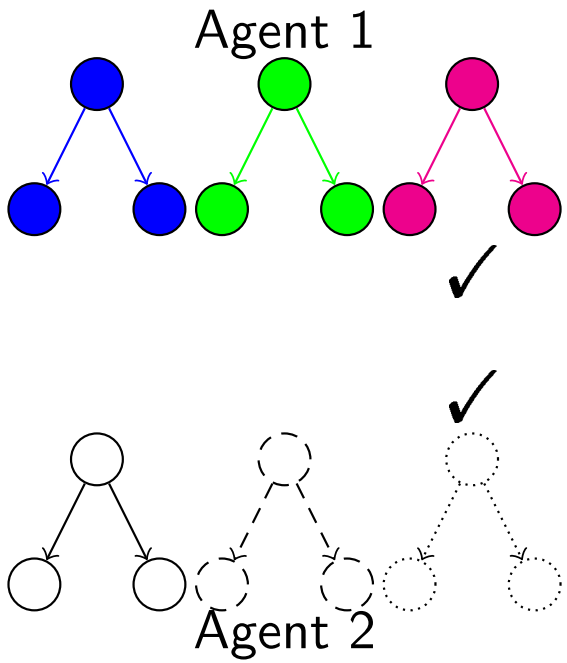

MBDP/NE : *Memory Bounded Dynamic Programming with Nash Equilibrium*

Pas une idée isolée : [kumar2010b], DecRSPI [wu2010], PBPG [wu2010b]

Optimisation locale

Recherche d'un maximum local : équilibre de Nash

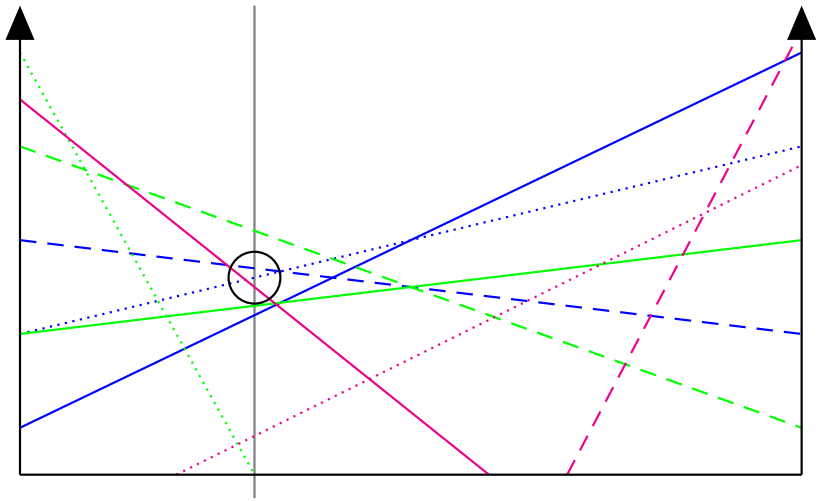

s_1
$\Pr(s_1) = 1$
$\Pr(s_2) = 0$

s_2
$\Pr(s_1) = 0$
$\Pr(s_2) = 1$

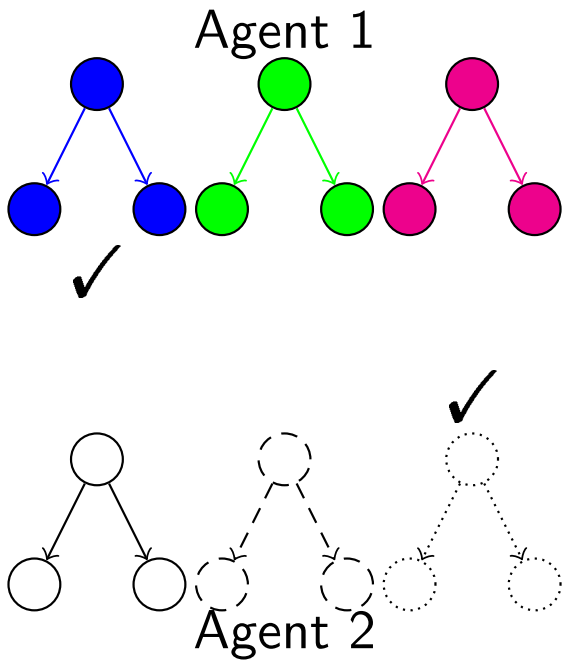

MBDP/NE : *Memory Bounded Dynamic Programming with Nash Equilibrium*

Pas une idée isolée : [kumar2010b], DecRSPI [wu2010], PBPG [wu2010b]

Optimisation locale

Recherche d'un maximum local : équilibre de Nash

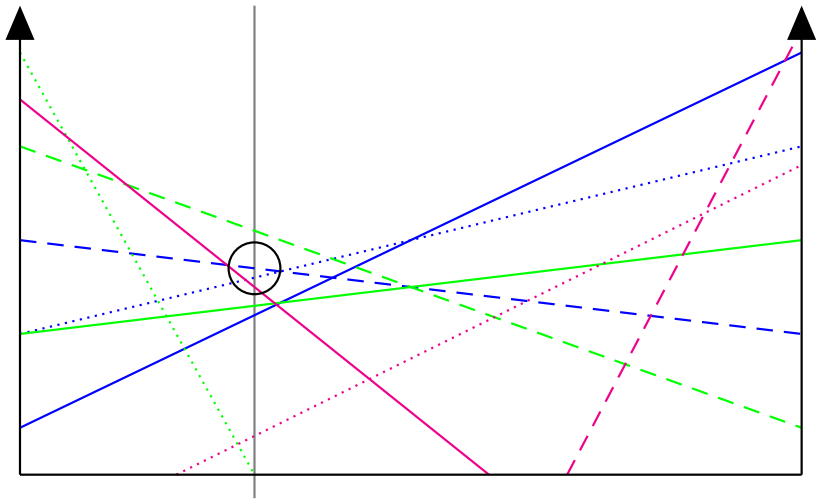

s_1
$\Pr(s_1) = 1$
$\Pr(s_2) = 0$

s_2
$\Pr(s_1) = 0$
$\Pr(s_2) = 1$

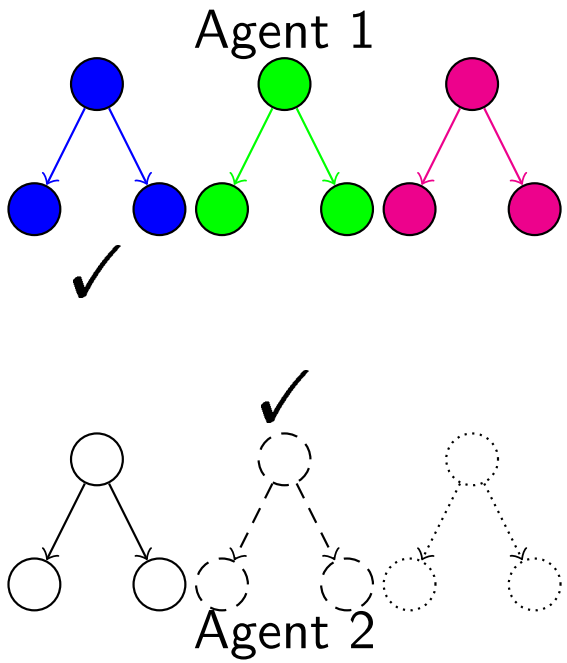

MBDP/NE : *Memory Bounded Dynamic Programming with Nash Equilibrium*

Pas une idée isolée : [kumar2010b], DecRSPI [wu2010], PBPG [wu2010b]

Optimisation locale

Recherche d'un maximum local : équilibre de Nash

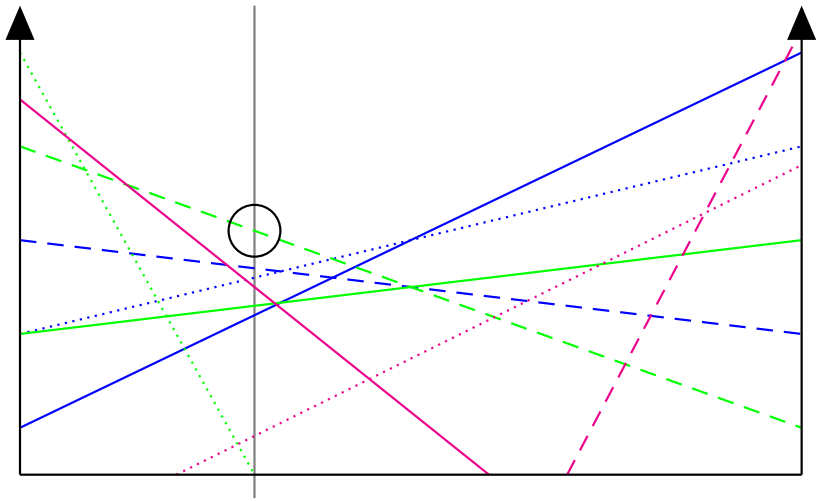

s_1
$\Pr(s_1) = 1$
$\Pr(s_2) = 0$

s_2
$\Pr(s_1) = 0$
$\Pr(s_2) = 1$

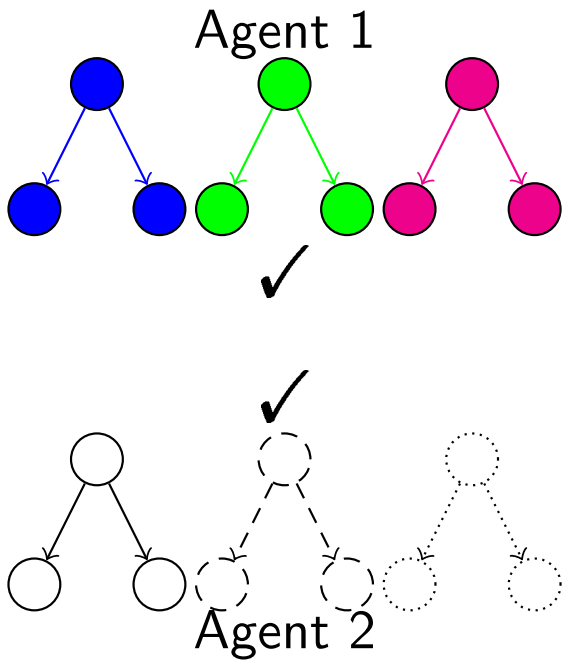

MBDP/NE : *Memory Bounded Dynamic Programming with Nash Equilibrium*

Pas une idée isolée : [kumar2010b], DecRSPI [wu2010], PBPG [wu2010b]

Résultats

Algorithme	W	M	AEV	σ	Temps (s)
PBIP/BeFS	7	-	423.4	14.0	101
MBDP/NE	7	30	423.0	9.6	83
PBIP/BeFS	20	-	?	?	>24h
MBDP/NE	20	30	445.2	7.2	822

TABLE : *Cooperative Box Pushing*, $T = 20$

$$|\mathcal{I}| = 2,\ |\mathcal{A}_i| = 4,\ |\Omega_i| = 5$$

Idée

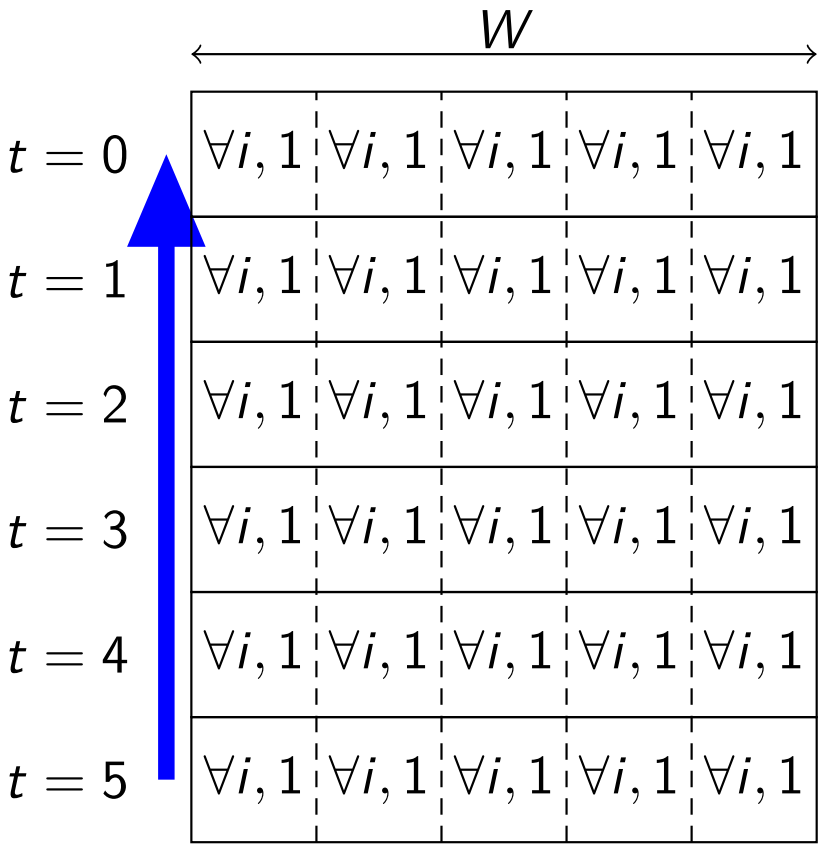

Choix indépendant des arbres

Choix dépendant des arbres

⇒ Meilleure utilisation des arbres

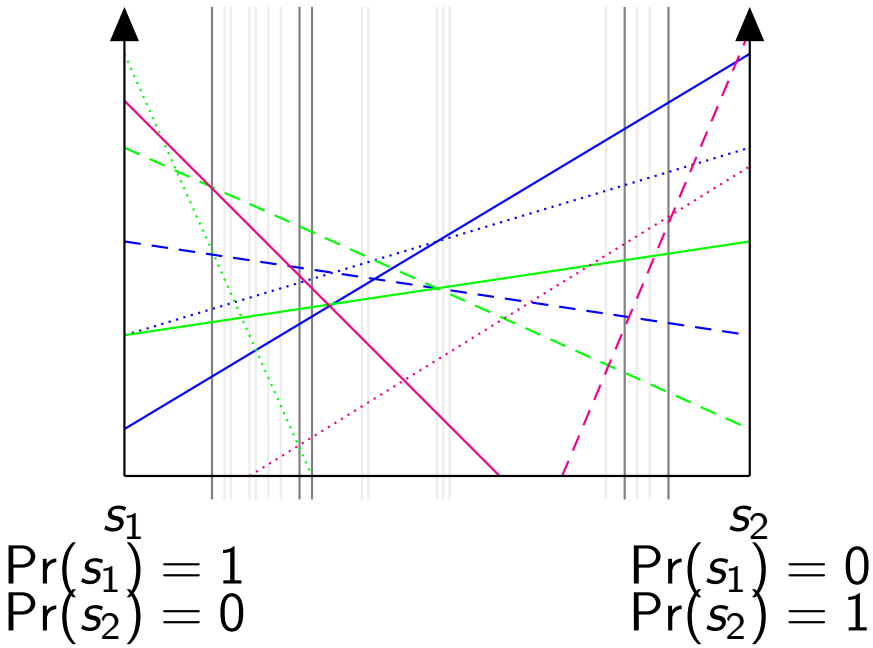

$N = W$ $N \gg W$

Faible nombre de points

Grand nombre de points

⇒ Plus d'information heuristique

Idée

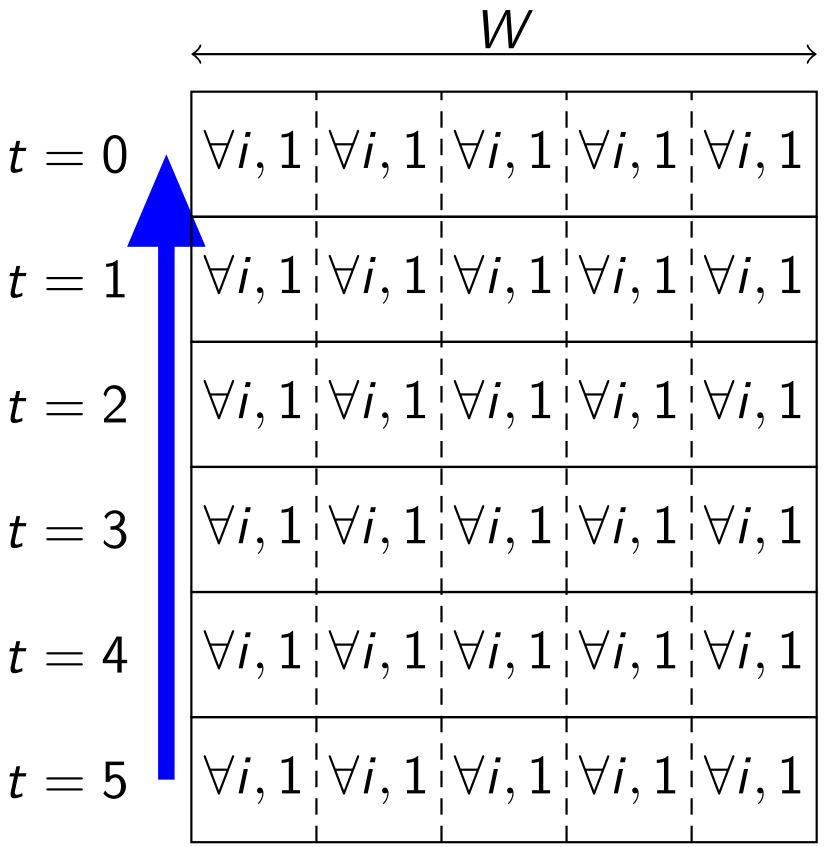

Choix indépendant des arbres

Choix dépendant des arbres

⇒ Meilleure utilisation des arbres

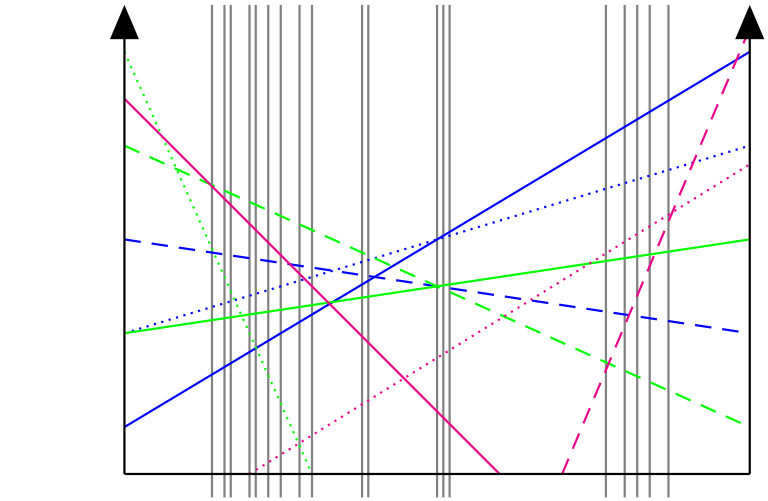

$N = W$ $N \gg W$

Faible nombre de points

Grand nombre de points

⇒ Plus d'information heuristique

Idée

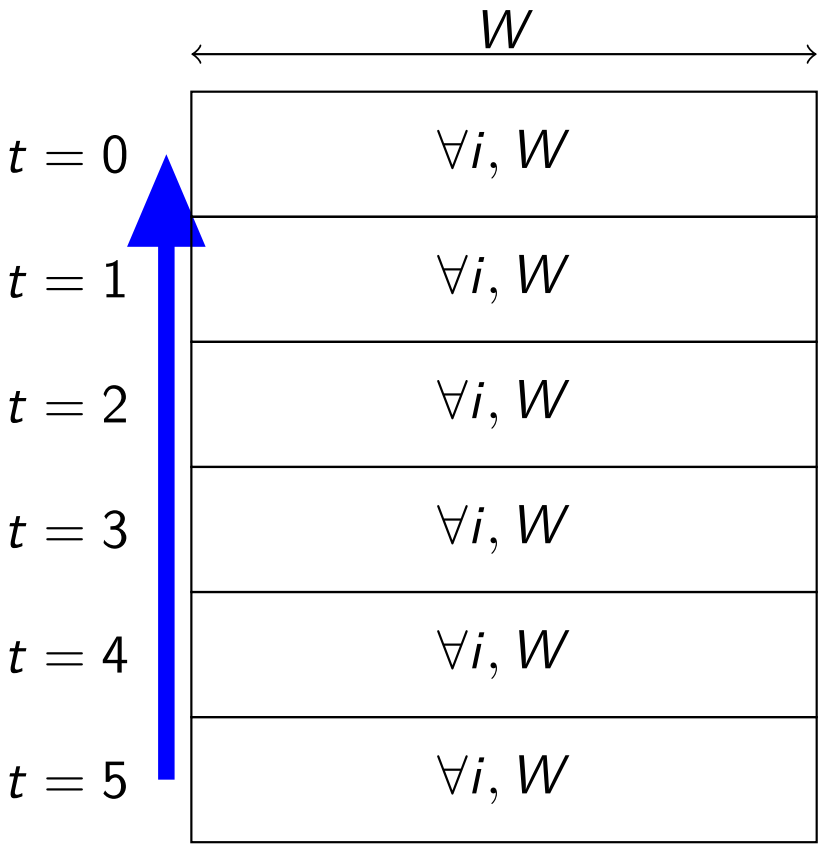

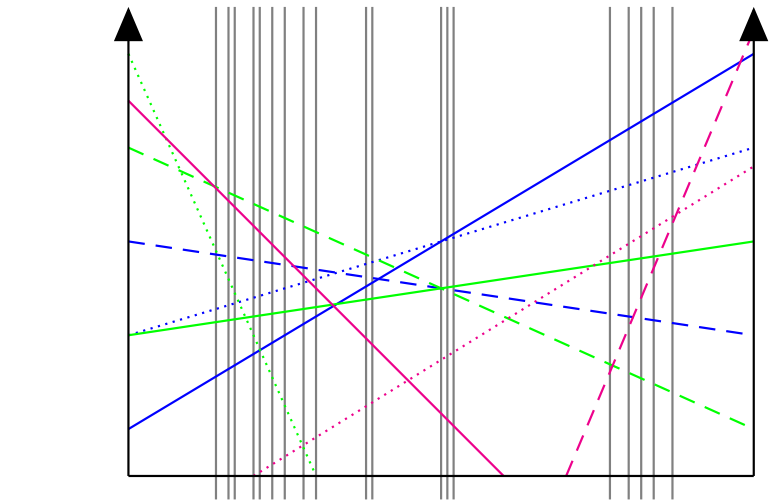

$N = W$ $N \gg W$

Choix indépendant des arbres

Choix dépendant des arbres

⇒ Meilleure utilisation des arbres

Faible nombre de points

Grand nombre de points

⇒ Plus d'information heuristique

Optimisation ponctuelle ou globale

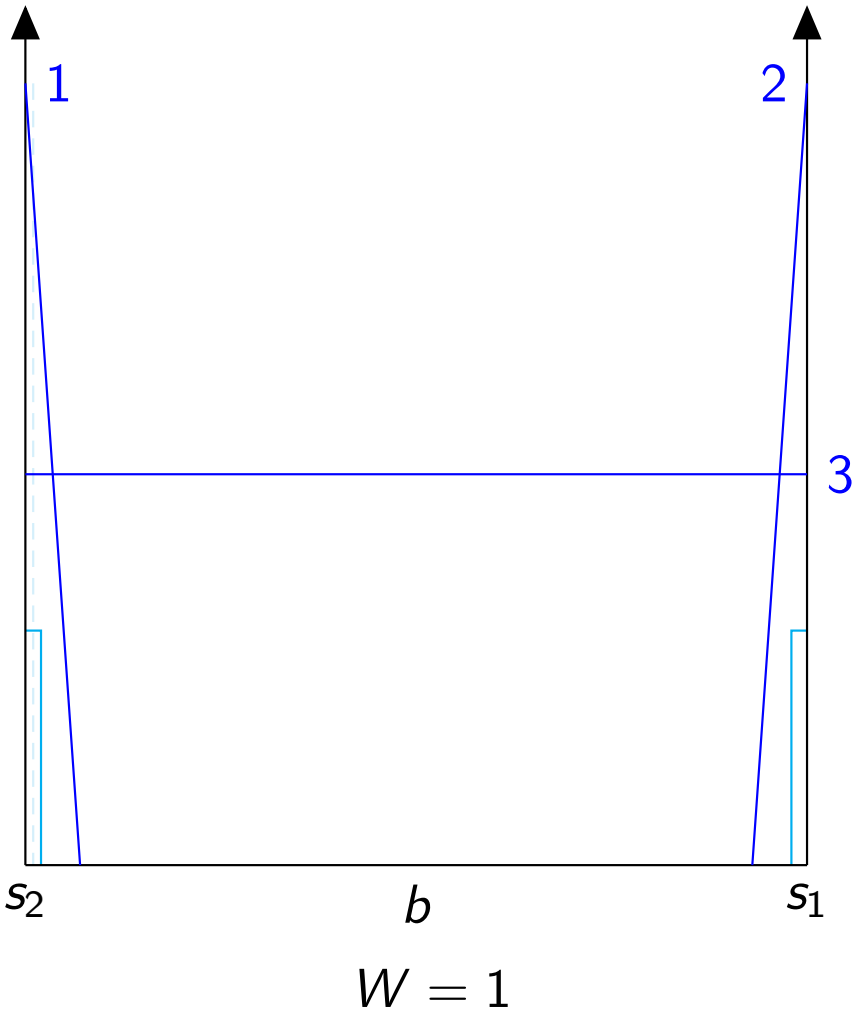

Optimiser ponctuellement en b_k problématique quand le nombre d'arbres retenu est faible

Optimisation ponctuelle ou globale

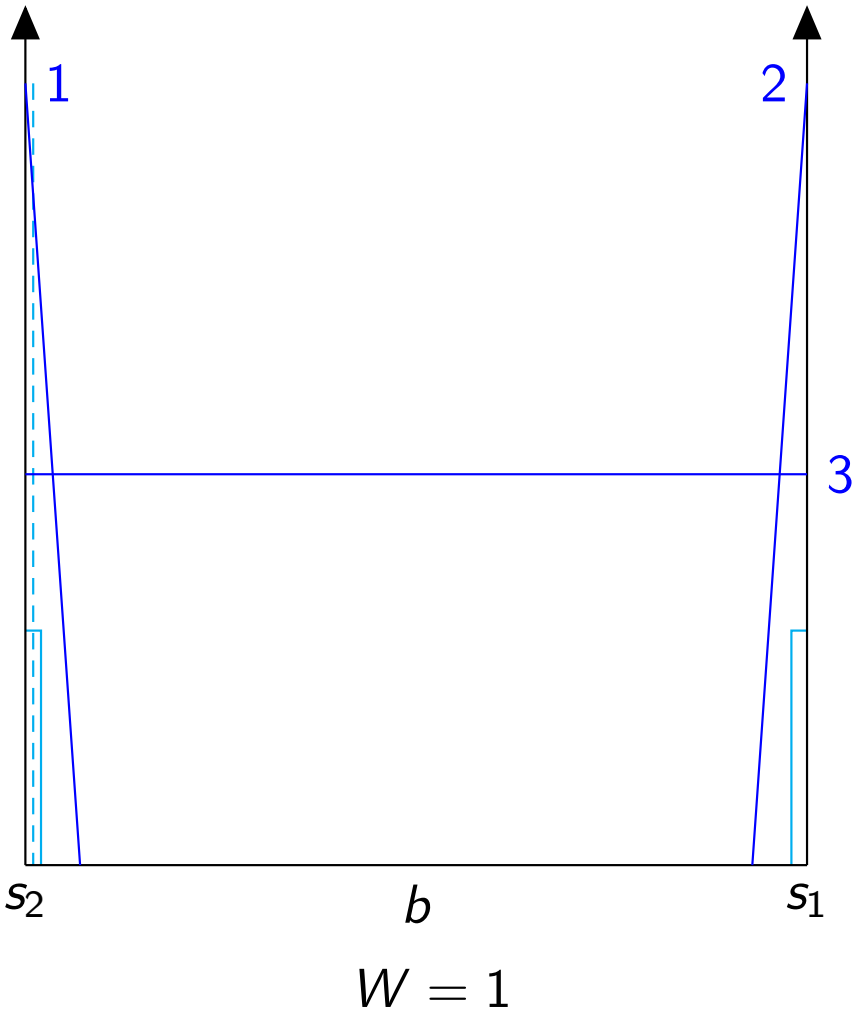

Optimiser ponctuellement en b_k problématique quand le nombre d'arbres retenu est faible

Choix indépendant ou dépendant des arbres

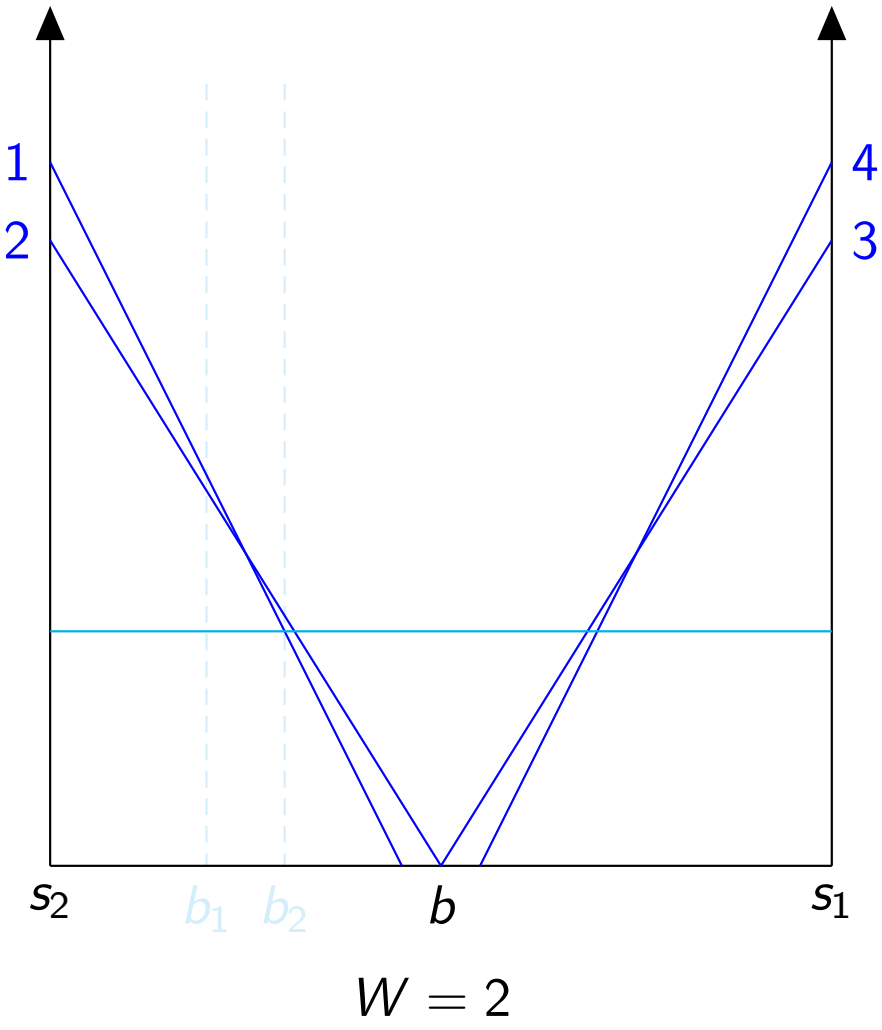

Le choix indépendant ignore la complémentarité entre les arbres.

Choix indépendant ou dépendant des arbres

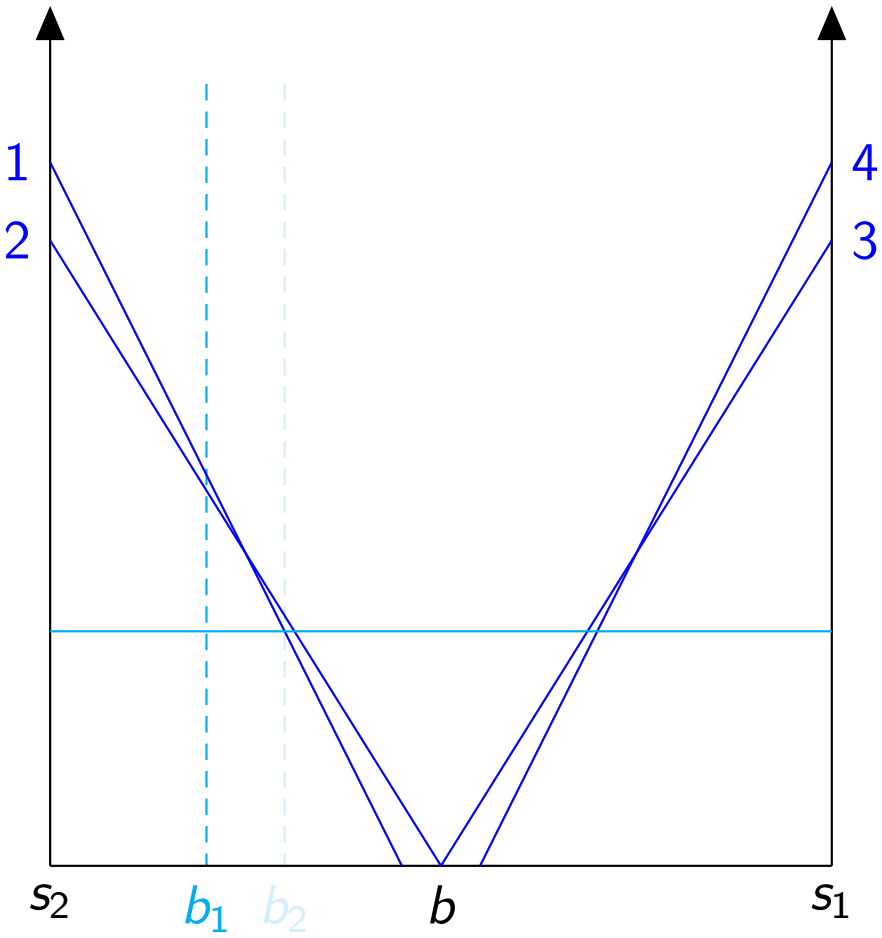

Le choix indépendant ignore la complémentarité entre les arbres.

Choix indépendant ou dépendant des arbres

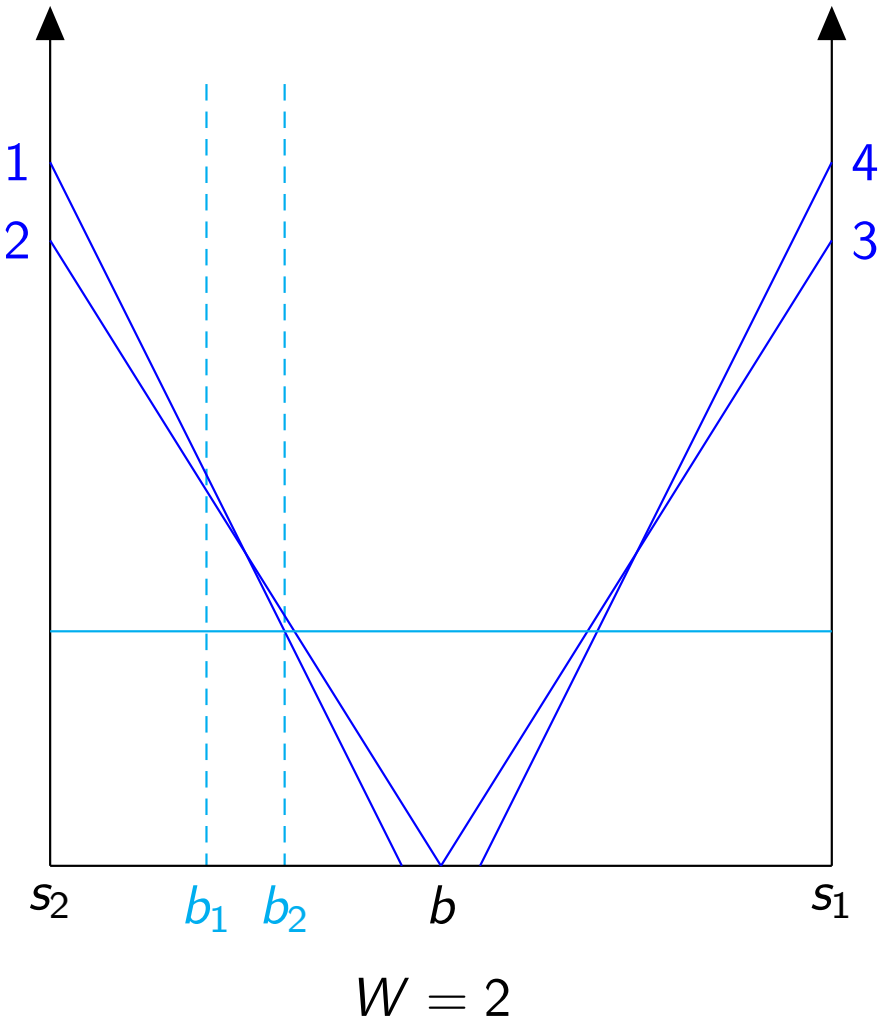

Le choix indépendant ignore la complémentarité entre les arbres.

Choix indépendant ou dépendant des arbres

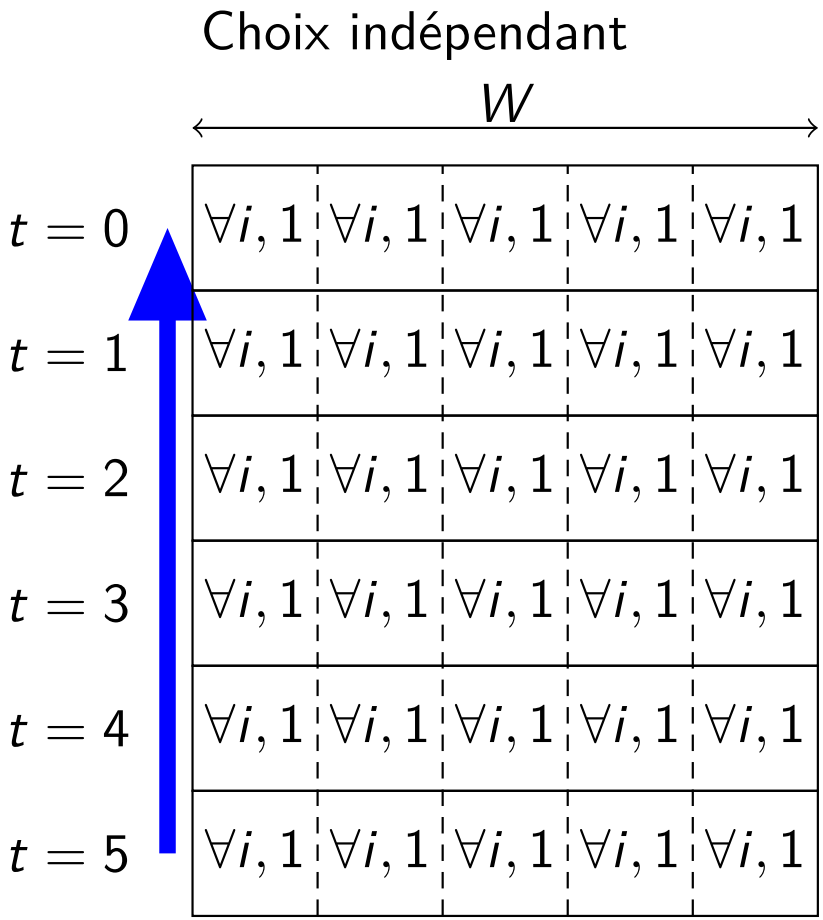

Choisir 1 arbre par agent (W fois)

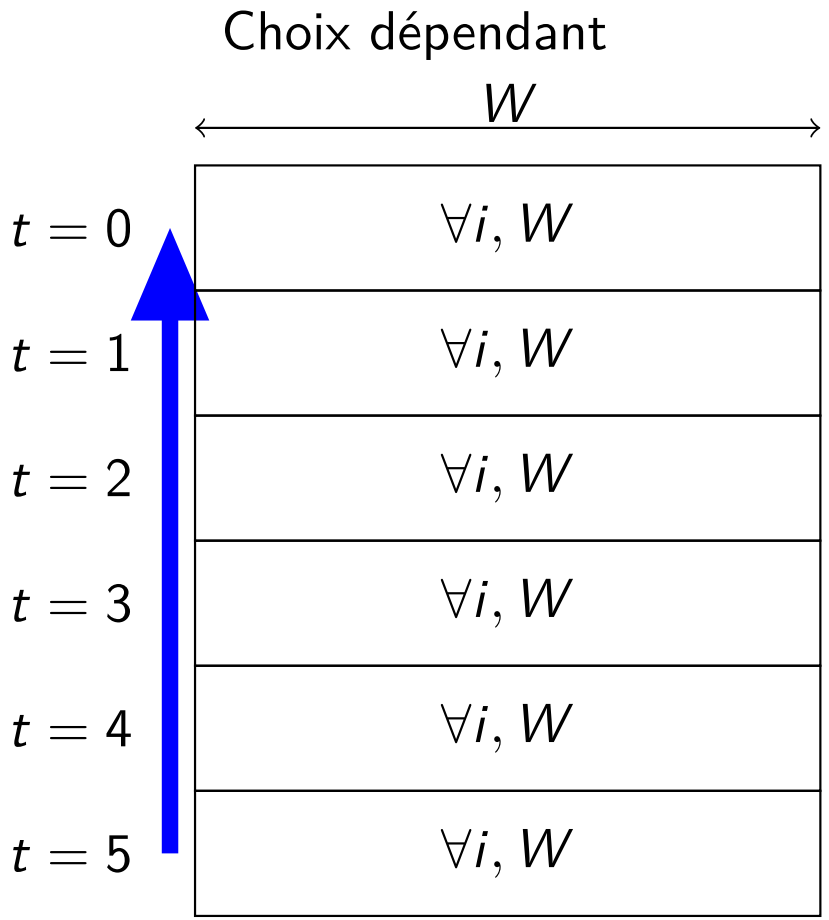

Choisir (au plus) W arbres par agent

Quel critère ?

Critère d'optimisation global

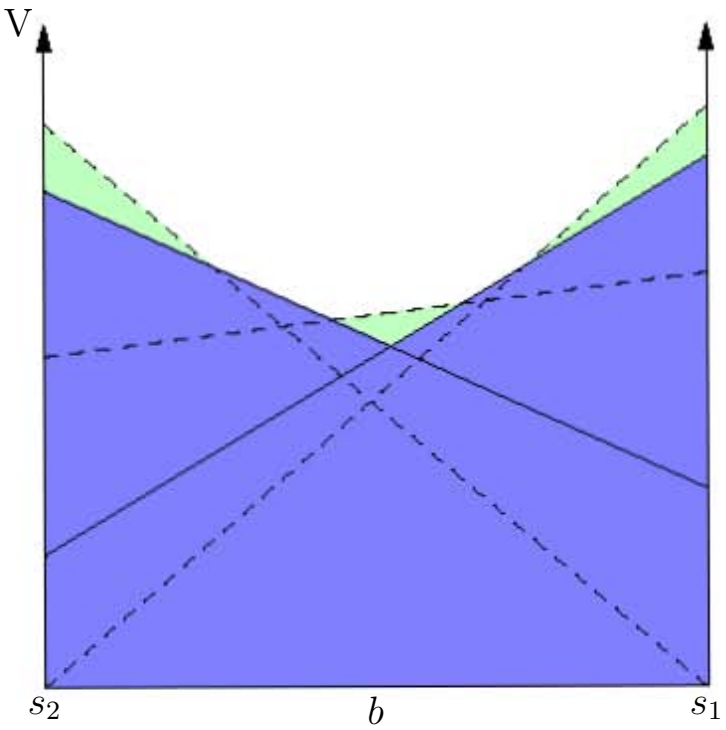

Critère moyen

$$\max_V \int V(b)\, db$$

Distribution heuristique

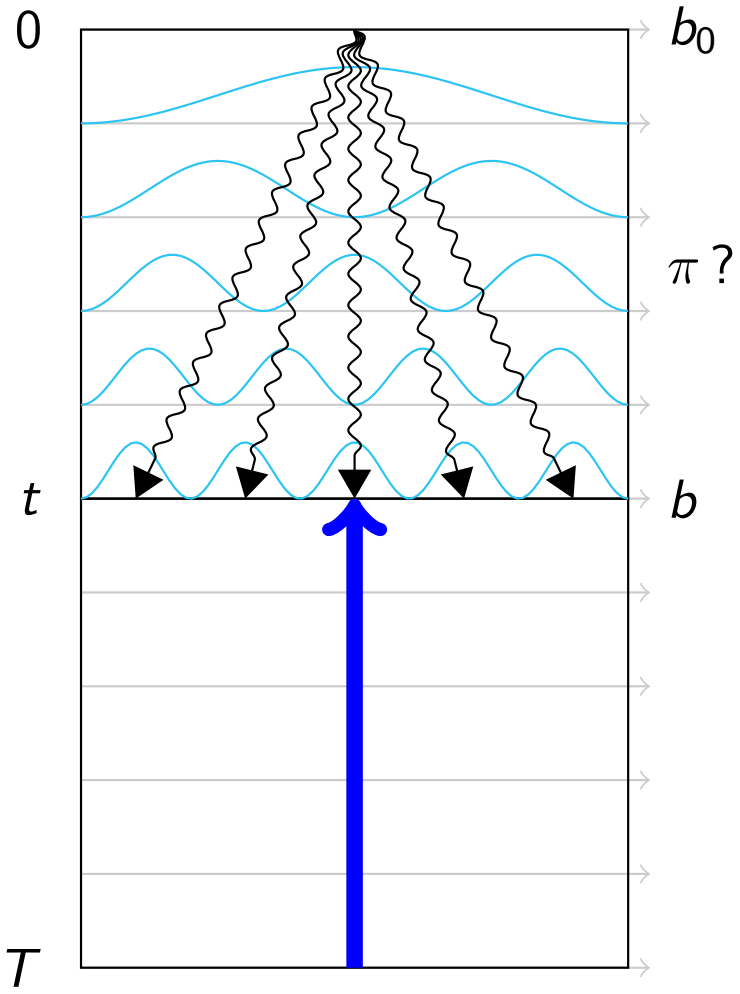

Croyance centralisée B_t :

$$B_t(s) = Pr(S_t = s | B_O = b_0, A_1, O_1, \ldots A_t, O_t)$$

Distribution de probabilité *a priori* heuristique :

$$\mu(b) = p(B_t = b | \pi, B_0 = b_0)$$

Distribution heuristique

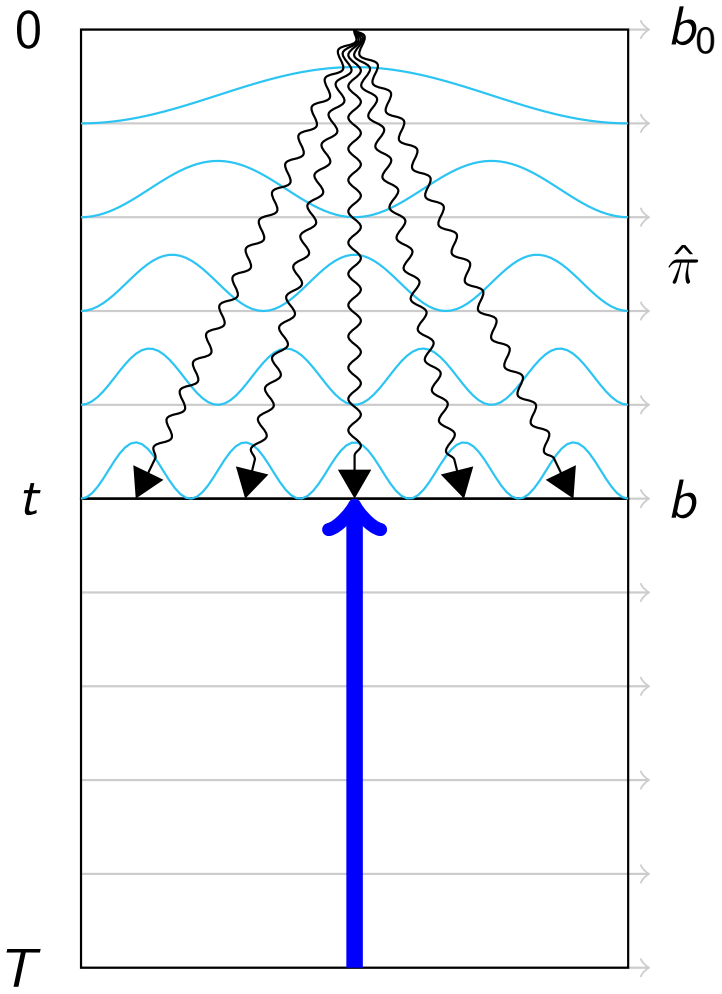

Croyance centralisée B_t :

$$B_t(s) = Pr(S_t = s | B_O = b_0, A_1, O_1, \ldots A_t, O_t)$$

Distribution de probabilité *a priori* heuristique :

$$\mu(b) = p(B_t = b | \hat{\pi}, B_0 = b_0)$$

Critère d'optimisation global

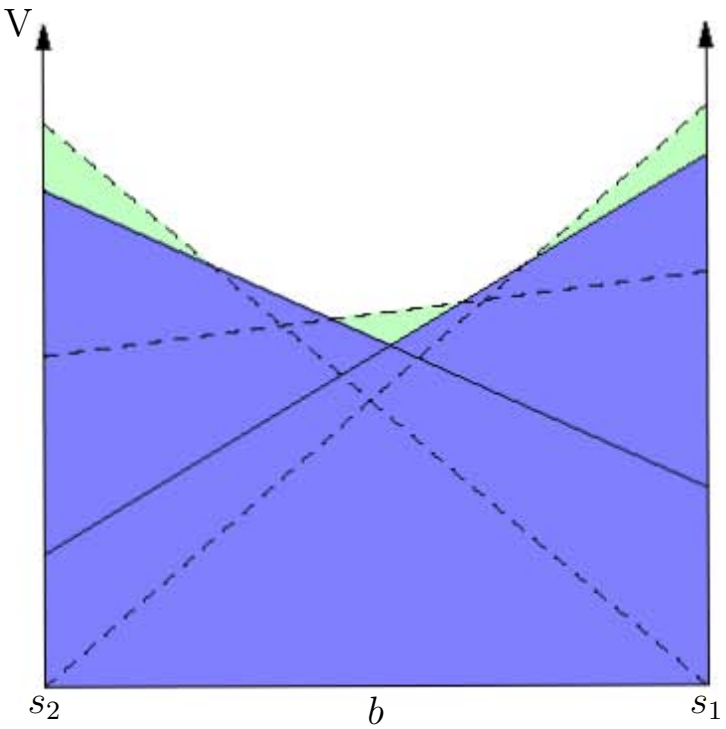

Critère moyen espéré échantilonné

$$\max_V \int \mu(b)\, V(b)\, db = \max_V \mathop{\mathrm{E}}_{b\sim\mu}[V(b)]$$

$$\approx \frac{1}{N} \max_V \sum_{k=1}^{N} V(b_k)$$

μ : distribution de probabilité sur l'espace des croyances centralisées (accessibilité)

b_k : échantillons de μ (Monte-Carlo)

On peut prendre $N \gg W$

PSMBDP (*Policy Search Memory Bounded Dynamic Programming*) [corona2010a, corona2010b]

Critère d'optimisation global

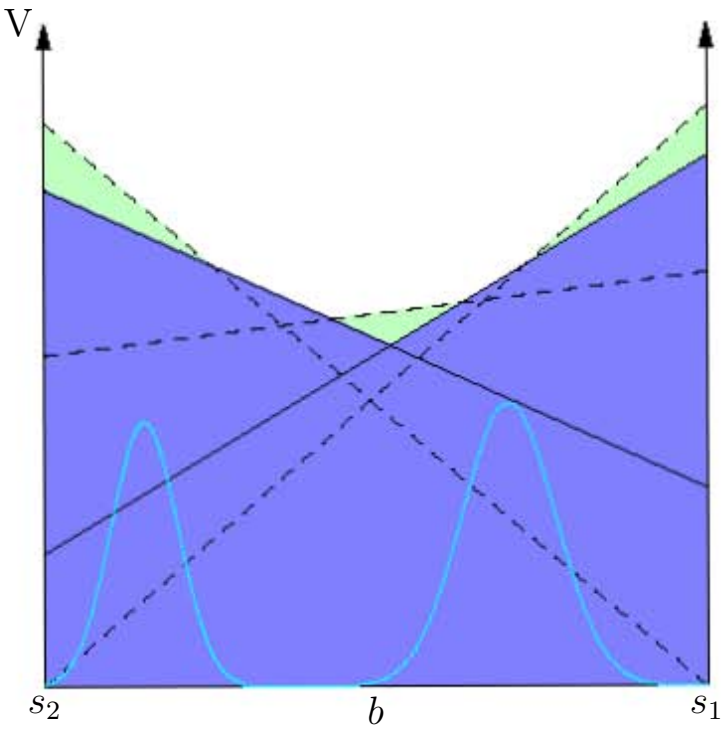

Critère ~~moyen~~ espéré échantilonné

$$\max_V \int \mu(b) V(b)\, db = \max_V \mathop{\mathrm{E}}_{b\sim\mu} [V(b)]$$

$$\approx \frac{1}{N} \max_V \sum_{k=1}^{N} V(b_k)$$

μ : distribution de probabilité sur l'espace des croyances centralisées (accessibilité)

b_k : échantillons de μ (Monte-Carlo)

On peut prendre $N \gg W$

PSMBDP (*Policy Search Memory Bounded Dynamic Programming*) [corona2010a, corona2010b]

Critère d'optimisation global

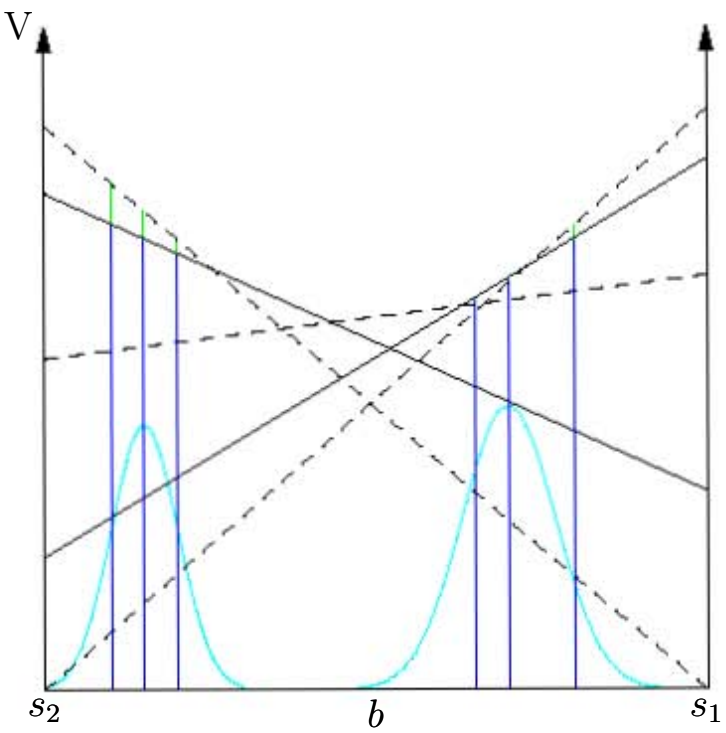

Critère ~~moyen~~ espéré échantilonné

$$\max_V \int \mu(b) V(b)\, db = \max_V \mathop{\mathrm{E}}_{b\sim\mu} [V(b)]$$

$$\approx \frac{1}{N} \max_V \sum_{k=1}^{N} V(b_k)$$

μ : distribution de probabilité sur l'espace des croyances centralisées (accessibilité)

b_k : échantillons de μ (Monte-Carlo)

On peut prendre $N \gg W$

PSMBDP (*Policy Search Memory Bounded Dynamic Programming*) [corona2010a, corona2010b]

Cas particulier

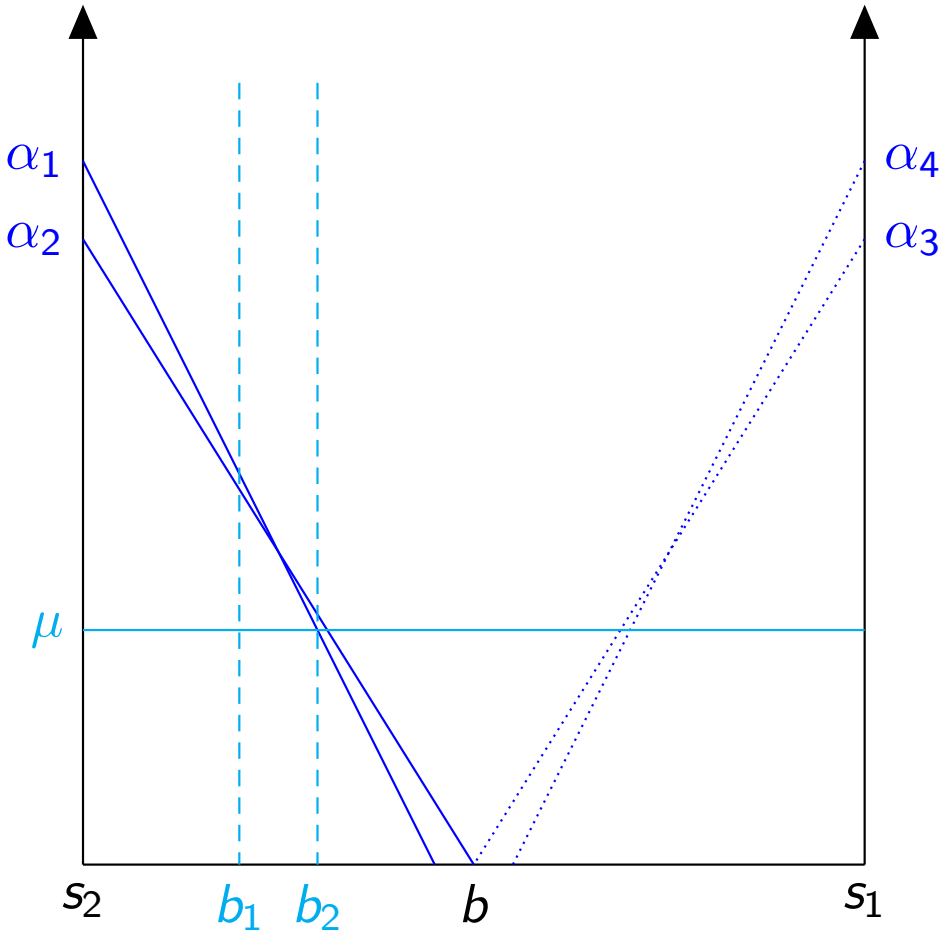

$$\max_V \sum_{k=1}^{N} V(b_k)$$

Si $N = W$,

- meilleur arbre joint en chaque point
- équivalent aux méthodes à base de *lookahead*

Généralise MBDP, PBIP avec $N \geq W$

Problème d'optimisation combinatoire

Pour chaque agent $i \in \mathcal{I}$, choisir au plus W arbres parmi $|\mathcal{A}_i|W^{|\Omega_i|}$:

$$\begin{aligned} \text{maximiser} \quad & \sum_{k=1}^{N} \max_{q \in \mathcal{Z}^t} V_q(b_k) && \mathcal{Z}^t = \prod_{i \in \mathcal{I}} \mathcal{Z}_i^t \\ \text{sujet à} \quad & \mathcal{Z}_i^t \subseteq \mathcal{A}_i \times (\mathcal{Z}_i^{t+1})^{\Omega_i} && \forall i \in \mathcal{I} \\ & |\mathcal{Z}_i^t| \leq W && \forall i \in \mathcal{I} \end{aligned}$$

Espace de recherche énorme :

$$\prod_i \binom{|\mathcal{A}_i|W^{|\Omega_i|}}{W}$$

Recherche approchée, utilisation de méta-heuristiques

Résolution approchée incrémentale gloutonne

- meilleure solution pour $W = 1$ (*lookahead* pour $b = \frac{1}{N} \sum b_k$)
- ajouter progressivement des arbres ($|\mathcal{I}|(W-1)$ fois)

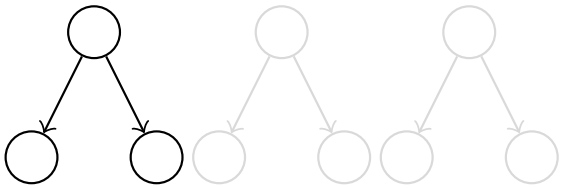

Agent 1

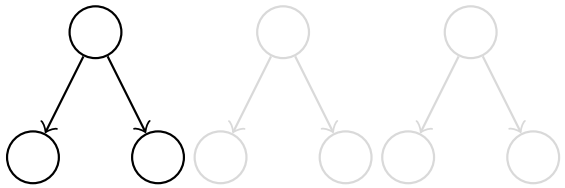

Agent 2

$$\prod_i \binom{|\mathcal{A}_i| W^{|\Omega_i|}}{W} \text{ devient } |\mathcal{A}_i| W^{|\Omega_i|} \text{ répété } |\mathcal{I}|(W-1) \text{ fois}$$

résolus par recherche *branch-and-bound* (ou approché, méta-heuristiques)

Résolution approchée incrémentale gloutonne

- meilleure solution pour $W = 1$ (*lookahead* pour $b = \frac{1}{N} \sum b_k$)
- ajouter progressivement des arbres ($|\mathcal{I}|(W-1)$ fois)

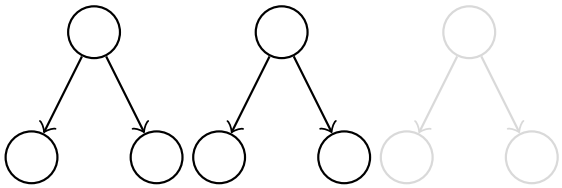

Agent 1

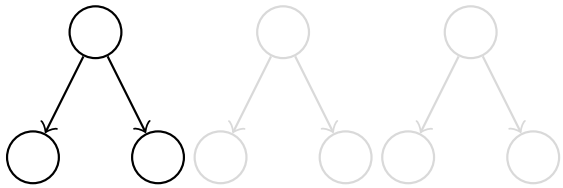

Agent 2

$$\prod_i \binom{|\mathcal{A}_i| W^{|\Omega_i|}}{W} \text{ devient } |\mathcal{A}_i| W^{|\Omega_i|} \text{ répété } |\mathcal{I}|(W-1) \text{ fois}$$

résolus par recherche *branch-and-bound* (ou approché, méta-heuristiques)

Résolution approchée incrémentale gloutonne

- meilleure solution pour $W = 1$ (*lookahead* pour $b = \frac{1}{N} \sum b_k$)
- ajouter progressivement des arbres ($|\mathcal{I}|(W-1)$ fois)

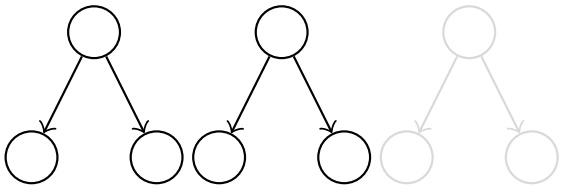

Agent 1

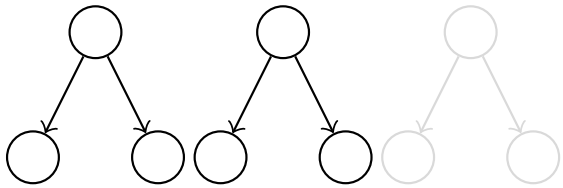

Agent 2

$$\prod_i \binom{|\mathcal{A}_i| W^{|\Omega_i|}}{W} \text{ devient } |\mathcal{A}_i| W^{|\Omega_i|} \text{ répété } |\mathcal{I}|(W-1) \text{ fois}$$

résolus par recherche *branch-and-bound* (ou approché, méta-heuristiques)

Résolution approchée incrémentale gloutonne

- meilleure solution pour $W = 1$ (*lookahead* pour $b = \frac{1}{N} \sum b_k$)
- ajouter progressivement des arbres ($|\mathcal{I}|(W-1)$ fois)

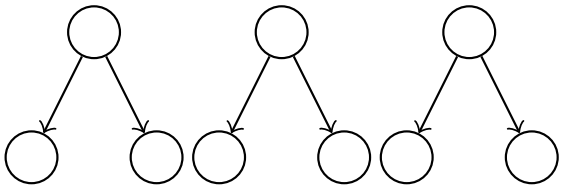

Agent 1

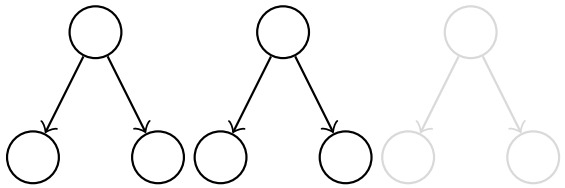

Agent 2

$$\prod_i \binom{|\mathcal{A}_i| W^{|\Omega_i|}}{W} \text{ devient } |\mathcal{A}_i| W^{|\Omega_i|} \text{ répété } |\mathcal{I}|(W-1) \text{ fois}$$

résolus par recherche *branch-and-bound* (ou approché, méta-heuristiques)

Résolution approchée incrémentale gloutonne

- meilleure solution pour $W = 1$ (*lookahead* pour $b = \frac{1}{N} \sum b_k$)
- ajouter progressivement des arbres ($|\mathcal{I}|(W-1)$ fois)

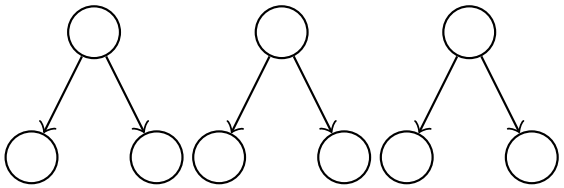

Agent 1

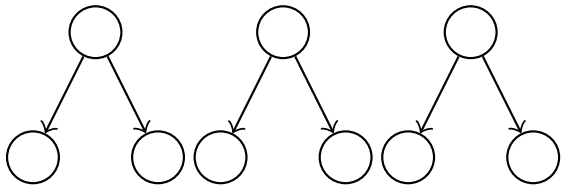

Agent 2

$$\prod_i \binom{|\mathcal{A}_i| W^{|\Omega_i|}}{W} \text{ devient } |\mathcal{A}_i| W^{|\Omega_i|} \text{ répété } |\mathcal{I}|(W-1) \text{ fois}$$

résolus par recherche *branch-and-bound* (ou approché, méta-heuristiques)

Résultats

Algorithm	VEM	σ	Temps (s)
Optimal MDP	-35.81	-	-
PBIP	-160.25	20.84	171
PBIP ‡	-111.85	0.00	234
PSMBDP	-89.08	0.00	274
PBIP	-216.64	35.92	612
PBIP ‡	-111.85	0.00	156
PSMBDP	-78.43	0.00	735

‡ : points tirés comme pour PSMBDP

TABLE : Problème des pompiers et problème des pompiers modifié, $W = 7$, $T = 20$, $N = 100$, 25 exécutions

Résumé

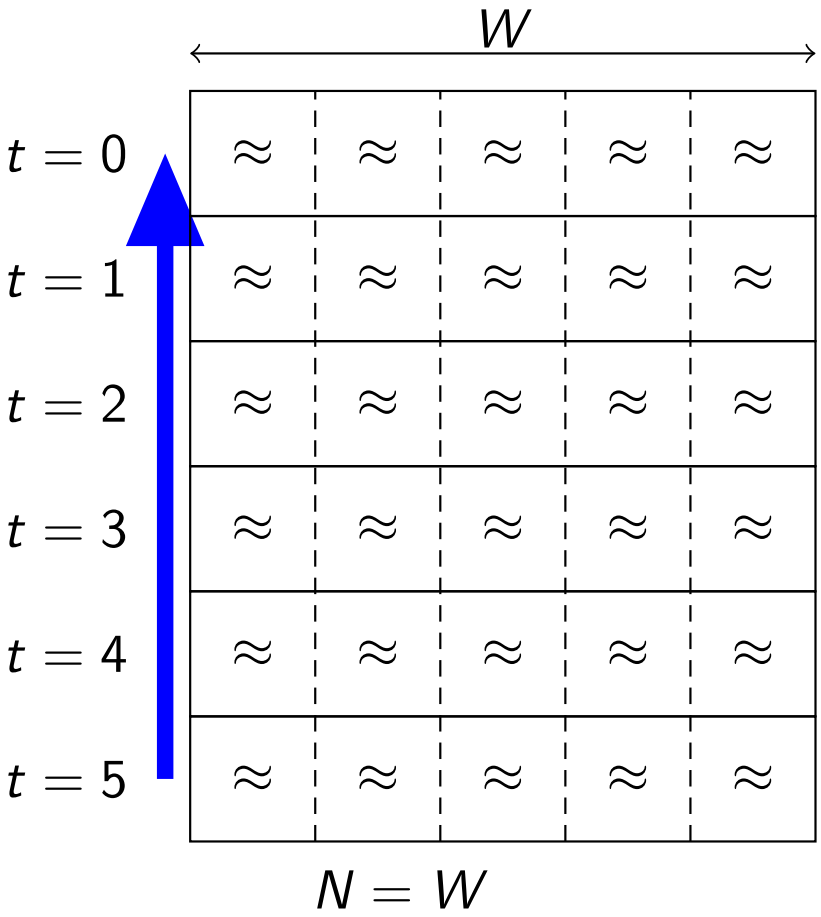

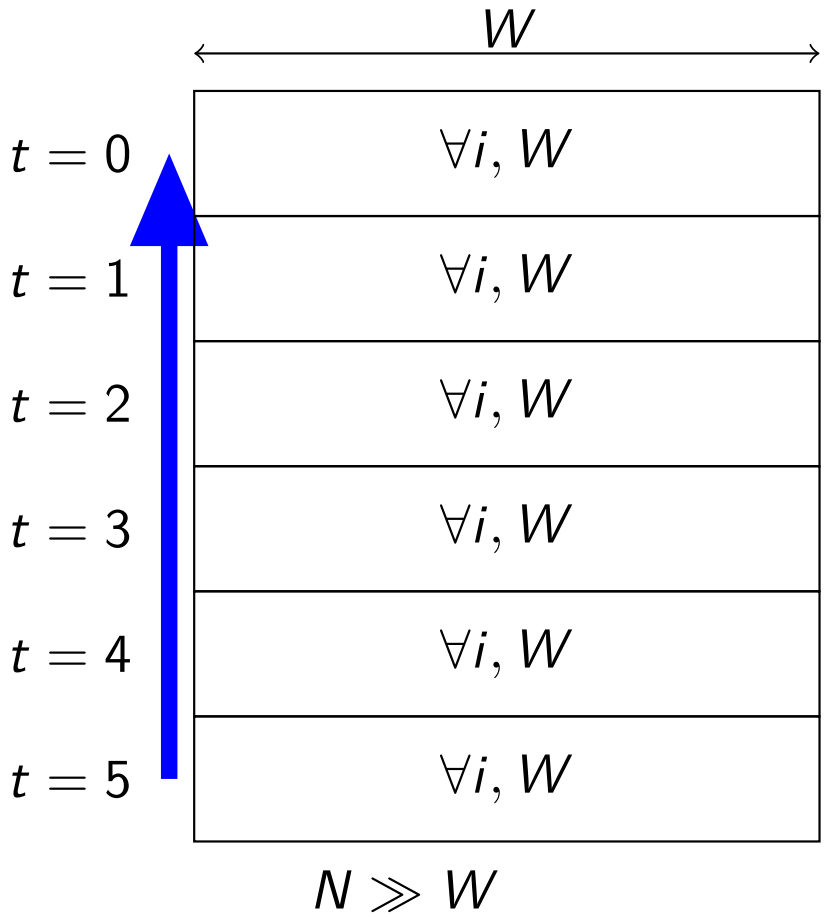

- réduire la complexité
- augmenter W (et N)

- bonne utilisation des heuristiques
- complémentarité

La fin

Bibliographie I


E. Richard Bellman.
Dynamic Programming.
Princeton University Press, 1957.


Daniel S. Bernstein, Shlomo Zilberstein, and Neil Immerman.
The Complexity of Decentralized Control of Markov Decision Processes.
In *Mathematics of Operations Research*, page 2002, 2000.


Gabriel Corona and François Charpillet.
Distribution sur les croyances pour la planification de Dec-POMDP.
Revue d'Intelligence Artificielle, 24(4) :525–544, 2010.


Gabriel Corona and François Charpillet.
Distribution over Beliefs for Dec-POMDP planning.
In *Proceedings of the Twenty-Sixth Conference on Uncertainty in Artificial Intelligence*, 2010.

Bibliographie II


Jilles S. Dibangoye, Abdel-Illah Mouaddib, and Brahim Chaib-draa.
Recherche incrémentale à base de points pour la résolution des DEC-POMDPs.
In *Actes des quinzièmes JFSMA*, Brest, France, October 2008.


E. Hansen, D. Bernstein, and Shlomo Zilberstein.
Dynamic programming for partially observable stochastic games.
In *Proceedings of the Nineteenth National Conference on Artificial Intelligence*, pages 709–715. AAAI Press, 2004.


Akshat Kumar and Shlomo Zilberstein.
Point-based backup for decentralized pomdps : Complexity and new algorithms.
In *Proceedings of the Ninth International Conference on Autonomous Agents and Multiagent Systems*, pages 1315–1322, Toronto, Canada, 2010.

Bibliographie III


Martin Mundhenk, Judy Goldsmith, Christopher Lusena, and Eric Allender.

Complexity of finite-horizon markov decision process problems.
J. ACM, 47 :681–720, July 2000.


Sven Seuken and Shlomo Zilberstein.
Memory-Bounded Dynamic Programming for DEC-POMDPs.
In *Proceedings of the Twentieth International Joint Conference on Artificial Intelligences (IJCAI-07)*. IJCAI, 2007.


E. J. Sondik.
The optimal control of partially observable Markov processes.
PhD thesis, Stanford University, 1971.


Daniel Szer.
Contribution à la résolution des processus de décision markoviens décentralisés.
PhD thesis, Universite Henri-Poincare, Nancy, France.

Bibliographie IV


Feng Wu, Schlomo Zilberstein, and Xiaoping Chen.
Rollout Sampling Policy Iteration for Decentralized POMDPs.
In *Proceedings of the Twenty-Sixth Conference on Uncertainty in Artificial Intelligence*, 2010.


Feng Wu, Shlomo Zilberstein, and Xiaoping Chen.
Point-Based Policy Generation for Decentralized POMDPs.
In *Proceedings of the Ninth International Conference on Autonomous Agents and Multiagent Systems*, pages 1307–1314, Toronto, Canada, 2010.

Droits d'auteurs

internet, ©The Opte Project, CC-BY-2.5
mars, domaine publique (NASA)
pompiers/maisons/radiations/mars/robots, domaine publique (OpenClipArt)
cycab, (honteusement récupéré sur le site du Lasmea)