

Monte Carlo Tree Search

Enjeux et affinités

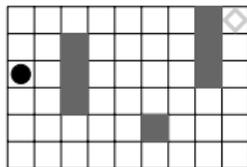
André Fabbri

15 Novembre 2013

Première partie I

Monte Carlo Tree Search

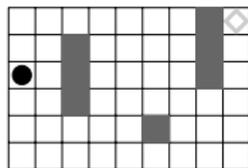
Présentation du problème



Problème du Labyrinthe

- ▶ 1 seul agent
- ▶ déterministe
- ▶ information parfaite

Présentation du problème



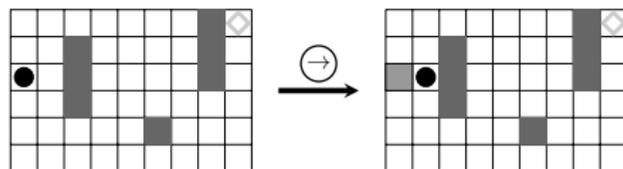
Problème du Labyrinthe

- ▶ 1 seul agent
- ▶ déterministe
- ▶ information parfaite

Description formelle

États : S (initial/final)

Présentation du problème



Problème du Labyrinthe

- ▶ 1 seul agent
- ▶ déterministe
- ▶ information parfaite

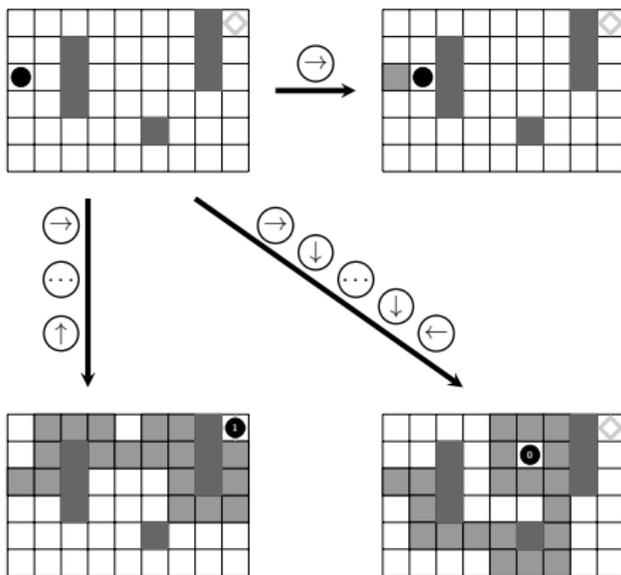
Description formelle

États : S (initial/final)

Actions : A \uparrow \downarrow \leftarrow \rightarrow

Objectif : case \diamond

Présentation du problème



Problème du Labyrinthe

- ▶ 1 seul agent
- ▶ déterministe
- ▶ information parfaite

Description formelle

États : S (initial/final)

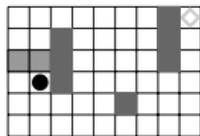
Actions : A \uparrow \downarrow \leftarrow \rightarrow

Objectif : case \diamond

Récomp : 0/1

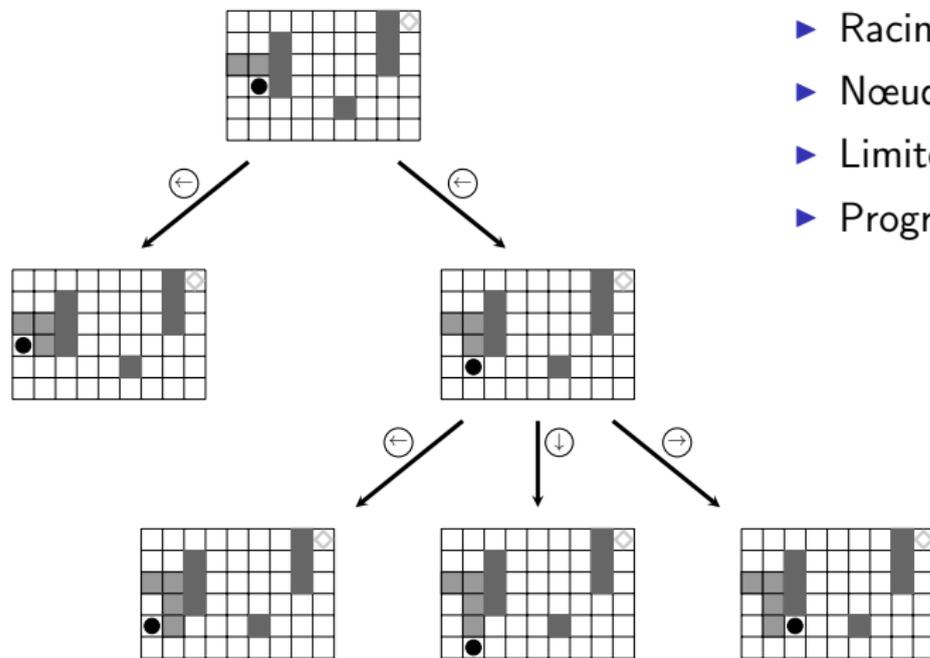
Planning = Trouver une séquence pour atteindre \diamond

Arbre de recherche



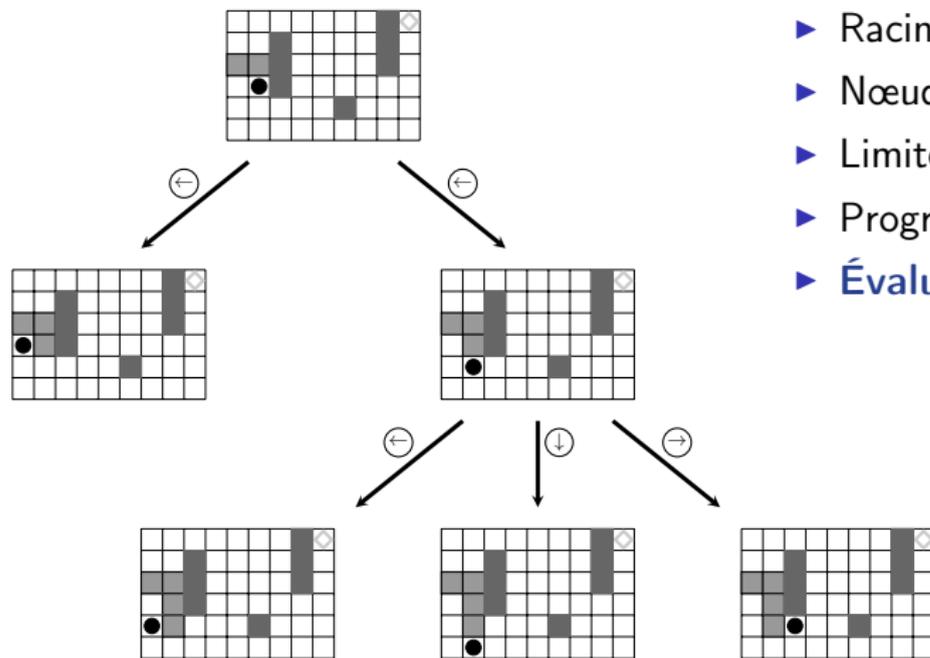
► Racine = État courant

Arbre de recherche



- ▶ Racine = État courant
- ▶ Nœuds = États possibles
- ▶ Limité $|S_{Go}| \simeq 10^{170}$
- ▶ Progressif (*a*)-symétrique

Arbre de recherche



- ▶ Racine = État courant
- ▶ Nœuds = États possibles
- ▶ Limité $|S_{Go}| \simeq 10^{170}$
- ▶ Progressif (*a*)-symétrique
- ▶ **Évaluation ?** heuristiques ?

Monte Carlo = Évaluation par échantillonnage aléatoire

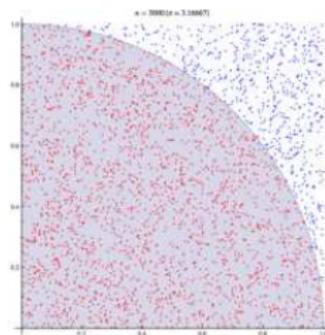


Figure: Approximation de π

Méthodes de Monte Carlo

Monte Carlo = Évaluation par échantillonnage aléatoire

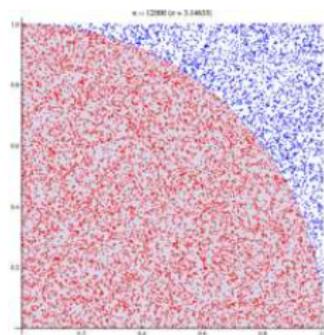


Figure: Approximation de π

Monte Carlo = Évaluation par échantillonnage aléatoire

Intérêt de Monte Carlo

- ▶ Générique (*faible apport en K*)
- ▶ Parallélisable (*puissance de calcul*)
- ▶ « *anytime* » (*temps réel*)

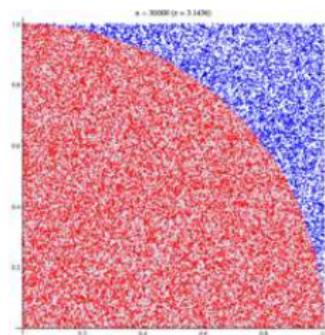
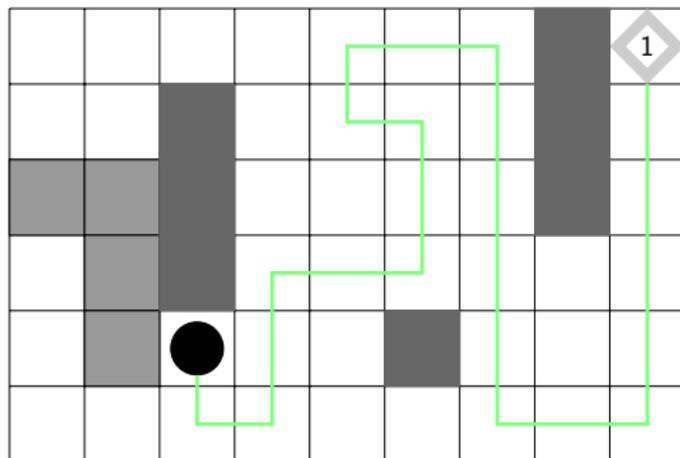
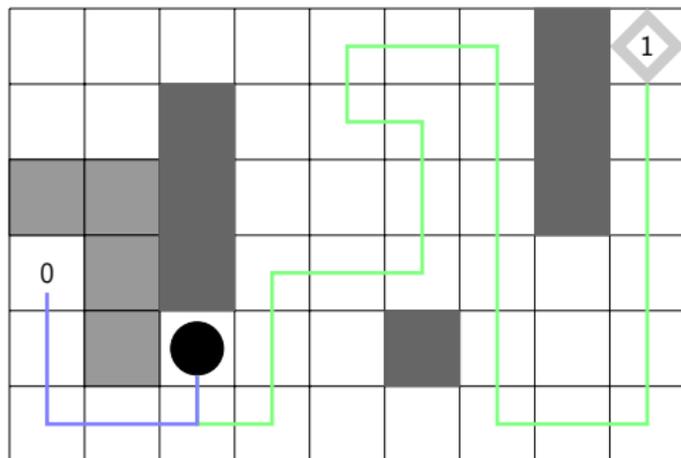


Figure: Approximation de π

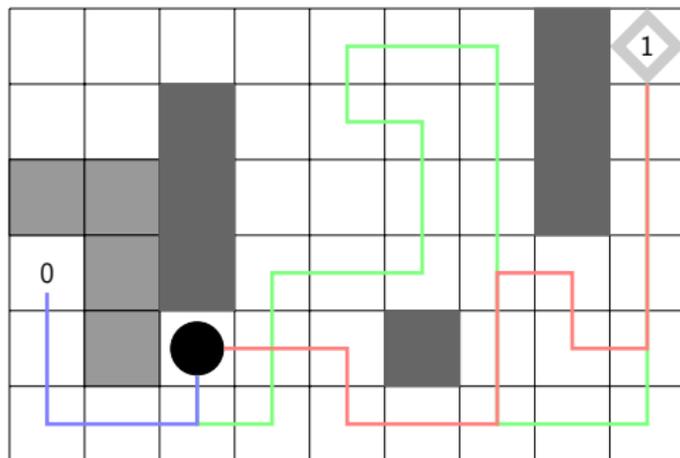
Monte Carlo & Apprentissage par Renforcement



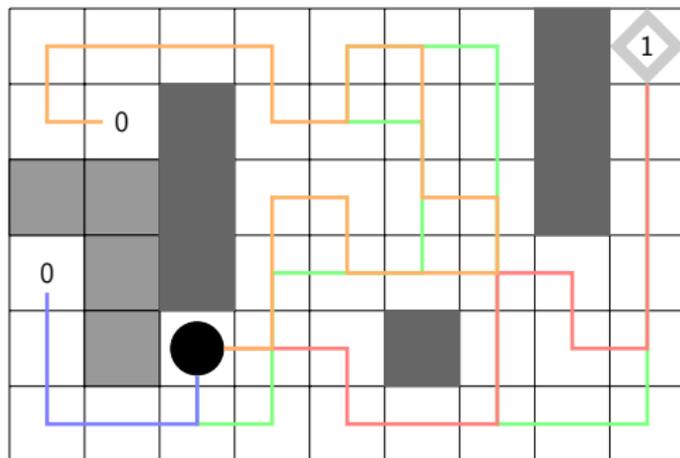
Monte Carlo & Apprentissage par Renforcement



Monte Carlo & Apprentissage par Renforcement

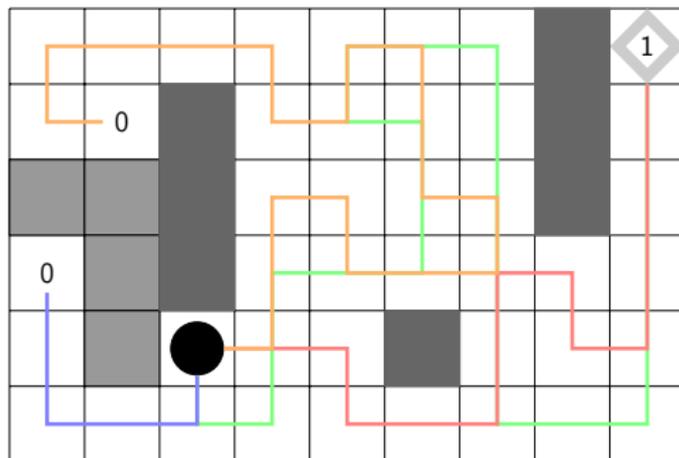


Monte Carlo & Apprentissage par Renforcement

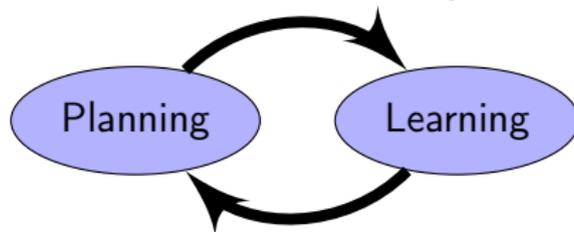


Séquence aléatoire d'action = expérience simulée

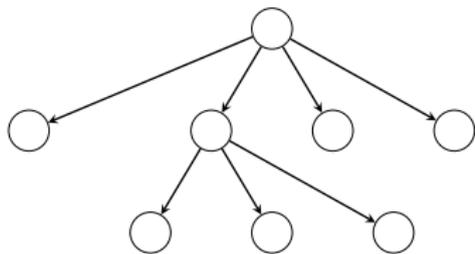
Monte Carlo & Apprentissage par Renforcement



Séquence aléatoire d'action = expérience simulée

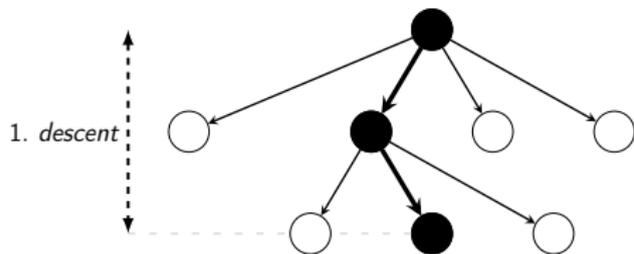


Monte Carlo Tree Search



Boucle d'apprentissage

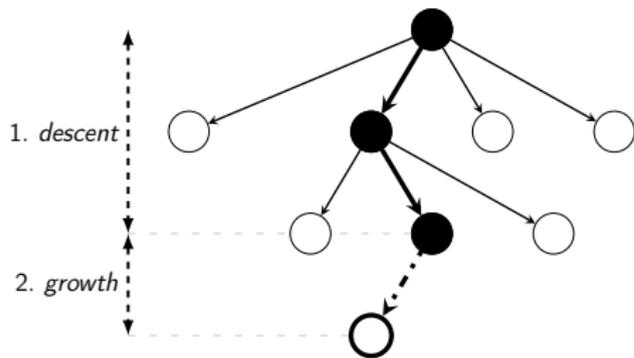
Monte Carlo Tree Search



Boucle d'apprentissage

1. déterministe

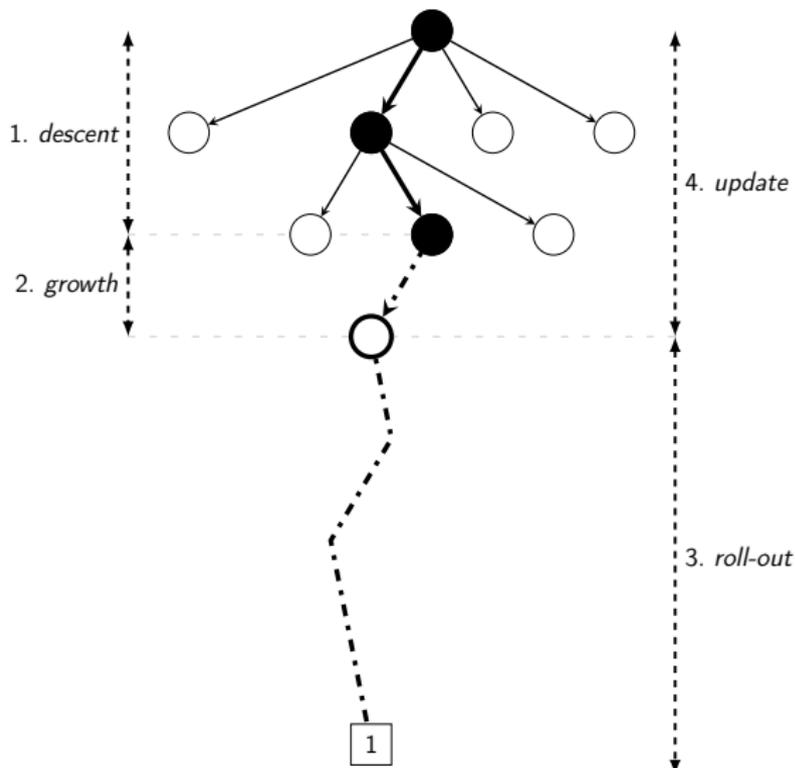
Monte Carlo Tree Search



Boucle d'apprentissage

1. déterministe
2. 1 seul nœud

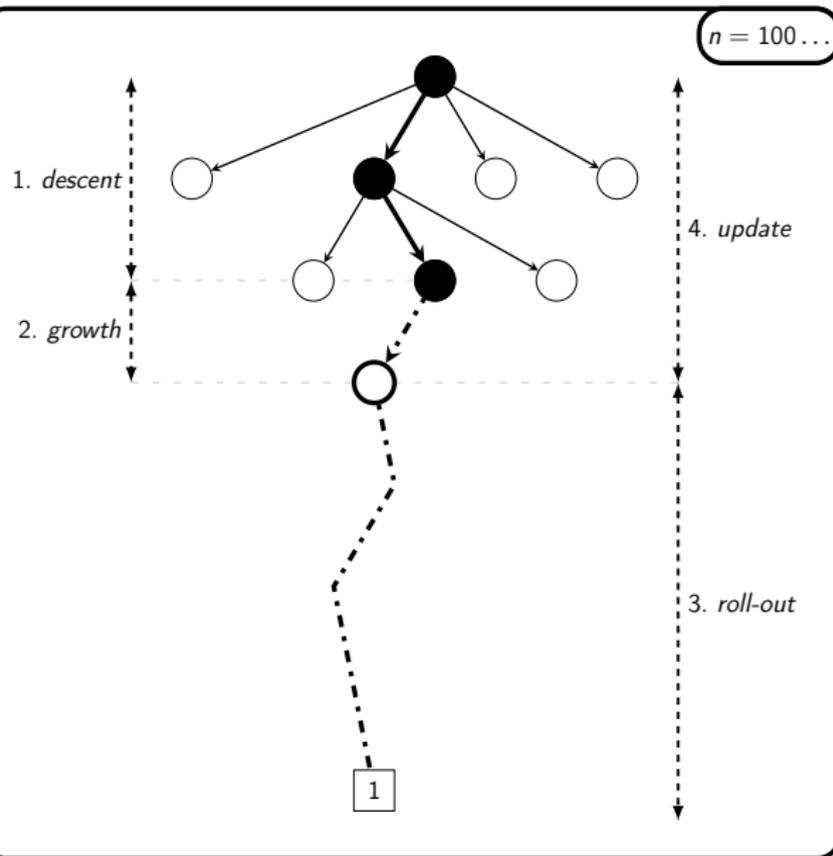
Monte Carlo Tree Search



Boucle d'apprentissage

1. déterministe
2. 1 seul nœud
3. aléatoire
4. 1 simulation

Monte Carlo Tree Search

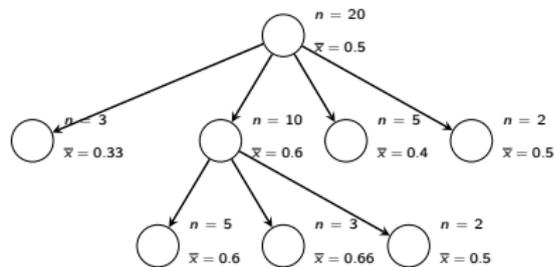


Boucle d'apprentissage

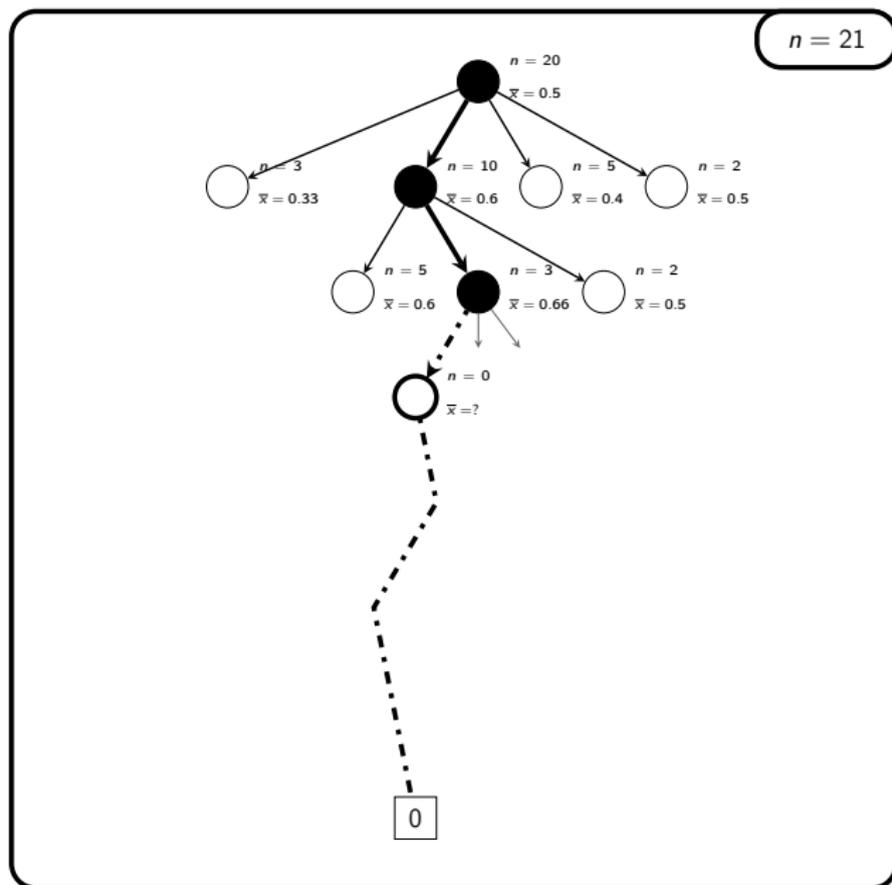
1. déterministe
2. 1 seul nœud
3. aléatoire
4. 1 simulation

Exécution de l'algorithme

$n = 20$

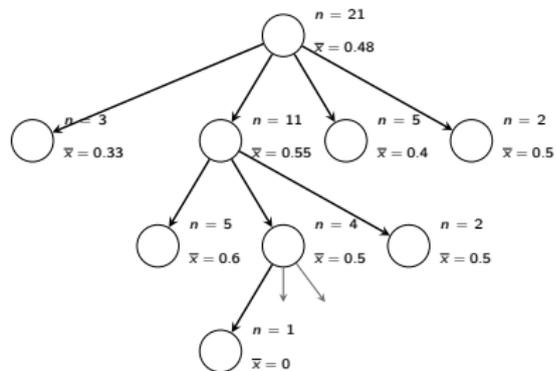


Exécution de l'algorithme

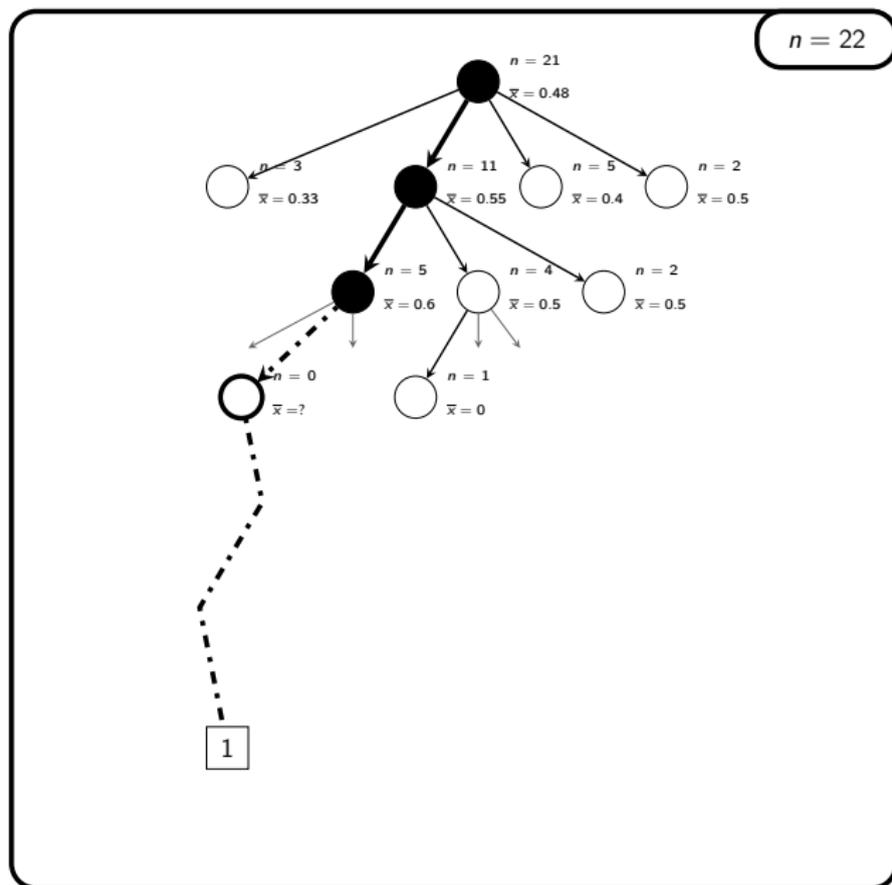


Exécution de l'algorithme

$n = 21$

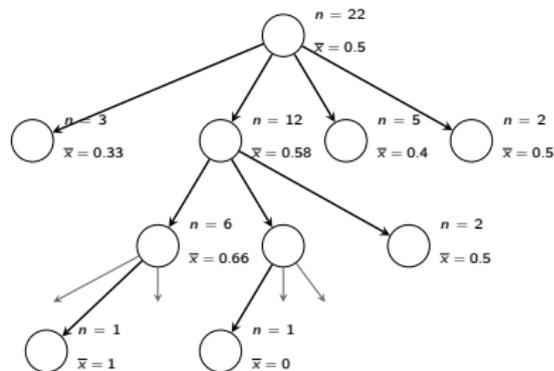


Exécution de l'algorithme



Exécution de l'algorithme

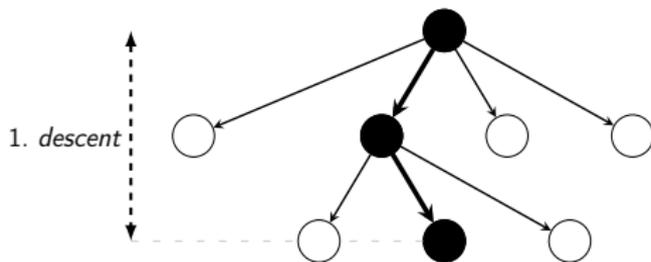
$n = 22$



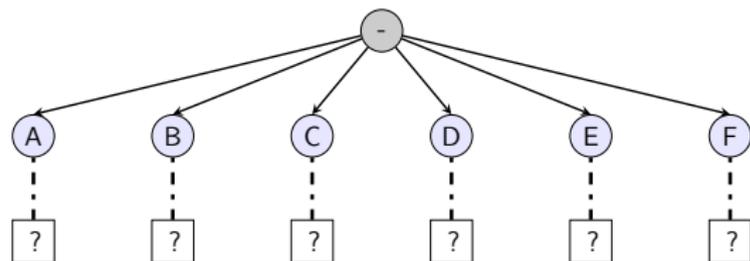
Deuxième partie II

Enjeux

1. *descent* phase



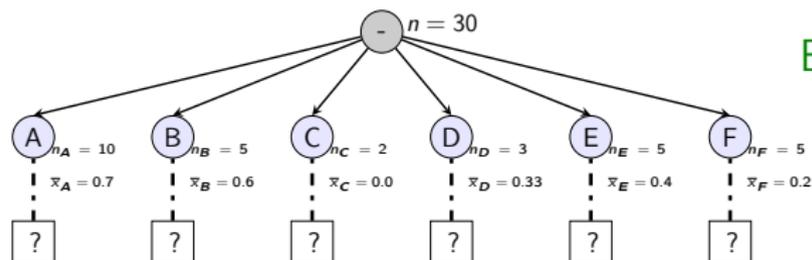
Exploration VS Exploitation



Bandit à n -bras

- ▶ n actions
- ▶ récompense inconnue
- ▶ minimiser le regret

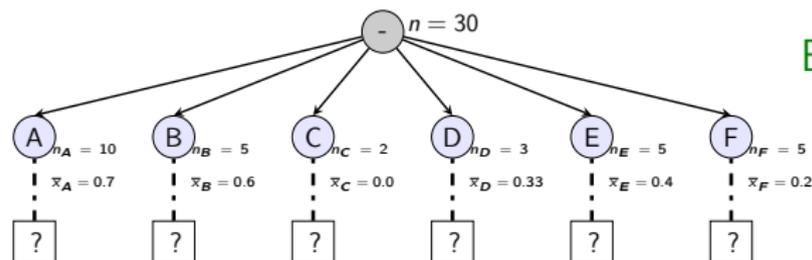
Exploration VS Exploitation



Bandit à n -bras

- ▶ n actions
- ▶ récompense inconnue
- ▶ minimiser le regret

Exploration VS Exploitation



Bandit à n -bras

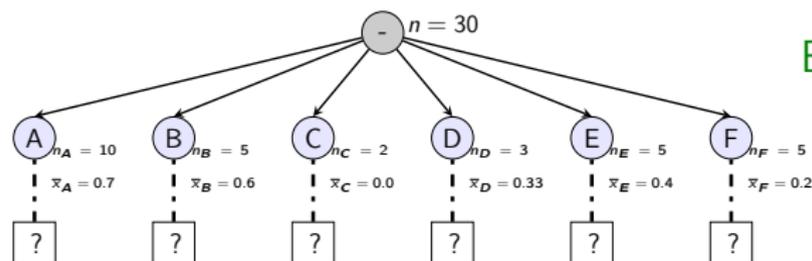
- ▶ n actions
- ▶ récompense inconnue
- ▶ minimiser le regret

Upper Confidence bound

$$UCB_i = \bar{x}_i + c \times \sqrt{\frac{\ln(n)}{n_i}}$$

c : coefficient d'exploration

Exploration VS Exploitation



Bandit à n -bras

- ▶ n actions
- ▶ récompense inconnue
- ▶ minimiser le regret

Upper Confidence bound applied to Trees

$$UCB_i = \bar{x}_i + c \times \sqrt{\frac{\ln(n)}{n_i}} \quad c : \text{coefficient d'exploration}$$

UCT = chaque nœud est un bandit à n -bras [Kocsis06]

Construction de l'arbre

Faible c : confiance aveugle *arbre asymétrique*

Fort c : circonspection *arbre symétrique (type MinMax)*

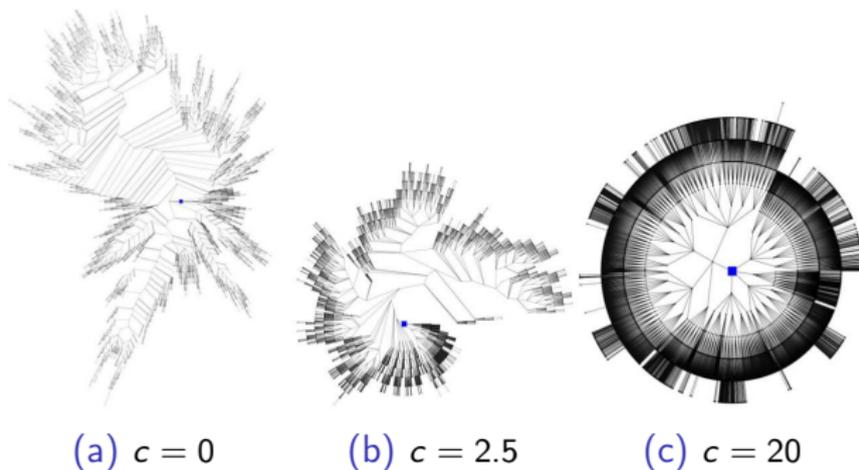


Figure: Arbre de recherche UCT avec c croissant [Ramanujan13]

Construction de l'arbre

Faible c : confiance aveugle *arbre asymétrique*

Fort c : circonspection *arbre symétrique (type MinMax)*

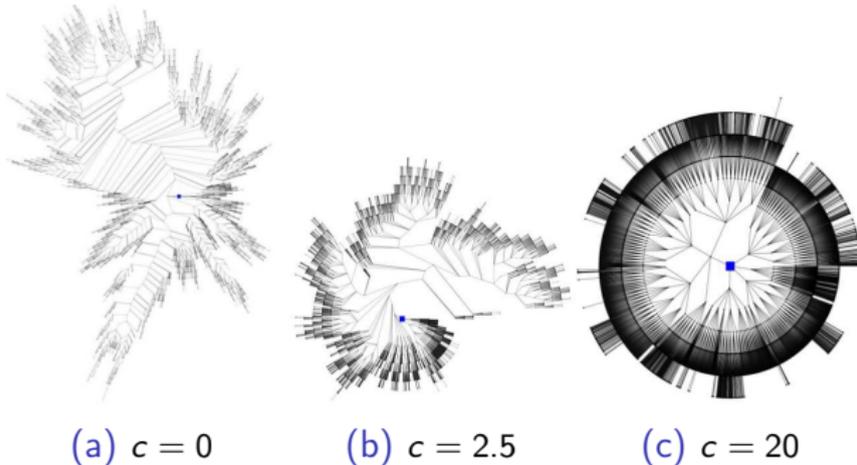
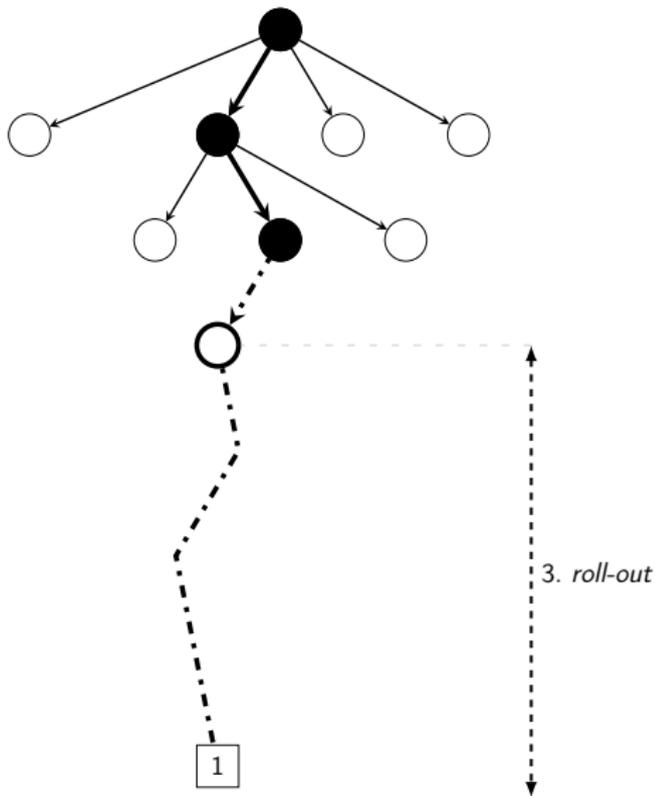


Figure: Arbre de recherche UCT avec c croissant [Ramanujan13]

L'estimateur (*UCB, RAVE, ...*) détermine la structure de l'arbre

3. *roll-out* phase



Dangers de Monte Carlo

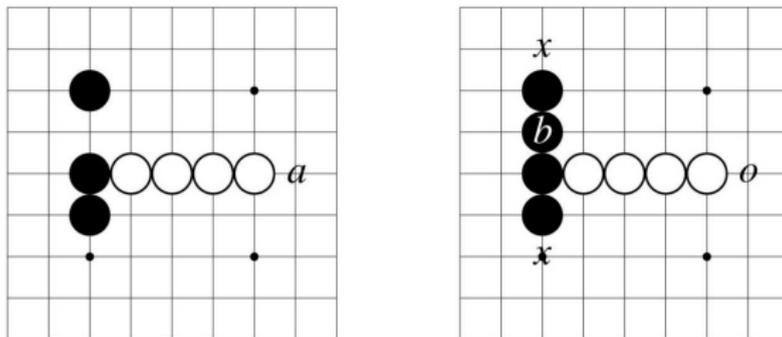


Figure: Situation critique pour Monte Carlo [Browne11]

Dangers de Monte Carlo

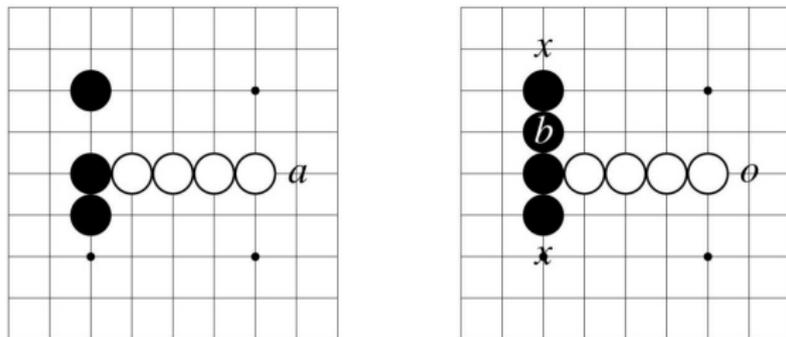
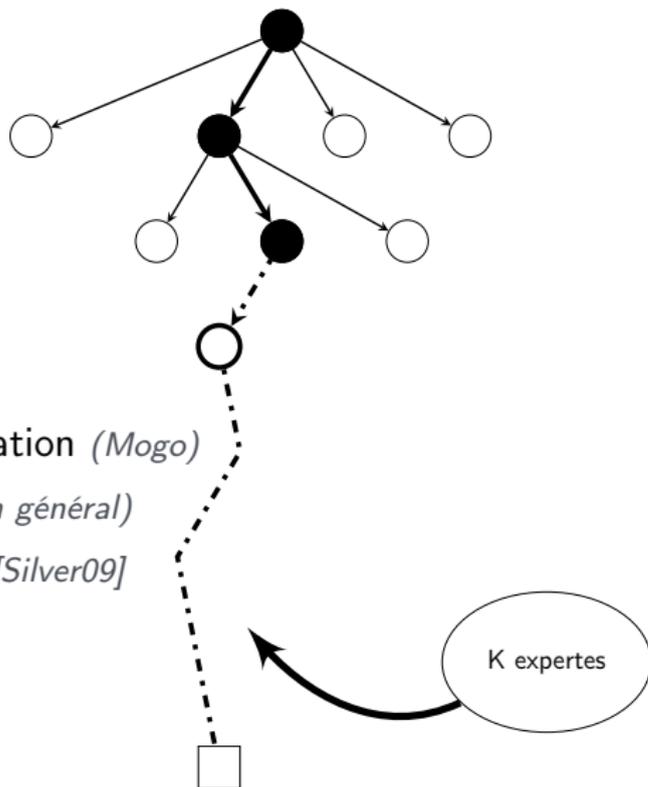


Figure: Situation critique pour Monte Carlo [Browne11]

Myopie des simulations aléatoires

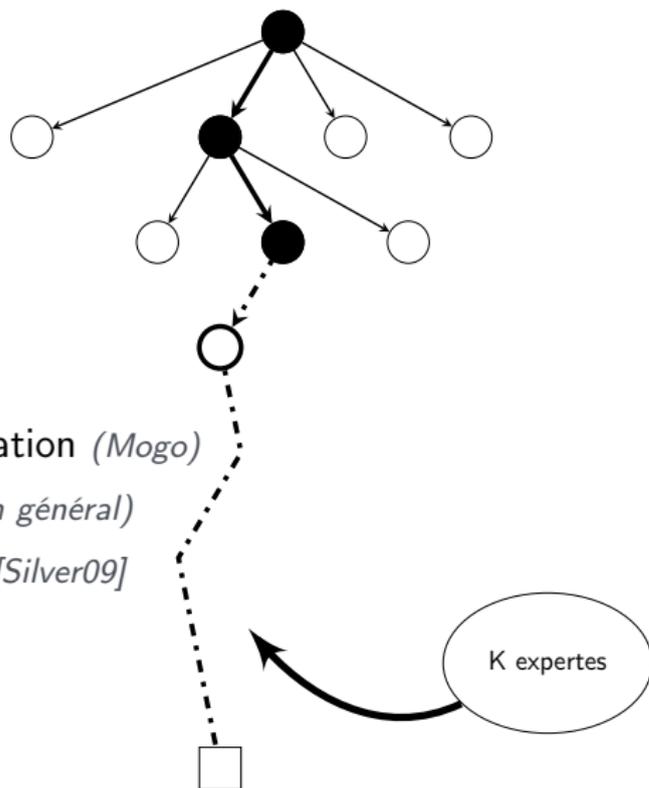
- ▶ coups « inutiles » (*invraisemblables*)
- ▶ situations pièges non couvertes par l'arbre (*Échecs/Go*)

Contrôle de l'aléatoire



- ▶ Meilleure représentation (*Mogo*)
- ▶ K spécifiques (... en général)
- ▶ « Magic formula » [Silver09]

Couplage complexe entre simulations & arbre de recherche



- ▶ Meilleure représentation (*Mogo*)
- ▶ K spécifiques (... en général)
- ▶ « Magic formula » [Silver09]

Forces

- ▶ \emptyset connaissances
- ▶ « *anytime* »
- ▶ robuste aux bruits

État d'avancement de la compréhension

Forces

- ▶ \emptyset connaissances
- ▶ « *anytime* »
- ▶ robuste aux bruits

Faiblesses

- ▶ \emptyset assimilation (*perte de K*)
- ▶ situations pièges (*changement de phase*)
- ▶ couplages mal-compris
(*peu de méthodes d'évaluation*)

État d'avancement de la compréhension

Forces

- ▶ \emptyset connaissances
- ▶ « *anytime* »
- ▶ robuste aux bruits

Faiblesses

- ▶ \emptyset assimilation (*perte de K*)
- ▶ situations pièges (*changement de phase*)
- ▶ couplages mal-compris
(*peu de méthodes d'évaluation*)

Applications

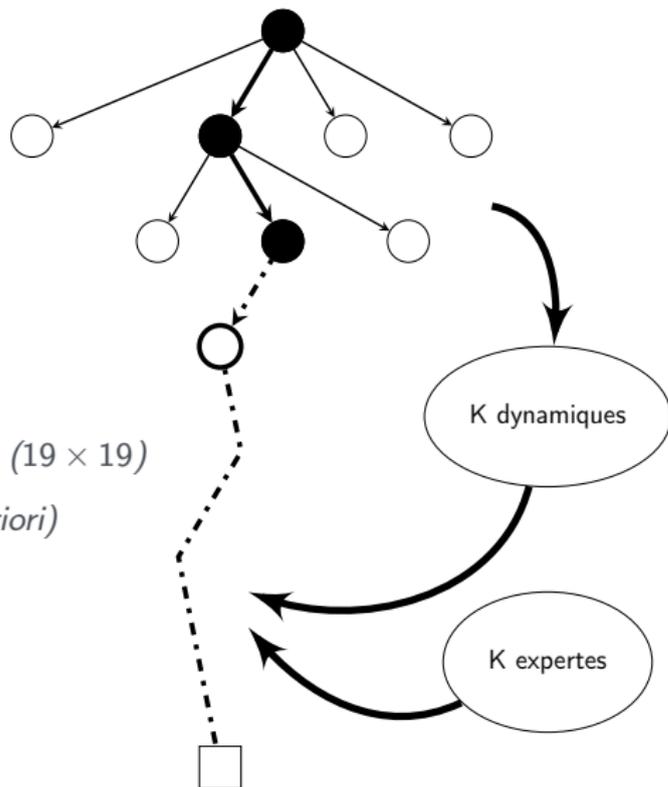
- ▶ Jeux combinatoires (*Go, Hex*)
- ▶ Jeux non-déterministes (*Poker, Backgammon*)
- ▶ Optimisation combinatoire (*TSP, approximation de fonction*)
- ▶ Planification
- ▶ ...

Troisième partie III

... et affinités

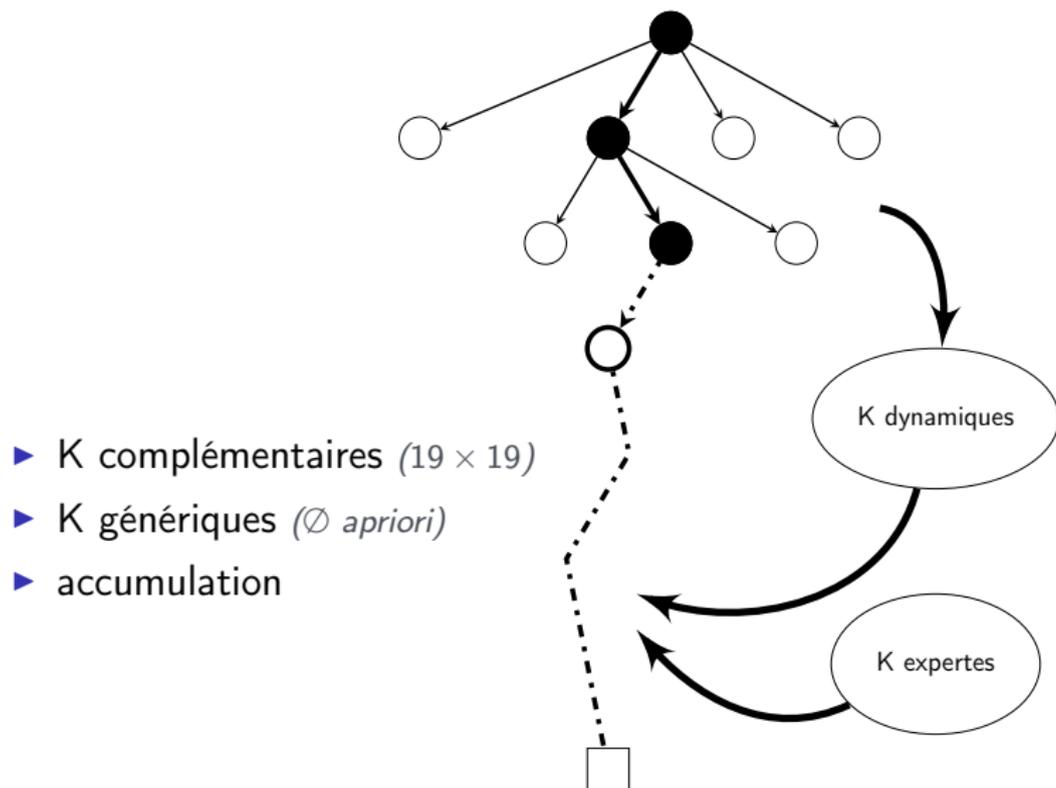
Contrôle par des connaissances dynamiques

- ▶ K complémentaires (19×19)
- ▶ K génériques (\emptyset *a priori*)
- ▶ accumulation



Contrôle par des connaissances dynamiques

Intérêt de réexploiter K de l'arbre pour les simulations



Représentation complémentaire émergente

Réprésentation plus abstraite au service de l'arbre

