

Échantillonnage adaptatif optimal dans les champs de Markov, application à l'échantillonnage d'une espèce adventice

Mathieu BONNEAU^{1,2}

¹INRA - Unité de Biométrie et Intelligence Artificielle - Toulouse

²INRA - UMR Agroécologie, pôle Écologie des Communautés et Durabilité des Systèmes Agricoles -Dijon

Encadrement : S. GABA², N. PEYRARD¹, R. SABBADIN¹

Définition du problème d'échantillonnage spatial

- ▶ **But** : Reconstruction d'un phénomène spatial.
- ▶ **Contrainte** : Nombre limité d'observations.
- ▶ **Problème** : Choix des lieux d'observations.



- ▶ **Échantillonnage adaptatif** : Choix **adaptatif** des lieux d'observations (\neq statique).
- ▶ **Problème d'échantillonnage adaptatif " hors-ligne "** : Choix d'une stratégie d'échantillonnage adaptatif permettant, en espérance, des reconstructions de meilleure qualité.

Exemple

- ▶ Échantillonnage pour la cartographie d'une espèce adventice à l'échelle de la parcelle.
- ▶ **Motivations :**
 - ▶ Cooccurrence d'espèces adventices ?
 - ▶ Corrélation entre rendement et présence d'espèce(s) adventice(s) ?

Objectif de ces travaux de thèse

- ▶ Objectif méthodologique : *Conception d'une méthode de résolution approchée du choix d'une stratégie d'échantillonnage adaptative dans les champs de Markov.*

- ▶ Objectif finalisé : *Conception de stratégies d'échantillonnage adaptatives d'une espèce adventice au sein d'une parcelle cultivée.*

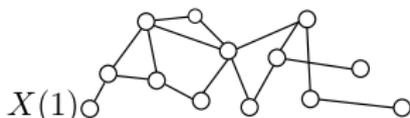
Contributions méthodologiques

- ▶ Objectif méthodologique : *Conception d'une méthode de résolution approchée du choix d'une stratégie d'échantillonnage adaptive dans les champs de Markov.*
 - ▶ **Idée** : Utilisation des algorithmes d'apprentissage par renforcement.
- 1. Modélisation du problème de calcul d'une stratégie optimale comme un Processus Décisionnel de Markov à horizon fini (de grande taille). [Bonneau et al, 2010](#)
- 2. Conception d'un algorithme de résolution approchée de tout PDM à horizon fini
 - ▶ Algorithme *Least-Squares Dynamic Programming* (LSDP, [Bonneau et al, 2012a](#))
- 3. Validation de LSDP sur des problèmes jouets de conception de stratégies d'échantillonnage. [Bonneau et al, 2012a](#)

Contributions finalisées

- ▶ Objectif finalisé : *Conception de stratégies d'échantillonnage adaptatives d'une espèce adventice au sein d'une parcelle cultivée.*
 1. Modélisation de la distribution spatiale des classes de densité d'une espèce adventice à l'aide des champs de Markov. [Bonneau et al, 2012b in prép.](#)
 2. Modélisation des contraintes d'échantillonnage d'une espèce adventice. [Bonneau et al, 2012c in prép.](#)
 3. Application de LSDP pour la conception de stratégies d'échantillonnage adaptatives et comparaison à des stratégies d'échantillonnage myope et statiques. [Bonneau et al, 2012c in prép.](#)

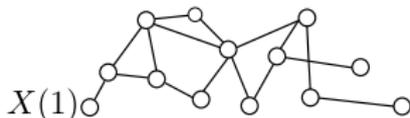
Modélisation du problème d'échantillonnage adaptatif



- ▶ $\mathbf{X} = (X(1), \dots, X(n))$ champ aléatoire.
- ▶ $X(i) \in \{0, \dots, K\}$

- ▶ $\mathbb{P}(\cdot)$: distribution de probabilités sur les valeurs \mathbf{x} du champ \mathbf{X} .
 - ▶ **Champ de Markov**, connu.

Modélisation du problème d'échantillonnage adaptatif

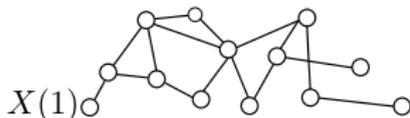


- ▶ $\mathbf{X} = (X(1), \dots, X(n))$ champ aléatoire.
- ▶ $X(i) \in \{0, \dots, K\}$

- ▶ $\mathbb{P}(\cdot)$: distribution de probabilités sur les valeurs \mathbf{x} du champ \mathbf{X} .
 - ▶ **Champ de Markov**, connu.

- ▶ $c(i, x(i))$: **coût** d'observation.
- ▶ Nombre d'observations limité par un **budget** B .

Modélisation du problème d'échantillonnage adaptatif



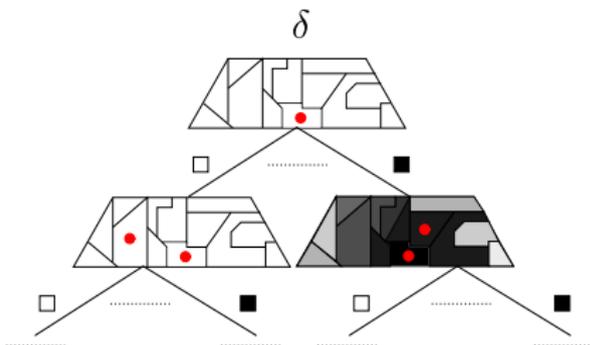
- ▶ $\mathbf{X} = (X(1), \dots, X(n))$ champ aléatoire.
- ▶ $X(i) \in \{0, \dots, K\}$

- ▶ $\mathbb{P}(\cdot)$: distribution de probabilités sur les valeurs \mathbf{x} du champ \mathbf{X} .
 - ▶ **Champ de Markov**, connu.

- ▶ $c(i, x(i))$: **coût** d'observation.

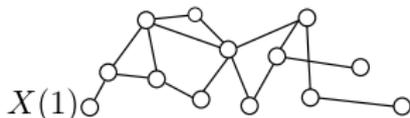
- ▶ Nombre d'observations limité par un **budget** B .

- ▶ Stratégie d'échantillonnage, notée δ .



$$\begin{aligned}
 a^1 &= \text{fixe} \\
 a^2 &= \delta((a^1, x(a^1))) \\
 &\vdots \\
 a^{t+1} &= \delta((a^1, x(a^1)), \dots, (a^t, x(a^t)))
 \end{aligned}$$

Modélisation du problème d'échantillonnage adaptatif



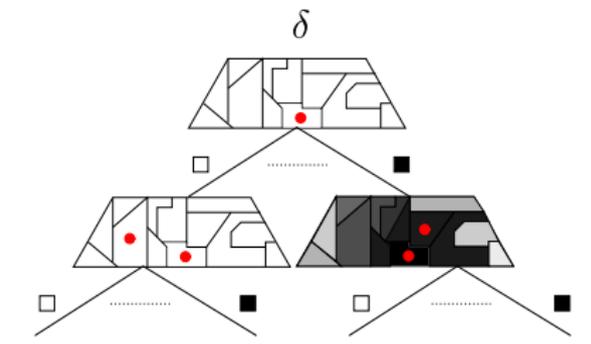
- ▶ $\mathbf{X} = (X(1), \dots, X(n))$ champ aléatoire.
- ▶ $X(i) \in \{0, \dots, K\}$

- ▶ $\mathbb{P}(\cdot)$: distribution de probabilités sur les valeurs \mathbf{x} du champ \mathbf{X} .
 - ▶ **Champ de Markov**, connu.

- ▶ $c(i, x(i))$: **coût** d'observation.

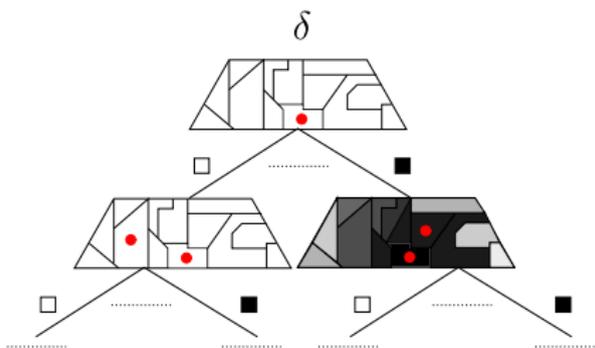
- ▶ Nombre d'observations limité par un **budget** B .

- ▶ Stratégie d'échantillonnage, notée δ .



- ▶ **Trajectoire** : $(A, x(A)) = \{(a^1, x(a^1)), \dots, (a^{t_{\text{final}}}, x(a^{t_{\text{final}}}))\}$.
- ▶ τ_δ : Ensemble des trajectoires possibles issues de δ .
- ▶ $\mathbf{U}(A, x(A))$: "Espérance du nombre de variables bien reconstruites".

Modélisation du problème d'échantillonnage adaptatif



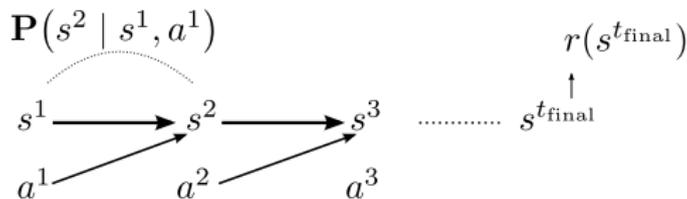
- ▶ **Trajectoire** : $(A, x(A)) = \{(a^1, x(a^1)), \dots, (a^{t_{\text{final}}}, x(a^{t_{\text{final}}}))\}$.
- ▶ τ_δ : Ensemble des trajectoires possibles issues de δ .
- ▶ $U(A, x(A))$: "Espérance du nombre de variables bien reconstruites".

Problème d'échantillonnage adaptatif optimal

Choix de la stratégie permettant en espérance la **meilleure reconstruction du champ X** et respectant les contraintes :

$$\delta^* = \operatorname{argmax}_\delta \left[\sum_{(A, x(A)) \in \tau_\delta} \mathbb{P}(X(A) = x(A)) U(A, x(A)) \right] \quad \text{tel que} \quad \text{coût}(\delta) \leq B$$

Modélisation en PDM à horizon fini

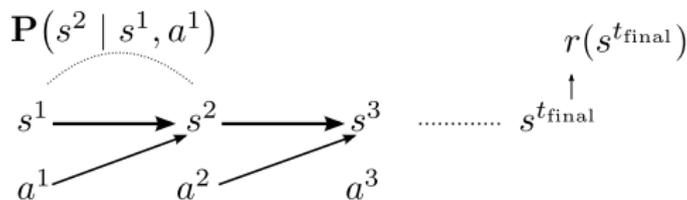


- ▶ **État s^t** : résume les indices des variables observées et leurs valeurs :

$$s^{t+1} \leftrightarrow (A^t, x(A^t)), \quad t \geq 1, \quad A^t = \cup_{t'=1}^t a^{t'}$$

- ▶ **Action a^t** : Indice de la variable observée au temps t .
- ▶ **Récompense r** : $r(s^{t_{\text{final}}}) = U(A^{t_{\text{final}}}, x(A^{t_{\text{final}}}))$
- ▶ **Transition $\mathbf{P}(s^{t+1} | s^t, a^t) = \mathbb{P}(X(a^t) = s^{t+1}(a^t) | x(A^{t-1}))$**

Modélisation en PDM à horizon fini



- ▶ **État s^t** : résume les indices des variables observées et leurs valeurs :

$$s^{t+1} \leftrightarrow (A^t, x(A^t)), \quad t \geq 1, \quad A^t = \cup_{t'=1}^t a^{t'}$$

- ▶ **Action a^t** : Indice de la variable observée au temps t .

- ▶ **Récompense r** : $r(s^{t_{\text{final}}}) = U(A^{t_{\text{final}}}, x(A^{t_{\text{final}}}))$

- ▶ **Transition P** $P(s^{t+1} | s^t, a^t) = \mathbb{P}(X(a^t) = s^{t+1}(a^t) | x(A^{t-1}))$

- ▶ **Valeur d'une stratégie δ dans l'état s^t** : $V^\delta(s^t) = \mathbb{E}[r(s^{t_{\text{final}}}) | s^t, \delta]$

$$\Rightarrow V^\delta(s^1) = V(\delta) = \sum_{(A, x(A)) \in \tau_\delta} \mathbb{P}(X(A) = x(A)) U(A, x(A))$$

- ▶ **Stratégie optimale δ^*** :

$$\forall t, s^t, \delta \quad V^{\delta^*}(s^t) \geq V^\delta(s^t)$$

Modélisation en PDM à horizon fini



- ▶ **État s^t** : résume les indices des variables observées et leurs valeurs :

$$s^{t+1} \leftrightarrow (A^t, x(A^t)), \quad t \geq 1, \quad A^t = \cup_{t'=1}^t a^{t'}$$

- ▶ **Action a^t** : Indice de la variable observée au temps t .

- ▶ **Récompense r** : $r(s^{t_{\text{final}}}) = U(A^{t_{\text{final}}}, x(A^{t_{\text{final}}}))$

- ▶ **Transition $P(s^{t+1} | s^t, a^t)$** = $\mathbb{P}(X(a^t) = s^{t+1}(a^t) | x(A^{t-1}))$

Théorème

Une stratégie optimale, δ^* , de ce PDM est optimale pour le problème d'échantillonnage adaptatif.

Résolution d'un PDM

- Utilisation de la Q -fonction :

$$\begin{aligned}\forall t, s^t, a^t \quad Q^*(s^t, a^t) &= \mathbb{E}[r(s^{t_{\text{final}}}) \mid s^t, a^t, \delta^*] \\ &= \sum_{s^{t+1}} \mathbf{P}(s^{t+1} \mid s^t, a^t) \max_{a^{t+1}} Q^*(s^{t+1}, a^{t+1})\end{aligned}$$

⇒ Équivalence entre connaissance de la stratégie optimale δ^* et de la fonction Q^* .

- Calcul de Q^* , outils disponibles :

1. Programmation dynamique exacte \Rightarrow impossible pour PDM de grande taille.

Résolution d'un PDM

- Utilisation de la Q -fonction :

$$\begin{aligned}\forall t, s^t, a^t \quad Q^*(s^t, a^t) &= \mathbb{E}[r(s^{t_{\text{final}}}) \mid s^t, a^t, \delta^*] \\ &= \sum_{s^{t+1}} \mathbf{P}(s^{t+1} \mid s^t, a^t) \max_{a^{t+1}} Q^*(s^{t+1}, a^{t+1})\end{aligned}$$

⇒ Équivalence entre connaissance de la stratégie optimale δ^* et la fonction Q^* .

- Calcul de Q^* , outils disponibles :

1. Programmation dynamique exacte ⇒ impossible pour PDM de grande taille.
2. Apprentissage par renforcement :
 - 2.1 Estimation de Q^* par simulation (Ex : Algorithme TD(λ))
⇒ impossible pour PDM de grande taille.
 - 2.2 Estimation d'une approximation linéaire de Q^* (Ex : Algorithme Least-Squares Policy Iteration (LSPI)).
⇒ inadaptée au PDM à horizon fini et à notre type de récompense.

Algorithme LSDP : les deux principes

- ▶ **Principe 1** : Rajouter une dépendance temporelle à la fonction \tilde{Q}^* :

$$\forall t, s^t, a^t \quad \tilde{Q}^*(s^t, a^t, t) = \sum_{i=1}^p w_i^t \phi_i(s^t, a^t)$$

- ▶ ϕ_i : fonctions simples appelées *features* (calcul rapide)
- ▶ **Principe 2** : Calculer les poids $\{w_i^t\}_{t,i}$ au sens des moindres carrés en combinant les principes de programmation dynamique et de la simulation.

$$\begin{cases} \tilde{Q}^*(s_1^{t_{\max}}, a_1^{t_{\max}}) = \sum_{i=1}^p w_i^{t_{\max}} \phi_i(s_1^{t_{\max}}, a_1^{t_{\max}}) = \mathbb{E} \left[r(s^{t_{\max}+1}) \mid s_1^{t_{\max}}, a_1^{t_{\max}} \right] \\ \vdots \\ \tilde{Q}^*(s_m^{t_{\max}}, a_m^{t_{\max}}) = \sum_{i=1}^p w_i^{t_{\max}} \phi_i(s_m^{t_{\max}}, a_m^{t_{\max}}) = \mathbb{E} \left[r(s^{t_{\max}+1}) \mid s_m^{t_{\max}}, a_m^{t_{\max}} \right] \end{cases}$$

t_{\max} : nombre maximal de variables que l'on peut observer avec le budget B .

Algorithme LSDP : les deux principes

- ▶ **Principe 1** : Rajouter une dépendance temporelle à la fonction \tilde{Q}^* :

$$\forall t, s^t, a^t \quad \tilde{Q}^*(s^t, a^t, t) = \sum_{i=1}^p w_i^t \phi_i(s^t, a^t)$$

- ▶ ϕ_i : fonctions simples appelées *features* (calcul rapide)
- ▶ **Principe 2** : Calculer les poids $\{w_i^t\}_{t,i}$ au sens des moindres carrés en combinant les principes de **programmation dynamique** et de la simulation.

$$\begin{cases} \tilde{Q}^*(s_1^{t_{\max}}, a_1^{t_{\max}}) = \sum_{i=1}^p w_i^{t_{\max}} \phi_i(s_1^{t_{\max}}, a_1^{t_{\max}}) = \mathbb{E} \left[r(s^{t_{\max}+1}) \mid s_1^{t_{\max}}, a_1^{t_{\max}} \right] \\ \vdots \\ \tilde{Q}^*(s_m^{t_{\max}}, a_m^{t_{\max}}) = \sum_{i=1}^p w_i^{t_{\max}} \phi_i(s_m^{t_{\max}}, a_m^{t_{\max}}) = \mathbb{E} \left[r(s^{t_{\max}+1}) \mid s_m^{t_{\max}}, a_m^{t_{\max}} \right] \end{cases}$$

t_{\max} : nombre maximal de variables que l'on peut observer avec le budget B .

Algorithme LSDP : les deux principes

- ▶ **Principe 1** : Rajouter une composante temporelle à la fonction Q^* :

$$\forall t, s^t, a^t \quad \tilde{Q}^*(s^t, a^t, t) = \sum_{i=1}^p w_i^t \phi_i(s^t, a^t)$$

- ▶ ϕ_i : fonctions simples appelées *features* (calcul rapide)
- ▶ **Principe 2** : Calculer les poids $\{w_i^t\}_{t,i}$ au sens des moindres carrés en combinant les principes de **programmation dynamique** et de la simulation.

$$\begin{cases} \sum_{i=1}^p w_i^{t_{\max}-1} \phi_i(s_1^{t_{\max}-1}, a_1^{t_{\max}-1}) = \mathbb{E} \left[\max_{a^{t_{\max}}} \tilde{Q}^*(s_1^{t_{\max}}, a_1^{t_{\max}}) \mid s_1^{t_{\max}-1}, a_1^{t_{\max}-1} \right] \\ \vdots \\ \sum_{i=1}^p w_i^{t_{\max}-1} \phi_i(s_m^{t_{\max}-1}, a_m^{t_{\max}-1}) = \mathbb{E} \left[\max_{a^{t_{\max}}} \tilde{Q}^*(s_m^{t_{\max}}, a_m^{t_{\max}}) \mid s_m^{t_{\max}-1}, a_m^{t_{\max}-1} \right] \end{cases}$$

t_{\max} : nombre maximal de variables que l'on peut observer avec le budget B .

Algorithme LSDP : les deux principes

- ▶ **Principe 1** : Rajouter une composante temporelle à la fonction Q^* :

$$\forall t, s^t, a^t \quad \tilde{Q}^*(s^t, a^t, t) = \sum_{i=1}^p w_i^t \phi_i(s^t, a^t)$$

- ▶ ϕ_i : fonctions simples appelées *features* (calcul rapide)
- ▶ **Principe 2** : Calculer les poids $\{w_i^t\}_{t,i}$ au sens des **moindres carrés** en combinant les principes de programmation dynamique et de la simulation.

$$\begin{cases} \sum_{i=1}^p w_i^{t_{\max}-1} \phi_i(s_1^{t_{\max}-1}, a_1^{t_{\max}-1}) = \mathbb{E} \left[\max_{a^{t_{\max}}} \tilde{Q}^*(s_1^{t_{\max}}, a_1^{t_{\max}}) \mid s_1^{t_{\max}-1}, a_1^{t_{\max}-1} \right] \\ \vdots \\ \sum_{i=1}^p w_i^{t_{\max}-1} \phi_i(s_m^{t_{\max}-1}, a_m^{t_{\max}-1}) = \mathbb{E} \left[\max_{a^{t_{\max}}} \tilde{Q}^*(s_m^{t_{\max}}, a_m^{t_{\max}}) \mid s_m^{t_{\max}-1}, a_m^{t_{\max}-1} \right] \end{cases}$$

t_{\max} : nombre maximal de variables que l'on peut observer avec le budget B .

Algorithme LSDP : les deux principes

- ▶ **Principe 1** : Rajouter une composante temporelle à la fonction Q^* :

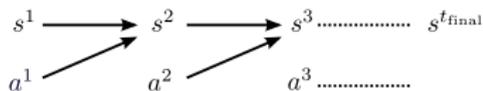
$$\forall t, s^t, a^t \quad \tilde{Q}^*(s^t, a^t, t) = \sum_{i=1}^p w_i^t \phi_i(s^t, a^t)$$

- ▶ ϕ_i : fonctions simples appelées *features* (calcul rapide)
- ▶ **Principe 2** : Calculer les poids $\{w_i^t\}_{t,i}$ au sens des moindres carrés en combinant les principes de programmation dynamique et de la **simulation**.

$$\begin{cases} \sum_{i=1}^p w_i^{t_{\max}-1} \phi_i(s_1^{t_{\max}-1}, a_1^{t_{\max}-1}) = \mathbb{E} \left[\max_{a^{t_{\max}}} \tilde{Q}^*(s_1^{t_{\max}}, a_1^{t_{\max}}) \mid s_1^{t_{\max}-1}, a_1^{t_{\max}-1} \right] \\ \vdots \\ \sum_{i=1}^p w_i^{t_{\max}-1} \phi_i(s_m^{t_{\max}-1}, a_m^{t_{\max}-1}) = \mathbb{E} \left[\max_{a^{t_{\max}}} \tilde{Q}^*(s_m^{t_{\max}}, a_m^{t_{\max}}) \mid s_m^{t_{\max}-1}, a_m^{t_{\max}-1} \right] \end{cases}$$

t_{\max} : nombre maximal de variables que l'on peut observer avec le budget B .

Algorithme LSDP : la simulation



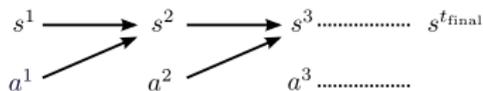
$$\begin{cases} \sum_{i=1}^P w_j^{t_{\max}-1} \phi_i(s_1^{t_{\max}-1}, a_1^{t_{\max}-1}) = \mathbb{E} \left[\max_{a^{t_{\max}}} \tilde{Q}^*(s_1^{t_{\max}}, a_1^{t_{\max}}) \mid s_1^{t_{\max}-1}, a_1^{t_{\max}-1} \right] \\ \vdots \\ \sum_{i=1}^P w_j^{t_{\max}-1} \phi_i(s_m^{t_{\max}-1}, a_m^{t_{\max}-1}) = \mathbb{E} \left[\max_{a^{t_{\max}}} \tilde{Q}^*(s_m^{t_{\max}}, a_m^{t_{\max}}) \mid s_m^{t_{\max}-1}, a_m^{t_{\max}-1} \right] \end{cases}$$

- ▶ $W = \{w_i^t\}_{t,i} \Leftrightarrow \delta^W$
 - ▶ Méthode ϵ -greedy pour le choix des actions.

Proba $1 - \epsilon$: Action aléatoire.

Proba ϵ : $\arg \max_{a^t} \tilde{Q}^*(s^t, a^t)$

Algorithme LSDP : la simulation



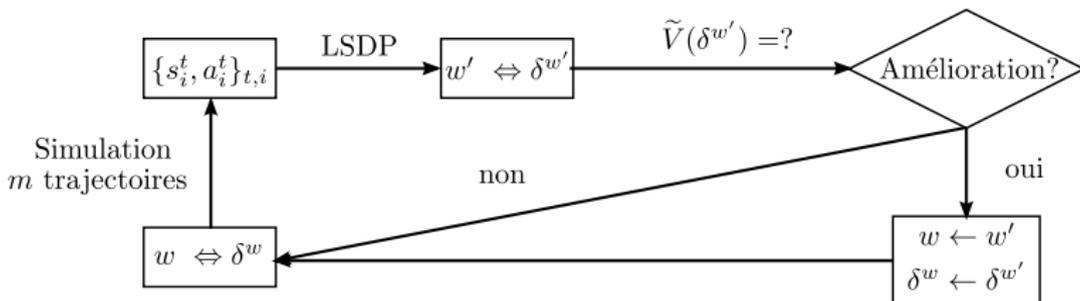
$$\begin{cases} \sum_{i=1}^P w_j^{t_{max}-1} \phi_i(s_1^{t_{max}-1}, a_1^{t_{max}-1}) = \mathbb{E} \left[\max_{a^{t_{max}}} \tilde{Q}^*(s_1^{t_{max}}, a_1^{t_{max}}) \mid s_1^{t_{max}-1}, a_1^{t_{max}-1} \right] \\ \vdots \\ \sum_{i=1}^P w_j^{t_{max}-1} \phi_i(s_m^{t_{max}-1}, a_m^{t_{max}-1}) = \mathbb{E} \left[\max_{a^{t_{max}}} \tilde{Q}^*(s_m^{t_{max}}, a_m^{t_{max}}) \mid s_m^{t_{max}-1}, a_m^{t_{max}-1} \right] \end{cases}$$

- ▶ $W = \{w_i^t\}_{t,i} \Leftrightarrow \delta^W$
 - ▶ Méthode ϵ -greedy pour le choix des actions.

Proba $1 - \epsilon$: Action aléatoire.

Proba ϵ : $\arg \max_{a^t} \tilde{Q}^*(s^t, a^t)$

- ▶ Représentation schématique de LSDP :



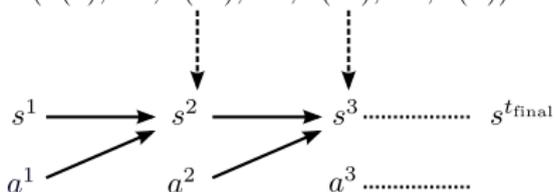
Algorithme LSDP : application à l'échantillonnage

- ▶ Calcul des probabilités de transition et des espérances (équations de programmation dynamique) :
 - ▶ Proposition d'une approximation ad-hoc, $\tilde{\mathbb{P}}(\cdot)$, des vraies marginales.
- ▶ Choix des features ($\tilde{Q}^*(s^t, a^t) = \sum_{i=1}^n w_i^t \phi_i(\mathbf{s}^t, \mathbf{a}^t)$) :
 - ▶ Basées sur l'incertitude sur les variables non observées ($\max_{x(i)} \tilde{\mathbb{P}}(x(i) | x(\mathbf{A}))$).
- ▶ Simulation des trajectoires :
 - ▶ Extraction des trajectoires à partir de valeurs simulées du champ \mathbf{X} .
 - ▶ Propriété d'équivalence.

Algorithme LSDP : application à l'échantillonnage

- ▶ Calcul des probabilités de transition et des espérances (équations de programmation dynamique) :
 - ▶ Proposition d'une approximation ad-hoc, $\tilde{\mathbb{P}}(\cdot)$, des vraies marginales.
- ▶ Choix des features ($\tilde{Q}^*(s^t, a^t) = \sum_{i=1}^n w_i^t \phi_i(\mathbf{s}^t, \mathbf{a}^t)$) :
 - ▶ Basées sur l'incertitude sur les variables non observées ($\max_{x(i)} \tilde{\mathbb{P}}(x(i) | x(A))$).
- ▶ **Simulation des trajectoires** :
 - ▶ Extraction des trajectoires à partir de valeurs simulées du champ \mathbf{X} .
 - ▶ Propriété d'équivalence.

$$\mathbf{x} = (x(1), \dots, x(a^1), \dots, x(a^2), \dots, x(n))$$

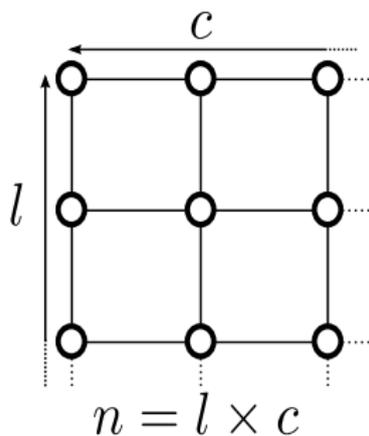


Évaluation expérimentale

- ▶ Modèle de distribution spatiale :

$$\forall \mathbf{x} \in \{0, 1\}^n \quad \mathbb{P}(\mathbf{X} = \mathbf{x}) = \exp \left(\frac{1}{2} \sum_{(i,j) \in E} \mathbb{1}_{\{x(i)=x(j)\}} \right),$$

où $E = \{i, j \in \{1, \dots, n\} \mid \text{les nœuds } i \text{ et } j \text{ sont voisins}\}$.



- ▶ Contraintes simples :

- ▶ $\forall i \in \{1 \dots n\}, x(i) \in \{0, 1\} \quad c(i, x(i)) = 1$

⇒ B : Nombre d'observations.

Comparaison à la stratégie optimale, $n = 16$

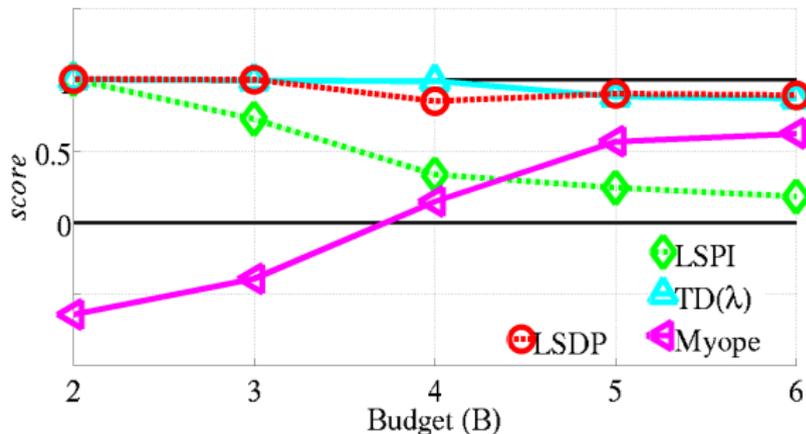
$$\forall \delta \quad \text{score}(\delta) = \frac{V(\delta) - V(\delta_R)}{V(\delta^*) - V(\delta_R)}, \text{ où } \delta_R \text{ est la stratégie aléatoire.}$$

- ▶ **Optimale** : Programmation dynamique exacte.
- ▶ **TD(λ)** : Estimation de Q^* par simulation (classique).
- ▶ **LSPI** : Combinaison linéaire Q^* (classique).
- ▶ **Myope** : Heuristique myope. [Peyrard et al, 2010](#)

Comparaison à la stratégie optimale, $n = 16$

$$\forall \delta \quad \text{score}(\delta) = \frac{V(\delta) - V(\delta_R)}{V(\delta^*) - V(\delta_R)}, \text{ où } \delta_R \text{ est la stratégie aléatoire.}$$

- ▶ **Optimale** : Programmation dynamique exacte.
- ▶ **TD(λ)** : Estimation de Q^* par simulation (classique).
- ▶ **LSPI** : Combinaison linéaire Q^* (classique).
- ▶ **Myope** : Heuristique myope. [Peyrard et al, 2010](#)

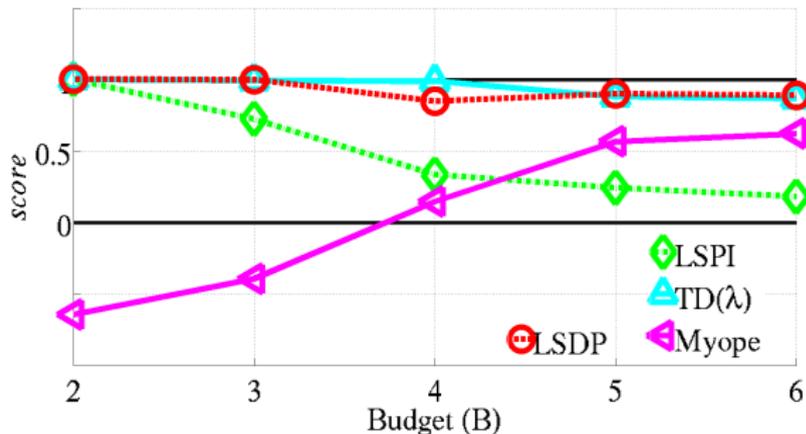


- ▶ Valeurs des stratégies proches.
- ▶ δ_{LSDP} proche de $\delta_{TD(\lambda)}$ et δ^* .
- ▶ Faible performance de δ_{LSPI} .

Comparaison à la stratégie optimale, $n = 16$

$$\forall \delta \quad \text{score}(\delta) = \frac{V(\delta) - V(\delta_R)}{V(\delta^*) - V(\delta_R)}, \text{ où } \delta_R \text{ est la stratégie aléatoire.}$$

- ▶ **Optimale** : Programmation dynamique exacte.
- ▶ **TD(λ)** : Estimation de Q^* par simulation (classique).
- ▶ **LSPI** : Combinaison linéaire Q^* (classique).
- ▶ **Myope** : Heuristique myope. [Peyrard et al, 2010](#)
- ▶ **LSDP** : Valeurs des stratégies proches.

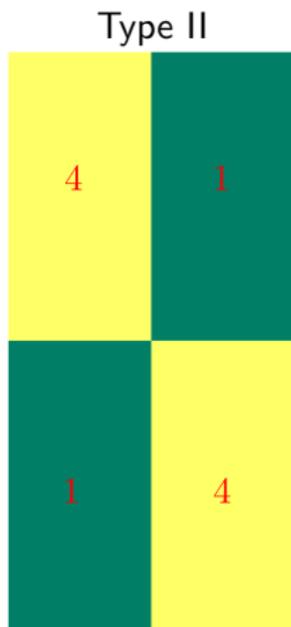
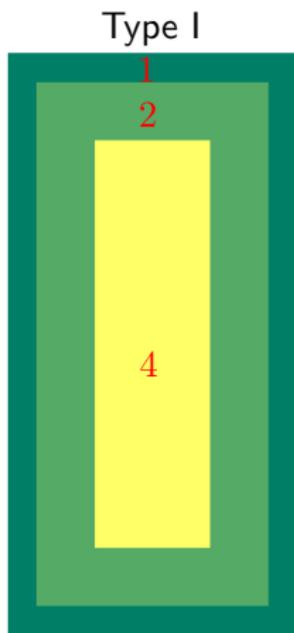


- ▶ Valeurs des stratégies proches.
- ▶ δ_{LSDP} proche de $\delta_{TD(\lambda)}$ et δ^* .
- ▶ Faible performance de δ_{LSPI} .

▶ **Même observations pour $n = 10 \times 10$.**

Contraintes non triviales, $n = 20 \times 10$

- ▶ Différentes fonctions de coût, $B = 38$:

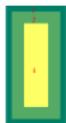


Type III

$$\forall i = 1, \dots, 200, \quad \forall x(i) \in \{0, 1\} :$$

$$c(i, x(i)) = \begin{cases} 2 & \text{si } x(i) = 0 \\ 1 & \text{si } x(i) = 1 \end{cases}$$

Contraintes non triviales, $n = 20 \times 10$


 $\forall i = 1, \dots, 200, \forall x(i) \in \{0, 1\} :$

$$c(i, x(i)) = \begin{cases} 2 & \text{si } x(i) = 0 \\ 1 & \text{si } x(i) = 1 \end{cases}$$

	Type I		Type II		Type III	
Stratégie	\tilde{V}	Nb. Obs.	\tilde{V}	Nb. Obs.	\tilde{V}	Nb. Obs.
δ_{LSDP}	64.80	27.3 (2.5)	63.6	22.8 (0.7)	65.4	25.6 (1.7)
δ_{Myope}	61.77	19 (1.9)	60.4	15.8 (1.9)	64.7	25.6 (1.8)
δ_{Random}	60.27	26.65 (2.8)	59.7	15.6 (2.3)	63.7	25.6 (1.9)

- \tilde{V} : Pourcentage moyen du nombre de variables bien reconstruites.

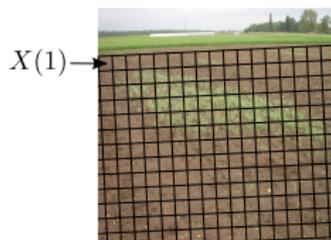
Conclusions partielles

- ▶ Objectif méthodologique : *Conception d'une méthode de résolution approchée du choix d'une stratégie d'échantillonnage adaptative dans les champs de Markov.*
 - ▶ Conception d'un algorithme de résolution approchée de tout PDM à horizon fini.
 - ▶ Application à la conception de stratégies d'échantillonnage adaptatives.
 - ▶ Amélioration de l'heuristique myope lorsque le nombre d'observations est faible ($\leq 40\%$) ou que les contraintes sont non triviales.

Contributions finalisées

- ▶ Objectif finalisé : *Conception de stratégies d'échantillonnage adaptatives d'une espèce adventice au sein d'une parcelle cultivée.*
 1. Modélisation de la distribution spatiale des classes de densité d'une espèce adventice à l'aide des champs de Markov.
 2. Modélisation des contraintes d'échantillonnage d'une espèce adventice.
 3. Application de LSDP pour la conception de stratégies d'échantillonnage adaptatives et comparaison à des stratégies d'échantillonnage myope ou statiques.

Des quadrats au champ de Markov

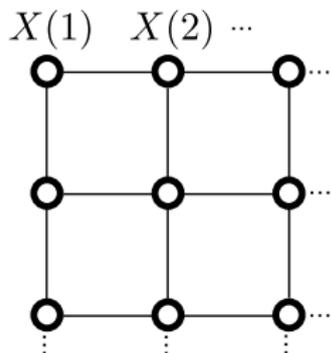


- ▶ $\mathbf{X} = (X(1), \dots, X(n))$ champ aléatoire.
 - ▶ **Cartographie** (inconnue) de la densité de l'espèce adventice.
- ▶ $X(i) \in \{0, \dots, 5\}$, **classe de densité** Barralis de l'espèce adventice sur le quadrat i .

- 0 : Nbl = 0,
- 1 : Nbl < 1,
- 2 : $1 \leq \text{Nbl} < 2$,
- 3 : $3 \leq \text{Nbl} < 20$,
- 4 : $20 \leq \text{Nbl} < 50$,
- 5 : $50 \leq \text{Nbl} < 500$,

Nbl : nombre d'individus moyen par m².

Des quadrats au champ de Markov



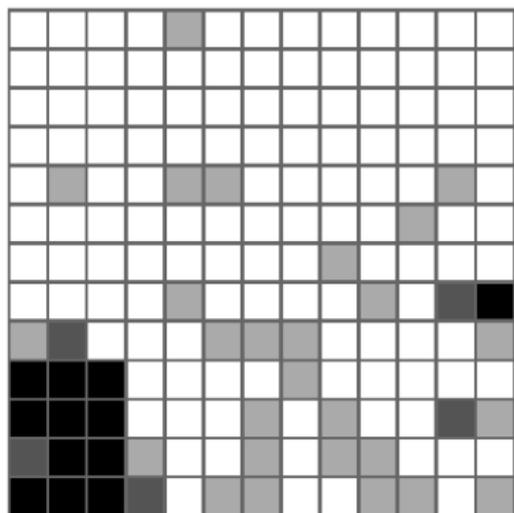
- ▶ $\mathbf{X} = (X(1), \dots, X(n))$ champ aléatoire.
 - ▶ **Cartographie** (inconnue) de la densité de l'espèce adventice.
- ▶ $X(i) \in \{0, \dots, 5\}$, **classe de densité** Barralis de l'espèce adventice sur le quadrat i .

▶ Données disponibles :

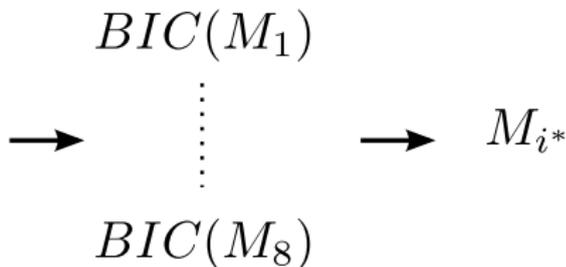
- ▶ Cartes complètes : 22 espèces adventices cartographiées sur des quadrats de 12.96m^2 dans une sous parcelle de 2500m^2
Dessaint, Communication personnelle - Dijon 2006
- ▶ Temps GPS : 14 000 temps de notation sur quadrats de 16m^2
Munnier-Jolain, Dijon-Époisses 2003-2008

Modèle de distribution spatiale

- Choix d'un modèle dans le cas de données complètes
 - Calcul du critère BIC de 8 modèles de distribution spatiale sur les 22 cartes complètes.



Cirsium arvense (L.) scopoli

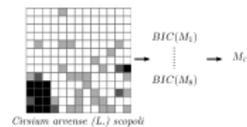


Modèle de distribution spatiale

► Choix d'un modèle dans le cas de données complètes

- Calcul du critère BIC de 8 modèles de distribution spatiale sur les 22 cartes complètes.

⇒ **Pas de structure spatiale universelle.**

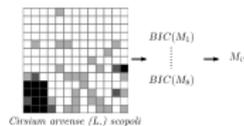


Modèle de distribution spatiale

► Choix d'un modèle dans le cas de données complètes

- Calcul du critère BIC de 8 modèles de distribution spatiale sur les 22 cartes complètes.

⇒ Pas de structure spatiale universelle.



► Quel modèle utiliser dans des cas réels ?

⇒ Modèle ad-hoc

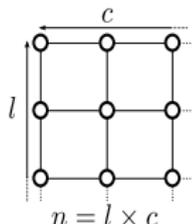
- Modèle de distribution spatiale, $\forall \mathbf{x} \in \{0, \dots, 5\}^n$:

$$\mathbb{P}(\mathbf{X} = \mathbf{x}) = \exp \left(\sum_{i=1}^n \alpha_{x(i)} + \beta \sum_{(i,j) \in E} \mathbb{1}_{\{x(i)=x(j)\}} \right)$$

- Valeur des paramètres, $\forall x(i) \in \{0, \dots, 5\}$:

$$\alpha_{x(i)} = \begin{cases} 0 & \text{si } x(i) = l \\ -0.2 & \text{si } x(i) \neq l \end{cases} \quad \beta = 0.58 \text{ (Structure spatiale moyenne)}$$

l : Valeur de la classe de densité la plus présente sur la parcelle.



Modélisation des contraintes d'échantillonnage

► **Question** : Pourquoi ne peut-on pas explorer l'ensemble de la parcelle ?

⇒ Trop coûteux en terme de temps.

⇒ Le budget B représente le temps disponible à l'échantillonnage d'une parcelle.

Modélisation des contraintes d'échantillonnage

- ▶ Question : Pourquoi ne peut-on pas explorer l'ensemble de la parcelle ?

⇒ Trop coûteux en terme de temps.

⇒ Le budget B représente le temps disponible à l'échantillonnage d'une parcelle.

- ▶ Question : De quoi dépend le temps de notation d'un quadrat ?

Z_1 : Culture

Z_2 : Période d'observation (couverture de la culture)

Z_3 : Densité totale d'adventices dans le quadrat

Z_4 : Nombre d'espèces adventices dans le quadrat

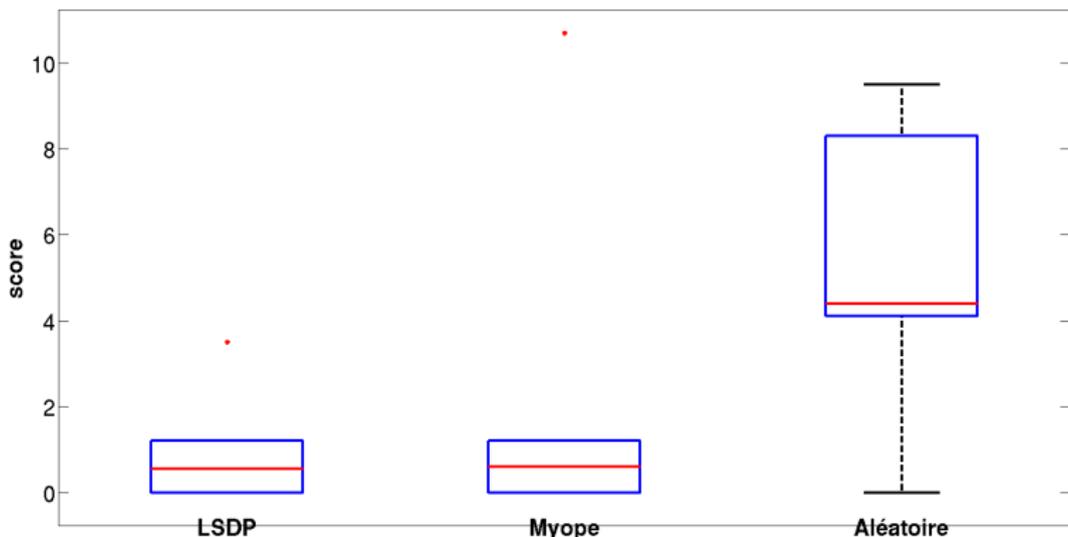
Z_5 : Intensité de désherbage (système de culture)

$$t_{\text{Obs}}(i, x(i)) = L(Z_1, Z_2, Z_3, Z_4, Z_5)$$

- ▶ Modèle linéaire ajusté sur données réelles.

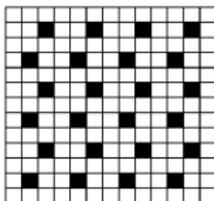
Performance des stratégies adaptatives

- **Modèle de distribution spatiale** : estimé sur cartes complètes (M_{i^*}).
- **Stratégies testées** : δ_{LSDP} , δ_{myope} , $\delta_{\text{Aléatoire}}$.
- **Contraintes** : temps d'échantillonnage ($B=2$ heures 30 minutes).
- **Score** : $QBR(\delta^{\text{best}}) - QBR(\delta)$, QBR= Nombre de quadrats bien reconstruits.

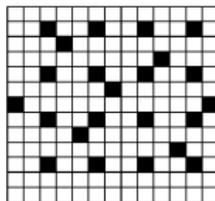


Performance des stratégies adaptatives

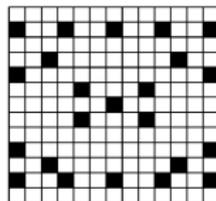
- ▶ **Modèle de distribution spatiale** : **Modèle "ad-hoc"**.
- ▶ **Stratégies testées** : δ_{LSDP} , δ_{myope} , $\delta_{\text{Aléatoire}}$ et 8 stratégies statiques.
- ▶ **Contraintes** : Nombre d'observations ($B=23$ ($\simeq 13.5\%$)).



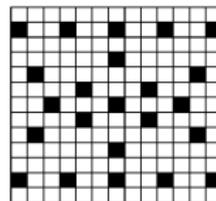
Reg1



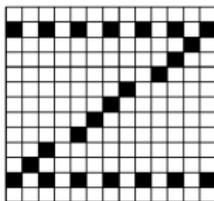
Reg2



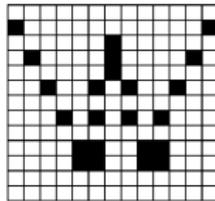
Reg3



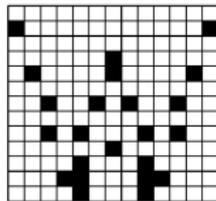
Reg4



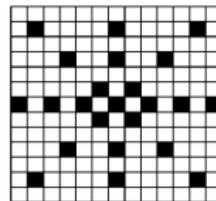
Z



W1



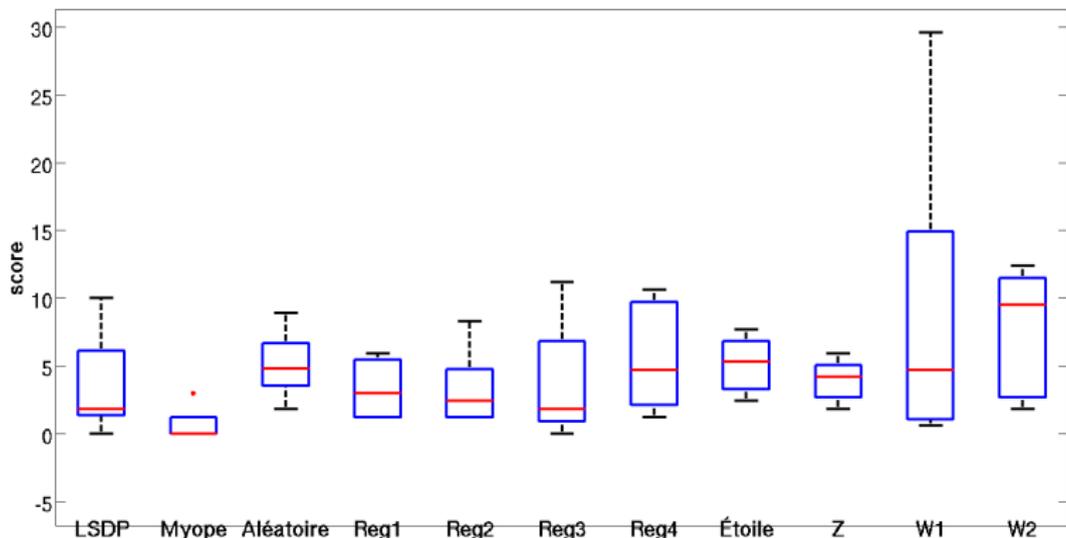
W2



Étoile

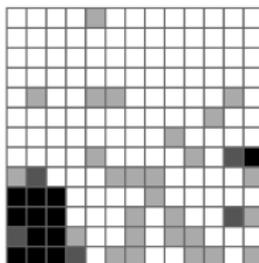
Performance des stratégies adaptatives

- ▶ **Modèle de distribution spatiale** : **Modèle "ad-hoc"**.
- ▶ **Stratégies testées** : δ_{LSDP} , δ_{myope} , $\delta_{\text{Aléatoire}}$ et 8 stratégies statiques.
- ▶ **Contraintes** : Nombre d'observations ($B=23$ observations ($\simeq 13.5\%$)).
- ▶ **Score** : $QBR(\delta^{\text{best}}) - QBR(\delta)$, QBR= Nombre de quadrats bien reconstruits.

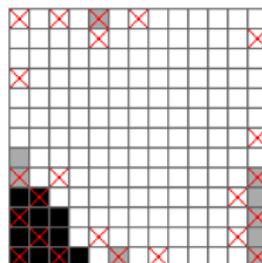


Performance des stratégies adaptatives

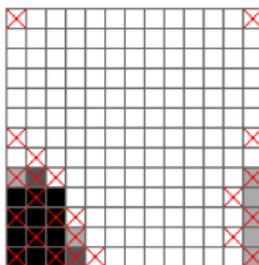
- **Modèle de distribution spatiale** : Modèle "ad-hoc".
- **Contraintes** : Nombre d'observations ($B=23$ ($\simeq 13.5\%$)).



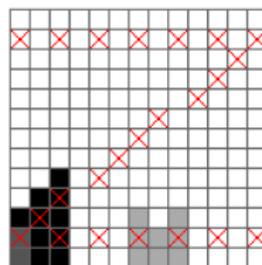
Vraie carte



LSDP



Myope



Z

□ 0 □ 1 □ 2 □ 3

Conclusions partielles

- ▶ Objectif finalisé : *Conception de stratégies d'échantillonnage adaptatives d'une espèce adventice au sein d'une parcelle cultivée.*
 - ▶ Conception de stratégies d'échantillonnage adaptatives exploitables sur le terrain.
 - ▶ Amélioration des stratégies classiques d'échantillonnage d'une espèce adventice.

Conclusions

- ▶ Apprentissage par renforcement \Rightarrow Conception de stratégies d'échantillonnage non myope (LSDP)
- ▶ Difficultés :
 - ▶ Nécessite un calcul rapide des probabilités de transition et des espérances.
 - ▶ Simulation rapide des trajectoires du PDM.

Perspectives

- ▶ D'autres utilisations de LSDP :
 - ▶ Échantillonnage de processus structurés (Markov logic networks, réseaux sociaux. . .).
 - ▶ Résolution générique d'un PDM à horizon fini.

- ▶ Utilisation de variables multidimensionnelles :
 - ▶ Adventices : Échantillonnage multi-espèces (modélisation des interactions entre espèces ?).

Remerciements

- ▶ À tous les membres du jury :
 - ▶ Liliane BEL, Vincent BRETAGNOLLE, Emmanuelle CAM, Pierre DRUIHLET, Bruno ZANUTTINI.

- ▶ À mes encadrants :
 - ▶ Sabrina GABA, Nathalie PEYRARD, Régis SABBADIN.

- ▶ Aux membres de mon comité de thèse :
 - ▶ Denis ALLARD, Jean-Noël AUBERTOT, Alain DUTECH, Florence FORBES, Nicolas MUNIER-JOLAIN.

- ▶ Au laboratoire BIA et à l'UMR agroécologie.

- ▶ Un merci spécial :
 - ▶ Alain DUTECH, Bruno SCHERRER, Olivier BUFFET (LORIA).
 - ▶ Dominique MEUNIER, Fabrice DESSAINT, Émilie CADET (UMR agroécologie).