

Inférence de réseaux écologiques par réseau bayésien dynamique

Étienne Auclair

INRA - Unité MIAT

July 3, 2015

Formation


Formation

- DUT **S**tatistique et **I**nformatique **D**écisionnelle - Carcassonne
- L3 **É**conomie et **I**nformatique - TSE
- Université Lyon 2 Lumière - Département Informatique et Statistique
 - Master **E**xtraction des **C**onnaissances à partir des **D**onnées

Contexte biologique et objectif

Contexte

- Gestion de la biodiversité dans un réseau écologique
- Difficulté : les interactions sont mal connues
- Influence de la protection



Objectif

Apprendre la structure d'un réseau écologique à partir de données de présence/absence temporelles

Données

Données réelles disponibles

- Fournies par Jennifer Caselle et Laura Dee (Univ. of California, Santa Barbara)
- Observation d'espèces marines dans des forêts de kelp au large de la Californie
- 164 espèces d'un réseau connu observées pendant 14 ans dans 4 zones différentes




Réseaux bayésiens

Réseau bayésien

- Dépendances entre variables : Graphe orienté sans circuit (DAG)
- Description quantitative des dépendances : Tables de probabilité conditionnelles (Paramètres du modèle)

Réseau bayésien dynamique

- Mesure un phénomène récurrent (ex : temporel)
- Extension d'une chaîne de markov : l'état des espèces à un temps t ne dépend que de son état à $t - 1$
- Processus stationnaire : les probabilités de transitions ne changent pas au cours du temps



Apprentissage de structure de réseau bayésien


Apprentissage par score

- Calcul de score à partir des paramètres du modèle (ex : BIC)
- Algorithme glouton
 - Étape 1 : Estimation des paramètres à graphe G connu
 - Étape 2 : Recherche d'un graphe améliorant G selon le critère BIC
 - Retour à l'étape 1 jusqu'à convergence

Modèle


Modélisation de réseau écologique

- Graphe orienté
- Arcs labellisés selon l'interaction :
 - p : proie
 - f : facilitateur
 - - : influence négative



Modélisation des dynamiques des espèces

- Modélisation par réseau bayésien dynamique



Spécificité du stage

Modèle paramétré

- Pas de table de probabilité conditionnelles
 - Probabilité de survie différente de la probabilité de recolonisation
 - Un paramètre par type de relation
 - Probabilité différente selon l'état de protection
- Que deviennent les formules du maximum de vraisemblance ?

Arcs labellisés

- Comment apprendre les labels des arcs ?

Notations

Données

- $X_t^i \in \{1, 0\}$ présence ou absence de l'espèce i ($i \in \{1, \dots, n\}$) au temps t ($t \in \{1, \dots, T\}$).
- $A^t \in \{1, 0\}$ protection ou absence de protection de la zone d'observation au temps t .
- N_i^{int} nombre de parents de type *int* de l'espèce i présents au temps t .

Paramètres

- Probabilité de recolonisation ε .
- Probabilités de réussite de chaque type d'influence ρ^p, ρ^f, ρ^- .
- Paramètre pénalisant l'absence de protection d'une zone : μ .

Probabilités

Recolonisation

Espèce absente au temps $t - 1$: probabilité de recolonisation au temps t

- $P(X_i^t = 1 | X_i^{t-1} = 0, A^{t-1} = 1) = \varepsilon$
- $P(X_i^t = 1 | X_i^{t-1} = 0, A^{t-1} = 0) = \mu\varepsilon$

Survie

Espèce présente au temps $t - 1$: probabilité de survie au temps t

- $P(X_i^t = 1 | X_i^{t-1} = 1, A^{t-1} = 1) =$
 $\left(1 - (1 - \rho^p)^{N_i^t}\right) \left(1 - (1 - \rho^f)^{N_i^t}\right) (1 - \rho^-)^{\bar{N}_i^t}$
- $P(X_i^t = 1 | X_i^{t-1} = 1, A^{t-1} = 0) =$
 $\mu \left(1 - (1 - \rho^p)^{N_i^t}\right) \left(1 - (1 - \rho^f)^{N_i^t}\right) (1 - \rho^-)^{\bar{N}_i^t}$

Déroulement du stage

Estimation des paramètres

- *Écriture de la vraisemblance et de son gradient*
- *Implémentation des formules de la vraisemblance et du gradient*
- **Recherche du maximum de vraisemblance**

Apprentissage de la structure

- Amélioration de la structure du graphe
- Algorithme itératif : alterner estimation et amélioration

Validation

- *Implémentation d'un simulateur du modèle*
- **Validation sur données simulées**
- Validation sur données réelles

Gradient

$$\frac{\partial}{\partial \varepsilon} = \left(\#_{0 \rightarrow 1}^{a=1} + \#_{0 \rightarrow 1}^{a=0} \right) \frac{1}{\varepsilon} - \left(\#_{0 \rightarrow 0}^{a=1} \right) \frac{1}{1 - \varepsilon} - \left(\#_{0 \rightarrow 0}^{a=0} \right) \frac{\mu}{1 - \mu \varepsilon}$$

$$\frac{\partial}{\partial \rho^P} = \sum_{\substack{m, n, p \\ \text{tq } 0 < m+n+p \leq K}} \frac{m x^{m-1} (\alpha(m, n, p) + \beta(m, n, p))}{1 - x^m} - \gamma(m, n, p) \frac{m x^{m-1} (1 - y^n) z^p}{1 - (1 - x^m)(1 - y^n) z^p} - \delta(m, n, p) \frac{\mu m x^{m-1} (1 - y^n) z^p}{1 - \mu (1 - x^m)(1 - y^n) z^p}$$


$$\frac{\partial}{\partial \rho^f} = \sum_{\substack{m, n, p \\ \text{tq } 0 < m+n+p \leq K}} \frac{n y^{n-1} (\alpha(m, n, p) + \beta(m, n, p))}{1 - y^n} - \gamma(m, n, p) \frac{(1 - x^m) n y^{n-1} z^p}{1 - (1 - x^m)(1 - y^n) z^p} - \delta(m, n, p) \frac{\mu (1 - x^m) n y^{n-1} z^p}{1 - \mu (1 - x^m)(1 - y^n) z^p}$$

$$\frac{\partial}{\partial \rho^P} = \sum_{\substack{m, n, p \\ \text{tq } 0 < m+n+p \leq K}} - \frac{p (\alpha(m, n, p) + \beta(m, n, p))}{z} + \gamma(m, n, p) \frac{(1 - x^m)(1 - y^n) p z^{p-1}}{1 - (1 - x^m)(1 - y^n) z^p} + \delta(m, n, p) \frac{\mu (1 - x^m)(1 - y^n) p z^{p-1}}{1 - \mu (1 - x^m)(1 - y^n) z^p}$$


$$\frac{\partial}{\partial \mu} = \left(\#_{0 \rightarrow 1}^{a=0} + \sum_{\substack{m, n, p \\ \text{tq } 0 < m+n+p \leq K}} \beta(m, n, p) \right) \frac{1}{\mu} - \left(\#_{0 \rightarrow 0}^{a=0} \right) \frac{\varepsilon}{1 - \mu \varepsilon} - \sum_{\substack{m, n, p \\ \text{tq } 0 < m+n+p \leq K}} \delta(m, n, p) \frac{(1 - x^m)(1 - y^n) z^p}{1 - \mu (1 - x^m)(1 - y^n) z^p}$$

Simulation

Graphe



Données simulées



Conclusion

Pour les écologues

- Amélioration de la connaissance des interactions biologiques
- Mesure de l'impact de la protection

Poursuite

- Gestion de la biodiversité lorsque les interactions sont mal connues
- Comment combiner gestion et apprentissage ?