

# Deux extensions du cadre HSMM : cas de plusieurs chaînes cachées factorisées et cas où la dynamique de la chaîne cachée dépend des observations

Nathalie Peyrard<sup>1</sup>, avec les collègues du projet ANR HSMM-INCA

<sup>1</sup>MIAT INRAE Toulouse

RMR 2024 - Rouen



On se place dans le cas temps discret et variables discrètes.

$(Z_t)_{\{t=1,2,\dots\}}$  est un modèle markovien si

$$\mathbb{P}(Z_t | Z_{t-1}, Z_{t-2}, \dots, Z_1) = \mathbb{P}(Z_t | Z_{t-1})$$

- Le modèle est défini par les probabilités de transition

$$R(i, j) = \mathbb{P}(Z_t = j | Z_{t-1} = i)$$

- Propriété : la durée de séjour dans un état suit une distribution géométrique

## Modèle semi-markovien

C'est le couple (état, durée) =  $(J_n, X_{n+1})$  qui est markovien




Figure: A sample path of a discrete time semi-Markov process

$$p_{(i,d),(i',d')} = \mathbb{P}(X_{n+1} = d', J_n = i' \mid X_n = d, J_{n-1} = i)$$

- Extension du modèle markovien à une distribution quelconque de la durée de séjour  $X_n$ .

Figure issue de V. S. Barbu et N. Limnios, *Semi-Markov Chains and Hidden Semi-Markov Models toward Applications*, Springer, 2008

## Exemple : modèle semi-markovien 'Explicit Duration HMM'




Figure: A sample path of a discrete time semi-Markov process

$$\begin{aligned} p_{(i,d),(i',d')} &= \mathbb{P}(X_{n+1} = d', J_n = i' \mid X_n = d, J_{n-1} = i) \\ &= \mathbb{P}(J_n = i' \mid J_{n-1} = i) \mathbb{P}(X_{n+1} = d' \mid J_n = i') \end{aligned}$$

avec  $P(X_{n+1} = d' \mid J_n = i')$  probabilité d'une **durée de séjour** égale à  $d'$  sachant qu'on est dans l'état  $i'$

# Modèle semi-markovien caché (HSMM)

## Le modèle


- l'état caché est un modèle de semi-Markov
- à chaque pas de temps on observe  $Y_t$
- cas le plus classique  $Y_t$  : ne dépend que de  $Z_t$  (comme en HMM)

## Estimation des lois du modèle

- classiquement : EM
- à l'étape E : un algorithme de forward-backward un peu plus tricky que pour un HMM
- à l'étape M : formules explicites dans le cas non paramétrique

## Deux extensions des HSMM

**Cas de plusieurs chaînes cachées qui émettent conjointement l'observation**



**Cas où l'observation influence l'état caché**



# Algorithme VBEM pour l'estimation d'un modèle HSMM multichaine factoriel, application à l'inférence de chemin migratoire des oiseaux


En collaboration avec

- Ronan Trépos, Régis Sabbadin, MIAT INRAE Toulouse
- Sam Nicol, CSIRO Brisbane

# Motivation : inférence de chemins migratoires à partir de données ebird

## Questions

- Quels sont les chemins utilisés préférentiellement par les oiseaux?
- Où faut-il acquérir plus de données pour améliorer l'inférence du réseau migratoire?




**Idéalement** : des séries temporelles de comptages à chaque site

**En pratique** : abondance relative hebdomadaire au niveau des pixels d'une grille (post-traitement ebird)

- données à agréger à l'échelle d'un site
- information imparfaite sur les comptages

# BIRDNET, un modèle de type Factorial HSMM: (1) la structure



8

## BIRDNET, un modèle de type Factorial HSMM: (2) les lois


- $n$  oiseaux/chaînes cachées;  $I$  sites
- Chaîne cachée
  - durée de séjour au site  $i$  : loi Poisson de paramètre  $\lambda_i$
  - Proba du nouvel état : loi catégorielle,  $(R(i, i + 1), R(i, i + 2), \dots, R(i, I))$
- Emission commune
  - $N_i^t$  : nombre d'oiseaux au site  $i$  à la date  $t$
  - $O_i^t$  : abondance relative au site  $i$  à la date  $t$
  - $O_i^t = \alpha_i N_i^t$
  - $P(O_i^t | N_i^t)$  : loi log-normale, i.e.  $\ln(\alpha_i)$  suit une loi normale de paramètres  $(\mu_i, \sigma_i)$

# BIRDNET, un modèle de type Factorial HSMM: (2) les lois

## Modèle bayésien

- $n$  oiseaux/chaînes cachées;  $I$  sites
- Chaîne cachée : SMM
  - ▶ durée de séjour au site  $i$  : loi Poisson de paramètre  $\lambda_i$ , prior Gamma
  - ▶ proba du nouvel état : loi catégorielle,  $(R(i, i + 1), R(i, i + 2), \dots, R(i, I))$ , prior Dirichlet
- Emission commune
  - ▶  $N_i^t$  : nombre d'oiseaux au site  $i$  à la date  $t$
  - ▶  $O_i^t$  : abondance relative au site  $i$  à la date  $t$
  - ▶  $O_i^t = \alpha_i N_i^t$
  - ▶  $P(O_i^t | N_i^t)$  : loi log-normale, i.e.  $\ln(\alpha_i)$  suit une loi normale de paramètres  $(\mu_i, \sigma_i)$ , prior Gaussienne sur  $\mu_i$  ( $\sigma_i$  pas estimé)

## Remarque sur la structure de dépendance



8

- Les chaînes cachées sont indépendantes
- MAIS elles ne le sont plus conditionnellement aux observations : inférence difficile

## Premières solutions mises en oeuvre pour l'inférence

- développement d'un algorithme MCEM et d'un ABC
- de bons résultats sur données simulées, et des résultats cohérents sur données ebird
- mais recherche d'une méthode plus rapide.

*S. Nicol, M.-J. Cros, N. Peyrard, R. Sabbadin, R. Trépos, R. A. Fuller, B. K. Woodworth. FlywayNet: A hidden semi-Markov model for inferring the structure of migratory bird networks from count data, Methods in Ecology and Evolution, 2022*

# Principe de l'algorithme VBEM (1)

## Une méthode déterministe pour faire de l'inférence approchée d'un modèle bayésien

- Le problème à résoudre
  - soit  $y$  observation,  $x$  variable cachée,  $\theta$  paramètre du modèle
  - trouver  $p(\theta | y)$  et  $p(x | y)$  qui maximisent  $p(y)$ .
- L'approche VBEM (Beal, 2003)
  - maximiser une borne inf de  $\ln p(y)$  parmi le sous-ensemble des distributions contraintes  $q$  telles que  $q(x, \theta) = q(x)q(\theta)$

*M.J. Beal, Variational algorithms for approximate Bayesian inference, Ph.D. Dissertation, UCL, 2003*

## Principe de l'algorithme VBEM (2)

Une borne inférieure de la vraisemblance :

$$\ln p(y) = \ln \int d\theta \, dx \, q(x, \theta) \frac{p(x, y, \theta)}{q(x, \theta)} \geq \int d\theta \, dx \, q(x, \theta) \ln \frac{p(x, y, \theta)}{q(x, \theta)}.$$

On note :

$$\mathcal{F}(q(x), q(\theta)) := \int d\theta \, dx \, q(x)q(\theta) \ln \frac{p(x, y, \theta)}{q(x)q(\theta)}.$$

Maximiser  $\mathcal{F}$  revient à minimiser une divergence de Kullbac-Leibler :

$$\mathcal{F}(q(x), q(\theta)) = \ln p(y) - KL(q(x)q(\theta) | p(x, \theta | y))$$

## Principe de l'algorithme VBEM (3)

VBEM : algorithme itératif qui maximise de manière alternée  $\mathcal{F}(q(x), q(\theta))$  selon  $q(x)$  et  $q(\theta)$

- **VBE step**: calculer

$$q(x | y) \propto e^{E_{\theta}^q[\ln p(x, y | \theta)]}$$

avec  $E_{\theta}^q$  l'espérance pour la valeur courante de  $q(\theta | y)$ .

- **VBM step**: calculer

$$q(\theta | y) \propto p(\theta) e^{E_x^q[\ln p(x, y | \theta)]}$$

avec  $p(\theta)$  la prior sur  $\theta$  et  $E_x^q$  l'espérance pour la valeur courante de  $q(x | y)$ .

### VBEM step :

- les mises à jour sont simples car on a choisi des lois conjuguées
- cela demande de savoir calculer

$$A(i, t) = q(\text{bird is in patch } i \text{ at time } t \mid O)$$

$$B(i) = E_{\pi}[\text{sojourn time of bird at } i \mid O]$$

$$C(i) = q(\text{bird stays at } i \mid O)$$

$$D(i, j) = q(\text{bird stays consecutively at site } i \text{ then } j \mid O)$$

## Etape VBE







- Hypothèse supplémentaire 'mean field'
  - ici  $x$  est l'ensemble des  $n$  chaînes des  $n$  oiseaux : ça reste trop complexe.
  - on suppose l'indépendance  $q(x) = \prod_{s=1}^n q(x_s)$ .
- la solution de la maximisation,  $q(x)$ , est alors un HSMM mono-chaine
  - on récupère tous les outils des HSMM (Fwd-Bwd) pour le calcul des quantités d'intérêt  $A, B, C$  et  $D$ .

## Quelques calibres nécessaires

- problèmes d'underflow dans le Forward-Backward: réécriture des formules de récursion basée sur les lois a posteriori (Yu 2016) et passage au log
- résolution de l'équation du point fixe à l'étape VBE : une itération, plusieurs, combien?
- durées de séjour moyennes : si trop faibles, pas assez d'observations

*Shun-Zheng Yu. Hidden Semi-Markov Models Theory, Algorithms and Applications. Elsevier, 2016*

## Exemple de résultat pour $l = 3$ sites




## V(B)EM versus ABC pour F-HMM

- V(B)EM
  - + des formules simples de mise à jour
  - + exécution rapide (pas de simulation)
    - implémentation pas si simple
    - approximation champ moyen trop grossière?
- ABC
  - + implémentation simple (paquet easyABC)
    - exécution longue
    - choix des statistiques

## Deux extensions des HSMM

Cas de plusieurs chaînes cachées qui émettent conjointement l'observation



Cas où l'observation influence l'état caché




# HSMM piloté par les observations pour l'estimation de la dynamique des adventices

Dans le cadre de la thèse d'Hanna Bacave, MIAT INRAE Toulouse  
Co-encadrement avec Nikolaos Limnios, UTC Compiègne, et Pierre-Olivier Cheptou, CEFE Montpellier

# Motivation : modélisation de la dynamique d'une population d'adventices dans une parcelle


## Question

Comment estimer les paramètres clés de la dynamique d'une espèce adventice à partir d'observation de flore levée uniquement?



- Adventices : plantes avec dormance
- Banque de graines dans le sol : non visible
- Dynamique : germination, grenaison, colonisation, dormance

## Travaux précédents : modélisation par un HMM 'Observation Driven'



Pas de difficulté de mise en œuvre

- la probabilité de transition dépend aussi de l'observation précédente
- estimation par EM : en adaptant les formules de l'algorithme du Forward-Backward

*M. Pluntz, S. Le Coz, N. Peyrard, R. Pradel, R. Choquet, P.-O. Cheptou. A general method for estimating seed dormancy and colonization in annual plants from the observation of existing flora, Ecology Letters 21(7), 2018*

## Rappel du modèle Explicit Duration HMM

$$\begin{aligned} p_{(i,d),(j,d')} &= \mathbb{P}(X_{n+1} = d', J_n = j \mid X_n = d, J_{n-1} = i) \\ &= \mathbb{P}(J_n = j \mid J_{n-1} = i) \mathbb{P}(X_{n+1} = d' \mid J_n = j) \end{aligned}$$

avec  $P(X_{n+1} = d' \mid J_n = j)$  probabilité d'une durée de séjour égale à  $d'$  sachant qu'on est dans l'état  $j$

## Deux extensions possibles

- soit l'influence ne joue qu'au moment des changements d'état mais pas sur la durée de séjour :  $\mathbb{P}(J_n = j \mid J_{n-1} = i, Y_{S(n)-1}) \rightarrow$  facile à modéliser mais pas réaliste
- soit elle joue aussi sur la durée de séjour : on ne peut plus fixer à l'entrée dans l'état la durée de séjour

## Solution proposée : se ramener à un HMM

### Autre façon de modéliser un HSMM


On considère les variables suivantes :

- $Z = (Z_t)_{t \in \mathbb{N}}$  la chaîne de semi-Markov cachée, **indexée sur le temps**
- $U = (U_t)_{t \in \mathbb{N}}$  le temps écoulé depuis l'entrée dans l'état courant de  $Z$ , lui aussi caché
- $Y = (Y_t)_{t \in \mathbb{N}}$  le processus observé

Le triplet  $(Z, U, Y) = (Z_t, U_t, Y_t)_{t \in \mathbb{N}}$  est une **chaîne de Markov cachée**

On étend cette modélisation au cas où l'observation influence les états cachés  
→ modèle OD-HSMM

## Structure de dépendance et lois définissant le OD-HSMM



- Loi initiale :

$$\pi(z_0, u_0) = \mathbb{P}(Z_0 = z_0, U_0 = u_0).$$

- Loi d'émission :

$$R(z_t, y_t) = \mathbb{P}(Y_t = y_t | Z_t = z_t),$$

- Loi de transition :

$$P_{y_{t-1}}((z_{t-1}, u_{t-1}), (z_t, u_t)) = \mathbb{P}(Z_t = z_t, U_t = u_t | Z_{t-1} = z_{t-1}, U_{t-1} = u_{t-1}, Y_{t-1} = y_{t-1})$$



## Principe (méthode par rejet)

Répéter un grand nombre de fois

- 1 générer  $\theta^c$  selon une prior  $P(\theta^c)$
- 2 générer  $(Y_{0:M}^c, Z_{0:M}^c, U_{0:M}^c)$
- 3 calculer des statistiques à partir de  $Y_{0:M}^c : S^c = (S_1^c, S_2^c, \dots)$
- 4 si  $Dist(S^c, S(Y_{0:M})) < \epsilon$  on accepte  $\theta^c$

## Les statistiques de base sur les données observées

- 1 nombre de 1
- 2 nombre de transitions de 0 vers 1
- 3 informations sur les longueurs de 0 et de 1 consécutifs (minimum, maximum, moyenne, quantile à 25%, médiane, quantile à 75%)
- 4 mode et valeur du mode dans les longueurs de 0 et de 1 consécutifs



## Plusieurs groupes de statistiques testés

- Groupe 1 : statistiques 1, 2 et 3
- Groupe 2 : statistiques 1, 2 et 4
- Groupe 3 : toutes les statistiques



### Protocole (répété 30 fois)

- tous les paramètres égaux à 0.5,
- simulation des données  $(Z_{0:M}^*, Y_{0:M}^*)$  pour  $M = 500$
- pour chaque groupe de statistique, estimation avec paquet easyABC avec méthode basée sur du SMC de Lenormand et al (2012)


*Lenormand, M., Jabot, F. & Deffuant, G. (2012) Adaptive approximate Bayesian computation for complex models.*



Estimation des paramètres  $c$  de colonisation et  $d$  de grenaison




Estimation des paramètres  $g$  de germination et  $s_0$  impliqué dans la survie  $s_0 e^{-\lambda(u_{n-1}-1)}$




Estimation du paramètre  $\lambda$  impliqué dans la survie  $s_0 e^{-\lambda(u_{n-1}-1)}$

# Influence de $g$ ?



$g = 0.5$



$g = 1$

Estimation du paramètre  $\lambda$  impliqué dans la survie  $s_0 e^{-\lambda(u_{n-1}-1)}$

## OD-HSMM pour dynamique adventice

- Pas vraiment de groupe de statistiques qui se détache
- Très bonne estimation de chaque paramètre sauf  $\lambda$  : quelle statistique pour mieux capter son rôle?
- La suite : exploration d'une approche alternative, avec EM

## Intérêt de l'approche au delà du OD-HSMM

- Modélisation de l'influence de l'observation sur l'état caché : le même problème se pose pour
  - l'influence de covariables sur l'état caché
  - l'influence de l'état caché d'une autre chaîne cachée, en contexte spatio-temporel

- **Aspects computationnels.** 'il n'y a plus qu'à faire tourner un (V)(B)EM' : ce n'est pas si trivial que ça!
- **Communauté HSMM** : deux visions
  - Les informaticiens.  
S.-Z. Yu. Hidden Semi-Markov Models Theory, Algorithms and Applications. Elsevier, 2016
  - Les statisticiens.  
V. S. Barbu et N. Limnios, Semi-Markov Chains and Hidden Semi-Markov Models toward Applications, Springer, 2008

Des travaux qui se complètent mais pas exactement le même formalisme HSMM  
→ pas toujours facile de faire les ponts, on y travaille!



## Principe

- étape E, on calcule  $Q(\theta|\theta^{(m)}) = \mathbb{E}_{\theta^{(m)}} [\ln \mathbb{P}_{\theta}(Y_{0:M}, Z_{0:M}, U_{0:M}) | Y_{0:M} = y_{0:M}]$
- étape M, on maximise  $Q(\theta|\theta^{(m)})$  pour mettre à jour les paramètres

## Difficultés

- étape E : repose sur un forward-backward couteux en temps et espace
- étape M : non explicite -> optim num et la vraisemblance complète était plate (testé dans le cas SEM).

## Une solution? (en cours)

- étape E : forward-backward
- étape M : mise à jour en mode 'non paramétrique', avec formules explicites
- à convergence : les probabilités estimées s'expriment en fonction des paramètres -> on identifie les paramètres par moindres carrés.