

# Estimateur de pseudo-vraisemblance pour les champs markoviens. Application dans le cas du PC.


Besnik PUMO

INH - UMR SAGAH - ANGERS

23 novembre 2006

## Modélisation de la distribution de *Zanthoxylum clava-herculis* : données binaires sur 180 espèces dans l'état de Californie (données recueillies Crumpacker)


On étudie le lien entre  $z_s = 0/1$  (abs./prés.) d'une espèce en fonction de 9 variables climatiques ( $\mathbf{x}$ ).




Wu & Huffer (1997) : Le modèle  $P(z_s = 1) = \frac{\exp(\eta_s)}{1 + \exp(\eta_s)}$  où  $\eta_s = \beta_0 + \mathbf{x}_s \beta_1$  est insuffisant et montre la nécessité de l'introduction de l'information spatiale.

## Processus de Contact (PC)

Image instant 49



Proportion de sites occupés



- Un premier exemple
- Un deuxième exemple (simulations)
- Plan de l'exposé

## 1 La technique de pseudo-vraisemblance

- Les auto-modèles
- Théorème de Hammersley-Clifford
- Auto-modèles binaires et Gaussien
- Les estimateurs de EPVC et EPVC associé au codage  $K$

## 2 Consistence, TCL et Tests

- Consistence
- TCL et Tests

## 3 Cas des Processus de Contact à temps discret

- Les PC à temps discret
- La PVC pour le PC
- Résultats asymptotiques et tests

## 4 Comparaison des estimateurs

- Exemple 1 - Régression auto-logistique
- Exemple 2 - Processus de Contact

## Notations

- $\mathbf{Z} = \{Z_s, s \in S\}$  : le vecteur de  $\mathbb{H}(S)$  v.a. dépendantes associé aux sites du réseau  $S$  - les observations  $\mathbf{z} = \{z_s, s \in S\}$

$$\mathbf{Z}_A := \{Z_s, s \in A\} \text{ pour } A \subset S$$

Pour un processus spatio-temporel,  $\mathbf{Z}(t)$  : la configuration à l'instant  $t$

- $\partial_s \subset S$  : le **voisinage** de  $s$ ;  $\partial_A$  : voisinage de  $A \subset S$

Un modèle spatial (possible) sur réseau peut être défini à partir de  $S$ , d'un système de voisinage  $\{N_s, s \in S\}$  associé et d'une famille de distributions conditionnelles appropriées - **Th. Hammersley-Clifford**

## Théorème de Hammersley-Clifford

Besag (1974) : Soit  $Q(\mathbf{z}) = \log\{P(\mathbf{z})/P(\mathbf{0})\}$ . Alors  $P(\mathbf{z}) = \frac{\exp(Q(\mathbf{z}))}{\sum_{\mathbf{z}} \exp(Q(\mathbf{z}))}$ . Le modèle est bien défini dans  $S$  si :

$$Q(\mathbf{z}) = \sum_s z_s G_i(z_s) + \sum_{s,s'} \sum_{\text{voisins}} z_s z_{s'} G_{s,s'}(z_s, z_{s'}) \\ + \sum_{s,s',s''} \sum_{\text{voisins}} z_s z_{s'} z_{s''} G_{s,s',s''}(z_s, z_{s'}, z_{s''}) + \dots$$

$$\Rightarrow \frac{P(Z_s=z_s | \mathbf{z}_{S \setminus s})}{P(Z_s=0 | \mathbf{z}_{S \setminus s})} = \exp\{Q(\mathbf{z}) - Q(\mathbf{z}_{z_s=0})\}$$

Les auto-modèles - famille des distributions exponentielles (au plus deux sites sont voisins)

$$Q(\mathbf{x}) = \sum_s z_s G_s(z_s) + \sum_{s,s'} \sum_{\text{voisins}} \beta_{s,s'} z_s z_{s'}$$

$$\text{Modèle binaire : } \Rightarrow P(z_s | z_{S \setminus s}) = \frac{\exp\{z_s(\alpha_s + \sum_{s' \in \partial_s} \beta_{s,s'} z_{s'})\}}{1 + \exp\{\alpha_s + \sum_{s' \in \partial_s} \beta_{s,s'} z_{s'}\}}$$

$$\Downarrow$$

$$P(\mathbf{z}) = \frac{\exp\{\sum_s z_s(\alpha_s + \sum_{s' \in \partial_s} \beta_{s,s'} z_{s'})\}}{\sum_{z \in \{0,1\}^{\#S}} \exp\{\sum_s z_s(\alpha_s + \sum_{s' \in \partial_s} \beta_{s,s'} z_{s'})\}}$$

$$\text{Modèle gaussien : } Z_s | z_{S \setminus s} \sim G(\mu_s + \sum_{s' \in \partial_s} \beta_{s,s'}(z_{s'} - \mu_{s'}), \sigma^2)$$

$$\Downarrow$$

$$P(\mathbf{z}) = (2\pi\sigma^2)^{-n/2} |B|^{1/2} \exp\left\{-\frac{1}{2\sigma^2} (\mathbf{z} - \boldsymbol{\mu})' B (\mathbf{z} - \boldsymbol{\mu})\right\}$$

$$B > 0 : \text{diag}(B) = 1, B_{s,s'} = B_{s',s} = -\beta_{s,s'} !!!$$

La  $PVC_S(\theta)$ , noté aussi  $PVC(\theta)$  est :


$$PVC_S(\theta) = \prod_{s \in S^o} P(z_s | z_{\partial_s}; \theta)$$

et l'estimateur de PVC ou EPMC :

$$\hat{\theta} = \arg \max_{\theta} PVC(\theta)$$

Un sous-ensemble  $K \subset S$  de sites est un codage si les sites de  $K$  sont indépendants conditionnellement à  $\mathbf{z}_{S \setminus K}$  ; l'EPVC associé à  $K$  est

$$\hat{\theta}_K = \arg \max_{\theta} PVC_K(\theta)$$



De nombreux résultats existent sur la consistance des EPVC (Guyon 1995, chapitre 5) - On suppose  $\#(S(n)) \rightarrow \infty$  : Le "contraste" de PVC est :

$$U(n; \theta) = -\frac{1}{\#(S(n))} \sum_{s \in S^o(n)} \log(P(z_s | z_{\partial_s}; \theta))$$

- $Z$  est un champ appartenant à la famille exponentielle ( $\phi$ ), stationnaire et ergodique - Les estimateurs par Codage et PVC sont consistents (p.s.) sous certaines conditions de régularité de  $\phi$ ,  $S(n)$  et  $U(n)$  (Guyon 1995, §5.2.1).
- Théorème sur les estimateurs de minimum de contraste (**Théorème 3.4.1**, Guyon 1995); voir aussi Comets (1992; Th. 2.1 et 3.1)

- $Z$  est un champ appartenant à la famille exponentielle ( $\phi$ ), stationnaire et ergodique - Les estimateurs par Codage et PVC vérifient le TCL sous certaines conditions de régularité de  $\phi$ ,  $S(n)$  et  $U(n)$ .
- TCL pour les estimateurs de minimum de contraste (**Théorème 3.4.5**, Guyon 1995); voir aussi Comets et Janžura (1998; Th. 4.1)
- Test des différences des contrastes pour les paramètres (**Théorème 3.4.6**, Guyon 1995)

## PC : Harris (1974)

- Un modèle spatio-temporel à valeurs binaires

$$(\mathbf{Z}(t), t \geq 0), Z_s(t) \in \{0, 1\}$$

- ▶  $Z_s(t) = 1$  (0) : présence (absence) d'un plant au site  $s$  à l'instant  $t$ ,
- ▶  $\mathbf{Z}(t)$  : configuration du processus à l'instant  $t$

- PC à temps continu ou à **temps discret**


## Définition

- $\partial_0$  le voisinage de 0 ;  $\partial_s = s + \partial_0$  le voisinage de  $s$
  - La probabilité de transition  $P(z_s(t+1)|z(t))$  est invariante dans l'espace-temps
- Règles de l'évolution (de  $t$  à  $t+1$  - synchrone) :
- a. Chaque plant disparaît avec une probabilité  $\gamma$ ,
  - b. Un plant en vie produit un nouveau plant dans  $s' \in \partial_s$  avec probabilité  $f(s' - s)$ ,
  - c. Au plus un plant survit en  $s$ .


Tous les événements sont indépendants (dans l'espace-temps).

## Un PC simulé - voisinage 4 ppv


Image instant 49



Proportion de sites occupés



## PC super critique




Deux situations sont possibles :

- PC **supercritique** : le processus survit avec une **probabilité positive**
- PC **sous-critique** : le processus disparaît avec probabilité 1

Théorème (Convergence 2.7, 2.15 et 3.4 (Durrett, 1995))

- $\mathbf{Z}^\infty$  d'un PC supercritique ne dépend pas  $\mathbf{Z}(0)$  (conditionnellement à la survie)
- $\mathbf{Z}^\infty$  est ergodique (par rapport aux translations spatiales)
- $\mathbf{Z}(t) \Rightarrow P(\tau < \infty)\delta_0 + P(\tau = \infty)\mathbf{Z}^\infty$

- Le paramètre :  $\theta = (\gamma, \lambda_1, \dots, \lambda_p) \in (0, 1)^{p+1}$



$$p = 3$$

- Le logarithme de la PVC normalisée :  $n(T)$  : Nbre total de sites informatifs

$$\log PVC(T; \theta) = \frac{1}{n(T)} \sum_{t=0}^{T-1} \log \prod_{s \text{ informatif}} P(Z_s(t+1) | \mathbf{z}(t))$$


Condition (I) :  $n(T) \rightarrow \infty$  quand  $T \rightarrow \infty$ .

**Convergence et TCL** (Guyon & Pumo 2005, 2006). Sous **(I)**  $\hat{\theta}_T$  est consistant (p.s.) et asymptotiquement gaussien :


$$\sqrt{n(T)} [J_T(\theta_o)]^{-1/2} A_T(\theta_o) (\hat{\theta}_T - \theta_o) \xrightarrow{d} \mathbf{G}_{p+1}(0, I_{p+1}).$$

**Tests sur les paramètres.** Soit  $H_0$  définissant un PC d'ordre  $p - q \geq 1$ . Sous  $H_0$  et la condition **(I)** :  $2 \cdot \sqrt{n(T)} [-\ell_T(\hat{\alpha}_T) + \ell_T(\hat{\theta}_T)] \stackrel{d}{\sim} \sum_{i=1, (p-q)+1} v_{i,T} \chi_i^2(1)$

Voisinage d'ordre  $p = 3$




Voisinage sous  $H_0$  ( $p' = 2$ )




## Validation numérique des résultats asymptotiques

PC supercritique ( $\gamma = 0.35$ ,  $\lambda = 0.25$ ) sur un réseau périodique  $64 \times 64$



Le biais et écart-type pour  
 $T$  variant de 1 à 100



Histogrammes obtenus à partir de  
100 estimations

- Guyon et Kunsch (1992) ont comparé les estimateurs MV, PVC et par Codage pour le modèle de Ising - voir aussi Guyon 1995 (§5.3.4)
- Etude comparative par simulation - basée sur 500 simulations (Wu et Huffer, 1997)

Paramètres	Méthode	$\hat{\beta}_0$ ( $\hat{s}_{\beta_0}$ )	$\hat{\beta}_1$ ( $\hat{s}_{\beta_1}$ )	$\hat{\gamma}$ ( $\hat{s}_{\gamma}$ )
(-1, 2, 1)	COD	-0.98 (0.36)	2.04 (0.30)	1.00 (0.12)
	PVC	-0.96 (0.35)	2.04 (0.30)	0.99 (0.12)
	MCMC	-0.93 (0.32)	2.06 (0.28)	0.98 (0.10)

- Etude comparative sur l'exemple (Wu et Huffer, 1997) - Le modèle :

$$P(Z_s = z_s | \mathbf{z}_{S \setminus s}) = \frac{\exp(\eta_s)}{1 - \exp(\eta_s)} \text{ où } \eta_s = \beta_0 + \mathbf{x}'_s \boldsymbol{\beta}_1 + \gamma \sum_{s' \in \partial_s} z_{s'}$$

$$\mathbf{x}' = (TM, TMM, ELV)$$

TMM : Température minimale du mois le plus froid,

TM : Temp. Moyenne du mois le plus froid, ELV : Altitude

Méthode	$\beta_0 (\hat{\beta}_0)$	$TM (\approx \hat{\sigma}_{TM})$	$TMM (\approx \hat{\sigma}_{TMM})$	$ELV (\approx \hat{\sigma}_{ELV})$	$\gamma (\approx \hat{\sigma}_\gamma)$
COD	-7.76 (0.88)	-4.28 (1.01)	3.99 (1.03)	-0.88 (0.29)	4.53 (0.48)
PVC	-7.05 (0.75)	-3.80 (0.94)	3.58 (0.97)	-0.74 (0.26)	4.04 (0.39)
MCMC	-4.78 (0.26)	-1.64 (0.17)	1.53 (0.16)	-0.32 (0.04)	2.55 (0.14)

Comparaison des méthodes : Critère  $SAE = \sum_{i=1}^m |y_i - \hat{p}_i|$  et  $SSE = \sum_{i=1}^m (y_i - \hat{p}_i)^2$  :

Critère	COD	PVC	MCMC
SAE	758.58	707.19	568.36
SSE	699.48	665.07	429.93

- 1 MCMC plus performant que PVC et PVC plus performant que COD
- 2 quand  $\gamma$  important ceci est plus évident ; sinon MCMC et PVC assez proches
- 3 PVC ou COD exigent moins de calculs et peuvent servir de valeurs pour initier l'algorithme MCMC


Simulations :  $\gamma_0 = 0.35$ ,  $\lambda_0 = 0.25$

	$\gamma$	$\sigma_{\hat{\gamma}}$	$\lambda$	$\sigma_{\hat{\lambda}}$
PVC	0.3572	0.0079	0.2434	0.0064
K-codage	0.3456	0.0218	0.2361	0.0181

Estimations PVC et K-codage

Estimation ( $T = 4$ ) des paramètres et leurs écart-types

$\gamma_0$	$\hat{\gamma}_4$	$\hat{\sigma}_{\hat{\gamma}_4}$	$\lambda_0 = 0.2$ $\hat{\lambda}_4$	$\hat{\sigma}_{\hat{\lambda}_4}$	$n_4$
0.2	0.189	0.6	0.193	0.4	15286
0.4	0.399	0.008	0.188	0.005	13565
0.6	0.607	0.009	0.206	0.008	10452



- Besag J. (1974) Spatial Interaction and the Statistical Analysis of Lattice Systems, *JRSS B*, 36, 192-225.
- F. Comets (1992) On **consistency of a class of estimators** for exponential families of markov random fields on the lattice, *The Ann. of Stat.*, 20, 455-468.
- F. Comets, M. Janžura (1998) A **CLT for conditionally** centred random fields with an application to markov fields, *J. Appl. Prob.*, 35, 608-621.
- Durrett R., Levin S.A. (1994) Stochastic spatial models : a user's guide to ecological applications, *Phil. Trans. R. Soc. Lond.*, B 343, 329-350.
- Guyon X. (1995) *Random fields on a network : modelling, statistics and applications*, Springer, Berlin.
- Guyon X., Künsch H.R. (1992) Asymptotic comparison of estimators in the Ising model, *L.N.S.* 74, 177-198.
- Guyon X., Pumo B. (en révision) Space-time estimation of a particle system model, en révision pour *Statistics*.
- Jensen J.L., Künsch H.R.(1994) On asymptotic normality of pseudo-likelihood estimate for pairwise interaction processes, *Ann. Inst. Statist. Math.*, 46, 475-486.
- Pumo B. (2007) Parameter estimation of the CP of order  $d$ , accepté pour publication dans *Comm. in Statistics*.
- Wu H., Huffer F. (1997) Modelling the distribution of plant species using the autologistic regression model, *Enviromental and Ecological Statistics*, 4, 49-64.
- Voir aussi [Livre de Stan Z. Li](#)