

# TCL pour U-statistiques géométriques dans le chaos poissonien

GT Probas, MAP 5  
Université Paris Descartes

Raphaël Lachièze-Rey  
En collaboration avec Giovanni Peccati, Université de Luxembourg

15 novembre 2011



## Définitions

Dans cet exposé :

- $\mu$  : mesure loc. finie sur  $X$  loc. compact (sans atomes).
- $\eta$  : Processus ponctuel de Poisson d'intensité  $\mu$ .
- $\eta_\lambda$  : Processus ponctuel de Poisson d'intensité  $\lambda\mu$ ,  $\lambda > 0$ .
- $h(x_1, \dots, x_k)$  : Fonction symétrique  $X^k \mapsto \mathbb{R}$ .

[Reitzner, Schulte 2011] : **U-statistique de noyau**  $h$  :

$$F = F(\eta) = \sum_{x_1, \dots, x_k \in \eta, x_i \neq x_j} h(x_1, \dots, x_k).$$

**Comportement asymptotique de  $F_\lambda := F(\eta_\lambda)$ .**

**Question :**

$$\tilde{F}_\lambda = \frac{F_\lambda - \mathbb{E}F_\lambda}{\sqrt{\text{Var}(F_\lambda)}} \Rightarrow \mathcal{N}(0, 1)$$

quand  $\lambda \rightarrow \infty$  ?

## Exemples 1 : Graphes aléatoires ( $k=2$ )

**Règle** : On connecte  $x$  et  $y$  s'ils satisfont une certaine condition géométrique déterministe :

- **Unit disk graph** :  $d(x, y) \leq \alpha_\lambda$  pour une métrique  $d$  et  $\alpha_\lambda > 0$ .

**notation** :  $x \sim y$ .

$$F_\lambda = \sum_{x \neq y \in \eta_\lambda} \varphi(x, y) 1_{x \sim y}$$

- **Exemple** : Longueur totale des arêtes.

**Hypergraphes aléatoires** :  $k=2, 3, \dots$

- **Complexe de Vietoris-Rips** : On connecte  $(x_1, \dots, x_k)$  si  $\text{diam}(x_1, \dots, x_k) \leq \alpha_\lambda$ .
- **Exemple** : Aire totale des triangles ayant des sommets dans  $\eta_\lambda$ .

## Exemple 2 : Particules en interaction

On suppose que les points de  $\eta_\lambda$  interagissent  $k$  par  $k$  :

$$\lambda = \sum_{x_1, \dots, x_k \in \eta_\lambda, x_i \neq x_j} U(x_1, \dots, x_k)$$

- Hypothèses sur la décroissance de  $U$  à l'  $\infty$ .

# Intersection de sous-espaces

[Thaele, Schulte 2011]

- $W$  : corps convexe.
- $\mathcal{H} : \{H_1, H_2, \dots\}$  Processus de Poisson ponctuel d'intensité  $\lambda\mu, \lambda > 0$ , dans l'espace des plans affines de  $\mathbb{R}^2$ .

$F$  : # Nombres d'intersection de plans dans  $W \Rightarrow$  U-stat. de noyau :

$$h(H_1, H_2) = \mathbf{1}_{H_1 \cap H_2 \cap W \neq \emptyset}.$$

## Généralisation :

- $F_{k,j}$  :  $j$ -ème volume intrinsèque d'un processus de sous-espaces de dimension  $k$  dans  $\mathbb{R}^d$ .
- Thaele et Schulte ont montré la normalité asymptotique de  $F_{k,j}$  lorsque  $\lambda \rightarrow \infty$  (en utilisant la décomposition de Wiener-Ito).


# Processus marqués

## Modèle germe-grain :


- $\mathcal{K}$  : compacts de  $\mathbb{R}^d$ .
- $\eta$  à valeurs dans  $\mathbb{R}^d \times \mathcal{K}$

Pour  $k \geq 1$  :

$$F = \#\{\text{chaines de longueur } k\}$$



# Télécommunications :



**bleus** : serveurs

**noir** : clients.

$F = \#$  clients desservis (comptés avec leur multiplicité).





## Intégrale de Wiener-Ito

- Soit  $f(x_1, \dots, x_k)$  : noyau sur  $X^k$ .
- **Intégrale de Wiener-Ito d'ordre  $k$  par rapport à  $\eta$**  :

$$I_k(f) = \int_{X^k} f(x_1, \dots, x_k) d(\eta - \mu)^{\otimes k}(x_1, \dots, x_k).$$

- **Ecriture intégrale d'une  $U$ -statistique** :

$$U_k(h) = \int_{X^k} h(x_1, \dots, x_k) d\eta^{\otimes k}(x_1, \dots, x_k).$$

**Une  $U$ -statistique admet une écriture comme somme finie d'intégrales de Wiener-Ito (formule du binome).**

$$U_k(h) = \sum_{j=0}^k I_j(h_j)$$

$$h_j(x_1, \dots, x_j) = \binom{k}{j} \int_{X^{k-j}} h(x_1, \dots, x_k) d\mu^{\otimes k-j}(x_{j+1}, \dots, x_k).$$

# Chaos poissonien

## Théorème

Toute variable aléatoire  $F = F(\eta)$  telle que  $\mathbb{E}(F^2) < \infty$  admet dans  $L^2(\mathbb{P})$  une unique décomposition orthogonale

$$F = \sum_{j \geq 0} I_j(f_j),$$

où  $f_j \in L^2(X^j, \mathbb{R})$ .

Terme constant :  $I_0(f_0) = \mathbb{E}(F)$ .

**Remarque :**  $\text{Var}(I_j(f_j)) = \|f_j\|_{L^2(\mu^j)}^2$ . On pose  $\tilde{f}_j = \frac{f_j}{\|f_j\|_{L^2}}$

- Isoler les noyaux  $f_j$  de variance prédominante,
- Montrer que chaque  $I_j(\tilde{f}_j)$  suit un TCL.



# Méthode de Stein

## Lemme

*Une variable aléatoire  $N$  a la loi normale ssi pour toute fonction  $h$  dérivable à support compact,*

$$\mathbb{E}(h(N) - Nh'(N)) = 0.$$

## Méthode de Stein :

Calculer la distance entre la loi d'une variable  $F$  et d'une gaussienne  $N$  en terme de  $|\mathbb{E}(h(F) - Fh'(F))|$ , pour  $h$  lisse.

# Distance de Wasserstein

$$d_W(F, N) = \sup_{h \in Lip_1} |\mathbb{E}h(F) - h(N)|$$

$d_W(F, N) \rightarrow 0$  implique  $F \Rightarrow \mathcal{N}(0, 1)$ .

En particulier,

$$d_K(F, N) = \sup_{t \in \mathbb{R}} |\mathbb{P}(F \leq t) - \mathbb{P}(N \leq t)| \leq \sqrt{d_W(F, N)}$$

**Reitzner, Schulte** (à venir) : Bornes en termes de  $d_K$ .

## Méthode de Stein (suite)

Pour chaque  $h \in Lip_1$ , l'équation de Stein

$$g'(y) - yg(y) = h(y) - \mathbb{E}(h(N))$$

admet une solution :  $g_h$ , qui satisfait

$$|g'_h(y)| \leq 1, \quad |g''_h(y)| \leq 2, \quad y \in \mathbb{R}.$$

On en déduit que

$$d_W(F, N) = \sup_{h \in Lip_1} |\mathbb{E}(h(F)) - \mathbb{E}(h(N))|$$

$$d_W(F, N) \leq \sup_{|g'| \leq 1, |g''| \leq 2} |\mathbb{E}(g'(F) - Fg(F))|.$$

C'est la **Borne de Stein** (existe pour d'autres lois que la loi normale).  
Pour estimer cette borne, on utilise le **calcul de Malliavin**.

# Calcul de Malliavin

**Idee** : Exprimer  $g'(F)$  et  $Fg(F)$  en termes d'opérateurs linéaires sur la serie

$$F = \sum_{q \geq 1} I_q(f_q).$$

## Opérateurs linéaires

- $D_z F = \sum_{q \geq 1} q I_{q-1}(f_q(\cdot, z)),$
- $LF = - \sum_{q \geq 1} q I_q(f)$
- $L^{-1}F = - \sum_{q \geq 1} \frac{1}{q} I_q(f).$

**Peccati, Sole, Utzet, Taqqu 2010** :

- Bornes génériques en termes des opérateurs de Malliavin

$$d_W(F, N) \leq \mathbb{E}|1 - \langle DF, -DL^{-1}F \rangle| + \int_X \mathbb{E}[D_z F^2 | D_z L^{-1}F] \mu(dz).$$



$\eta_\lambda$  : Processus de Poisson d'intensité  $\lambda\mu$ ,  $\lambda > 0$ .

## Théorème

Soit une  $U$ -statistique  $U_k(h_\lambda)$  telle que  $U_k(|h_\lambda|) \in L^2(\mathbb{P})$ .

- $h_\lambda = h$  ne dépend pas de  $\lambda$  ( $U$ -stat. géométrique) et  $h_1 \neq 0$  le 1er noyau n'est pas identiquement nul.
- OU  $h_\lambda(x_1, \dots, x_k) = \mathbf{1}_{\text{diam}(x_1, \dots, x_k) \geq \lambda^{1/d}}$  (+Bornes plus générales pour "U-statistiques locales")

Alors  $d_W(\tilde{F}, N) \leq C\lambda^{-1/2}$ .

# Applications (Reitzner, Schulte 2011)

- Intersections d'hyperplans dans un convexe.
- **Problème de Sylvester.**  $\eta_\lambda$  : PPP dans un convexe compact  $W$ .  
Avec

$$h(x_1, \dots, x_k) = \mathbf{1}_{\{x_1, \dots, x_k \text{ sont en position convexe}\}},$$

$F_\lambda = U_k(h)$  est asymptotiquement normal, donc  $\lambda^{-k} F_\lambda$  est un estimateur asymptotiquement gaussien de

$$p_k = \mathbb{P}(k \text{ variables uniformes dans } W \text{ sont en position convexe})$$

- Longueur totale du **Unit disk graph** (2 points sont reliés s'ils sont à distance  $\leq \lambda^{-1/d}$  dans  $[0, 1]^d$ ).

# Contractions

## Formule de multiplication

$$I_q(f)I_k(g) = \sum_{r=0}^{q \wedge k} \sum_{l=0}^r \varkappa_{q,k,r,l} I_{q+k-r-l}(f \star_r^l g)$$

- $\varkappa_{q,k,r,l}$  : Terme combinatoire.
- $f \star_r^l g$  : Symétrisée de la contraction de  $f$  et  $g$ .

$$\begin{aligned} f \star_r^l g(x_1, \dots, x_{k-l}, t_1, \dots, t_{k-l}, y_1, \dots, y_{r-l}) \\ = \int f(x_1, \dots, x_{q-l}, y_1, \dots, y_{r-l}, z_1, \dots, z_l) \\ g(t_1, \dots, t_{k-l}, y_1, \dots, y_{r-l}, z_1, \dots, z_l) d\mu^{\otimes l}(z_1, \dots, z_l) \end{aligned}$$

On met  $r$  variables en commun, parmi lesquelles on en intègre  $l$ .

# Bornes en termes de contractions

Théorème (Peccati, Solé, Utzet, Taqqu 2010)

Soit  $F = \sum_{i=1}^k I_i(f_i)$ ,  $f_i \in L^2(X^i)$ .

Alors

$$d_W(F, N) \leq C[\max_1 \|f_i \star_r^l f_j\|_{L^2} + \max_{1 \leq i \leq k} \|f_i\|_{L^4}] + C' \frac{\text{Var}^2(F) - 1}{\text{Var}(F) \vee 1}.$$

où  $\max_1$  porte sur

$$i \leq j \leq k, 0 \leq l \leq r \leq i, (i, j) \neq (1, 1), r \geq 1, l < j.$$

## Exemple pour $k = q = 2$

Soit

- $f : X^2 \mapsto \mathbb{R}_+$

telle que  $\|f\|_{L^2} \neq 0$ .

$$f \star_1^1 f(x, y) = \int f(x, z)f(y, z)\mu(dz)$$

$$\|\tilde{f} \star_1^1 \tilde{f}\|_{L^2}^2 = \frac{\int f(x, z)f(y, z)f(x, t)f(y, t)\mu^{\otimes 4}(dx, dy, dz, dt)}{\int f(x, y)f(x, y)f(z, t)f(z, t)\mu^{\otimes 4}(dx, dy, dz, dt)}$$

Si  $f$  est “petite loin de la diagonale” (ex :  $f(x, y) = \mathbf{1}_{\|x-y\| \leq \lambda^{-1/d}}$ ),

- **intégrale numérateur** : on ne compte que les termes où  $(x, y, z, t)$  sont “proches”
- **Intégrale dénominateur** : on compte les termes où  $(x, y)$  sont proches, et  $(z, t)$  sont proches. ( $\Rightarrow$  plus de termes !)

# Dernier ingrédient : TCL multi-dimensionnel

## Théorème (Peccati, Zheng 2010)

Soit  $F = \sum_{i=1}^k I_i(f_i)$ ,  $f_i \in L^2(X^i)$ .

Si

$$\max_1 \|f_i \star_r^l f_j\|_{L^2} + \max_{1 \leq i \leq k} \|f_i\|_{L^4} \rightarrow 0,$$

alors pour  $\varphi$  3 fois dérivable tq  $\|\varphi''\|_\infty, \|\varphi'''\|_\infty < \infty$

$$\mathbb{E}(\varphi(I_1(f_1), \dots, I_k(f_k))) - \mathbb{E}(\varphi(N_1, \dots, N_k)) \rightarrow 0$$

où  $N_i \sim \mathcal{N}(0, 1)$ .



## “4th moment bound” pour les U-stat. à noyau positif

On suppose que  $h_i \geq 0, 1 \leq i \leq k$ .

### Théorème

Si

$$B = [\max_1 \|f_i \star_r^l f_j\|_{L^2} + \max_{1 \leq i \leq k} \|f_i\|_{L^4}]$$

$$cB \leq \sqrt{\mathbb{E}(F^4 - 3)} \leq CB$$

- Traditionnellement, les auteurs vérifiaient  $\mathbb{E}(F_\lambda^k) \rightarrow \mathbb{E}(N^k)$ , pour  $k \geq 1$ .
- La condition sur les contractions est **nécessaire** pour la normalité asymptotique si  $\{F_\lambda^4; \lambda > 0\}$  est uniformément intégrable.



# U-stat. géométriques

$$F = \sum_{\eta_k^\neq} h(x_1, \dots, x_k) = \sum_{i=1}^k l_i(h_i).$$

où  $h$  ne dépend pas de  $\lambda$ .

## Théorème

- Si  $h_1 \neq 0$ ,  $\tilde{F} \Rightarrow N$  à la vitesse  $\lambda^{-1/2}$  (pour  $d_W$ ). (R,S, '11)
- Si  $h_1 = 0$  et  $h_2 \neq 0$ ,  $\tilde{F}$  n'est pas asymptotiquement normale.
- Si  $h_1 = 0, h_2 = 0, \dots, h_{i-1} = 0, h_i \neq 0, h_i \geq 0$ ,  $\tilde{F}$  ne suit pas un TCL.

# Graphes aléatoires géométriques

On suppose

$$F_\lambda = \sum_{x \neq y \in \eta_\lambda} \mathbf{1}_{\alpha_\lambda(x-y) \in H} = \mathbb{E}(F_\lambda) + I_1(h_1) + I_2(h_2).$$

pour un certain  $H \subseteq \mathbb{R}^d$  (Unit disk graph :  $H = B(0, 1)$ ) et un facteur d'échelle  $\alpha_\lambda > 0$ . On pose

$$\psi(\lambda) = \frac{\ell(H \cap Q_\lambda)}{\ell(Q_\lambda)}$$

où  $Q_\lambda = [-\lambda^{1/d}, \lambda^{1/d}]^d$ .

# Conditions analytiques sur $H$

On pose  $F = \mathbb{E}(F) + F_1 + F_2$ .

## Théorème

On fait "l'hypothèse de régularité" que

$$0 < \inf_{\lambda > 0} \frac{\psi(c\lambda)}{\psi(\lambda)} \leq \sup_{\lambda > 0} \frac{\psi(c\lambda)}{\psi(\lambda)} < \infty,$$

pour tout  $c > 0$ . Alors

$$\text{Var}(\tilde{F}_1) \sim \lambda^3 \psi(\lambda)^2$$

$$\text{Var}(\tilde{F}_2) \sim \lambda^2 \psi(\lambda)$$

$$d_W(\tilde{F}_2, N) \leq C \sqrt{\psi(\lambda)}$$

# U-stats locales généralisées

$$F = \sum_{x_1, \dots, x_k \in \eta_\lambda^\neq} h(\lambda^{1/d}(x_1, \dots, x_k))$$

pour  $h \geq 0$  stationnaire sur  $(\mathbb{R}^d)^k$ .

## Théorème

Si il existe  $\varepsilon > 0$  tel que

$$|h(0, x_2, \dots, x_k)| \leq C \prod_{i=2}^k 1 \wedge \|x_i\|^{-d-\varepsilon},$$

Alors  $\tilde{F}$  suit un TCL à la vitesse  $\lambda^{-1/2}$ .

## Remarques

- Ne rentre pas dans le cadre de la stabilisation (la contribution d'un  $x$  dépend de ce qui se passe loin de  $x$ )
- Possibilité de considérer des processus stationnaires marqués.
- Autres remises à l'échelle possibles.