

# Étude à distance finie d'un $R$ -estimateur pour la matrice de forme des distributions symétriques elliptiques complexes

*Stefano Fortunati*<sup>1,2</sup>, *Alexandre Renaux*<sup>1</sup>, *Frédéric Pascal*<sup>1</sup>

<sup>1</sup>Université Paris-Saclay, CNRS, CentraleSupélec, L2S,

<sup>2</sup>DR2I-IPSA.

GRETSI 2022

Nancy, 06-09 Septembre 2022.

- ▶ Un modèle semi-paramétrique<sup>1</sup>  $\mathcal{P}_{\theta, h}$  est un ensemble de densités de probabilité (dp) caractérisées par un paramètre de dimension fini  $\theta \in \Theta$  ainsi que d'une *fonction*  $h \in \mathcal{L}$  qui est un paramètre de dimension infini :

$$\mathcal{P}_{\theta, g} \triangleq \{p_X(\mathbf{x}_1, \dots, \mathbf{x}_M | \theta, h), \theta \in \Theta \subseteq \mathbb{C}^q, h \in \mathcal{L}\}.$$

- ▶ Généralement,  $\theta$  est le paramètre à estimer alors que  $h$  est une fonction de *nuisance*.
- ▶ **Avantage:** Un modèle semi-paramétrique combine la *concision* d'un modèle paramétrique avec la *généralité* d'un modèle non-paramétrique.
- ▶ **Inconvénient:** Des outils d'analyse fonctionnelle sont nécessaires.

---

<sup>1</sup>P.J. Bickel, C.A.J. Klaassen, Y. Ritov and J.A. Wellner, *Efficient and Adaptive Estimation for Semiparametric Models*, Johns Hopkins University Press, 1993.

## Exemples: données manquantes.

---

- ▶ Soit  $\mathbf{z} \triangleq (\mathbf{x}^T, \mathbf{y}^T)^T$  un ensemble *complet* de données, où:
  - ▶  $\mathbf{x}$  est l'ensemble de données observées (disponibles).
  - ▶  $\mathbf{y}$  est l'ensemble de données non observable (manquantes).
- ▶ **Problème:** Estimer  $\theta \in \Theta$  à partir des données observées  $\mathbf{x}$  lorsque la dp  $p_Y$  des données manquantes  $\mathbf{y}$  est inconnue.
- ▶ La dp  $p_X$  des données observées peut être exprimée comme :

$$p_X(\mathbf{x}|\theta) = \int_{\mathcal{Y}} p_{X,Y}(\mathbf{x}, \mathbf{y}|\theta) d\mathbf{y} = \int_{\mathcal{Y}} p_{X|Y}(\mathbf{x}|\mathbf{y}, \theta) p_Y(\mathbf{y}) d\mathbf{y}.$$

- ▶ L'ensemble des dp de  $\mathbf{x}$  est un *modèle semi-paramétrique* :

$$\mathcal{P}_{\theta, p_Y} \triangleq \{p_X | p_X(\mathbf{x}|\theta, p_Y), \theta \in \Theta, p_Y \in \mathcal{K}\}.$$

## Exemples: régression non-linéaire

---

- ▶ Considérons le modèle générale de régression non-linéaire :

$$\mathbf{x} = f(\mathbf{z}, \boldsymbol{\theta}) + \epsilon,$$

- ▶  $\boldsymbol{\theta} \in \Theta$ : vecteur de paramètres à estimer,
  - ▶  $f \in \mathcal{F}$ : fonction éventuellement inconnue,
  - ▶  $\mathbf{z}$ : vecteur aléatoire de dp  $p_Z \in \mathcal{K}$  éventuellement inconnue,
  - ▶  $\epsilon$ : bruit de dp  $p_\epsilon \in \mathcal{E}$  éventuellement inconnue.
- 
- ▶ L'ensemble de dp de  $\mathbf{x}$  est un *modèle semi-paramétrique* :

$$\mathcal{P}_{\boldsymbol{\theta}, f, p_Z, p_\epsilon} \triangleq \{p_X(\mathbf{x}|\boldsymbol{\theta}, f, p_Z, p_\epsilon), \boldsymbol{\theta} \in \Theta, f \in \mathcal{F}, p_Z \in \mathcal{K}, p_\epsilon \in \mathcal{E}\}.$$

- ▶ Si on a une connaissance "a priori", nous pouvons réduire les inconnues.

## Exemples: processus autorégressifs

---

- ▶ Considérons le processus  $\text{AR}(p)$  :

$$x_n = \sum_{i=1}^p \theta_i x_{n-i} + w_n, \quad n \in \mathbb{Z}$$

- ▶  $\boldsymbol{\theta} \triangleq [\theta_1, \dots, \theta_p]$ : vecteur de paramètres à estimer,
  - ▶  $w_n$ : i.i.d. innovations de dp  $p_w \in \mathcal{W}$  inconnue,
- ▶ Soit  $\mathbf{x} \in \mathbb{R}^N$  un vecteur de  $N$  observations issus d'un  $\text{AR}(p)$ .
- ▶ L'ensemble des dp de  $\mathbf{x}$  est un *modèle semi-paramétrique* :

$$\mathcal{P}_{\boldsymbol{\theta}, p_w} \triangleq \{p_X | p_X(\mathbf{x} | \boldsymbol{\theta}, p_w), \boldsymbol{\theta} \in \Theta, p_w \in \mathcal{W}\}.$$

- ▶ Un vecteur symétrique elliptique complexe  $\mathbf{x} \in \mathbb{C}^N$  a une dp :

$$p_{\mathbf{X}}(\mathbf{x}) = |\Sigma|^{-1} h((\mathbf{x} - \boldsymbol{\mu})^H \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu})) \triangleq CES_N(\boldsymbol{\mu}, \Sigma, h).^2$$

- ▶  $\mathcal{L} \ni h : \mathbb{R}^+ \rightarrow \mathbb{R}^+$  est la fonction dite *génératrice*,
  - ▶  $\boldsymbol{\mu} \in \mathbb{C}^N$  est un paramètre de position,
  - ▶  $\Sigma \in \mathcal{M}_N$  est une matrice de dispersion.
- 
- ▶ Notez que  $\Sigma$  et  $h$  ne sont pas identifiables conjointement:

$$CES_N(\boldsymbol{\mu}, \Sigma, h(t)) \equiv CES_N(\boldsymbol{\mu}, c\Sigma, h(ct)), \quad \forall c > 0.$$

- ▶ Pour éviter cela, on définit la *matrice de forme* :

$$\mathbf{V}_1 \triangleq \Sigma / [\Sigma]_{1,1}.$$

---

<sup>2</sup>E. Ollila, D. E. Tyler, V. Koivunen and H. V. Poor, "Complex Elliptically Symmetric Distributions: Survey, New Results and Applications", *IEEE Trans. on Signal Processing*, vol. 60, no. 11, pp. 5597-5625, Nov. 2012.

- ▶ Sans perte de généralité, on suppose que  $\boldsymbol{\mu} \equiv \mathbf{0}$ .
- ▶ L'ensemble des dp CES est un *modèle semi-paramétrique* :

$$\mathcal{P}_{\boldsymbol{\theta}, h} = \left\{ p_X \mid p_X(\mathbf{x} \mid \boldsymbol{\theta}, h) = |\mathbf{V}_1|^{-1} h(\mathbf{x}^H \mathbf{V}_1^{-1} \mathbf{x}); \boldsymbol{\theta} \in \Theta, h \in \mathcal{L} \right\},$$

- ▶  $h$  joue le rôle d'un paramètre de nuisance *de dimension infini*.
- ▶ Le paramètre d'intérêt à estimer est : <sup>3</sup>

$$\boldsymbol{\theta} \triangleq \underline{\text{vec}}(\mathbf{V}_1) \in \Theta.$$

- ▶ Notez que l'estimateur du *maximum de vraisemblance* **n'est pas une option** puisque  $h \in \mathcal{L}$  est **inconnue** !

---

<sup>3</sup>L'opérateur  $\underline{\text{vec}}(\mathbf{A})$  définit le vecteur de dimension  $N^2 - 1$  obtenu à partir de  $\text{vec}(\mathbf{A})$  en supprimant son premier élément, c'est-à-dire  $\underline{\text{vec}}(\mathbf{A}) \triangleq [\partial_{11}, \text{vec}(\mathbf{A})^T]^T$ .

# En présence d'une fonction $h$ inconnue

- ▶ Matrice de covariance empirique (ou  $SCM$ ):
  - ▶ Non robuste,
  - ▶ Manque d'efficacité semi-paramétrique,
- ▶  $M$ -estimateurs (*Maronna, Tyler*): <sup>4,5</sup>
  - ▶ Robustes,
  - ▶ Manque d'efficacité semi-paramétrique,
- ▶  $R$  (rank-based)-estimateurs (*Hallin, Paindaveine*): <sup>6,7</sup>
  - ▶ Robustes,
  - ▶ Efficacité semi-paramétrique.

---

<sup>4</sup>R. A. Maronna, "Robust  $M$ -estimators of multivariate location and scatter," *The Annals of Statistics*, vol. 4, no. 1, pp. 51–67, 01 1976.

<sup>5</sup>D. E. Tyler, "A distribution-free  $M$ -estimator of multivariate scatter," *The Annals of Statistics*, vol. 15, no. 1, pp. 234–251, 1987.

<sup>6</sup>M. Hallin, H. Oja, and D. Paindaveine, "Semiparametrically efficient rank-based inference for shape II. optimal  $R$ -estimation of shape," *The Annals of Statistics*, vol. 34, no. 6, pp. 2757–2789, 2006.

<sup>7</sup>M. Hallin and B. J. M. Werker, "Semi-parametric efficiency, distribution-freeness and invariance," *Bernoulli*, vol. 9, no. 1, pp. 137–165, 2003.



# Un $R$ -estimateur efficace pour $\mathbf{V}_1$ (1/3)

- ▶ Soit  $\{\mathbf{x}_I\}_{I=1}^L$  un ensemble de  $L$  observations i.i.d..
- ▶ Un  $R$ -estimateur peut être représenté comme : <sup>8</sup>

$$\hat{\boldsymbol{\theta}}_R = \hat{\boldsymbol{\theta}}^* + L^{-1/2} \hat{\boldsymbol{\Upsilon}}_{\hat{\boldsymbol{\theta}}^*}^{-1} \tilde{\boldsymbol{\Delta}}_{\hat{\boldsymbol{\theta}}^*}.$$

- ▶  $\hat{\boldsymbol{\theta}}^*$  est un *estimateur préliminaire* (consistant, non efficace) de  $\boldsymbol{\theta} \triangleq \text{vec}(\mathbf{V}_1)$ , par exemple la SCM or l'estimateur de Tyler,
- ▶  $\hat{\boldsymbol{\Upsilon}}_{\hat{\boldsymbol{\theta}}^*}$  est un estimateur de la *matrice d'information semi-paramétrique*,
- ▶  $\tilde{\boldsymbol{\Delta}}_{\hat{\boldsymbol{\theta}}^*} \triangleq \sum_{I=1}^L \tilde{\boldsymbol{\varphi}}(\mathbf{x}_I, \hat{\boldsymbol{\theta}}^*)$ , où  $\tilde{\boldsymbol{\varphi}}$  est une approximation du *vecteur de score semi-paramétrique*.

- ▶ L'estimation de  $h \in \mathcal{L}$  **n'est pas nécessaire !**

<sup>8</sup>M. Hallin, H. Oja, and D. Paindaveine, "Semiparametrically efficient rank-based inference for shape II. optimal  $R$ -estimation of shape,"

## Un $R$ -estimateur efficace pour $\mathbf{V}_1$ (2/3)

La forme explicite du  $R$ -estimateur de la matrice de forme est :

$$\begin{aligned} \underline{\text{vec}}(\widehat{\mathbf{V}}_{1,R}) &= \underline{\text{vec}}(\widehat{\mathbf{V}}_1^*) + \frac{1}{L\hat{\alpha}} \left[ \mathbf{L}_{\widehat{\mathbf{V}}_1^*} \mathbf{L}_{\widehat{\mathbf{V}}_1^*}^H \right]^{-1} \mathbf{L}_{\widehat{\mathbf{V}}_1^*} \times \\ &\quad \times \sum_{l=1}^L K_h \left( \frac{r_l^*}{L+1} \right) \text{vec}(\hat{\mathbf{u}}_l^* (\hat{\mathbf{u}}_l^*)^H), \end{aligned}$$

- ▶  $\{r_l^*\}_{l=1}^L$ : rangs de  $\hat{\mathbf{Q}}_l^* \triangleq \mathbf{x}_l^H [\widehat{\mathbf{V}}_1^*]^{-1} \mathbf{x}_l$ ,
- ▶  $\hat{\mathbf{u}}_l^* \triangleq (\hat{\mathbf{Q}}_l^*)^{-1/2} [\widehat{\mathbf{V}}_1^*]^{-1/2} \mathbf{z}_l$ ,
- ▶  $\hat{\alpha}$  est une quantité dépendant des données,
- ▶  $\widehat{\mathbf{V}}_1^*$  est un estimateur préliminaire: **paramètre libre**,
- ▶  $K_h(\cdot)$  est une fonction *score*: **paramètre libre**.

## Un $R$ -estimateur efficace (3/3)

- ▶ Dans nos récents travaux<sup>9,10</sup>, on a :
  - ▶ Généralisé le  $R$ -estimateur au cas complexe,
  - ▶ Étudier le réglage optimal de paramètres,
  - ▶ Étudier la robustesse aux données aberrantes,en utilisant la version matricielle suivante :

$$\widehat{\mathbf{V}}_{1,R} = \widehat{\mathbf{V}}_1^* + \frac{1}{\hat{\alpha}} \left( \mathbf{W} - [\mathbf{W}]_{1,1} \widehat{\mathbf{V}}_1^* \right)$$

où  $\mathbf{W}$  est une matrice dont l'expression explicite est connue.

- ▶ Quel est l'impact des deux paramètres libres
  1. l'estimateur préliminaire  $\widehat{\mathbf{V}}_1^*$ ,
  2. la fonction score  $K_h(\cdot)$sur les performances à distance finie?

<sup>9</sup>S. Fortunati, A. Renaux, F. Pascal, "Robust semiparametric efficient estimators in complex elliptically symmetric distributions", *IEEE Transactions on Signal Processing*, vol. 68, pp. 5003-5015, 2020.

<sup>10</sup>S. Fortunati, A. Renaux, F. Pascal "Joint Estimation of Location and Scatter in Complex Elliptical Distributions: A robust semiparametric and computationally efficient R-estimator of the shape matrix," *MLSP Special Issue of the Journal of Signal Processing Systems*, 2021.

- ▶ Les données sont générées en utilisant une  $t$ -distribution complexe à moyenne nulle :

$$p_{\mathbf{X}}(\mathbf{x}|\mathbf{V}_1, h) = |\mathbf{V}_1|^{-1} h \left( \mathbf{x}^H \mathbf{V}_1^{-1} \mathbf{x} \right),$$

$$h(t) = \frac{\Gamma(\lambda + N)}{\pi^N \Gamma(\lambda)} \left( \frac{\lambda}{\eta} \right)^\lambda \left( \frac{\lambda}{\eta} + t \right)^{-(\lambda + N)},$$

- ▶  $\lambda \in ]1, +\infty[$  est un paramètre de forme qui contrôle la queue de la distribution,
- ▶  $\eta > 0$  est un paramètre d'échelle qui rend compte de la puissance des données.


### Remark:

Grâce à la nature semi-paramétrique du  $R$ -estimateur considéré, les résultats obtenus pour des données  $t$ -distribuées sont valables pour toutes les autres distributions CES.

# SCM comme estimateur préliminaire

$$\underline{\text{vec}}(\widehat{\mathbf{V}}_{1,R}^{SCM}) = \underline{\text{vec}}(\widehat{\mathbf{V}}_{1,SCM}^*) + L^{-1/2} \widehat{\mathbf{\Upsilon}}_{\widehat{\mathbf{V}}_{1,SCM}^*}^{-1} \widetilde{\Delta} \widetilde{\mathbf{V}}_{1,SCM}^*,$$


$$\varsigma_{\gamma}^{\varphi} \triangleq \|E\{\text{vec}(\widehat{\mathbf{V}}_{\gamma}^{\varphi} - \mathbf{V}_0)\text{vec}(\widehat{\mathbf{V}}_{\gamma}^{\varphi} - \mathbf{V}_0)^H\}\|_F,$$



- Le terme de correction linéaire  $L^{-1/2} \widehat{\mathbf{\Upsilon}}_{\widehat{\mathbf{V}}_{1,SCM}^*}^{-1} \widetilde{\Delta} \widetilde{\mathbf{V}}_{1,SCM}^*$  peut améliorer de manière significative l'efficacité de la SCM ( $\lambda = 2$  et  $N = 8$ ).

# Estim. Tyler comme estimateur préliminaire

$$\text{vec}(\widehat{\mathbf{V}}_{1,R}^{Ty}) = \text{vec}(\widehat{\mathbf{V}}_{1,Ty}^*) + L^{-1/2} \widehat{\mathbf{\Upsilon}}_{\widehat{\mathbf{V}}_{1,Ty}^*}^{-1} \widetilde{\Delta} \widehat{\mathbf{v}}_{1,Ty}^*,$$



- $\widehat{\mathbf{V}}_{1,R}^{Ty}$  est plus performant que  $\widehat{\mathbf{V}}_{1,R}^{SCM}$  pour de données à codes lourdes ( $L = 5N$  et  $N = 8$ ).

## Deux exemples utiles de fonctions score

---

- ▶ La fonction *score* de *van der Waerden* :

$$K_{vdW}(u) \triangleq \Phi_G^{-1}(u), \quad u \in ]0, 1[,$$

où  $\Phi_G^{-1}$  indique la fonction inverse de la distribution cumulative (dc) d'une variable aléatoire Gamma avec paramètres  $(N, 1)$ .


- ▶ La fonction  $t_\nu$ -score :

$$K_{t_\nu}(u) = \frac{N(2N + \nu)F_{2N, \nu}^{-1}(u)}{\nu + 2NF_{2N, \nu}^{-1}(u)}, \quad u \in ]0, 1[,$$

où  $F_{2N, \nu}(u)$  indique la dc de Fisher avec  $2N$  et  $\nu \in ]0, \infty[$  degrés de liberté.

- ▶ La fonction  $t_\nu$ -score dépend d'un paramètre supplémentaire  $\nu$  qui doit être choisi avec soin.

# van der Waerden et fonction $t_\nu$ -score



- ▶ La fonction  $t_\nu$ -score fournit les meilleures performances pour les données à queue très lourde ( $1 < \lambda < 5$ ).
- ▶ La fonction de *van der Waerden* offre de bonnes performances sans avoir besoin de paramètres de réglage supplémentaires.



- ▶ Une étude à distance finie d'un  $R$ -estimateur pour la matrice de forme des distributions symétriques elliptiques complexes a été développé.
- ▶ L'étude numérique proposée a montré que les paramètres suivant :
  - ▶ Estimateur préliminaire: *estimateur de Tyler*,
  - ▶ Function score: *van der Waerden*,conduisent à de bonne performances en termes d'erreur quadratique moyenne (EQM) pour quasiment toutes les valeurs de  $\lambda$ .
- ▶ Les travaux futurs porteront sur l'application de l'estimateur proposé aux problèmes de clustering robuste et de distance learning.

*Essayez-le et faites-nous savoir s'il fonctionne dans vos applications ;)*

Le code est disponible sur GitHub.

**Merci de votre attention !**

**Des questions?**

# Backup slides

# A lower bound in semiparametric estimation

- ▶ Let  $\{\mathbf{x}_l\}_{l=1}^L$  be a set of iid observations, such that  $\mathbf{x}_l \sim p_0(\mathbf{x}; \boldsymbol{\theta}_0, h_0) \in \mathcal{P}_{\boldsymbol{\theta}, h} \forall l$ .
- ▶ The class of *Regular and Asymptotically Linear (RAL) estimators* is defined as:
  1.  $\sqrt{L}$ -consistent:  $\sqrt{L}(\hat{\boldsymbol{\theta}}_L - \boldsymbol{\theta}_0) = O_P(1)$ ,
  2. Asymptotically normal:  $\sqrt{L}(\hat{\boldsymbol{\theta}}_L - \boldsymbol{\theta}_0) \underset{L \rightarrow \infty}{\overset{d}{\rightsquigarrow}} \mathcal{N}(\mathbf{0}, \boldsymbol{\Xi}(\boldsymbol{\theta}_0, h_0))$ .
- ▶ The ML and all the robust estimators belong to this class.

**Semiparametric CRB (SCRIB):** Any *RAL* estimator  $\hat{\boldsymbol{\theta}}_L$  of  $\boldsymbol{\theta}_0$ , derived in  $\mathcal{P}_{\boldsymbol{\theta}, h}$  from  $\{\mathbf{x}_l \sim\}_{l=1}^L$  iid observations, satisfies: <sup>11</sup>

$$\boldsymbol{\Xi}(\boldsymbol{\theta}_0, h_0) \geq \bar{\mathbf{I}}(\boldsymbol{\theta}_0 | h_0)^{-1} \triangleq \text{SCRIB}(\boldsymbol{\theta}_0 | h_0).$$

<sup>11</sup>P.J. Bickel, C.A.J. Klaassen, Y. Ritov and J.A. Wellner, *Efficient and Adaptive Estimation for Semiparametric Models*, Johns Hopkins University Press, 1993.

## Ranks (1/2)

---

- ▶ Let  $\{x_l\}_{l=1}^L$  be a set of  $L$  continuous i.i.d. random variables with pdf  $p_X$ .
- ▶ Define the vector of the *order statistics* as

$$\mathbf{v}_X \triangleq [x_{L(1)}, x_{L(2)}, \dots, x_{L(L)}]^T,$$

whose entries

$$x_{L(1)} < x_{L(2)} < \dots < x_{L(L)}$$

are the values of  $\{x_l\}_{l=1}^L$  ordered in an ascending way.<sup>12</sup>

- ▶ The rank  $r_l \in \mathbb{N}$  of  $x_l$  is the position index of  $x_l$  in  $\mathbf{v}_X$ .

---

<sup>12</sup>Note that, since  $x_l, \forall l$  are continuous random variable the equality occurs with probability 0.

- ▶ Let  $\mathbf{r}_X \triangleq [r_1, \dots, r_L]^T \in \mathbb{N}^L$  be the vector collecting the ranks.
- ▶ Let  $\mathcal{K}$  be the family of score functions  $K : (0, 1) \rightarrow \mathbb{R}$  that are continuous, square integrable and that can be expressed as the difference of two monotone increasing functions.

Let  $\{x_l\}_{l=1}^L$  be a set of i.i.d. random variables s.t.  $x_l \sim p_X, \forall l$ .  
Then, we have:

1. The vectors  $\mathbf{v}_X$  and  $\mathbf{r}_X$  are independent,
2. Regardless the actual pdf  $p_X$ , the rank vector  $\mathbf{r}_X$  is uniformly distributed on the set of all  $L!$  permutations on  $\{1, 2, \dots, L\}$ ,
3. For each  $l = 1, \dots, L$ ,  $K\left(\frac{r_l}{L+1}\right) = K(u_l) + o_P(1)$ , where  $K \in \mathcal{K}$  and  $u_l \sim \mathcal{U}[0, 1]$  is a random variable uniformly distributed in  $(0, 1)$ .

## Tyler's $M$ -estimator

---

- ▶ Tyler's  $M$ -estimator  $\hat{\mathbf{V}}_{Ty}$  is given by the convergence point ( $k \rightarrow \infty$ ) of:

$$\begin{cases} \hat{\Sigma}_{Ty}^{(k+1)} = \frac{N}{L} \sum_{l=1}^L [\hat{Q}_l^{(k)}]^{-1} \mathbf{x}_l \mathbf{x}_l^H \\ \hat{\mathbf{V}}_{Ty}^{(k+1)} \triangleq N \hat{\Sigma}_{Ty}^{(k+1)} / \text{tr}(\hat{\Sigma}_{Ty}^{(k+1)}). \end{cases}$$

where:

$$\hat{Q}_l^{(k)} = \mathbf{x}_l^H [\hat{\mathbf{V}}_1^{(k)}]^{-1} \mathbf{x}_l,$$

- ▶ The estimator  $\hat{\mathbf{V}}_{Ty}$  is  $\sqrt{L}$ -consistent under any (unknown) density generator  $h \in \mathcal{H}$ .
- ▶ **It is not semiparametric efficient.**