



Exploitation de la parcimonie par la factorisation de Cholesky et son application pour la détection d'anomalies en imagerie hyperspectrale

Ahmad W. Bitar, Jean-Philippe Ovarlez, Loong-Fah Cheong

► To cite this version:

Ahmad W. Bitar, Jean-Philippe Ovarlez, Loong-Fah Cheong. Exploitation de la parcimonie par la factorisation de Cholesky et son application pour la détection d'anomalies en imagerie hyperspectrale. Gretsi, XXVIème Colloque , Sep 2017, Juan-Les-Pins, France. <hal-01656899>

HAL Id: hal-01656899

<https://hal-centralesupelec.archives-ouvertes.fr/hal-01656899>

Submitted on 6 Dec 2017

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Exploitation de la parcimonie par la factorisation de Cholesky et son application pour la détection d’anomalies en imagerie hyperspectrale

Ahmad W. BITAR¹, Jean-Philippe OVARLEZ^{1,2}, Loong-Fah CHEONG³

¹SONDRA/CentraleSupélec, Plateau du Moulon, 3 rue Joliot-Curie, F-91190 Gif-sur-Yvette, France

²ONERA, DEMR/TSI, Chemin de la Huniere, 91120 Palaiseau, France

³Université Nationale de Singapour, Singapour, Singapour

ahmad.bitar@centralesupelec.fr, jeanphilippe.ovarlez@centralesupelec.fr
eleclf@nus.edu.sg

Résumé – Dans ce papier, deux stratégies de parcimonie sont proposées et appliquées sur la matrice de covariance à travers sa matrice unitaire triangulaire inférieure (ou facteur de Cholesky) \mathbf{T} . La première permet d’abord d’estimer les entrées de \mathbf{T} par la méthode des moindres carrés ordinaires (*Ordinary Least Squares (OLS)*), et ensuite introduire de la parcimonie en profitant de quelques techniques de seuillages comme Soft et *Smoothly Clipped Absolute Deviation (SCAD)*. La deuxième consiste à directement estimer une version parcimonieuse de \mathbf{T} en pénalisant le logarithme du maximum de vraisemblance normal négatif par la norme L_1 et SCAD. La propriété que la matrice de covariance résultante estimée soit définie positive (et inversible) est toujours garantie. L’efficacité des méthodes proposées est évaluée sur quelques simulations de Monte-Carlo pour la détection d’anomalies en imagerie hyperspectrale.

Abstract – Estimating large covariance matrices has been a longstanding important problem in many applications and has attracted increased attention over several decades. This paper deals with two methods based on pre-existing works to impose sparsity on the covariance matrix via its unit lower triangular matrix (aka Cholesky factor) \mathbf{T} . The first method serves to estimate the entries of \mathbf{T} using the Ordinary Least Squares (OLS), then imposes sparsity by exploiting some generalized thresholding techniques such as Soft and Smoothly Clipped Absolute Deviation (SCAD). The second method directly estimates a sparse version of \mathbf{T} by penalizing the negative normal log-likelihood with L_1 and SCAD penalty functions. The resulting covariance estimators are always guaranteed to be positive definite. Some Monte-Carlo simulations demonstrate the effectiveness of our estimators for hyperspectral anomaly detection using the Kelly anomaly detector.

1 Introduction

Une image hyperspectrale est constituée d’une série d’images de la même scène spatiale, mais prises dans plusieurs dizaines de longueurs d’onde contiguës et très étroites, qui correspondent à autant de “couleurs”. Lorsque la dimension spectrale est très grande, la détection de cibles devient délicate et caractérise une des applications les plus importantes de l’imagerie hyperspectrale [1]. Une information préalable sur la signature spectrale de la cible n’est souvent pas disponible pour l’utilisateur. On parle alors du problème de la détection d’anomalies, une anomalie caractérisant tout ce qui pourrait être différent du fond.

Différents détecteurs d’anomalies ont été proposés dans la littérature. La performance de ces détecteurs dépend principalement de la matrice de covariance originale (inconnue) qui a besoin d’être très précisément estimée surtout en grandes dimensions. En raison du fait qu’en imagerie hyperspectrale, le nombre d’éléments à estimer dans la matrice de covariance augmente quadratiquement avec la dimension spectrale, les estimateurs traditionnels deviennent alors impraticables, et avec lesquelles la détection peut se détériorer significativement. Beaucoup de temps, les chercheurs présument que ce problème peut

être allégé en se basant sur l’hypothèse que la matrice de covariance est parcimonieuse.

Ce papier décrit deux méthodes simples basées sur des travaux déjà existants pour imposer de la parcimonie dans la matrice de covariance à travers son facteur de Cholesky \mathbf{T} . La première méthode sert à exploiter quelques techniques de seuillages comme Soft et SCAD sur la version estimée OLS de \mathbf{T} . La deuxième méthode estime directement une version parcimonieuse de \mathbf{T} en pénalisant le logarithme du maximum de vraisemblance normal négatif par la norme L_1 et SCAD.

Notation : Une lettre en italique désigne une quantité scalaire. Les caractères gras en minuscule (resp. majuscule) correspondent à des vecteurs (resp. matrices). La notation $(\cdot)^T$ correspond à l’opérateur transposé, tandis que $|\cdot|$, $(\cdot)^{-1}$, et $\det(\cdot)$ caractérisent la valeur absolue, l’inverse, et le déterminant, respectivement. Pour une variable z , on définit $\text{sign}(z) = 1$ si $z > 0$, $\text{sign}(z) = 0$ si $z = 0$ et $\text{sign}(z) = -1$ si $z < 0$.

2 Contexte

Soit n vecteurs aléatoires $\{\mathbf{x}_i\}_{i \in [1, n]}$ indépendants et identiquement distribués (i.i.d.) caractérisés par une distribution

gaussienne de moyenne nulle et de matrice de covariance inconnue Σ . La première estimation traditionnelle de Σ est basée sur la matrice de covariance empirique (*Sample Covariance Matrix* (*SCM*)) définie comme $\hat{\Sigma}_{SCM} = [\hat{\sigma}_{g,l}]_{p \times p} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^T$.

Afin de résoudre le problème de la contrainte que $\hat{\Sigma}_{SCM}$ soit définie positive et inversible, la méthode de Pourahmadi [2] était la première servant à modéliser la matrice de covariance à partir de la régression linéaire simple. Ceci est fait en notant $\hat{\mathbf{x}} = [\hat{x}_1, \hat{x}_2, \dots, \hat{x}_p]^T \in \mathbb{R}^p$, et considérer que chaque élément \hat{x}_t , $t \in [1, p]$, est la version estimée des moindres carrés linéaires de x_t en se basant sur ses $t - 1$ prédécesseurs $\{x_j\}_{j \in [1, t-1]}$. Plus particulièrement, pour $t \in [1, p]$, on a :

$$\hat{x}_t = \sum_{j=1}^{t-1} C_{t,j} x_j, \quad \mathbf{T}\Sigma\mathbf{T}^T = \mathbf{D}. \quad (1)$$

où \mathbf{T} est la matrice unitaire triangulaire inférieure d'éléments $-C_{t,j}$ à la position (t, j) pour $t \in [2, p]$ et $j \in [1, t - 1]$, et \mathbf{D} est une matrice diagonale composée des entrées $\theta_t^2 = \text{var}(\epsilon_t)$, où $\epsilon_t = x_t - \hat{x}_t$ est l'erreur de prédiction pour $t \in [1, p]$.

Notons que pour $t = 1$, on a $\hat{x}_1 = E(x_1) = 0$, et alors, $\text{var}(\epsilon_1) = \theta_1^2 = E[(x_1)^2]$. Pour un échantillon $\{\mathbf{x}_i\}_{i \in [1, n]}$, avec $n > p$, une estimation traditionnelle de \mathbf{T} et \mathbf{D} , nommée comme $\hat{\mathbf{T}}_{OLS}$ et $\hat{\mathbf{D}}_{OLS}$ dans ce papier, est tout simplement donnée en remplaçant ses éléments par les régressions de coefficients et les variances résiduelles dans (1), respectivement. Dans ce papier, nous désignons le deuxième estimateur traditionnel par $\hat{\Sigma}_{OLS} = \hat{\mathbf{T}}_{OLS}^{-1} \hat{\mathbf{D}}_{OLS} \hat{\mathbf{T}}_{OLS}^{-T}$.

Évidemment, quand la dimension spectrale p est considérée grande par rapport au nombre total de données secondaires n , $\hat{\Sigma}_{SCM}$ et $\hat{\Sigma}_{OLS}$ rencontrent de grandes difficultés à estimer Σ sans un extrême nombre d'erreurs. Dans ce contexte, les chercheurs allègent souvent ce problème en proposant des techniques de régularisations pour estimer Σ d'une façon cohérente. Dans [3], Bickel *et al.* ont proposé une version *banded* de $\hat{\Sigma}_{SCM}$, notée comme $B_m(\hat{\Sigma}_{SCM}) = [\hat{\sigma}_{g,l} \mathbb{1}(|g-l| \leq m)]_{g,l}$ dans ce papier, où $\mathbb{1}(\cdot)$ est la fonction indicatrice et $0 \leq m < p$. Cependant, ce type de régularisation ne garantit pas la propriété que la matrice soit toujours définie positive, principalement dans les applications réelles. Dans [4], quelques opérateurs de seuillages ont été exploités sur les entrées (sauf la diagonale) de $\hat{\Sigma}_{SCM}$. Les opérateurs comme *Soft* et *SCAD* [5] appliqués sur $\hat{\Sigma}_{SCM}$, notés $\hat{\Sigma}_{SCM}^{Soft}$ et $\hat{\Sigma}_{SCM}^{SCAD}$ dans ce papier, ont l'avantage de faire conjointement du *shrinkage* et de seuillage et sont capables d'estimer les vrais zéros comme zéros avec une probabilité tendant vers 1. Cependant, ces opérateurs ne garantissent toujours pas la propriété que la matrice soit définie positive. Dans [6], la matrice de décomposition des valeurs propres de la matrice de covariance est représentée comme une *sparse matrix transform* (*SMT*). La matrice résultante estimée, notée comme $\hat{\Sigma}_{SMT}$ dans ce papier, est toujours définie positive.

En addition, quelques travaux ont été aussi développés afin d'imposer de la parcimonie sur la matrice de covariance à travers son

facteur de Cholesky \mathbf{T} . Dans [7], les auteurs ont décidé de lisser les premières sous-diagonales de $\hat{\mathbf{T}}_{OLS}$. Dans [8], Huang *et al.* ont proposé d'estimer directement une version parcimonieuse de \mathbf{T} en pénalisant le logarithme du maximum de vraisemblance de la matrice $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n] \in \mathbb{R}^{p \times n}$ par la norme L_1 [9]. Le principal avantage de [8] par rapport à [7] est que les zéros sont placés d'une façon irrégulière dans le facteur de Cholesky.

Le but principal de ce papier est, dans un premier temps, de supposer que la matrice de covariance inconnue est parcimonieuse et d'identifier, ensuite, cette parcimonie à travers son facteur de Cholesky \mathbf{T} afin d'évaluer les performances du détecteur d'anomalies de Kelly [10] en imagerie hyperspectrale. Le papier présente une discussion sur deux stratégies différentes qui exploitent la propriété de parcimonie. La première stratégie permet d'exploiter quelques techniques de seuillages déjà existantes comme *Soft* et *SCAD* sur $\hat{\mathbf{T}}_{OLS}$. La deuxième stratégie consiste à généraliser l'algorithme proposé dans [8] pour qu'il puisse être utilisé avec plusieurs fonctions de pénalités.

Clairement, en imagerie hyperspectrale réelle, la matrice de covariance Σ est complètement inconnue. L'hypothèse de parcimonie sur Σ semble être alors une contrainte très forte, mais le fait d'exploiter la possibilité que Σ est parcimonieuse, peut potentiellement permettre l'amélioration des performances de détection. D'un autre côté, si Σ n'est pas parcimonieuse, il ne devrait pas y avoir de résultats de détection plus mauvais que ceux des estimateurs traditionnels.

Nos estimateurs sont évalués sur quelques simulations de Monte-Carlo en utilisant le détecteur d'anomalies de Kelly [10]. Plus précisément, on considère trois modèles de matrices avec différents degrés de parcimonie. Pour les modèles parcimonieux, nos estimateurs améliorent la détection significativement par rapport aux celles des estimateurs traditionnels, et sont compétitifs aux estimateurs de l'état de l'art. Quand le modèle n'est pas parcimonieux, nos estimateurs ne détériorent pas la détection par rapport aux celles des estimateurs traditionnels et ce qui n'est pas le cas pour les estimateurs de l'état de l'art. En addition, nous allons remarquer que $\hat{\Sigma}_{OLS}$ donne toujours de meilleures détections que celles de $\hat{\Sigma}_{SCM}$.

3 Contributions principales

Avant de commencer à décrire les deux méthodes, on donne un petit récapitulatif sur $\hat{\Sigma}_{OLS}$. Pour un échantillon $\{\mathbf{x}_i\}_{i \in [1, n]}$, avec $n > p$, on a :

$$x_{i,t} = \sum_{j=1}^{t-1} C_{t,j} x_{i,j} + \epsilon_{i,t}, \quad t \in [2, p], \quad i \in [1, n]. \quad (2)$$

En écrivant (2) sous forme matricielle pour $t \in [2, p]$, on obtient le modèle de régression linéaire simple suivant :

$$\mathbf{y}_t = \mathbf{A}_{n,t} \boldsymbol{\beta}_t + \mathbf{e}_t \quad (3)$$

où $\mathbf{y}_t = (x_{1,t}, \dots, x_{n,t})^T \in \mathbb{R}^n$, $\mathbf{A}_{n,t} = [x_{i,j}]_{n \times (t-1)}$, $\boldsymbol{\beta}_t = (C_{t,1}, \dots, C_{t,t-1})^T \in \mathbb{R}^{(t-1)}$, $\mathbf{e}_t = (\epsilon_{1,t}, \dots, \epsilon_{n,t})^T \in \mathbb{R}^n$. En supposant que $n > p$, l'estimation OLS de $\boldsymbol{\beta}_t$ et sa variance

résiduelle correspondante sont remplacées dans \mathbf{T} et \mathbf{D} pour chaque $t \in [2, p]$, respectivement. On obtient finalement un deuxième estimateur traditionnel, noté dans ce papier comme $\hat{\Sigma}_{OLS} = \hat{\mathbf{T}}_{OLS}^{-1} \hat{\mathbf{D}}_{OLS} \hat{\mathbf{T}}_{OLS}^{-T}$. Notons que $\hat{\mathbf{T}}_{OLS}$ a $-\hat{C}_{t,j}^{OLS}$ dans la position (t, j) pour $t \in [2, p]$ et $j \in [1, t-1]$.

3.1 Seuillage basé sur le facteur de Cholesky \mathbf{T}

On définit l'opérateur du seuillage par $\text{th}(\cdot)$, et on note par $\text{th}(\hat{\mathbf{T}}_{OLS}) = \left[\text{th} \left(-\hat{C}_{t,j}^{OLS} \right) \right]_{p \times p}$ la matrice résultante après application de $\text{th}(\cdot) \in \{\text{Soft}, \text{SCAD}\}$ sur chaque élément de la matrice $\hat{\mathbf{T}}_{OLS}$ pour $t \in [2, p]$ et $j \in [1, t-1]$. On considère alors le problème de minimisation suivant :

$$\text{th}(\hat{\mathbf{T}}_{OLS}) = \underset{\mathbf{T}}{\text{argmin}} \sum_{t=2}^p \sum_{j=1}^{t-1} \left\{ \frac{1}{2} (\hat{C}_{t,j}^{OLS} - C_{t,j})^2 + p_\lambda \{|C_{t,j}|\} \right\} \quad (4)$$

où $\hat{\mathbf{T}}$ est la matrice unitaire triangulaire unitaire inférieure seuillée et $p_\lambda \in \{p_\lambda^{L1}, p_\lambda^{SCAD}\}$ avec $0 \leq \lambda \leq 1$ est défini soit par $p_\lambda^{L1}(|C_{t,j}|) = \lambda |C_{t,j}|$, soit par :

$$p_{\lambda, a > 2}^{SCAD}(|C_{t,j}|) = \begin{cases} \lambda |C_{t,j}| & |C_{t,j}| \leq \lambda \\ -\frac{|C_{t,j}|^2 - 2a\lambda |C_{t,j}| + \lambda^2}{2(a-1)} & \lambda < |C_{t,j}| \leq a\lambda \\ \frac{(a+1)\lambda^2}{2} & |C_{t,j}| > a\lambda \end{cases}$$

Les solutions de (4) avec p_λ^{L1} et $p_{\lambda, a > 2}^{SCAD}$ sont chacune de forme analytique [4], [5]. La valeur $a=3.7$ recommandée par Fan et Li [5] est utilisée dans la suite de ce papier. On désigne les deux matrices seuillées obtenues par $\hat{\mathbf{T}}_{Soft}$ et $\hat{\mathbf{T}}_{SCAD}$ qui appliquent le seuillage *Soft* et *SCAD* sur $\hat{\mathbf{T}}_{OLS}$, respectivement. On obtient finalement les deux premiers estimateurs :

$$\hat{\Sigma}_{OLS}^{Soft} = \hat{\mathbf{T}}_{Soft}^{-1} \hat{\mathbf{D}}_{OLS} \hat{\mathbf{T}}_{Soft}^{-T}$$

$$\hat{\Sigma}_{OLS}^{SCAD} = \hat{\mathbf{T}}_{SCAD}^{-1} \hat{\mathbf{D}}_{OLS} \hat{\mathbf{T}}_{SCAD}^{-T}$$

3.2 Généralisation de l'estimateur dans [8]

On présente le même principe que dans [8] mais en modifiant la procédure avec laquelle les entrées de \mathbf{T} ont été estimées. La vraisemblance logarithmique normale négative de \mathbf{X} est : $\Lambda = -2 \log(L(\Sigma, \mathbf{x}_1, \dots, \mathbf{x}_n)) = n \log(\det(\Sigma)) + \mathbf{X}^T \Sigma^{-1} \mathbf{X} = n \log(\det(\Sigma)) + (\mathbf{T} \mathbf{X})^T \mathbf{D}^{-1} (\mathbf{T} \mathbf{X})$.

En rappelant que $\epsilon = \mathbf{T} \mathbf{x}$, en sachant que $\det(\mathbf{T}) = 1$ et que $\Sigma = \mathbf{T}^{-1} \mathbf{D} \mathbf{T}^{-T}$, il s'ensuit que $\det(\Sigma) = \det(\mathbf{D}) = \prod_{t=1}^p \theta_t^2$, et que, de fait, $\Lambda = n \sum_{t=1}^p \log \theta_t^2 + \sum_{t=1}^p \sum_{i=1}^n \epsilon_{i,t}^2 / \theta_t^2$. En

appliquant la fonction pénalité $\sum_{t=2}^p \sum_{j=1}^{t-1} p_\alpha \{|C_{t,j}|\}$ à Λ , où $p_\alpha \in \{p_\alpha^{L1}, p_{\alpha, a > 2}^{SCAD}\}$ (voir la sous section 3.1), on obtient :

$$n \log \theta_1^2 + \sum_{i=1}^n \frac{\epsilon_{i,1}^2}{\theta_1^2} + \sum_{t=2}^p \left(n \log \theta_t^2 + \sum_{i=1}^n \frac{\epsilon_{i,t}^2}{\theta_t^2} + \sum_{j=1}^{t-1} p_\alpha \{|C_{t,j}|\} \right), \quad (5)$$

avec $\alpha \in [0, \infty)$. La minimisation de (5) par rapport à θ_1^2 et θ_t^2 conduit respectivement aux solutions $\hat{\theta}_1^2 = \frac{1}{n} \sum_{i=1}^n \epsilon_{i,1}^2 =$

$$\frac{1}{n} \sum_{i=1}^n x_{i,1}^2 \text{ et } \hat{\theta}_t^2 = \frac{1}{n} \sum_{i=1}^n \epsilon_{i,t}^2 = \frac{1}{n} \sum_{i=1}^n (x_{i,t} - \sum_{j=1}^{t-1} C_{t,j} x_{i,j})^2.$$

Il nécessite maintenant à estimer les entrées de \mathbf{T} . En minimisant (5) par rapport à β_t , et à partir des equations (1) et (2), on a pour chaque $t \in [2, p]$:

$$\begin{aligned} \hat{\beta}_t &= \underset{\beta_t}{\text{argmin}} \sum_{i=1}^n \frac{\epsilon_{i,t}^2}{\theta_t^2} + \sum_{j=1}^{t-1} p_\alpha \{|C_{t,j}|\} \\ &= \underset{\beta_t}{\text{argmin}} \frac{1}{\theta_t^2} \sum_{i=1}^n \left(x_{i,t} - \sum_{j=1}^{t-1} C_{t,j} x_{i,j} \right)^2 + \sum_{j=1}^{t-1} p_\alpha \{|C_{t,j}|\} \quad (6) \\ &= \underset{\beta_t}{\text{argmin}} \frac{1}{\theta_t^2} \|\mathbf{y}_t - \mathbf{A}_{n,t} \beta_t\|_F^2 + \sum_{j=1}^{t-1} p_\alpha \{|C_{t,j}|\} \end{aligned}$$

En notant $l(\beta_t) = \frac{1}{\theta_t^2} \|\mathbf{y}_t - \mathbf{A}_{n,t} \beta_t\|_F^2$ et $r(\beta_t) = \sum_{j=1}^{t-1} p_\alpha \{|C_{t,j}|\} = \sum_{j=1}^{t-1} r_j(C_{t,j})$, on résout β_t itérativement en utilisant l'algorithme

General Iterative Shrinkage and Thresholding (GIST) [11] :

$$\begin{aligned} \beta_t^{(k+1)} &= \underset{\beta_t}{\text{argmin}} l(\beta_t^{(k)}) + \frac{w^{(k)}}{2} \|\beta_t - \beta_t^{(k)}\|^2 \\ &\quad + r(\beta_t) + \left(\nabla l(\beta_t^{(k)}) \right)^T (\beta_t - \beta_t^{(k)}) \\ &= \underset{\beta_t}{\text{argmin}} \frac{1}{2} \|\beta_t - \mathbf{u}_t^{(k)}\|^2 + \frac{1}{w^{(k)}} r(\beta_t), \quad (7) \end{aligned}$$

où $\mathbf{u}_t^{(k)} = \beta_t^{(k)} - \nabla l(\beta_t^{(k)}) / w^{(k)}$, et où $w^{(k)}$ est la taille du pas (*step size*) initialisée par la règle de *Barzilai-Browein*.

En décomposant (7) en $(t-1)$ problèmes d'optimisation univariés indépendants, on obtient pour $j \in [1, t-1]$:

$$C_{t,j}^{(k+1)} = \underset{C_{t,j}}{\text{argmin}} \frac{1}{2} (C_{t,j} - u_{t,j}^{(k)})^2 + \frac{1}{w^{(k)}} r_j(C_{t,j}), \quad (8)$$

où $\mathbf{u}_t^{(k)} = (u_{t,1}^{(k)}, \dots, u_{t,t-1}^{(k)})^T$ et $r(\beta_t) = \sum_{j=1}^{t-1} r_j(C_{t,j})$. Ré-

soudre (8) avec la fonction de pénalité p_α^{L1} conduit à la solution analytique suivante :

$$C_{t,j}^{(k+1)} = \text{sign}(u_{t,j}^{(k)}) \max(0, |u_{t,j}^{(k)}| - \alpha / w^{(k)}). \quad (9)$$

Pour la fonction de pénalité SCAD, $p_{\alpha, a > 2}^{SCAD}$, la solution contient en fait trois parties qui correspondent à trois conditions différentes (voir la sous section 3.1). Dans ce cas, et en décomposant le problème (8) en trois sous problèmes de minimisation pour chaque condition, et après avoir résolu, on obtient les trois sous solutions $h_{t,j}^1$, $h_{t,j}^2$, and $h_{t,j}^3$:

$$\begin{aligned} h_{t,j}^1 &= \text{sign}(u_{t,j}^{(k)}) \min \left(\alpha, \max \left(0, |u_{t,j}^{(k)}| - \alpha / w^{(k)} \right) \right), \\ h_{t,j}^2 &= \text{sign}(u_{t,j}^{(k)}) \min \left(a\alpha, \max \left(\alpha, \frac{w^{(k)} |u_{t,j}^{(k)}| (a-1) - a\alpha}{w^{(k)} (a-2)} \right) \right), \\ h_{t,j}^3 &= \text{sign}(u_{t,j}^{(k)}) \max \left(a\alpha, |u_{t,j}^{(k)}| \right). \end{aligned}$$

On obtient alors la solution analytique suivante :

$$\begin{aligned} C_{t,j}^{(k+1)} &= \underset{q_{t,j}}{\text{argmin}} \frac{1}{2} (q_{t,j} - u_{t,j}^{(k)})^2 + \frac{1}{w^{(k)}} r_j(q_{t,j}) \quad (10) \\ &\text{s.t. } q_{t,j} \in \{h_{t,j}^1, h_{t,j}^2, h_{t,j}^3\}. \end{aligned}$$

| HSIs | Σ_{TRUE} | $\hat{\Sigma}_{SCM}$ | $\hat{\Sigma}_{OLS}$ | $\hat{\Sigma}_{OLS}^{\text{Soft}}$ | $\hat{\Sigma}_{OLS}^{\text{SCAD}}$ | $\hat{\Sigma}_{L_1}$ | $\hat{\Sigma}_{SCAD}$ | $\hat{\Sigma}_{SMT}$ | $B_k(\hat{\Sigma}_{SCM})$ | $\hat{\Sigma}_{Soft}^{SCM}$ | $\hat{\Sigma}_{SCAD}^{SCM}$ |
|-----------------|------------------------|----------------------|----------------------|------------------------------------|------------------------------------|----------------------|-----------------------|----------------------|---------------------------|-----------------------------|-----------------------------|
| Modèle 1 | 0.9541 | 0.7976 | 0.8331 | 0.9480 | 0.9480 | 0.9509 | 0.9509 | 0.9503 | 0.9509 | 0.9509 | 0.9509 |
| Modèle 2 | 0.9540 | 0.7977 | 0.8361 | 0.9124 | 0.9124 | 0.9264 | 0.9264 | 0.9184 | 0.9478 | 0.9274 | 0.9270 |
| Modèle 3 | 0.9541 | 0.7978 | 0.8259 | 0.8169 | 0.8257 | 0.8236 | 0.8261 | 0.7798 | 0.5321 | 0.5969 | 0.5781 |

Table 1. Une liste des valeurs AUC pour les estimateurs $\hat{\Sigma}_{OLS}^{\text{Soft}}$, $\hat{\Sigma}_{OLS}^{\text{SCAD}}$, $\hat{\Sigma}_{L_1}$, $\hat{\Sigma}_{SCAD}$ comparées avec des autres.

On désigne nos deux seconds estimateurs comme suit :

$$\hat{\Sigma}_{L_1} = \hat{\mathbf{T}}_{L_1}^{-1} \hat{\mathbf{D}} \hat{\mathbf{T}}_{L_1}^{-T}$$

$$\hat{\Sigma}_{SCAD} = \hat{\mathbf{T}}_{SCAD}^{-1} \hat{\mathbf{D}} \hat{\mathbf{T}}_{SCAD}^{-T}$$

où $\hat{\mathbf{T}}_{L_1}$ et $\hat{\mathbf{T}}_{SCAD}$ contiennent respectivement $-\hat{C}_{t,j,(L_1)}$ et $-\hat{C}_{t,j,(SCAD)}$ dans la position (t, j) pour $t \in [2, p]$ et $j \in [1, t-1]$, tandis que $\hat{\mathbf{D}}$ contient $(\hat{\theta}_1^2, \hat{\theta}_t^2)$ sur la diagonale. Notons que dans [8], les auteurs ont utilisé l'approximation Locale Quadratique Linéaire (LQA) de la norme L_1 afin d'obtenir une solution analytique pour β_t dans (6). L'algorithme proposé est maintenant plus général car il exploite l'algorithme de *GIST* pour résoudre (6). Il peut être facilement être étendu à d'autres fonctions de pénalités comme *SCAD*, *Capped-L1*, *Log Sum*, etc. et toutes possèdent des solutions analytiques [11]. Ce papier présente seulement les fonctions de pénalités L_1 et *SCAD*.

4 La détection d'anomalies

On considère le modèle du signal suivant :

$$\begin{cases} H_0 : \mathbf{x} = \mathbf{n}, & \mathbf{x}_i = \mathbf{n}_i, \quad i = 1, \dots, n \\ H_1 : \mathbf{x} = \gamma \mathbf{d} + \mathbf{n}, & \mathbf{x}_i = \mathbf{n}_i, \quad i = 1, \dots, n \end{cases} \quad (11)$$

où $\mathbf{n}_1, \dots, \mathbf{n}_n$ sont n vecteurs i.i.d. caractérisant les données *secondaires* et distribués selon la loi normale $\mathcal{N}(\mathbf{0}_p, \Sigma)$. Le vecteur \mathbf{d} caractérise l'information spectrale "inconnue" de l'anomalie à détecter et $\gamma > 0$ désigne son amplitude, également inconnue. Le détecteur du Maximum de Vraisemblance généralisé (GLRT) optimal pour le test d'hypothèses présenté constitue le détecteur de *Kelly* [10] et est décrit par :

$$D_{\text{KellyAD}\hat{\Sigma}}(\mathbf{x}) = \mathbf{x}^T \hat{\Sigma}_{SCM}^{-1} \mathbf{x} \underset{H_0}{\overset{H_1}{\geq}} \delta, \quad (12)$$

où δ est un seuil de détection fixée par la probabilité de Fausse Alarme. La matrice $\hat{\Sigma}_{SCM}$ peut être remplacée par un autre estimateur. On parle alors de *two-step* GLRT.

Les expérimentations suivantes sont effectuées sur trois modèles de matrices de covariance :

- Modèle 1 : $\Sigma = \mathbf{I}$, la matrice identité,
- Modèle 2 : le modèle autorégressif d'ordre 1, AR(1), $\Sigma = [\sigma_{gl}]_{p \times p}$, où $\sigma_{gl} = c^{|g-l|}$, pour $c = 0.3$,
- Modèle 3 : $\Sigma = [\sigma_{gl}]_{p \times p}$, où $\sigma_{gl} = (1 - (|g-l|/r))_+$, pour $r = p/2$: la matrice triangulaire.

Le Modèle 1 est très parcimonieux, le Modèle 2 est relativement parcimonieux, tandis que le Modèle 3 avec $r = p/2$ peut-être considéré le moins parcimonieux des trois modèles considérés [4].

Les performances du détecteur de Kelly construit avec les estimateurs $\hat{\Sigma}_{OLS}^{\text{Soft}}$, $\hat{\Sigma}_{OLS}^{\text{SCAD}}$, $\hat{\Sigma}_{L_1}$ et $\hat{\Sigma}_{SCAD}$ sont évaluées dans le tableau 1 par les valeurs de l'aire sous la courbe Pd-Pfa (en Anglais "*Area Under Curve (AUC) values*") pour un rapport signal sur bruit égal à 15 dB. Les estimateurs utilisés pour la comparaison sont : $\hat{\Sigma}_{SCM}$, $\hat{\Sigma}_{OLS}$, $\hat{\Sigma}_{SMT}$ [6], $B_k(\hat{\Sigma}_{SCM})$ [3], $\hat{\Sigma}_{SCM}^{\text{Soft}}$ [4], et $\hat{\Sigma}_{SCM}^{\text{SCAD}}$ [4]. Une procédure de validation logarithmique croisée [8] est mise en œuvre pour fixer les paramètres λ (sous section 3.1) et α (sous section 3.2).

Toutes les valeurs dans le tableau 1 sont calculées à partir de 10^5 tirages de Monte-Carlo. On choisit $n = 80$ données secondaires pour l'estimation de la matrice de covariance sous l'hypothèse Gaussienne, et le nombre de bandes spectrales $p = 60$. L'anomalie artificielle considérée est un vecteur contenant des nombres pseudo-aléatoires normalement distribués (le même vecteur est utilisé pour les trois modèles).

Les plus grandes valeurs de AUC pour chaque modèle apparaissent en gras dans le tableau 1. Les résultats obtenus démontrent que pour les modèles parcimonieux (Modèle 1 et 2), nos estimateurs $\{\hat{\Sigma}_{OLS}^{\text{Soft}}, \hat{\Sigma}_{OLS}^{\text{SCAD}}, \hat{\Sigma}_{L_1}, \hat{\Sigma}_{SCAD}\}$ améliorent significativement la détection par rapport aux estimateurs classiques $\{\hat{\Sigma}_{SCM}, \hat{\Sigma}_{OLS}\}$, et ayant des résultats compétitifs aux estimateurs de l'état de l'art $\hat{\Sigma}_{SMT}$, $B_k(\hat{\Sigma}_{SCM})$, $\hat{\Sigma}_{SCM}^{\text{Soft}}$, $\hat{\Sigma}_{SCM}^{\text{SCAD}}$. Le résultat le plus important est que même si le modèle n'est pas parcimonieux (Modèle 3), nos estimateurs ne détériorent pas la détection par rapport à celles des estimateurs traditionnels. Cependant, bien que $\hat{\Sigma}_{OLS}^{\text{Soft}}$, $\hat{\Sigma}_{OLS}^{\text{SCAD}}$ et $\hat{\Sigma}_{L_1}$, ont une très légère détérioration de détection par rapport à celle de $\hat{\Sigma}_{OLS}$, cette détérioration est encore acceptable et donc on peut l'ignorer. D'un autre côté, on remarque que $B_k(\hat{\Sigma}_{SCM})$, $\hat{\Sigma}_{SCM}^{\text{Soft}}$ and $\hat{\Sigma}_{SCM}^{\text{SCAD}}$ présentent une très grande détérioration de détection par rapport aux estimateurs traditionnels, et donc ceci démontre le principal avantage de nos estimateurs par rapport à ceux de l'état de l'art.

Pour les trois modèles considérés, on remarque que $\hat{\Sigma}_{OLS}$ donne toujours de meilleures détections que celles de $\hat{\Sigma}_{SCM}$.

Références

- [1] D. Manolakis, D. Marden, and G. Shaw, "Hyperspectral image processing for automatic target detection applications," *Lincoln Laboratory Journal*, vol. 14, no. 1, pp. 79–116, 2003.
- [2] M. Pourahmadi, "Joint mean-covariance models with applications to longitudinal data : unconstrained parameterisation," *Bio-metrika*, vol. 86, no. 3, pp. 677–690, 1999.
- [3] P. J. Bickel and E. Levina, "Regularized estimation of large covariance matrices," *The Annals of Statistics*, vol. 36, no. 1, pp.

199–227, 2008.

- [4] A. J. Rothman, E. Levina, and J. Zhu, “Generalized thresholding of large covariance matrices,” *Journal of the American Statistical Association*, vol. 104, no. 485, pp. 177–186, 2009.
- [5] J. Fan and R. Li, “Variable selection via nonconcave penalized likelihood and its oracle properties,” *Journal of the American Statistical Association*, vol. 96, no. 456, pp. 1348–1360, 2001.
- [6] G. Cao and C. Bouman, “Covariance estimation for high dimensional data vectors using the sparse matrix transform,” in *Advances in Neural Information Processing Systems 21*. Curran Associates, Inc., 2009, pp. 225–232.
- [7] W. B. Wu and M. Pourahmadi, “Nonparametric estimation of large covariance matrices of longitudinal data,” *Biometrika*, vol. 90, no. 4, p. 831, 2003. [Online]. Available : + <http://dx.doi.org/10.1093/biomet/90.4.831>
- [8] J. Z. Huang, N. Liu, M. Pourahmadi, and L. Liu, “Covariance matrix selection and estimation via penalised normal likelihood,” *Biometrika*, vol. 93, no. 1, pp. 85–98, 2006.
- [9] R. Tibshirani, “Regression shrinkage and selection via the lasso.” *Journal of the Royal Statistical Society. Series B (Methodological)*, vol. 58, no. 1, pp. 267–288, 1996.
- [10] E. J. Kelly, “An adaptive detection algorithm,” *Aerospace and Electronic Systems, IEEE Transactions on*, vol. 23, no. 1, pp. 115–127, November 1986.
- [11] P. Gong, C. Zhang, Z. Lu, J. Huang, and J. Ye, “Gist : General iterative shrinkage and thresholding for non-convex sparse learning,” 2013.