

Détermination du nombre optimal de composantes dans l'Analyse en Composantes Indépendantes

Amine Kassouf ¹ Delphine Jouan-Rimbaud Bouveresse ^{2,3} Douglas N. Rutledge²

¹ Département de Chimie et de Biochimie, Faculté des Sciences II, Université Libanaise, 90656 Jdeideth El Matn, Fanar, Liban.

² UMR Ingénierie Procédés Aliments, AgroParisTech, INRA, Université Paris-Saclay, F-91300 Massy, France.

³ UMR 914 Physiologie de la Nutrition et du Comportement Alimentaire, INRA, AgroParisTech, Université Paris-Saclay, F-75005 Paris





Plan

- Introduction
- Aperçu théorique
 - ICA_by_blocks
 - Random_ICA
 - Critère de Durbin-Watson: DW_Residuals
 - Indice de Kaiser-Meyer-Olkin: KMO_ICA_Residuals
 - ICA_corr_y
- Applications
- Conclusion

- **Analyse en composantes indépendantes (ICA):** technique de séparation en aveugle de sources.
- Elle consiste à estimer F signaux sources, statistiquement indépendants, à partir de n signaux observés, considérés comme étant des combinaisons linéaires de ces signaux sources.

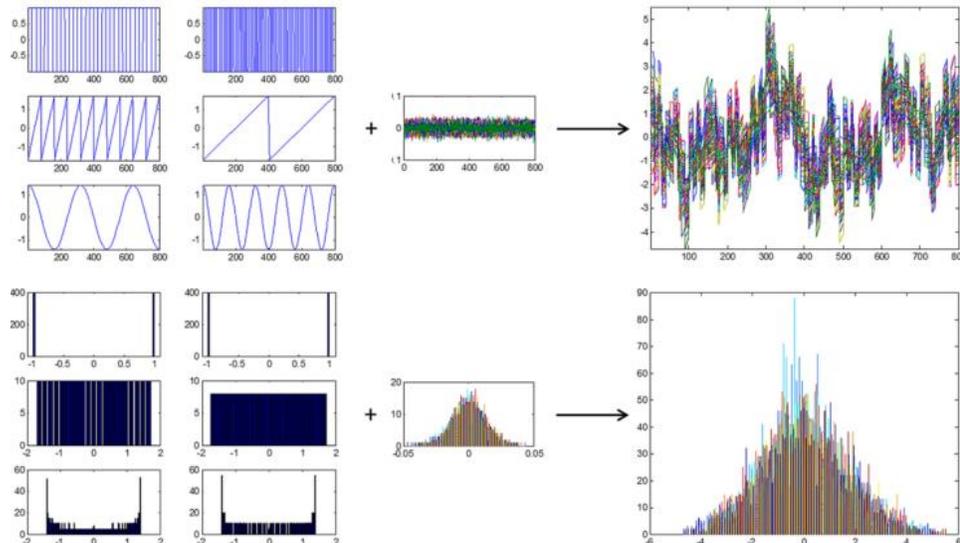
Modèle général

$$X = A.S$$

X: matrice des signaux observés

A: matrice des proportions

S: matrice des signaux "sources" (ICs)

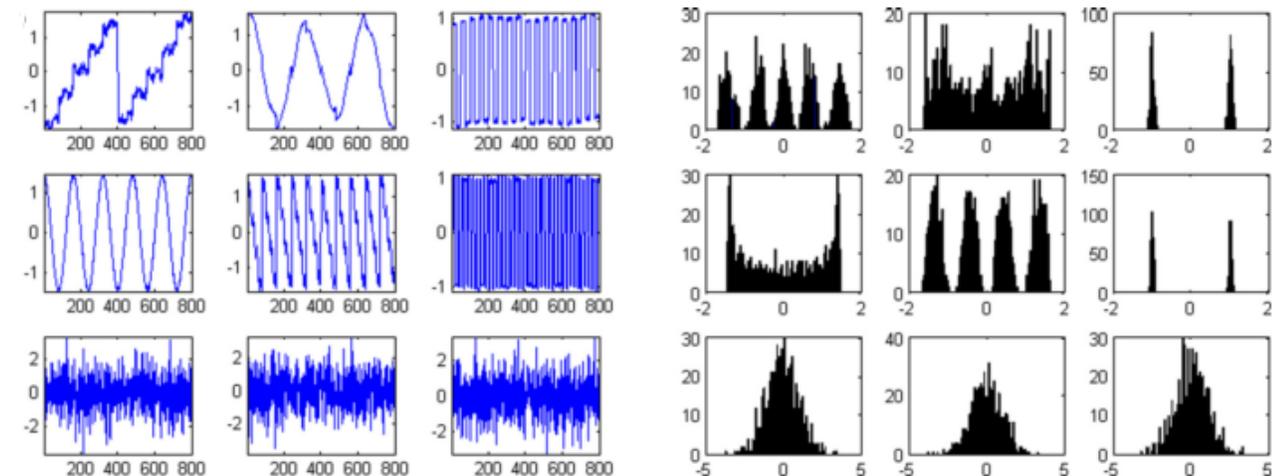


ICA

(JADE algorithm)

ICA cherche à estimer les signaux sources (ICs) par une transformation linéaire visant à maximiser l'indépendance entre les signaux extraits, en maximisant leur caractère **non-gaussien** (Théorème Central Limit).

ICA
→





Introduction

Pourquoi déterminer le nombre optimal de composantes indépendantes (ICs)



- Les ICs ne sont pas classées par ordre d'importance.
- Calculer trop peu d'ICs → des signaux non-purs.
- Extraire trop d'ICs → sur-décomposition des signaux / introduction de bruit.



ICA_by_blocks

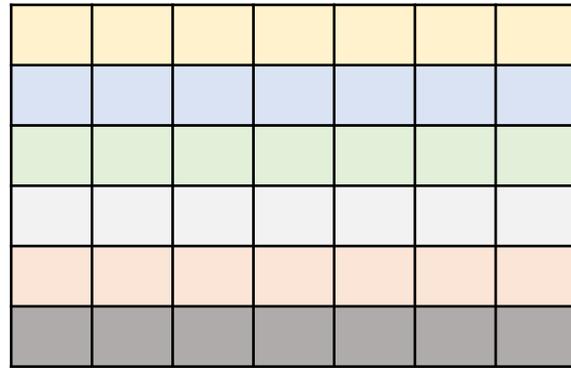
Random_ICA

DW_Residuals

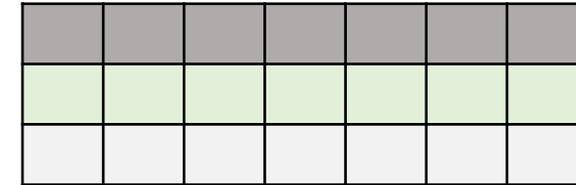
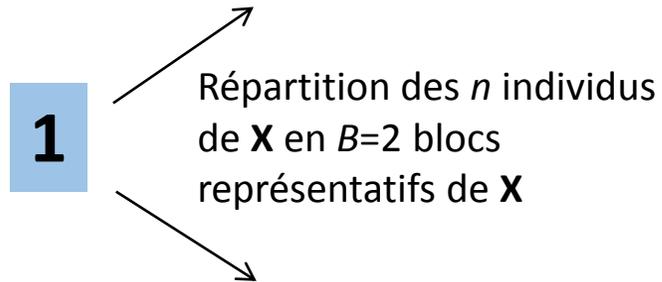
KMO_ICA_Residuals

ICA_corr_y

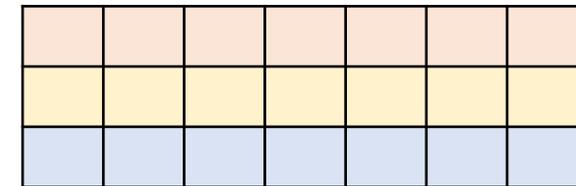
Aperçu théorique: ICA_by_blocks



$X(n,p)$



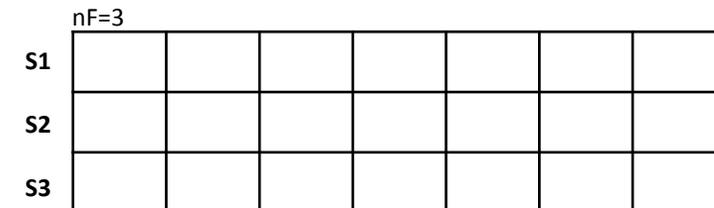
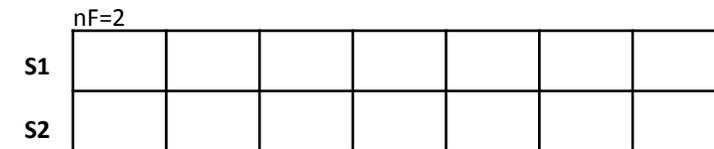
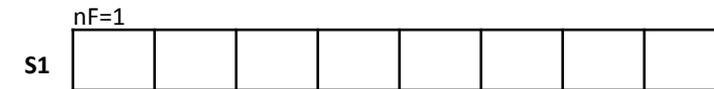
$B1(n/2,p)$



$B2(n/2,p)$

2

Pour chaque bloc, F_{max} modèles ICA sont calculés avec $nF=1;2;3...F_{max}$ ICs



	S1 (B1)	S2 (B1)	S1 (B2)	S2 (B2)
S1 (B1)			~0	~1
S2 (B1)			~1	~0
S1 (B2)				
S2 (B2)				

3 Les corrélations entre les ICs extraites des deux blocs sont calculées

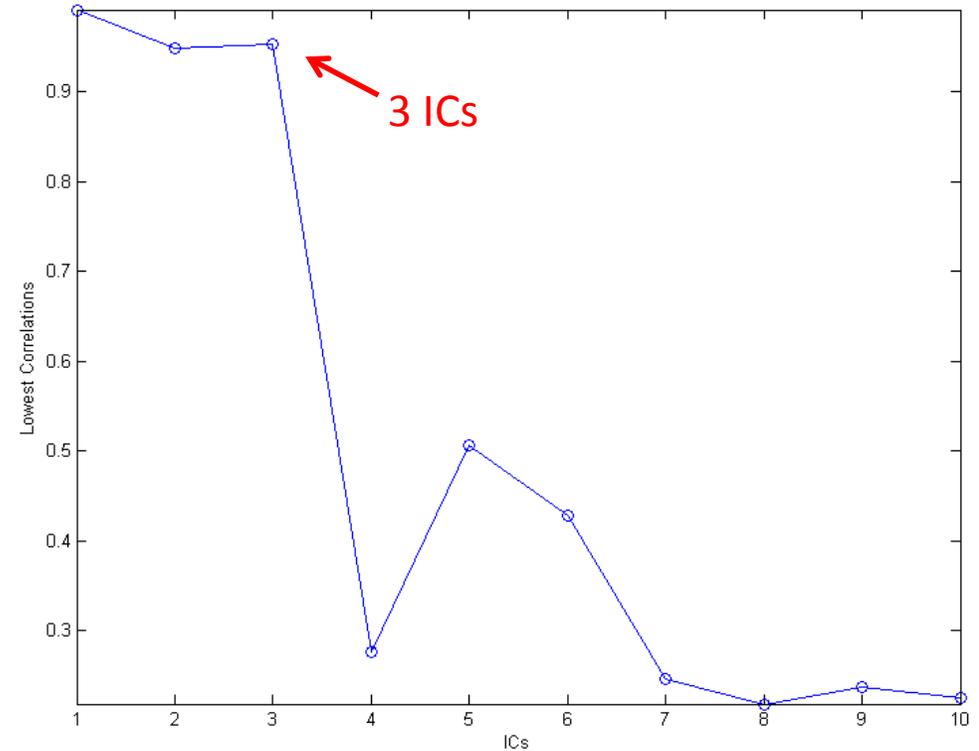
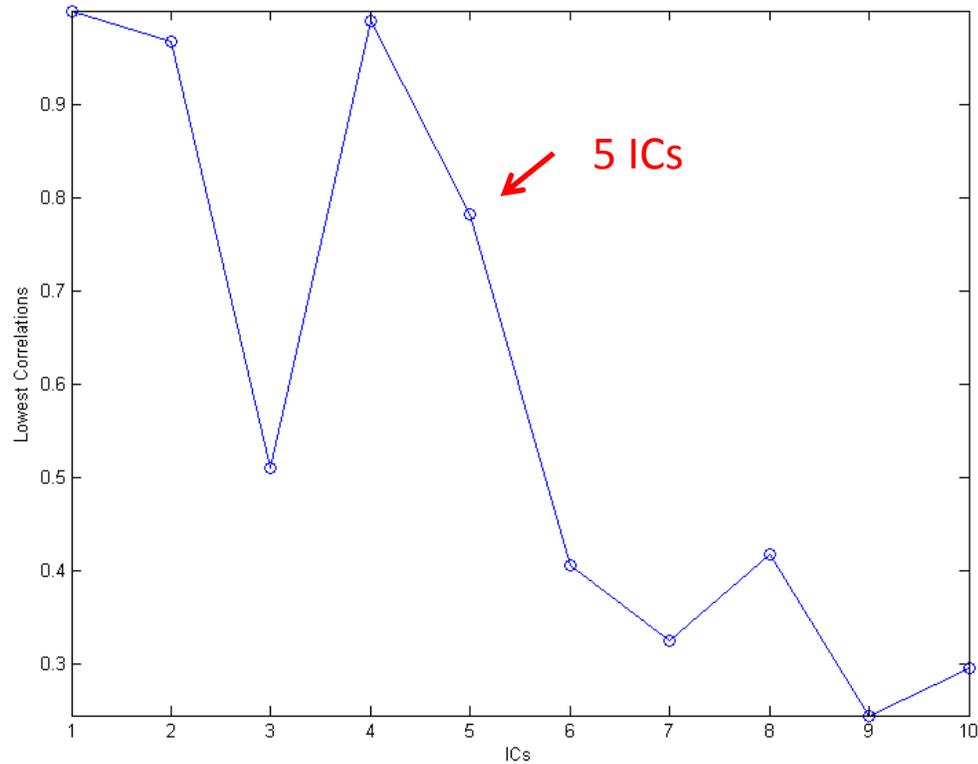
4 Le modèle donnant le plus grand nombre d'ICs corrélées indique le nombre optimal d'ICs

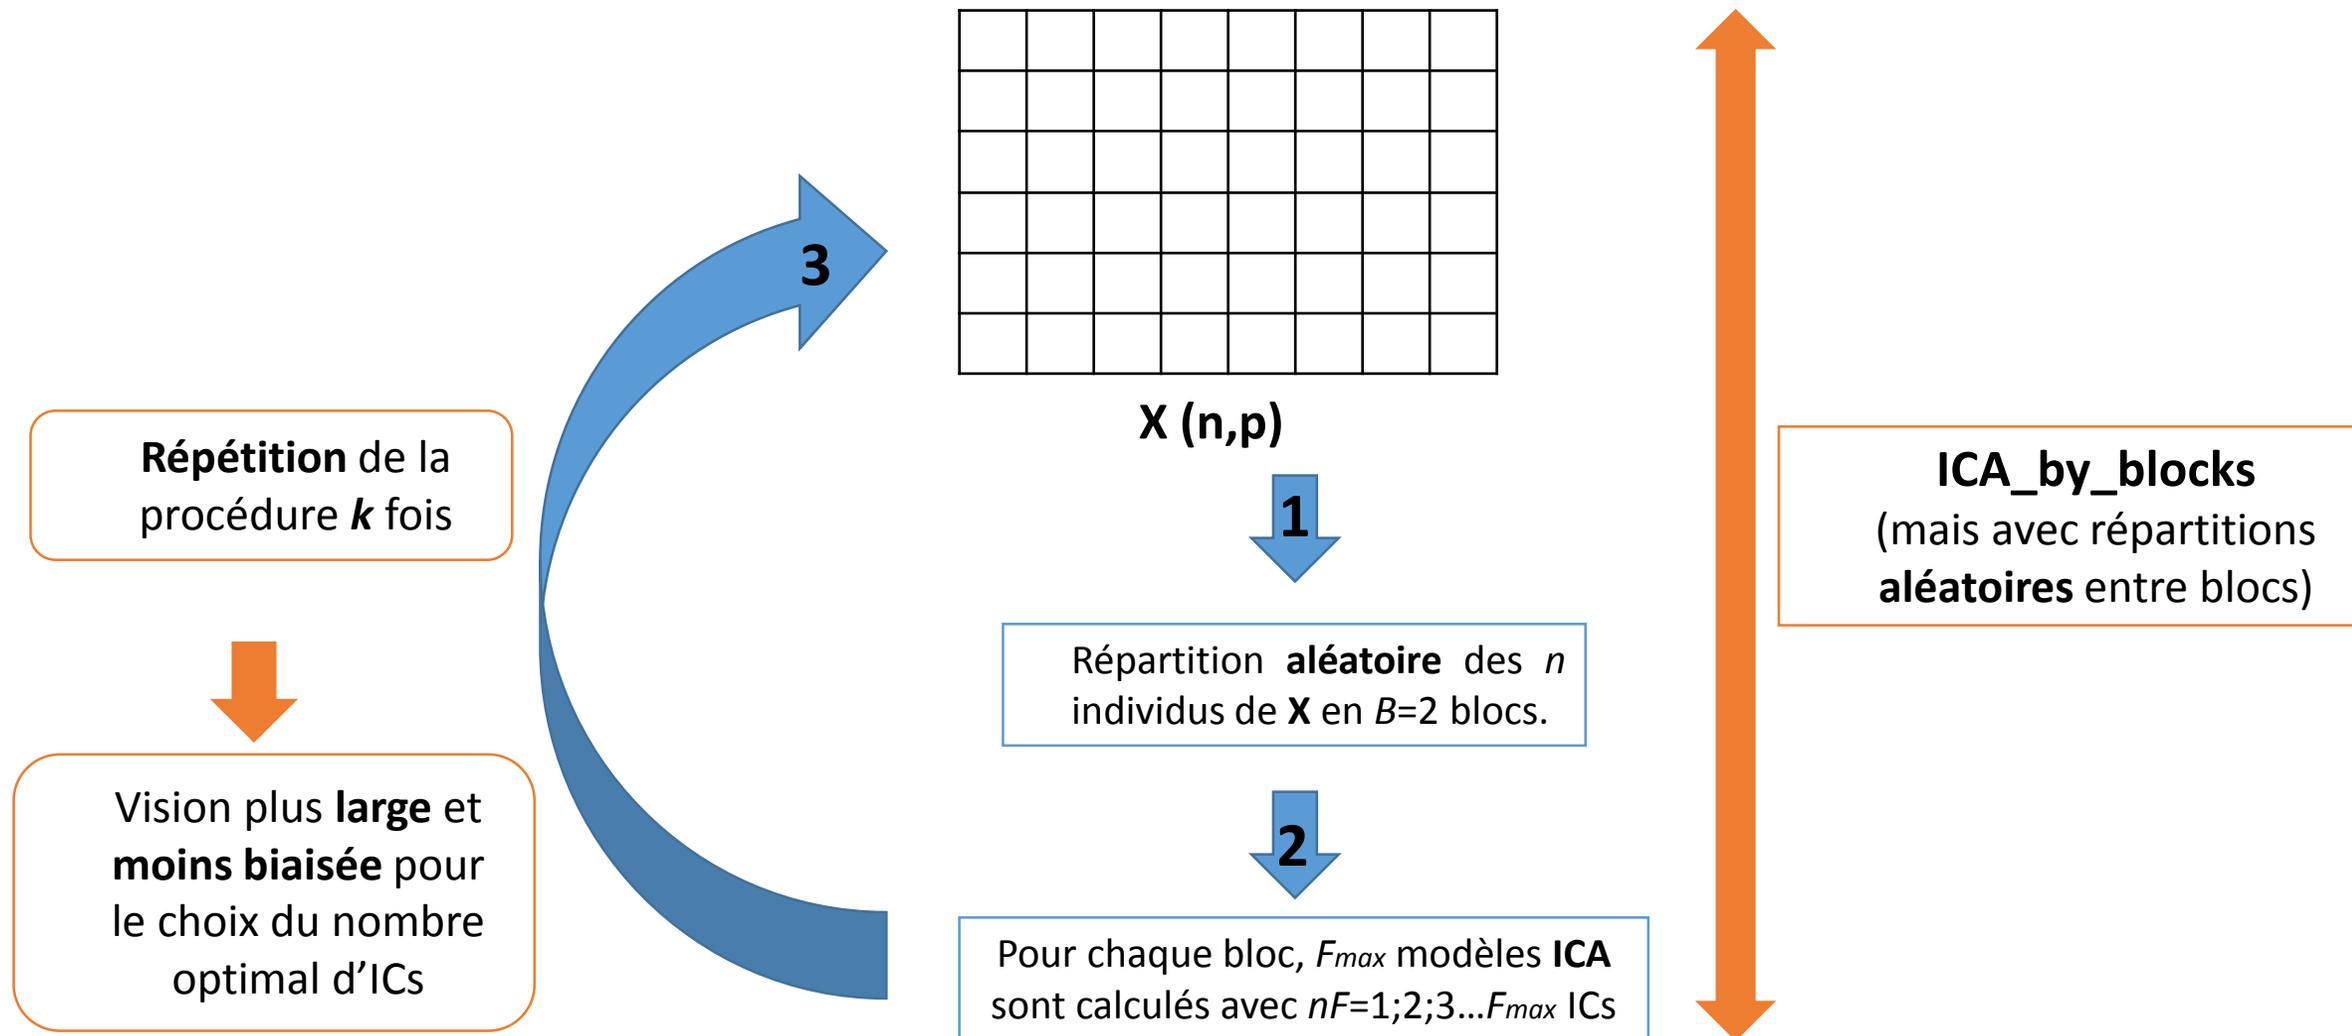


Problème avec la méthode

Lignin data (58 × 260)

ICA_by_Blocks, B = 2

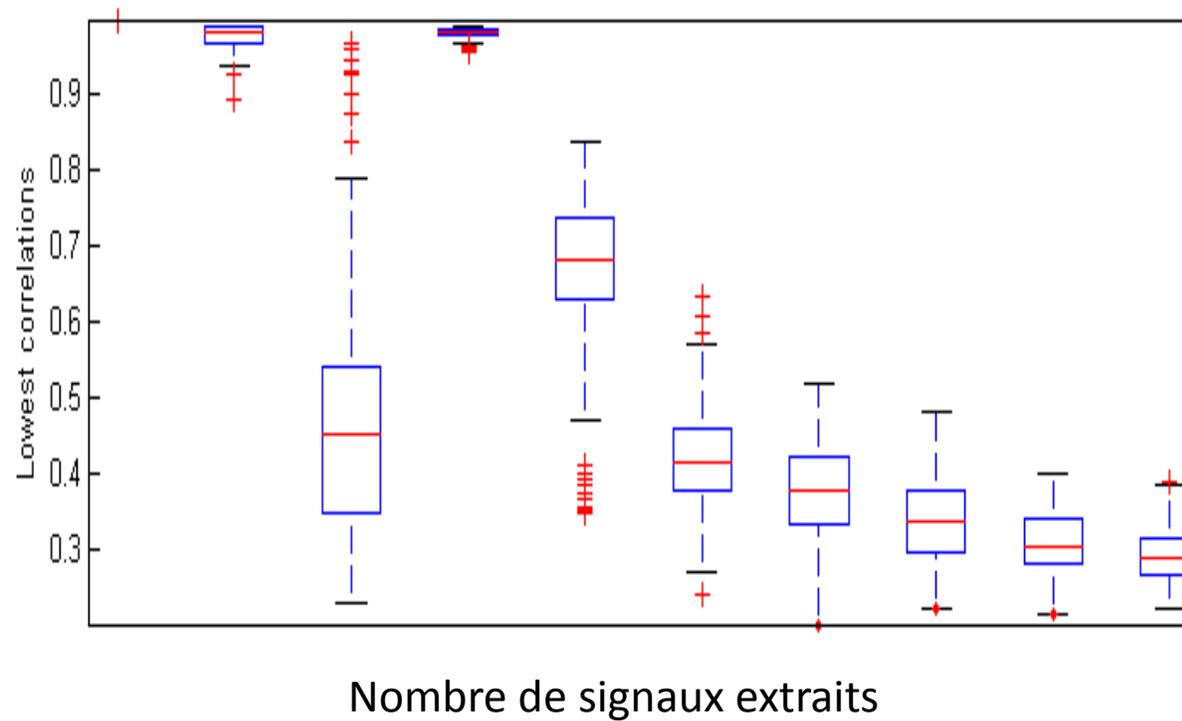






Random_ICA avec 100 répétitions

Lignin data (58 × 260)





Aperçu théorique: Critère de Durbin-Watson

Jouan-Rimbaud Bouveresse et al. *Chem. Intell. Lab. Syst.* 2012

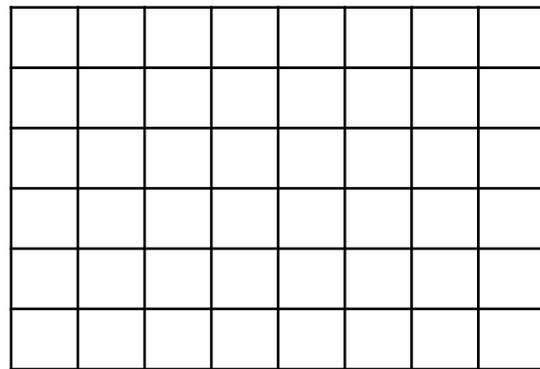
Critère de Durbin-Watson (DW)

$$DW = \frac{\sum_{i=2}^n (s(i) - s(i-1))^2}{\sum_{i=1}^n s(i)^2}$$

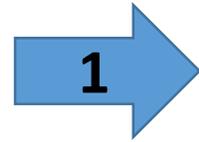
s est un signal, s(i) est le i^{ème} point du signal

- DW tend vers 0 s'il n'y a pas de bruit dans le signal
- DW tend vers 2 s'il n'y a que du bruit dans le signal

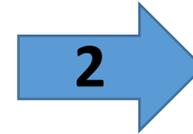
Aperçu théorique: Critère de Durbin-Watson



$X(n,p)$



F_{max} modèles ICA
sont calculés avec
 $nF=1;2;3...F_{max}$ ICs



Pour chaque modèle ICA:

Matrice résiduelle
 $R = (X - (AS))$



Calcul du critère DW pour chaque signal résiduel (ligne de R)

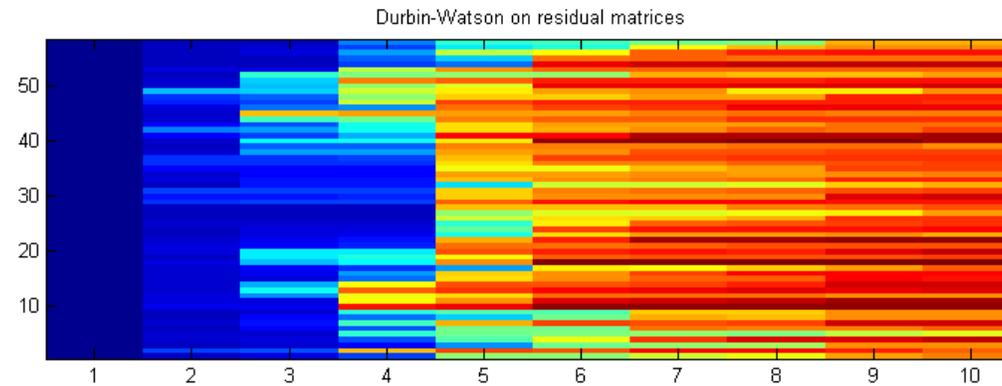
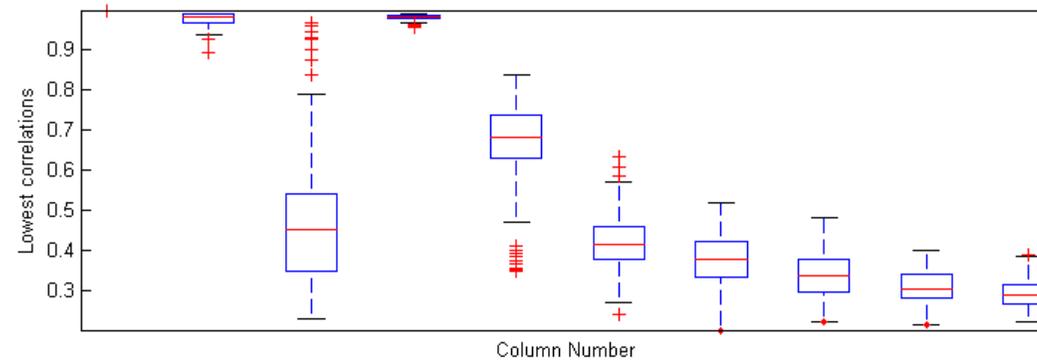


On suit l'évolution des critères DW en fonction du nombre d'ICs dans le modèle



Durbin-Watson

Lignin data (58×260)



Nombre de signaux extraits

Indice de Kaiser-Meyer-Olkin :

$$KMO = \frac{\sum_i \sum_{j \neq i} r_{ij}^2}{\sum_i \sum_{j \neq i} r_{ij}^2 + \sum_i \sum_{j \neq i} a_{ij}^2}$$

$$a_{ij} = -\frac{v_{ij}}{\sqrt{v_{ii} + v_{jj}}}$$

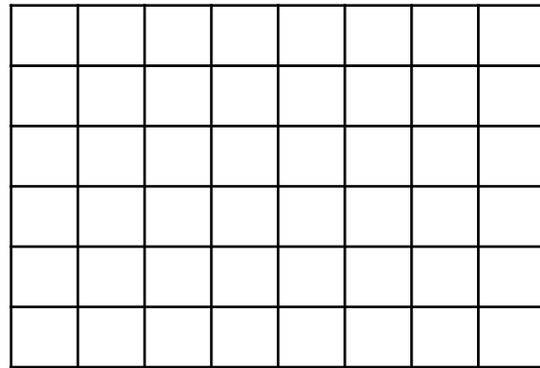
$$0 \leq KMO \leq 1$$

r_{ij} : corrélation entre les variables i et j

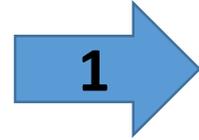
a_{ij} : corrélation partielle entre les variables i et j

- $KMO \approx 0$: Il n'y a pas de corrélation entre les variables
- $KMO \approx 1$: Les variables sont corrélées

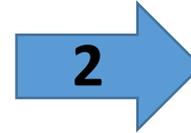
L'indice KMO est utilisé pour déterminer s'il est utile d'appliquer une Analyse en Composantes Principales à un jeu de données.



$X(n,p)$



1
 F_{max} modèles ICA
 sont calculés avec
 $nF=1;2;3...F_{max}$ ICs



Pour chaque modèle ICA:
 Matrice résiduelle
 $R = (X - (AS))^T$



Calcul de l'indice KMO
 →
 Corrélations partielles entre
 les signaux résiduels



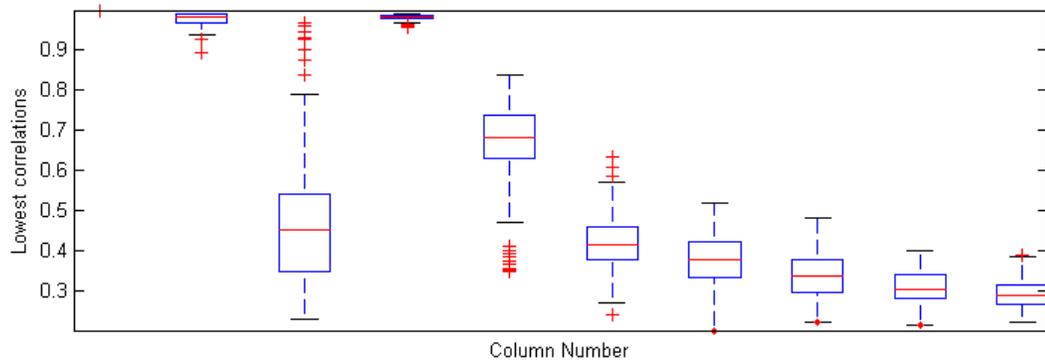
- Indice KMO **proche de 0.5**: pas de corrélations entre les colonnes = tous les signaux sources sont déjà extraits.
- Indice KMO **proche de 1**: il reste encore des signaux sources dans la matrice résiduelle.

↓

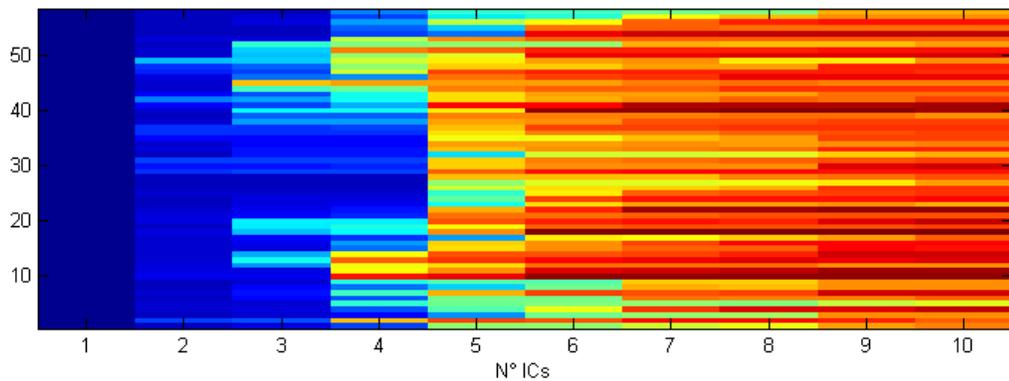
Nombre optimal d'ICs

KMO_ICA_Residuals

Lignin data (58 × 260)

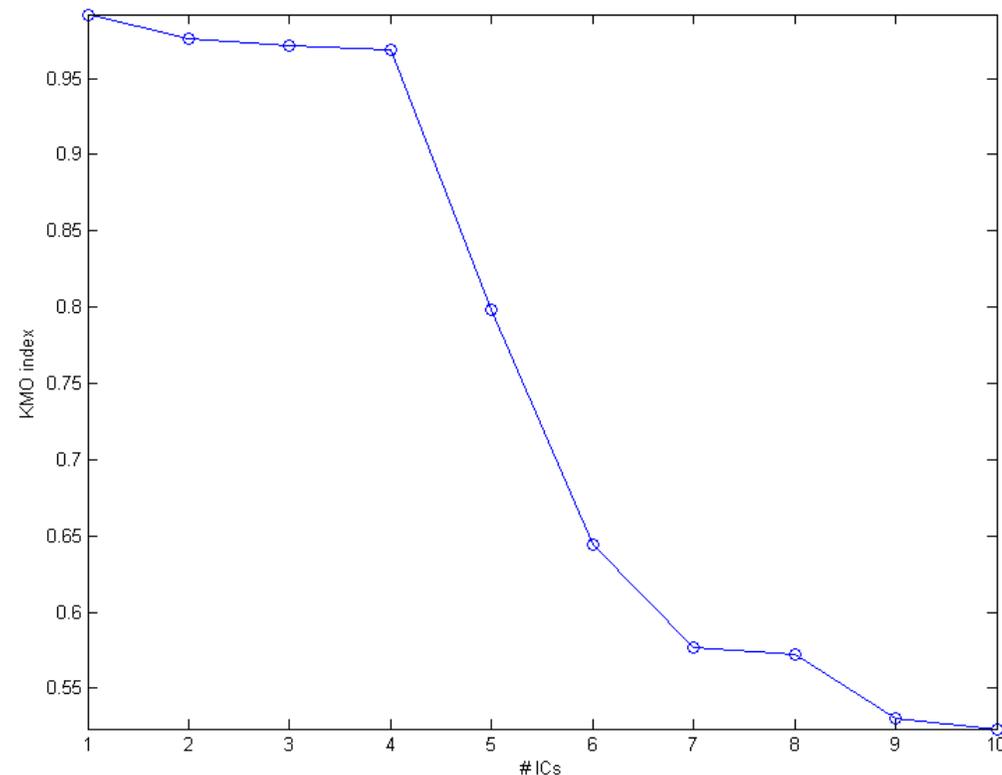


Durbin-Watson on residual matrices

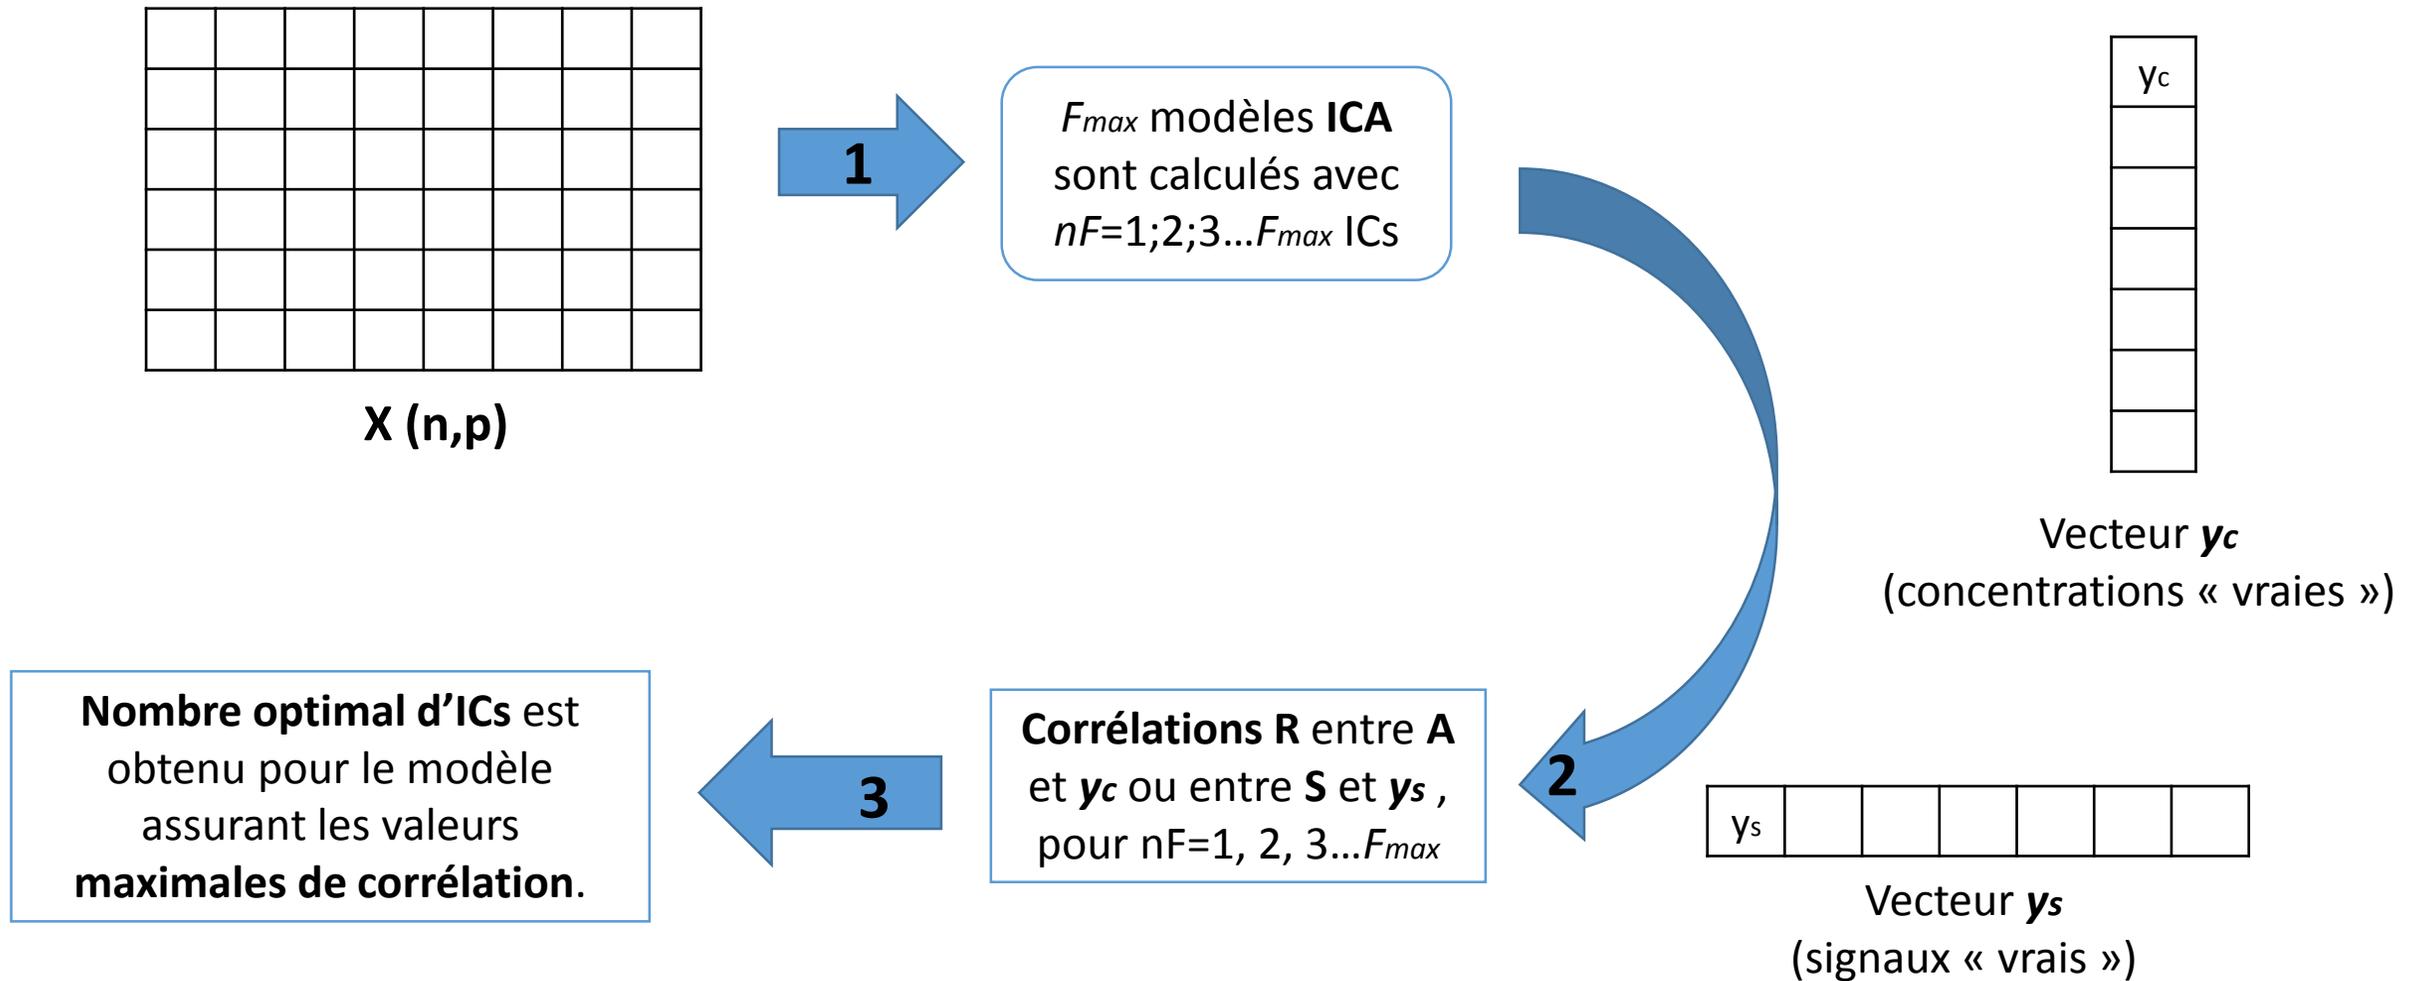


Nombre de signaux extraits

KMO

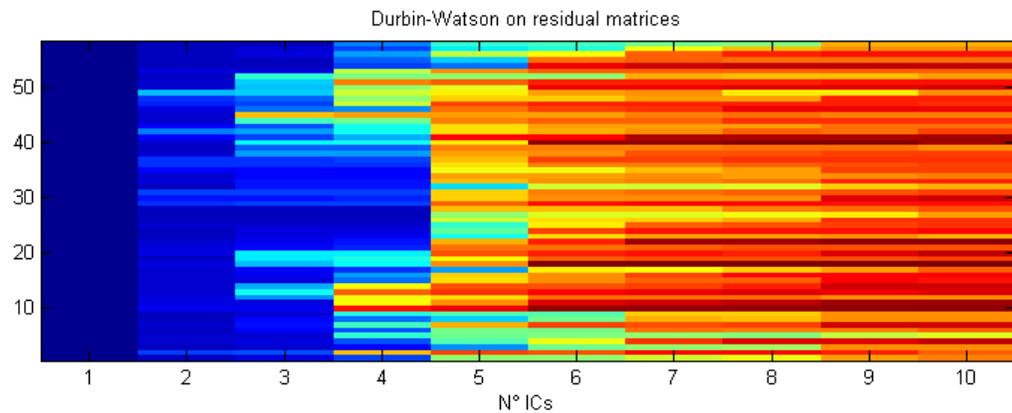
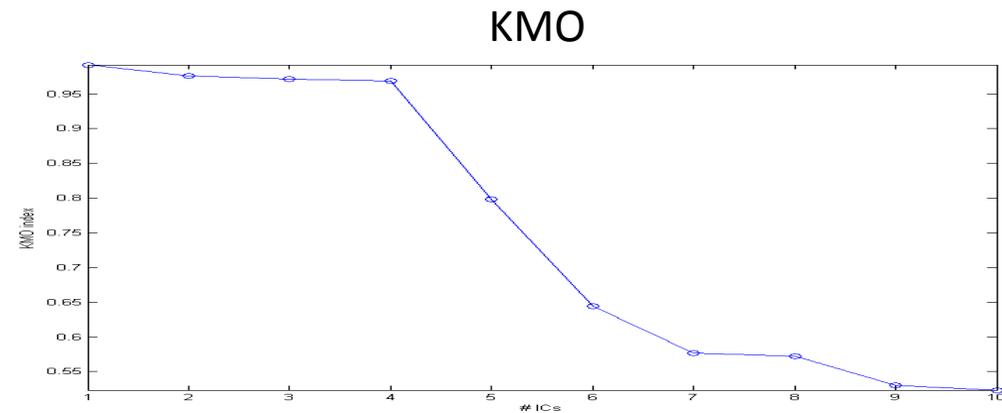
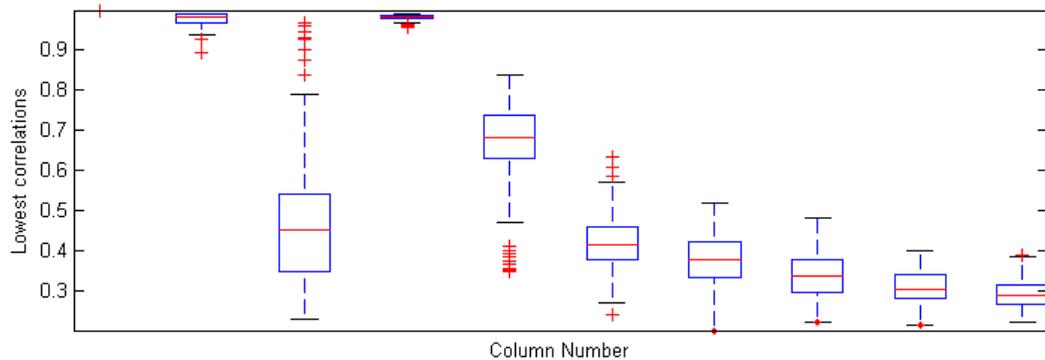


Nombre de signaux extraits

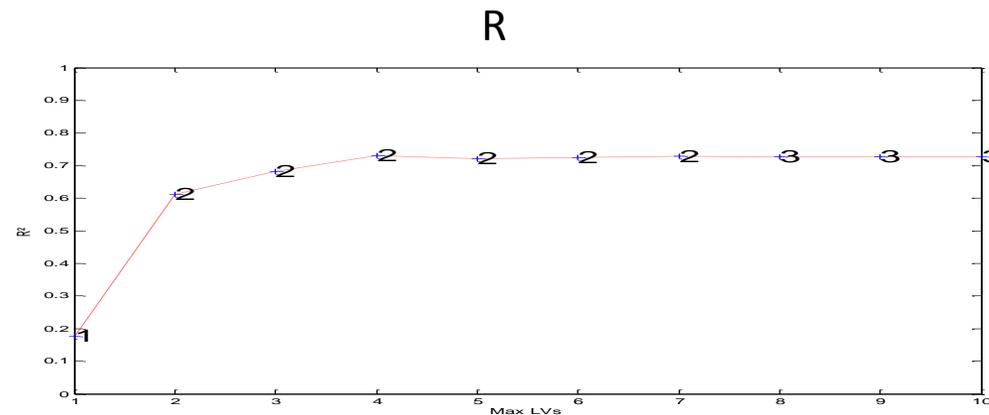


ICA_corr_y

Lignin data (58 × 260)

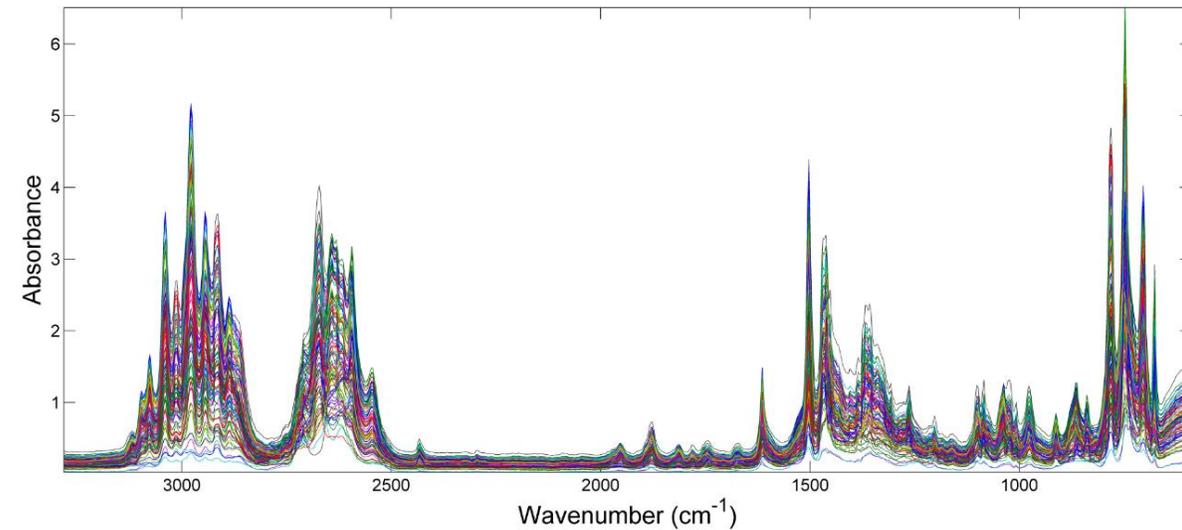
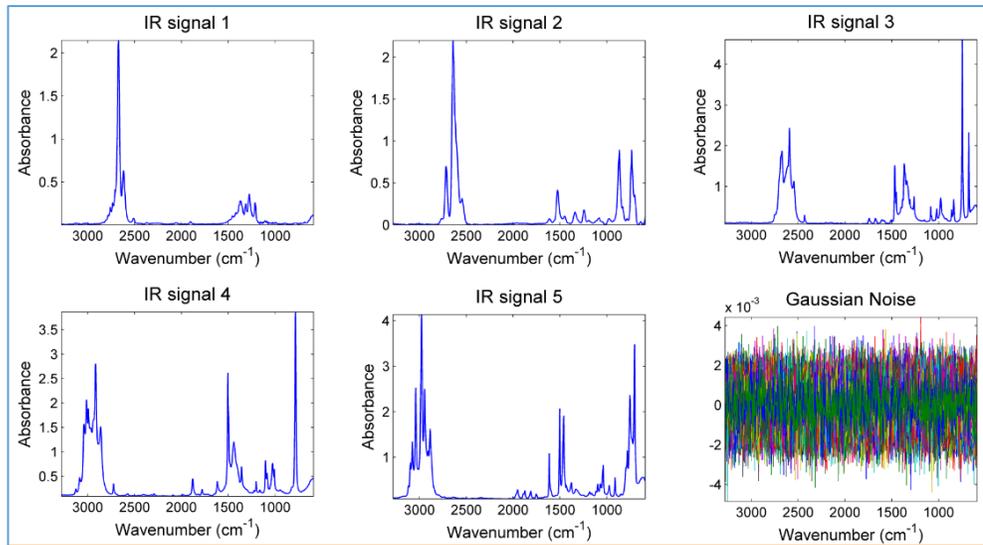


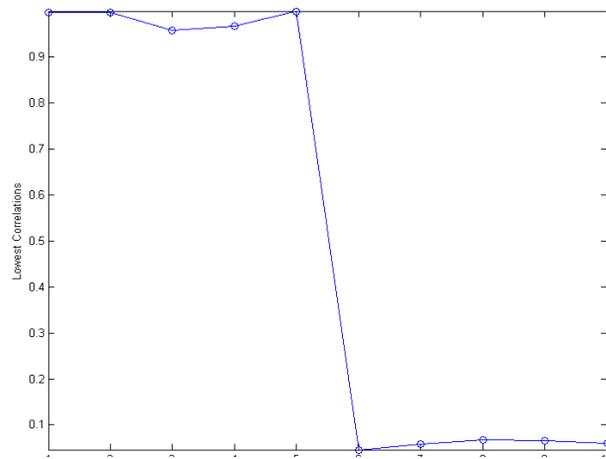
Nombre de signaux extraits



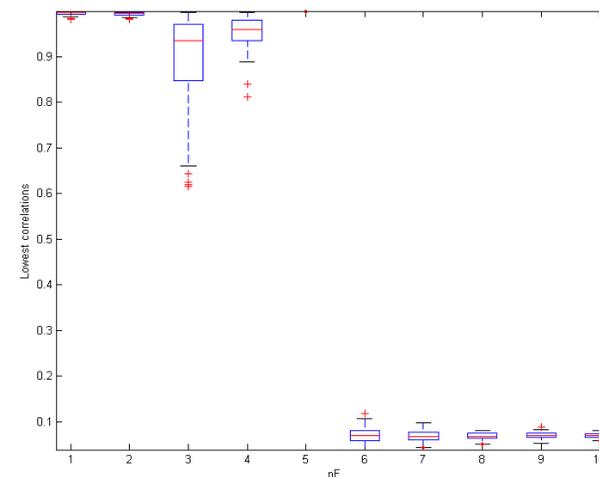
Nombre de signaux extraits

Données IR simulées X (100,800)

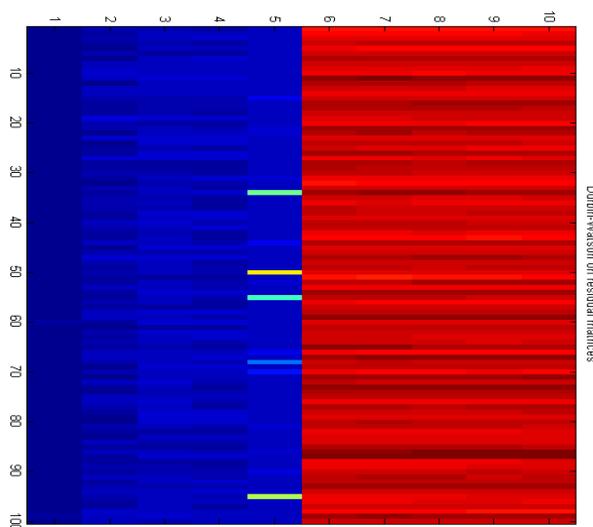




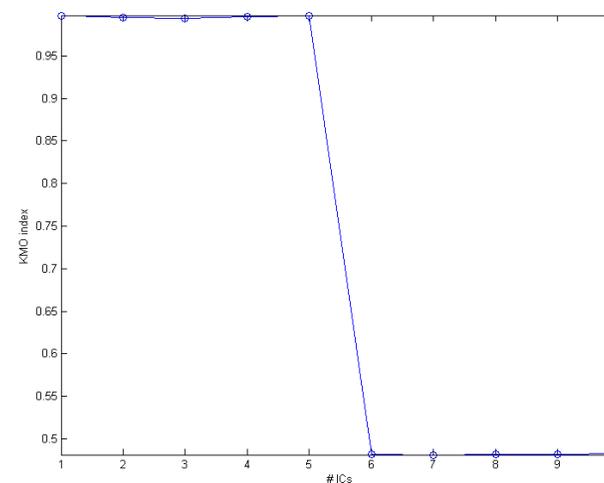
ICA_by_Blocks
B = 2



Random_ICA
50 répétitions



DW

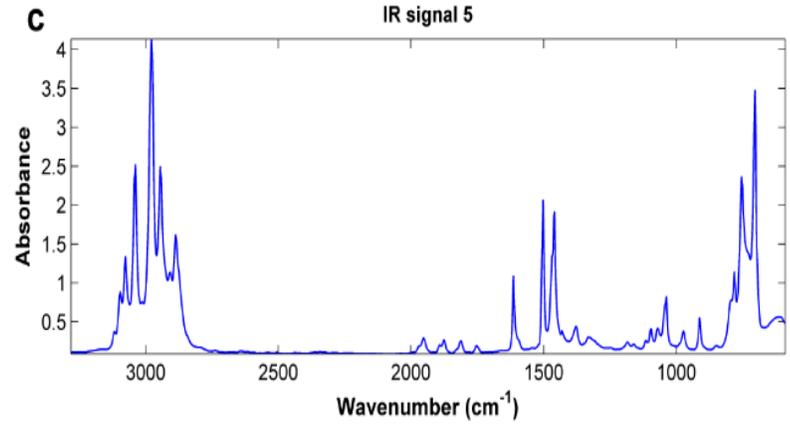
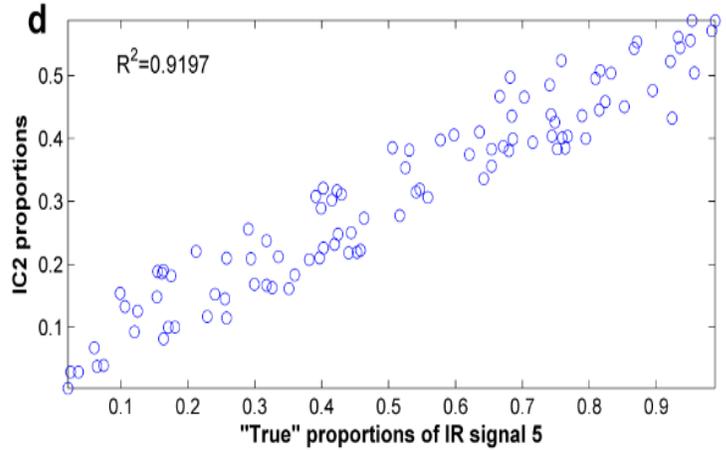
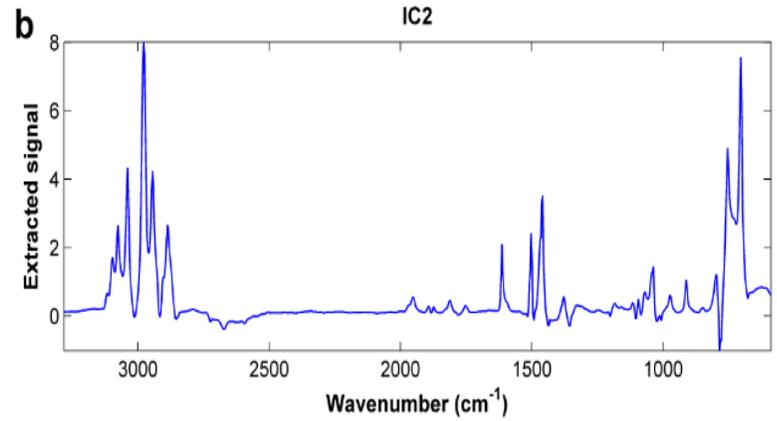
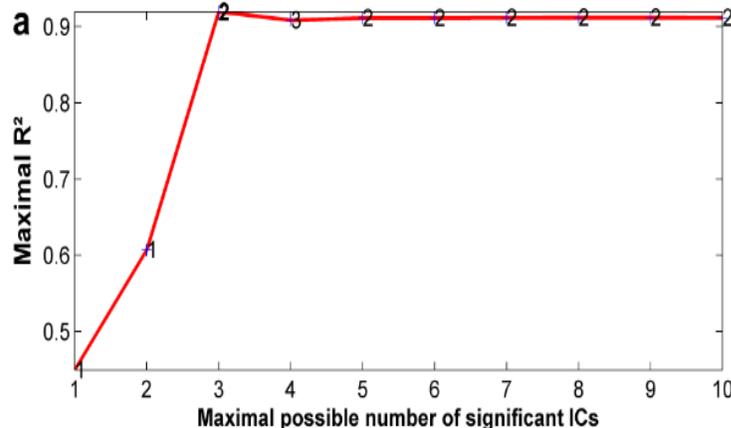


KMO

Donnée IR simulée
X (100,800)

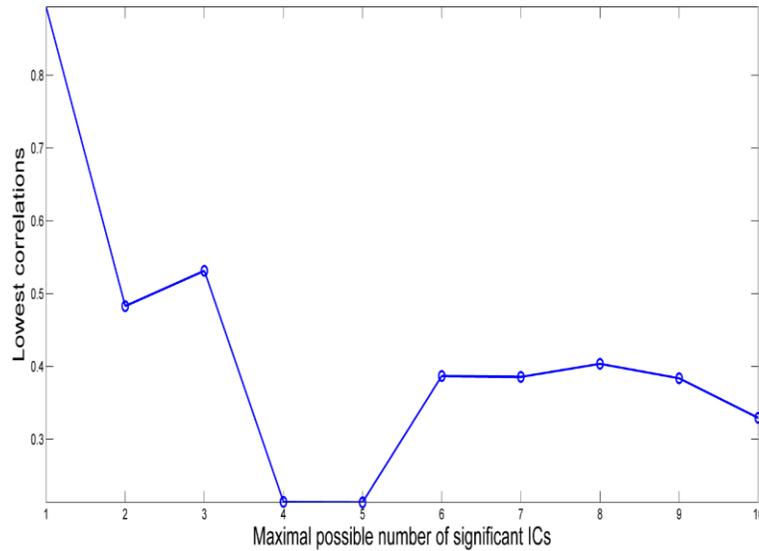
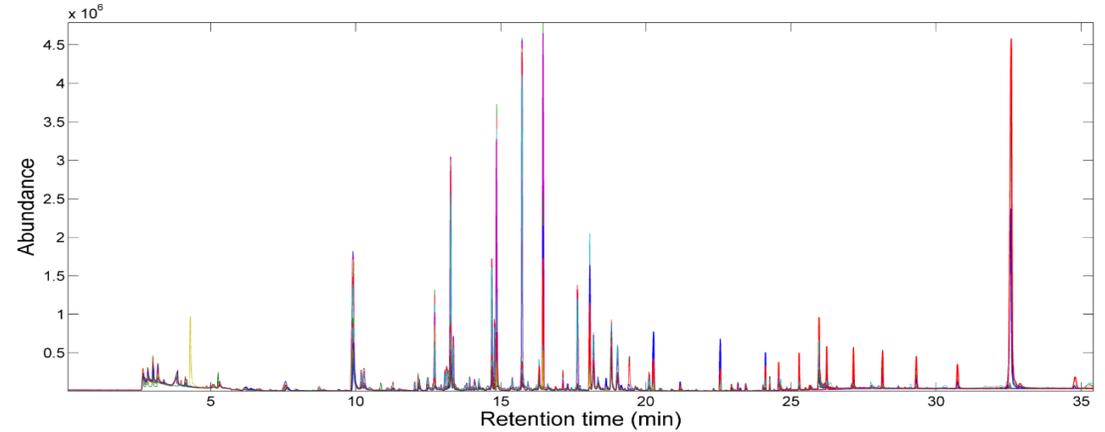


Vecteur y_c
(proportions de IR signal 5)

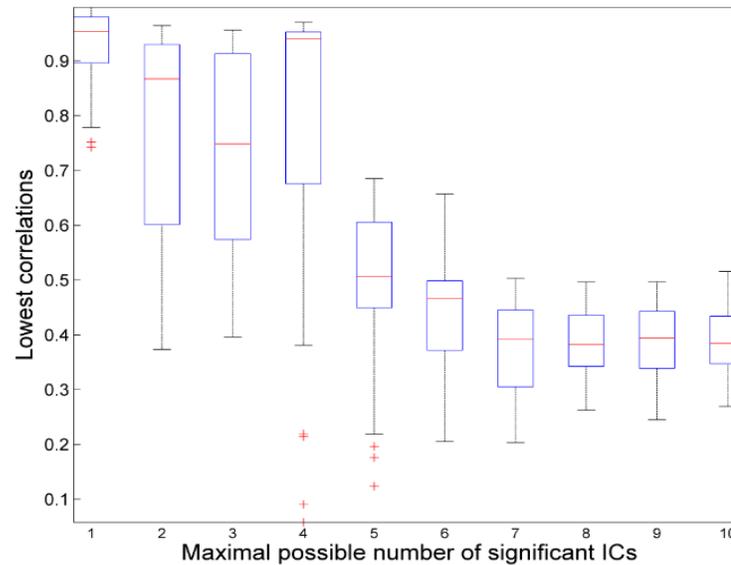


ICA_corr_y

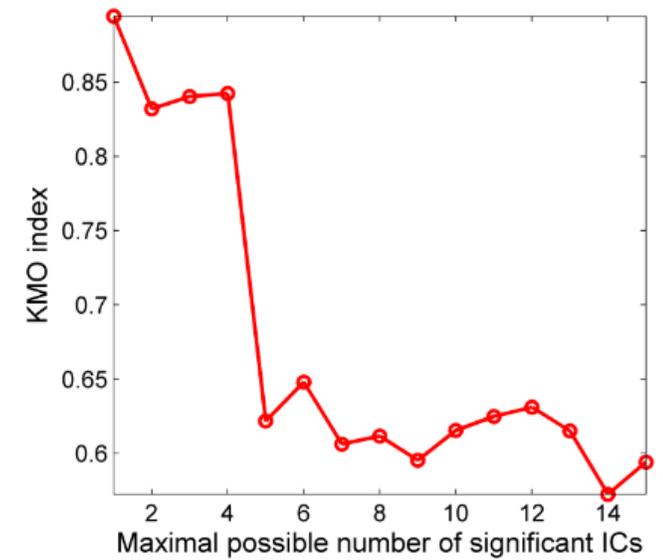
**Donnée HS-SPME/GC-MS sur huile d'olive
X (21,5453)**



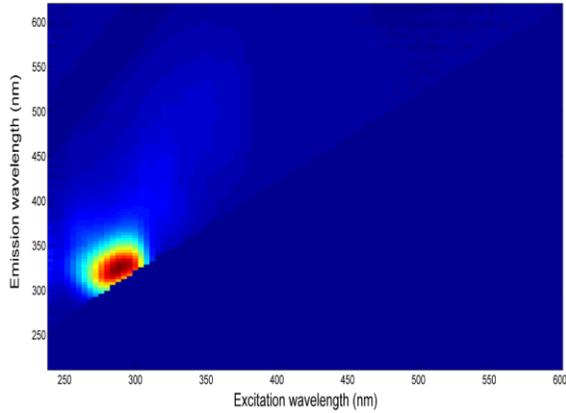
ICA_by_blocks
($B=2$; $F_{max}=10$)



Random_ICA
($B=2$; $F_{max}=10$); $k=50$)



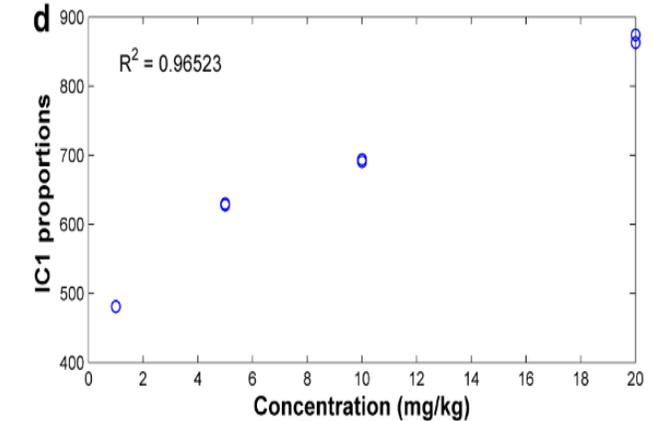
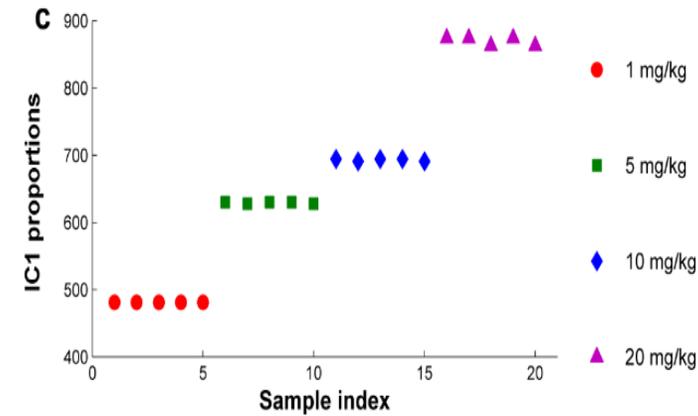
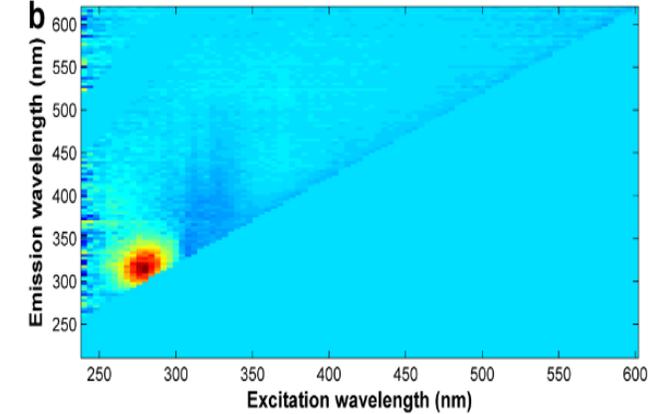
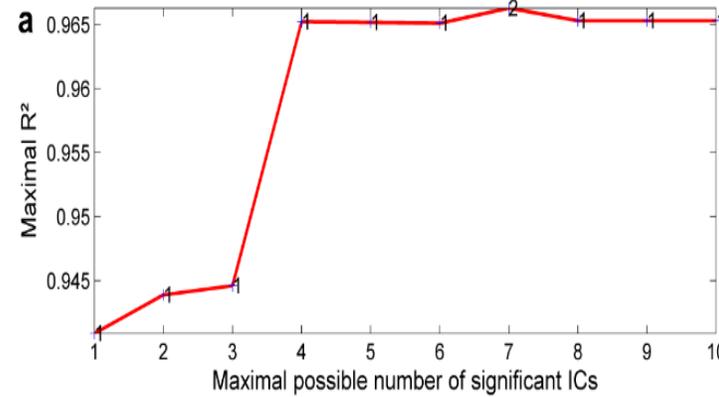
KMO_ICA_Residuals
 $F_{max}=15$;



Donnée fluorescence frontale 3D / Huiles d'olive dopées par des concentrations croissantes d'Irganox 1010 X (20,11375)

Vecteur y_c
Concentrations
mg/kg Irganox 1010

y_c
1
5
10
20



ICA_corr_y



Conclusion

- La détermination du nombre de composantes indépendantes est un facteur essentiel
- Il existe plusieurs méthodes complémentaires:
 - Le critère de Durbin-Watson permet de voir le nombre de signaux source dans chaque signal; MAIS il n'est applicable qu'aux données structurées
 - La méthode Random_ICA est plus performante qu'ICA_by_blocks
 - La méthode KMO_ICA_Residuals donne des résultats similaires à Random_ICA
 - La méthode ICA_corr_y est utile quand une variable connue existe
- Toutes ces méthodes peuvent être appliquées à l'Analyse en Composantes Principales



Remerciements

Merci pour votre attention

delphine.bouveresse@agroparistech.fr

aminekassouf@hotmail.com

rutledge@agroparistech.fr





Multi_ICA_corr_y

Lignin data (58 × 260)

