

Analyse en composantes indépendantes parcimonieuse pour le diagnostic de systèmes répartis

ZOHRA L.CHERFI¹, LATIFA OUKHELLOU^{1,2}, PATRICE AKNIN¹, THIERRY DENCEUX³

¹ Institut National de Recherche sur les Transports et leur Sécurité, INRETS-LTN, Laboratoire des Technologies Nouvelles, 2 rue de la Butte Verte, 93166 Noisy le Grand Cedex, France

² Paris12- CERTES, Centre d'Etudes et de Recherche en Thermique Environnement et Systèmes 61 av du Gal de Gaulle, 94100 Créteil Cedex, France

³ Université de Technologie de Compiègne. HEUDIASYC. Centre de Royallieu. BP 20529. 60205 Compiègne Cedex, France

Zohra.Cherfi@inrets.fr, Latifa.Oukhellou@inrets.fr,
Patrice.Aknin@inrets.fr, Thierry.Denoeux@hds.utc.fr.

Résumé - Cet article présente une approche basée sur l'Analyse en Composantes Indépendantes parcimonieuse pour le diagnostic automatique d'un système réparti de l'infrastructure ferroviaire. Ce système est composé de plusieurs sous-systèmes sur lesquels les observations prélevées sont spatialement liées; la défaillance d'un sous-système influera donc sur toutes les observations ou sur une partie d'entre elles. En considérant les variables observées comme des mélanges linéaires des variables latentes liées aux défauts, l'estimation de ces dernières est possible par une Analyse en Composantes Indépendantes (ACI) à condition qu'elles soient indépendantes et non gaussiennes. L'introduction de parcimonie dans le modèle d'ACI grâce à l'utilisation de fonctions de pénalité ou de contraintes de structure permet d'améliorer l'estimation des variables d'intérêt et d'identifier les relations particulières entre les données observées et les variables latentes recherchées.

Abstract - This paper presents a study on the potential interest of sparse Independent Component Analysis (ICA) for the diagnosis of a complex railway infrastructure device. This complex system is composed of several spatially related subsystems, i.e. a defective subsystem not only modifies its own inspection data but also those of other subsystems. In this context, the ICA model will be used to extract from inspection data indicators of each subsystem state. We assume here that inspection data are observed variables generated by a linear mixture of independent and nongaussian latent variables linked to the defects. Furthermore, physical knowledge on the inspection system provides prior information on the mixing structure. We will then investigate the ability of sparse ICA to recover this structure and to provide meaningful defect indicators. Also, we will show that introducing sparsity in the mixing process slightly improves the results.

1 Introduction

1.1 Contexte applicatif

Cet article présente une méthode basée sur l'Analyse en Composantes Indépendantes (ACI) parcimonieuse pour le diagnostic d'un système réparti de l'infrastructure ferroviaire, le Circuit de Voie (CdV).

Le CdV est l'organe qui intervient dans le contrôle-commande des trains et qui permet de détecter de façon automatique et continue la présence d'un véhicule sur une portion de voie donnée. Dans le cas des lignes à grande vitesse, il sert également de support pour la transmission d'informations entre la voie et le véhicule telle que la vitesse maximale autorisée. Le CdV est constitué des éléments suivants (Figure 1) :

- un émetteur, branché à l'une des extrémités de la portion de voie, qui émet un courant alternatif modulé en fréquence,
- une ligne de transmission, constituée par les 2 files de rail,
- un récepteur, branché à l'autre extrémité de la portion de voie, qui reçoit le signal provenant de

l'émetteur via les rails et commande un relais (l'état du relais régit la signalisation à l'entrée de la portion de voie),

- des condensateurs dits de compensation, connectés entre les deux files de rail à intervalles réguliers tout le long du CdV, qui permettent de compenser le caractère inductif de la voie ferrée.

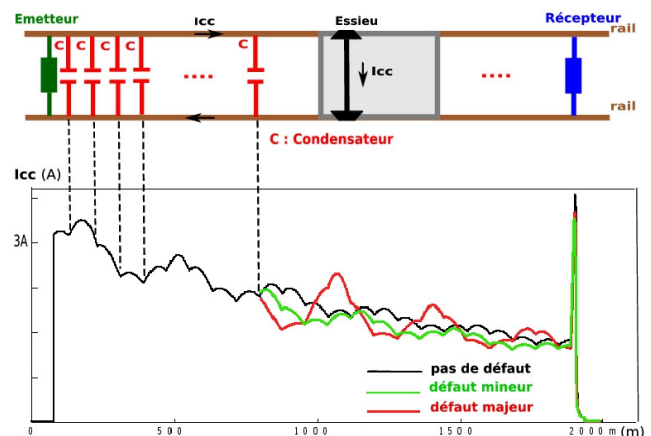


Figure 1: Représentation du circuit de voie et du signal I_{cc}

Un train est détecté lorsque son premier essieu court-circuite la voie et provoque une perte du signal au niveau du récepteur.

1.2 Problématique

L'ensemble de ce système peut être sujet à des dysfonctionnements qu'il convient de diagnostiquer le plus tôt possible afin de conserver une disponibilité maximale. En effet, si le signal de transmission voie/machine est trop faible, l'information ne parvient pas au véhicule, et le train est automatiquement arrêté.

Nous nous intéressons dans cet article aux défauts liés aux condensateurs de compensation. Le diagnostic de ces derniers s'effectue à l'aide d'un véhicule d'inspection qui fournit une mesure qui correspond au courant de court circuit (I_{cc} , cf. Figure 1) et dont l'allure est étroitement liée aux caractéristiques des condensateurs. L'objectif ici est de développer une méthode de diagnostic des condensateurs qui prenne en compte une particularité principale liée au principe même de mesure, à savoir que chaque portion du signal I_{cc} comprise entre deux condensateurs (chaînette) est influencée par les caractéristiques des condensateurs situés en amont (Figure 1).

2 Méthodologie

2.1 Modélisation par approche générative

L'idée est de considérer un CdV composé de N condensateurs comme un système global réparti composé de N sous-systèmes S_1, S_2, \dots, S_N sur lesquels sont prélevées les observations d_1, d_2, \dots, d_N où chaque observation d_i correspond à 2 descripteurs extraits de la paramétrisation de la chaînette i . En effet, chaque portion du signal est approximée à l'aide d'un polynôme de 2nd degré où deux de ces coefficients sont utilisés comme descripteurs de la chaînette (les contraintes de continuité éliminent l'un d'entre eux). Ces observations sont liées aux variables d'intérêt c_1, c_2, \dots, c_N qui correspondent aux capacités des condensateurs. Il est possible de modéliser ce système global par un modèle graphique génératif qui permet de prendre en compte les informations a priori sur les relations entre sous-systèmes (Figure 2).




Figure 2 : Modèle graphique génératif

Partant de cette représentation et en considérant le système comme un système linéaire instantané, on peut représenter les liens entre variables observées et variables d'intérêt (latentes) par la relation :

$$\mathbf{d} = \mathbf{A} \cdot \mathbf{c} \quad (1)$$

où $\mathbf{d} = (d_1, d_2, \dots, d_N)^T$ correspond au vecteur de variables observées, $\mathbf{c} = (c_1, c_2, \dots, c_N)^T$ correspond au vecteur de variables latentes et \mathbf{A} est une matrice dotée d'une structure parcimonieuse mettant en évidence les relations amont-aval entre les variables du modèle.

2.2 Estimation du modèle par analyse en composantes indépendantes

Pour l'estimation des différentes variables, nous avons considéré le modèle précédent (1) comme un problème de séparation de sources. Ainsi, sous l'hypothèse que les variables latentes soient non gaussiennes et mutuellement indépendantes, il est possible d'estimer la matrice \mathbf{A} et les variables latentes à partir des variables observées par une Analyse en Composantes Indépendantes. Cette méthode permet d'estimer les variables latentes à deux indéterminations près : les permutations et le facteur d'échelle [1].

L'estimation de \mathbf{A} se fait en maximisant la log-vraisemblance sur T échantillons, qui grâce à l'hypothèse d'indépendance s'écrit comme suit :

$$L(\mathbf{A}) = -T \log(|\det \mathbf{A}|) + \sum_{k=1}^T \sum_{i=1}^N \log p_i \left[(\mathbf{A}^{-1} \mathbf{d}_k)_i \right] \quad (2)$$

où p_i est la densité de la source i . Pour la maximisation de la log-vraisemblance, on utilisera l'algorithme du gradient naturel [2] défini par la règle de mise à jour :

$$\Delta \mathbf{A} \propto \mathbf{A} \left(E \{ \boldsymbol{\psi}(\mathbf{c}) \mathbf{c}^T \} - \mathbf{I} \right) \quad (3)$$

où E correspond à la moyenne empirique, \mathbf{I} correspond à la matrice identité, \mathbf{c} est l'estimation courante de la source $\mathbf{c} = \mathbf{A}^{-1} \cdot \mathbf{d}$ et $\boldsymbol{\psi}(\mathbf{c}) = [\psi_1(c_1), \dots, \psi_N(c_N)]^T$ tel que $\psi_i(c_i) = -p'_i(c_i)/p_i(c_i)$. Il n'est pas nécessaire d'estimer la densité p_i , $\psi_i(c_i)$ est adapté en ligne selon la nature des sources : dans le cas de sources sous-gaussiennes $\psi_i(c_i) = \tanh(c_i) - c_i$ et $\psi_i(c_i) = -2 \tanh(c_i)$ dans le cas de sources super-gaussiennes [1].

2.2.1 ACI avec contraintes de structures

Afin d'améliorer l'estimation des variables d'intérêt, il est possible de prendre en compte les relations connues entre les variables du modèle en exploitant la structure particulière de la matrice \mathbf{A} . La première solution consiste à poser des contraintes de structure sur la matrice de mixage [3]. Un masque appliqué à \mathbf{A} lors de son estimation permet alors d'obtenir une structure parcimonieuse fidèle aux relations amont-aval connues sur le modèle. Dans ce cas, le processus de mixage définit une matrice \mathbf{A} triangulaire inférieure telle que :

$$d_i \perp c_j \Leftrightarrow a_{ij} = 0$$

où $d_i \perp c_j$ signifie que la variable latente c_i n'influence pas l'observation d_i et les a_{ij} sont les éléments de \mathbf{A} .

La maximisation de la log-vraisemblance sous ces contraintes se fait en considérant un gradient uniquement sur les coefficients non nuls de A . Plus formellement les étapes d'initialisation et de mise à jour de l'algorithme sont décrites par :

$$A^{(0)} = M \bullet A^{(0)} \\ \Delta A_{Cr} \propto M \bullet A \left(E \{ \psi(c) c^t \} - I \right) \quad (4)$$

où \bullet définit le produit d'Hadamard entre deux matrices et M est une matrice binaire définie comme suit :

$$m_{ij} = \begin{cases} 0 & \text{si } d_i \perp c_j \\ 1 & \text{sinon} \end{cases}$$

2.2.2 ACI avec contraintes de structures

L'autre alternative consiste à appliquer des fonctions de pénalité sur les éléments de la matrice de mixage de la même façon qu'en régression [4]. La matrice de mixage parcimonieuse est alors estimée à partir de la fonction objectif constituée de la log-vraisemblance associée à la fonction de pénalité P_λ où λ définit le degré de pénalisation [5] [6] [7] :

$$L_{pen} = \frac{1}{T} L(A) - \sum_{i,j=1}^N P_\lambda(a_{ij}) \quad (5)$$

L'optimisation de la fonction objectif (5) se fait également par l'algorithme du gradient naturel :

$$\Delta A_{pen} \propto A \left(E \{ \psi(c) c^t \} - I - A^t [P'_\lambda(a_{ij})] \right) \quad (6)$$

où $[P'_\lambda(a_{ij})]$ définit la matrice dont l'élément (i,j) est $P'_\lambda(a_{ij})$. Les fonctions de pénalités L_2 , L_1 évaluées par la suite sur ce modèle sont décrites dans le Tableau 1 :

Tableau 1 : Expression de la fonction de pénalité P_λ

Pénalité	P_λ
L_1	$\lambda a $
L_2	$\lambda a ^2$

3 Résultats

L'approche est évaluée sur une base de données constituée de signaux pour lesquels on dispose des informations relatives aux sources afin de pouvoir mesurer la qualité des estimations. Cette base de données est constituée de 2500 signaux qui correspondent à des CdV composés de $N=19$ condensateurs avec des valeurs différentes des capacités de chaque condensateur. 1000 signaux servent de base d'apprentissage et 1500 servent de base de test.

Chaque variable observée étant décrite par deux coefficients, le but est alors d'estimer N variables latentes à partir des $2N$ variables observées, N étant

le nombre de condensateurs. Comme dans le cadre de l'ACI sans bruit, le nombre de variables latentes doit correspondre au nombre de variables observées, nous avons extrait $2N$ variables latentes, la moitié d'entre elles correspondent aux états de dégradation des condensateurs et l'autre moitié à des variables de bruit.

Dans l'objectif de quantifier l'apport des différents modèles d'ACI envisagés pour le diagnostic, les performances sont évaluées sur la base de test à l'aide de deux indicateurs : les coefficients de corrélation entre les capacités réelles et leur estimation d'une part et la parcimonie de la matrice de mixage d'autre part. Les résultats présentés sont obtenus en fonction de la permutation qui conduit à la meilleure corrélation moyenne.

Dans le cas de l'ACI pénalisée, deux fonctions de pénalité ont été testées avec différents degrés de pénalisation afin de sélectionner un modèle performant en termes d'estimation. La Figure 3 présente les résultats de l'ACI pénalisée avec une pénalité L_1 puis avec une pénalité L_2 , lorsque le degré de pénalisation λ varie entre 0 et 25. Ces résultats sont obtenus en moyennant 30 exécutions de chaque algorithme et avec différentes initialisations de la matrice de mixage. Nous présentons d'une part, la moyenne sur l'ensemble des condensateurs du coefficient de corrélation (en valeur absolue) entre les sources estimées et les capacités des condensateurs. D'autre part, nous présentons l'évolution de la parcimonie de la matrice de mixage en fonction du degré de pénalisation.

La mesure de parcimonie utilisée permet de quantifier l'énergie contenue au niveau des éléments d'un vecteur [8]. Celle-ci prend la valeur 1 si et seulement si A contient un unique élément non nul et prend la valeur 0 si tous les éléments sont égaux. Elle est calculée par la formule :

$$parcimonie(A) = \frac{\sqrt{N * 2N} - \sum |a_{ij}| / \sqrt{\sum a_{ij}^2}}{\sqrt{N * 2N} - 1} \quad (7)$$

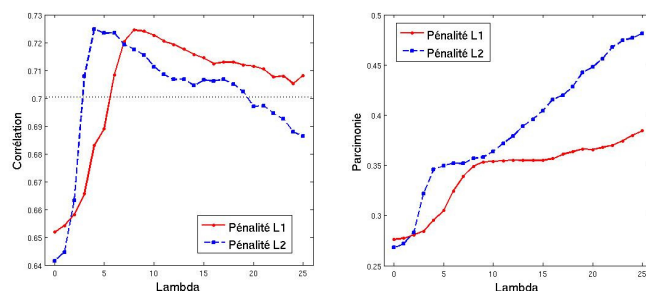


Figure 3 : Corrélation moyenne et Mesure de parcimonie

D'après la Figure 3 la parcimonie de la matrice A augmente de manière continue en fonction du degré de pénalisation, alors que la corrélation augmente jusqu'à un certain niveau pour diminuer ensuite. Par conséquent, pour une pénalité de type L_2 un degré de pénalisation égal à 4 devrait être suffisant, quant à la pénalité de type L_1 , le paramètre λ devrait être fixé à 8. L'ACI avec pénalité de type L_2 et $\lambda = 4$ semble

néanmoins parvenir à de meilleures performances que la pénalisation L_1 en termes de degré de corrélation et de niveau de parcimonie.

Une fois le modèle d'ACI pénalisée choisi (type et degré de pénalité), nous avons comparé ses résultats à ceux des modèles d'ACI standard et d'ACI avec contraintes de structure. Les performances ont été évaluées en fonction de la corrélation obtenue entre chaque source estimée et réelle. Le Tableau 2 donne les résultats de la valeur absolue des coefficients de corrélation entre les sources estimées et les capacités des 19 condensateurs pour les trois modèles. Les différentes solutions ont été moyennées sur les 30 initialisations. Globalement, on peut noter que les performances des modèles d'ACI avec parcimonie sont meilleures que celles du modèle standard. Les corrélations entre les capacités des condensateurs et leur estimation sont plus significatives (> 0.7) et largement améliorées pour les sources situées en fin de circuit de voie (17 et 18). Il est important de noter qu'il existe un facteur d'échelle entre les sources estimées et réelles que l'on peut éviter en normalisant les sources.

Tableau 2 : Résultats de l'ACI standard, avec contraintes de structure puis avec pénalité. Moyenne de la valeur absolue des coefficients de corrélation entre les sources estimées et les capacités des 19 condensateurs sur 30 exécutions

	1	2	3	4	5	6	7
CorACIstd	0.63	0.61	0.72	0.59	0.73	0.72	0.71
CorACIct	0.74	0.64	0.67	0.61	0.77	0.71	0.76
CorACIpen	0.73	0.64	0.68	0.63	0.74	0.73	0.71
	8	9	10	11	12	13	14
CorACIstd	0.78	0.72	0.72	0.68	0.68	0.75	0.65
CorACIct	0.71	0.77	0.75	0.76	0.77	0.73	0.75
CorACIpen	0.76	0.77	0.74	0.77	0.79	0.75	0.79
	15	16	17	18	19	< >	
CorACIstd	0.75	0.74	0.36	0.39	0.20	0.64	
CorACIct	0.80	0.74	0.69	0.56	0.32	0.71	
CorACIpen	0.80	0.85	0.81	0.74	0.31	0.72	

Enfin, nous nous sommes intéressés à la structure de la matrice de mixage et à sa concordance par rapport aux liens connus entre les variables du système. La Figure 4 donne une représentation de la matrice A obtenue avec l'ACI standard, pénalisée puis avec contraintes de structure.




Figure 4 : Matrice A (en valeur absolue) estimée avec l'ACI standard (a), avec contraintes de structure (b) et pénalisée (c)

La structure de la matrice de mixage est clairement identifiée dans les cas (b) et (c). Sachant que l'on cherche à estimer N sources pour $2N$ variables observées, la matrice A est ainsi triangulaire inférieure par bloc et traduit bien les relations amont-aval entre les données d'inspection et les variables latentes recherchées. L'état d'un condensateur n'influence donc que les variables situées en aval (entre le condensateur et le récepteur).

4 Conclusion

Nous nous sommes intéressés dans cet article au diagnostic d'un composant de l'infrastructure ferroviaire à l'aide d'une analyse en composantes indépendantes. L'approche proposée vise à retrouver les variables latentes liées aux défauts à partir de leurs mélanges linéaires observés et extraits des données d'inspection. Différents modèles d'ACI (standard, avec contraintes de structure et pénalisée) ont été testés sur une base de données dont les sources sont connues. Les résultats obtenus ont montré l'apport de telles approches pour le diagnostic. La parcimonie semble nettement plus efficace dans l'identification de la structure de la matrice de mixage et par là même des connexions entre variables latentes et observées. En perspective, Nous envisageons une extension de la méthode au cas non-linéaire et la prise en compte de l'aspect historisé dans le diagnostic.

5 Références

- [1] A. Hyvarinen, J. Karhunen, and E. Oja. *Independent Component Analysis*. John Wiley & Sons, 2001.
- [2] S. Amari, A. Cichocki, and H. H. Yang. A new learning algorithm for blind signal separation. In *Advances in Neural Information Processing Systems*, pages 757–763. MIT Press, 1996.
- [3] E. Côme. *Apprentissage de modèles génératifs pour le diagnostic de systèmes complexes avec labellisation douce et contraintes spatiales*. PhD thesis, Université de Technologie de Compiègne, 2009.
- [4] R. Tibshirani. Regression shrinkage and selection via the lasso. *Journal of the Royal statistical Society*, 58:267–288, 1996.
- [5] K. Zhang and L. Chan. Ica with sparse connections. In *IDEAL*, pages 530–537, 2006.
- [6] A. Hyvarinen and R. Kathikesh. Imposing sparsity on the mixing matrix in independent component analysis. *Neurocomputing*, 49:151–162, 2001.
- [7] J. Fan and R. Li. Variable selection via nonconcave penalized likelihood and its oracle properties. *Journal of the American Statist. Assoc.*, 96 : 1348–1360, 2001.
- [8] P. Hoyer. Non-negative matrix factorization with sparseness constraints. *Journal of Machine Learning Research*, 5:1457–1469, 2004.