

Diagnostic de systèmes répartis à l'aide de modèles génératifs en contexte supervisé ou non supervisé

Latifa Oukhellou^{1,2}, Etienne Côme¹, Zohra Cherfi¹, Patrice Aknin¹, Thierry Denœux³

¹LTN, Institut National de recherche sur les Transports et leur Sécurité, 2 Av Malleret Joinville 94114 Arcueil France

²Certes, Université Paris XI, 61 Av du Gal de Gaulle 94110 Créteil France

³Heudiasyc, Université technologique de Compiègne, UMR CNRS 6599, BP 20529, 60205 Compiègne France

oukhellou@inrets.fr, come@inrets.fr, aknin@inrets.fr, thierry.denoeux@hds.utc.fr

Résumé – Cet article présente un outil de diagnostic automatique d'un système de l'infrastructure ferroviaire : le circuit de voie. Ce système est composé de plusieurs sous-systèmes dont le nombre est variable et sur lesquels les observations prélevées sont spatialement dépendantes; une défaillance d'un sous-système influera non seulement sur sa signature mais également sur les signatures des sous-systèmes situés en amont. L'objectif est d'estimer la gravité du défaut de chaque sous-système en tenant compte de ces particularités. L'approche développée est basée sur l'utilisation d'un modèle graphique qui permet de spécifier les dépendances et les indépendances existant entre les différentes variables décrivant le système complet. La mise au point d'un tel modèle dans un cadre supervisé avec prise en compte de non linéarité est détaillée ici. De par le faible nombre de signaux labellisés disponibles, un cadre d'apprentissage autre que supervisé semble plus adapté. L'apprentissage non supervisé est donc également considéré dans cet article et plus particulièrement dans le cadre de l'analyse factorielle indépendante.

Abstract – This paper deals with an automatic diagnosis of a railway component : the track circuit. This system is made up of a series of spatially dependent subsystems of which the number is variable. The signature of a subsystem is determined not only by its state but also by the state of subsystems located upstream. The goal of the diagnosis system is to estimate the defect severity of each subsystem by taking account of these particularities. Here, the diagnosis approach is based on a graphical model which allows to taking advantage from prior knowledge on the dependencies existing between the variables describing the system. This model is first considered within a supervised learning framework by taking account of nonlinearities. Then, the paper addresses classification problems in which the class membership of training data is not known. This framework is suitable to deal with applications where only few labelled signals are available. The unsupervised learning is also considered in this paper through the independent component analysis.

1. Introduction

1.1 Contexte Applicatif

L'infrastructure ferroviaire est soumise à de fortes contraintes mécaniques, électriques, thermiques... et tous les organes placés à la voie (rails, circuits de voie, caténaire...) subissent des dégradations inévitables qui peuvent occasionner des dysfonctionnements. Ceux-ci se doivent bien sûr d'être le moins pénalisant possible pour l'exploitation du réseau, tant en terme de sécurité qu'en terme de disponibilité et de qualité de service. Pour remédier à ces dégradations, des procédures de diagnostic et de maintenance sont mises en œuvre et pour ne pas solliciter le réseau pendant de trop grandes périodes, ces procédures sont le plus souvent effectuées depuis une voiture d'inspection à vitesse relativement élevée. Si l'on

tente de dégager les spécificités de ce type de diagnostic embarqué, on relève plusieurs points communs :

- Les capteurs utilisés ne sont pas forcément placés dans des configurations de mesure optimales du fait des contraintes de gabarit sous (ou sur) caisse. Les données recueillies sont donc souvent imprécises. On notera également que les voitures de mesure embarquent souvent beaucoup de capteurs. La gestion de l'ensemble des données à disposition est donc à réaliser en prenant en compte les problèmes d'incomplétude, de redondance et d'incertitude.

- Les données sont émises « au kilomètre » (fonction de l'abscisse curviligne) et donc en grande quantité. Se pose rapidement le problème de l'automatisation de leur dépouillement et de leur étiquetage.

- La localisation des points singuliers à la voie est un passage obligé lors du dépouillement des inspections, car

elle permet de baliser la voie en termes d'abscisse curviligne et d'envoyer par la suite des équipes d'intervention au bon endroit. Sur ce point, on remarquera que l'infrastructure ferroviaire est un système fortement structuré par les règles de pose de ses éléments ; leur succession à la voie est rarement le fait du hasard et cette information peut être utilisée pour la distinction des points singuliers structuraux et des défauts réels.

• Les approches de diagnostic à base de modèle sont difficiles à mettre en œuvre car les modèles de bon fonctionnement n'existent pas, où au mieux s'ils existent, ils sont complexes et difficilement compatibles avec les contraintes de diagnostic en ligne.

En s'attachant à prendre en compte ces spécificités et afin d'illustrer la méthodologie employée, cet article présente un outil développé pour le diagnostic d'un système de l'infrastructure ferroviaire : le circuit de voie (CdV).

Ce système utilisé dans le contrôle-commande des trains, permet de détecter de façon automatique et continue la présence d'un véhicule sur une portion de voie donnée appelée canton. Sur les lignes à grande vitesse, il sert également à transmettre des informations entre la voie et le véhicule (vitesse maximale autorisée, paramètres de freinage...).

Un circuit de voie est principalement constitué de 4 éléments (cf. Figure 1):

- un émetteur, branché à une extrémité du CdV, 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 du CdV, qui reçoit le courant provenant de l'émetteur via les rails et commande un relais. L'état du relais régit la signalisation à l'entrée des cantons,
- des condensateurs dits de « compensation » connectés entre les deux files de rail, à intervalles réguliers tout le long du CdV qui limitent l'affaiblissement du signal dû au caractère inductif de la voie ferrée.

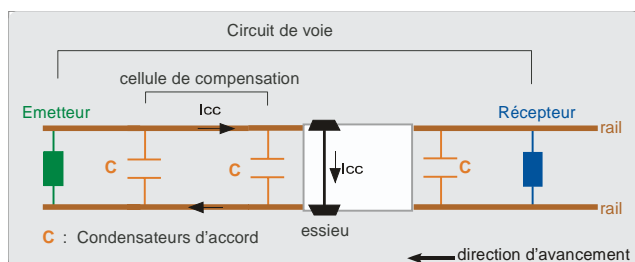


Fig. 1 : Schéma d'un circuit de voie

Ce système complexe 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 en cabine, et le train est automatiquement arrêté. De plus, cette situation sera interprétée comme un canton occupé systématiquement qu'un train soit présent ou non. Ces situations peuvent être

causées par des défauts d'un élément quelconque du CdV, mais dans cet article, nous nous intéresserons aux défauts des condensateurs de compensation. Ces défauts peuvent avoir plusieurs origines (vieillesse, connectique...). Ils seront modélisés par des résistances mises en série avec les condensateurs, une résistance nulle correspondant à un condensateur sans défaut alors qu'une valeur infinie indique que le condensateur est décroché.

Le diagnostic des CdV s'effectue à l'aide d'un véhicule d'inspection spécifique qui permet de mesurer l'amplitude de la porteuse, notée I_{cc} (cf. Figure 2).




Fig. 2 : Allure d'un signal de mesure avec et sans défaut

1.2 Problématique

Le CdV peut être considéré comme un système global décomposable en plusieurs sous-systèmes (les condensateurs d'accord) interconnectés. L'objectif visé ici est de développer un outil d'analyse automatique des relevés qui permet le diagnostic de chaque sous-système. Cet outil doit donc prendre en compte les particularités suivantes :

- les sous-systèmes sont répartis spatialement sur un axe orienté (de l'émetteur vers le récepteur),
- les signatures des sous-systèmes (chaînettes visibles figure 2) sont liées spatialement de façon unidirectionnelle: dans les signaux de mesure, la signature d'un sous-système dépend de son état mais également de l'état des sous-systèmes situés en amont. En revanche, elle ne dépend pas de l'état des sous-systèmes situés en aval,
- le nombre de sous-systèmes est variable. Il dépend de la longueur du CdV.

Ces points sont résumés sur la figure 3.




Fig. 3 : Dépendance spatiale entre sous-systèmes répartis

Une approche classifiante du problème est possible. Elle consiste à mettre au point plusieurs classifieurs élémentaires dont chacun est dédié au diagnostic d'un sous-système. Les sorties des classifieurs sont ensuite fusionnées dans le cadre de la théorie des fonctions de

croissance pour limiter l'impact d'éventuels des conflits entre sous-classifieurs [1]. Cette approche permet à la fois de détecter le sous-système défectueux et de le positionner. En revanche, elle ne permet pas d'estimer la gravité des défauts.

La deuxième approche que nous présentons ici est basée sur les modèles graphiques génératifs. Ces derniers offrent en effet un cadre intéressant pour résoudre notre problème de diagnostic dans la mesure où ils permettent de représenter les relations entre variables d'intérêt (liées aux défauts) et les variables extraites des signaux observés par un modèle graphique tout en spécifiant l'ensemble des dépendances et indépendances entre variables.

2. Diagnostic par modèle génératif en contexte supervisé

2.1 Modèle graphique linéaire gaussien

Nous nous plaçons ici dans un cadre de régression pour répondre à la question de l'estimation de la gravité des défauts ; chaque défaut est alors représenté par un paramètre à valeur continue dont on cherche à estimer la valeur. Pour un système S spatialement réparti, composé de N sous-systèmes S_1, S_2, \dots, S_N sur lesquels les observations c_1, c_2, \dots, c_N sont prélevées, la dépendance spatiale évoquée signifie qu'une défaillance du sous-système S_j influencera inévitablement les observations c_j, \dots, c_N (et pas uniquement c_j). Toutes les relations entre les variables d'intérêt r_1, r_2, \dots, r_N et les variables observées (issues de la paramétrisation du signal) peuvent être représentées par un modèle graphique (cf. figure 4). Ce modèle offre l'avantage de pouvoir s'adapter à un nombre N variable de sous-systèmes. Car en apprenant le modèle pour les systèmes les plus longs, il est possible d'extraire des sous-modèles utilisables sur des systèmes de taille inférieure ($N' < N$).




Fig. 4 : Modèle génératif des données

Grâce à cette représentation et en considérant un modèle linéaire gaussien entre variables d'intérêt et variables observées, on peut écrire la relation :

$$c = A.r + \varepsilon, \quad \varepsilon \sim N(0, \Sigma_\varepsilon) \quad (1)$$

où $c = (c_1, c_2, \dots, c_N)^t$, $r = (r_1, r_2, \dots, r_N)^t$, A une matrice triangulaire inférieure par bloc et Σ_ε une matrice diagonale.

L'apprentissage des paramètres A et Σ_ε de ce modèle dans un cadre supervisé s'effectue à l'aide d'une approche par maximum de vraisemblance, en prenant en considération la structure particulière de la matrice de régression. La matrice A est alors la solution de N

problèmes aux moindres carrés, puis Σ_ε s'obtient à l'aide d'une estimation empirique de la variance des résidus.

Le problème de l'inférence dans ce modèle consiste à estimer les densités de probabilités des différentes variables d'intérêt connaissant les variables observables. Si aucun a priori sur les variables d'intérêt n'est disponible, l'estimateur est alors de type maximum de vraisemblance. Comme le modèle est linéaire gaussien, nous obtenons :

$$\hat{r} = c^t \Sigma_\varepsilon^{-1} A \Sigma_r, \quad \Sigma_r = (A^t \Sigma_\varepsilon^{-1} A)^{-1} \quad (2)$$

2.2 Modèle graphique non linéaire

Le modèle précédent suppose des relations linéaires entre variables d'intérêt et variables observées. La prise en compte de non linéarités est possible grâce aux techniques d'échantillonnage [2] qui sont malheureusement très lourdes en temps de calcul. Plutôt que d'intégrer la non linéarité dans le modèle et donc d'en compliquer l'inférence, nous proposons d'effectuer une étape de prétraitement des variables qui permet de mieux contrôler la complexité du modèle tout en gardant une inférence linéaire. Ce prétraitement repose sur l'analyse canonique des corrélations à noyaux régularisée RKCCA [3] [4] que nous allons présenter succinctement.

L'analyse canonique des corrélations (CCA, Canonical Correlation Analysis) est une méthode de réduction de dimension qui s'applique à des données décrites dans deux espaces différents (ici les espaces d'entrée et de sortie). L'idée clé est de rechercher deux sous-espaces de projection dans lesquels la corrélation entre les données projetées est maximale. Grâce à « l'astuce noyau », il est tout à fait possible d'effectuer cette recherche dans un espace résultant de transformations non linéaires des variables explicatives ou à expliquer initiales [3][4]. Dans ce cas, il est cependant nécessaire d'introduire dans le critère (corrélation) un terme de régularisation pour prévenir un surapprentissage. En effet, l'espace induit par le noyau peut être de très grande dimension, voire de dimension infinie pour le noyau gaussien. On parle alors d'analyse canonique régularisée à noyau (RKCCA).

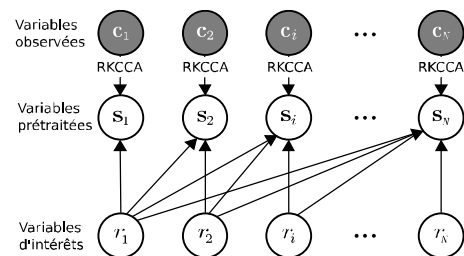


Fig. 5 : Modèle génératif avec un prétraitement non linéaire des variables observées

L'objectif du prétraitement par RKCCA est de trouver de nouvelles variables, transformations non linéaires des variables observées c_i , qui dépendent linéairement de leurs parents $\pi_i = \{r_1, r_2, \dots, r_i\}$ (cf. Figure 5). Ces variables

transformées définissent ainsi un nouvel espace d'entrée pour le modèle linéaire présenté dans la partie précédente.

On recherchera donc pour chaque nœud c_i , une transformation non linéaire, de corrélation maximale avec une combinaison linéaire de ses parents (cf. figure 5). Le calcul nécessite de résoudre le problème de valeur propre généralisé dual défini par la relation :

$$\begin{pmatrix} 0 & K_{c_i} (\Pi_i \Pi_i^t) \\ (\Pi_i \Pi_i^t) K_{c_i} & 0 \end{pmatrix} \begin{pmatrix} \alpha_i \\ \beta_i \end{pmatrix} = \lambda \begin{pmatrix} (1-\tau) K_{c_i}^2 + \tau K_{c_i} & 0 \\ 0 & (\Pi_i \Pi_i^t)^2 \end{pmatrix} \begin{pmatrix} \alpha_i \\ \beta_i \end{pmatrix} \quad (3)$$

où $\Pi_i = \{\pi_{i1}, \pi_{i2}, \dots, \pi_{iM}\}$, K_{c_i} est la matrice de Gram construite en utilisant un noyau K sur les données $[c_{i1}, c_{i2}, \dots, c_{iM}]^t$, M étant le nombre d'individus.

Lorsque les vecteurs propres ont été trouvés, nous pouvons alors calculer les variables canoniques grâce à :

$$s_i = K_{c_i} \alpha_i \quad (4)$$

Les combinaisons s_i sont alors utilisées comme nouvelles entrées du modèle décrit par l'équation (1), en remplacement des c_i :

$$s = A.r + \varepsilon, \quad s = [s_1, \dots, s_N]^t \quad (5)$$

Plusieurs points doivent être ajustés pour optimiser ce prétraitement :

- choix du type de noyau : le noyau gaussien et le noyau polynomial ont été testés;
- ajustement des hyperparamètres du noyau et des paramètres de régularisation : un ensemble de validation a été utilisé pour quantifier la corrélation entre les variables canoniques, obtenues pour un jeu d'hyperparamètres, et les variables explicatives. Le jeu d'hyperparamètres maximisant cette corrélation a été sélectionné.

Pour résoudre numériquement, en un temps raisonnable, le problème de valeurs propres généralisé défini par l'équation 3, nous avons utilisé la méthode décrite dans [5] reposant sur la décomposition incomplète de Cholesky de la matrice K_{c_i} . Grâce à cette méthode, le calcul des variables canoniques ne nécessite la diagonalisation que d'une matrice de taille $i \times i$.

Finalement, pour contrôler la complexité du modèle global (prétraitement + modèle linéaire), nous avons ordonné les caractéristiques si trouvées par notre prétraitement suivant leur corrélation avec la meilleure combinaison linéaire de variables explicatives. Cette corrélation étant estimée sur un ensemble de validation. La taille finale de l'espace d'entrée du modèle linéaire a été choisie de manière à minimiser l'erreur quadratique moyenne sur globale l'ensemble de validation. Lorsque toutes les caractéristiques du modèle ont été fixées l'estimation des variables d'intérêts s'effectue en remplaçant c par s dans l'équation (2), soit,

$$\hat{r} = s^t \Sigma_s^{-1} A \Sigma_s, \quad \Sigma_s = (A^t \Sigma_c^{-1} A)^{-1} \quad (6)$$

3. Résultats

En raison du très faible nombre de signaux réels étiquetés et disponibles sur notre application, on utilise une base de 5000 signaux simulés grâce à un modèle électrique du CdV en effectuant préalablement un tirage aléatoire des résistances de chaque condensateur. Pour que les signaux soient les plus proches possibles des signaux réels, ils sont bruités en utilisant un modèle de bruit «réaliste». 2500 signaux servent à l'apprentissage, 1000 à la validation et 1500 au test. Pour toute la base, le CdV comporte 19 condensateurs, soit un nombre $N=19$ de sous-systèmes à diagnostiquer.

Les résultats fournis par les 3 modèles différents sont présentés dans le tableau 1. Ces performances ont été évaluées sur la base de test à l'aide de 2 indicateurs : l'erreur quadratique moyenne (EQM) entre r et \hat{r} et leur coefficient de corrélation.

Tableau 1 : Résultats sur signaux simulés bruités

	EQM	Corr. Coef.
Linéaire gaussien	0,1018	0.77
RKCCA noyau polynomial	0.0139	0,97
RKCCA noyau gaussien	0.0244	0,94

On peut noter que les performances des modèles non linéaires sont meilleures que celle du modèle linéaire. En effet, l'erreur quadratique moyenne est améliorée d'un facteur 7 par le noyau polynomial et 4 par le noyau gaussien. Pour illustrer ces résultats, nous avons représenté sur la figure 5 l'évolution de la résistance estimée en fonction de la résistance réelle pour les 2 modèles (avec et sans prétraitement).

Nous pouvons observer sur cette figure l'intérêt du prétraitement non linéaire, en particuliers pour les faibles valeurs de résistance. Ce bon comportement permet d'espérer obtenir un taux de fausse alarme très faible, peu de condensateurs fonctionnant normalement seront diagnostiqués comme défectueux.




Figure 5 : Evolution de la résistance estimée en fonction de la résistance réelle pour le 9ème condensateur (ensemble de validation)

4. Diagnostic en contexte non supervisé

4.1 Problématique

La mise au point de tels modèles pour le diagnostic dans un cadre supervisé nécessite de disposer d'une base de données de taille importante labellisée. Dans le contexte ferroviaire, on dispose en général d'une grande quantité de données qu'il n'est pas toujours aisé de labelliser car cela nécessite un travail fastidieux et/ou coûteux. En revanche, il existe souvent une expertise sur les signaux de mesure que l'on peut mettre à profit pour une labellisation mais tenant compte d'imprécision et/ou d'incertitude. Dans ce cas, un cadre d'apprentissage autre que supervisé est plus adapté.

Le problème de diagnostic qui nous intéresse peut également être formalisé d'une autre manière où l'on considère que les variables observées (extraites du signal de mesure) sont issues de mélanges des variables latentes (liées aux défauts). Dans ce cadre, plusieurs méthodes utilisées traditionnellement en traitement du signal permettent de résoudre ce problème, parmi lesquelles l'analyse en composantes indépendantes (ACI) ou l'analyse factorielle indépendante (AFI) [10,11,12].

4.2 Analyse factorielle indépendante (IFA)

L'ACI cherche à trouver des composantes indépendantes $\{r_1, \dots, r_S\}$ à partir de leurs combinaisons linéaires $\{c_1, \dots, c_M\}$. Elle postule le modèle génératif suivant :

$$c = A.r + \varepsilon \quad (6)$$

où ε est un bruit gaussien et A une matrice de taille $(M \times S)$. L'hypothèse d'indépendance des sources se traduit par la relation :

$$p(r) = \prod_{s=1}^S p_s(r_s) \quad (7)$$

Dans cet article on supposera qu'il n'y a pas de bruit et que $M=S$ (le nombre de sources est égal au nombre de mélanges). La densité des variables observées est donnée par :

$$p(c) = \frac{1}{|\det(A)|} \prod_{s=1}^S p_s \left[(A^{-1}c)_s \right] \quad (8)$$

Sa vraisemblance pour un ensemble de données $\{c\}_1^N$ est égale à :

$$L(A; \{c\}_1^N) = \prod_{i=1}^N \frac{1}{|\det(A)|} \left(\prod_{s=1}^S p_s(A_s^{-1}c_i) \right) \quad (9)$$

Remarque : dans cette partie N désigne le nombre d'individus de la base de données

En pratique, il est souvent difficile de connaître les densités marginales de chaque source que l'ACI nécessite de fixer. Plusieurs solutions ont été proposées dans la

littérature. Dans [11], Hyvarinen propose de switcher entre des densités super ou sous gaussiennes selon un indicateur de la nature de la source. Une autre solution consiste à postuler un modèle semi-paramétrique pour la densité marginale de chacune des sources. L'analyse factorielle indépendante s'inscrit dans ce cadre et suppose que la densité marginale de chaque source (variable latente) est un modèle de mélange :

$$p_s(r_s) = \sum_{k=1}^{K_s} \pi_k^s N(r_s; \mu_k^s, \sigma_k^s) \quad (10)$$

où $N(\cdot; \mu, \sigma)$ est une distribution gaussienne unidimensionnelle.

Les paramètres du modèle sont la matrice de mélange A et les paramètres des distributions des variables latentes. L'ensemble de ces paramètres est noté

$$\theta = (A, \pi^1, \dots, \pi^S, \sigma^1, \dots, \sigma^S)$$

où π^s est le vecteur des proportions de mélange pour la source s vérifiant

$$\sum_{k=1}^{K_s} \pi_k^s = 1$$

K_s est le nombre de groupes dans le mélange, μ^s et σ^s sont les vecteurs des moyennes et variances des K_s groupes. Disposant d'une base de N i.i.d observations $\{c\}_1^N$, la vraisemblance peut s'écrire sous la forme:

$$L(\theta; \{c\}_1^N) = \prod_{i=1}^N \frac{1}{|\det(A)|} \left(\prod_{s=1}^S \left(\sum_{k=1}^{K_s} \pi_k^s N(A_s^{-1}c_i; \mu_k^s, \sigma_k^s) \right) \right) \quad (11)$$

L'estimation des paramètres par maximum de vraisemblance repose alors sur la maximisation de la log-vraisemblance du jeu de données :

$$\text{Log} \left(L(\theta; \{c\}_1^N) \right) = -N |\det(A)| + \sum_{i=1}^N \sum_{k=1}^S \log \left(\sum_{k=1}^{K_s} \pi_k^s N(A_s^{-1}c_i; \mu_k^s, \sigma_k^s) \right) \quad (12)$$

Si les densités des sources sont connues, l'optimisation de ce critère par rapport à A peut s'opérer à l'aide de l'algorithme du gradient. En revanche, on peut également avoir recours à l'algorithme EM pour l'estimation des paramètres du mélange. L'algorithme GEM (Generalized Expectation Maximisation) proposé par [10] utilise cette démarche. Il se résume aux étapes suivantes :

<p><i>Entrées:</i> données centrées</p> <p>Initialiser le vecteur des paramètres</p> $\theta^{(0)} = (A^{(0)}, \pi^{(0)}, \dots, \pi^{S(0)}, \sigma^{1(0)}, \dots, \sigma^{S(0)})$ <p>$q=0$</p> <p>Tant que l'incrément de la log-vraisemblance > seuil</p> <p style="padding-left: 20px;">$\mathbf{R} = \mathbf{C} \mathbf{A}^{-1}$</p> <p style="padding-left: 20px;">Pour toutes les sources $s \in \{1, \dots, S\}$ et tous les groupes de chaque densité $k \in \{1, \dots, K_s\}$</p>
--

$t_{ik}^{(q)} = \frac{\pi_k^{s(q)} N(\mathbf{r}_{is}; \boldsymbol{\mu}_k^{s(q)}, \sigma_k^{s(q)})}{\sum_{k'=1}^{K_s} \pi_{k'}^{s(q)} N(\mathbf{r}_{is}; \boldsymbol{\mu}_{k'}^{s(q)}, \sigma_{k'}^{s(q)})}$ Etape E
<p>Pour toutes les sources $s \in \{1, \dots, S\}$ et tous les groupes de chaque densité $k \in \{1, \dots, K_s\}$</p>
$\pi_k^{s(q+1)} = \frac{1}{N} \sum_{i=1}^N t_{ik}^{s(q)}$
$\boldsymbol{\mu}_k^{s(q+1)} = \frac{1}{\sum_{i=1}^N t_{ik}^{s(q)}} \sum_{i=1}^N t_{ik}^{s(q)} \mathbf{R}_{is}$
$\sigma_k^{s(q+1)} = \frac{1}{\sum_{i=1}^N t_{ik}^{s(q)}} \sum_{i=1}^N t_{ik}^{s(q)} (\mathbf{R}_{is} - \boldsymbol{\mu}_k^{s(q+1)})^2$
<p>Fin</p>
<p>Mise à jour de A</p>
<p>q=q+1</p>
<p>Fin</p>
<p>Sorties : paramètres estimés du modèle</p>
$\theta = (A, \pi^1, \dots, \pi^S, \sigma^1, \dots, \sigma^S)$

5. Conclusion et perspectives

La méthode proposée dans cet article traite le problème de diagnostic d'un système constitué de plusieurs sous-systèmes répartis dont le nombre est variable et les signatures dépendantes. Un défaut sur un sous-système modifie en effet l'allure du signal collecté sur celui-ci mais également sur l'ensemble des sous-systèmes situés en aval.

L'approche présentée est basée sur un modèle graphique qui offre une représentation et une modélisation appropriée de ce type de problème. Le premier volet des travaux présentés dans cet article se place dans le cadre de l'apprentissage supervisé et utilise pour ce faire des bases de données labellisées constituées à l'aide d'un modèle électrique du système. La prise en compte de non linéarités est traitée à l'aide de l'analyse canonique des corrélations dans un espace noyau. Elle permet de linéariser les relations entre les nœuds enfants et parents du modèle génératif sans avoir à effectuer une inférence non linéaire. Sur l'application, les 2 noyaux (gaussien et polynomial) fournissent des résultats quasi-similaires avec un avantage pour le noyau polynomial ; le modèle linéaire obtient des résultats bien plus faibles.

La dernière partie de la communication replace le problème du diagnostic dans un cadre non supervisé, du fait du faible nombre de données réelles étiquetées pour notre application, tout en conservant le cadre des modèles graphiques génératifs. Dans cette approche, les variables observées (extraites du signal de mesure) sont supposées être issues de mélanges de variables latentes (liées aux défauts) et dont les marginales sont, par hypothèse, des mélanges de gaussiennes. L'analyse factorielle indépendante (IFA) combinée à l'algorithme GEM est alors utilisée pour estimer la matrice de demixage et les paramètres du modèle de mélange ce qui permet de produire un estimé des défauts de condensateurs. Le test de cette méthode sur notre application est en cours de réalisation.

Enfin, une extension à un cadre partiellement supervisé est également à l'étude. En effet, il existe souvent une expertise sur les signaux de mesure que l'on peut mettre à profit pour une labellisation mais tenant compte d'imprécision et/ou d'incertitude.

Références

- [1] A. Debiolles, L. Oukhellou, T. Denoeux, P. Aknin. *Output coding of spatially dependent subclassifiers in evidential framework. Application to the diagnosis of railway track/vehicle transmission system.* FUSION'06. Firenze 2006.
- [2] C. Bishop. *Pattern Recognition and Machine Learning.* Springer, 2006.
- [3] T. De Bie, N. Cristianini, and R. Rosipal. *Eigenproblems in pattern recognition.* In E. Bayro-Corrochano, editor, *Handbook of Geometric Computing : Applications in Pattern Recognition, Computer Vision, Neuralcomputing, and Robotics,* pages 129–170. Springer-Verlag, Heidelberg, 2005.
- [4] B. Magnus, L. Tomas, and K. Hans. *A unified approach to pca, pls, mlr and cca.* Technical report, Computer Vision Laboratory, Linköping University, 1992.
- [5] J. Shawe-Taylor, N. Cristianini. *Kernel Methods for Pattern Analysis.* Cambridge University Press, 2004
- [6] P. Vannoorenberghe. Estimation de modèles de mélanges nis par un algorithm EM crédibiliste. *Traitement du Signal*, 24(2):103-113, 2007.
- [7] P. Vannoorenberghe and P. Smets. *Partially supervised learning by a credal EM approach.* In L. Godo, editor, *Proceedings of the 8th European Conference on Symbolic and Quantitative Approaches to Reasoning with Uncertainty (ECSQARU '05),* pages 956-967, Barcelona, Spain, 2005. Springer.
- [8] A. P. Dempster, N. M. Laird, and D. B. Rubin. *Maximum likelihood from incomplete data via the EM algorithm.* *Journal of the Royal Stat. Soc.*, 1977.
- [9] E. Côme, L. Oukhellou, P. Aknin, T. Denœux, *Diagnostic par reconnaissance des formes d'organes de l'infrastructure ferroviaire. Approche couplée par méthodes à noyaux et modèles graphiques.* GRETSI, Reims, 2007.
- [10] H. Attias. *Independent factor analysis.* *Neural Computation*, 11(4):803-851, 1999.
- [11] A. Hyvarinen. *Independent Component Analysis.* Inter-Science, Wiley, 2001.
- [12] E. Moulines, J. Cardoso, and E. Cassiat. *Maximum likelihood for blind separation and deconvolution of noisy signals using mixture models.* In ICASSP, volume 5, pages 3617-3620,