

# Diagnostic de systèmes spatialement répartis, modèle génératif et méthode à noyau

Etienne CÔME<sup>1</sup>, Latifa OUKHELLOU<sup>1,2</sup>, Patrice AKNIN<sup>1</sup>, Thierry DENOËUX<sup>3</sup>

<sup>1</sup>Institut National de Recherche sur les Transports et leur Sécurité,  
2 av. Malleret-Joinville, 94114 Arcueil Cedex, France

<sup>2</sup>Université Paris XII - CERTES,  
61 av du Général de Gaulle, 94100 Créteil, France

<sup>3</sup>Université de Technologie de Compiègne - HEUDIASYC,  
Centre de Royallieu ,BP 20529, 60205 Compiègne Cedex, France

come@inrets.fr,oukhellou@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 (condensateurs) dont le nombre est variable et sur lesquels les observations prélevées sont spatialement dépendantes ; une défaillance d'un sous-système influera donc sur toute ou partie des observations. L'objectif est d'estimer la gravité du défaut de chaque sous-système en tenant compte de ces interdépendances. 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 prise en compte de non linéarités dans le modèle est traitée ici à l'aide d'une analyse canonique régularisée à noyau. Des résultats encourageants obtenus sur des signaux simulés bruités montrent l'efficacité de l'approche développée.

**Abstract** – This paper presents an automatic diagnosis tool of a railway infrastructure system: the track circuit. This system is made up by a variable number of spatially dependent subsystems (trimming capacitors). A defective subsystem modifies inspection data downstream its position. The aim is to estimate the defect graveness of each subsystem by taking into account these particularities. The diagnosis approach is based on a graphical model which allows to taking advantages from prior knowledge on the dependencies existing between the variables describing the system. The relations between nodes of the generative model have been linearized with the help of the Regularized Kernel Canonical Correlation Analysis. We show that good results are obtained on noised simulated signals, which demonstrate the efficiency of the approach.

## 1 Introduction

### 1.1 Contexte applicatif

Cet article concerne le diagnostic d'un système complexe de l'infrastructure ferroviaire, le circuit de voie (CdV) qui intervient dans le contrôle-commande des trains. Il 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 de support de transmission d'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. Ils permettent de limiter l'affaiblissement du signal émis résultant du caractère inductif de la voie ferrée.




FIG. 1 – Schéma d'un circuit de voie

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 en cabine, et le train est automatiquement arrêté. De même, lorsque le signal

est trop faible, le canton est supposé occupé alors qu'il ne l'est pas. Ces défauts peuvent concerner l'ensemble des éléments constitutifs du CdV, mais dans cet article, nous ne nous intéresserons qu'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  $I_{cc}$ . Pour des raisons de sécurité, cette amplitude doit rester suffisamment grande de manière à garantir la transmission d'information de manière certaine.

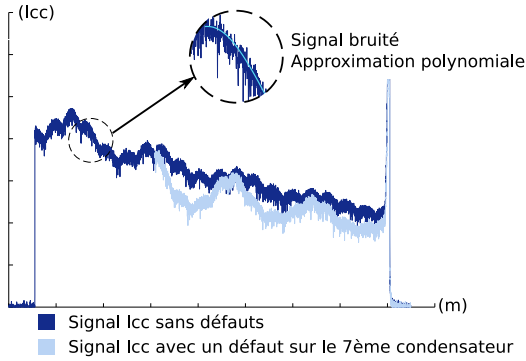


FIG. 2 – Exemple de relevé  $I_{cc}$  pour un système sans défaut et avec défaut sur le condensateur 7

## 1.2 Problématique

Le CdV peut être considéré comme un système global décomposé en plusieurs sous-systèmes (les condensateurs d'accord). 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 (cf. Figure 2) :

- les sous-systèmes sont organisés spatialement sur un axe orienté (de l'émetteur vers le récepteur),
- les signatures des sous-systèmes (chainettes) sont liées spatialement de façon unidirectionnelle : l'allure de la signature d'un sous-système dépend 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  $N$  est variable. Il dépend de la longueur du CdV.

Une approche classifiante du problème qui cherche à agréger les défauts en catégories, est possible [1], mais nous nous placerons ici dans un cadre de régression ; on cherche à estimer la résistance série de chaque condensateur de compensation à partir de  $I_{cc}$ .

## 2 Modèle linéaire du système

### 2.1 Modèle graphique linéaire gaussien

Pour un système  $S$  spatialement réparti, composé de  $N$  sous-systèmes  $S_1, S_2, \dots, S_N$  sur lesquels les observations  $\mathbf{c}_1, \mathbf{c}_2, \dots, \mathbf{c}_N$  sont prélevées, la dépendance amont-aval signifie qu'une défaillance du sous-système  $S_j$  influencera quasi inévitablement les observations  $\mathbf{c}_j, \dots, \mathbf{c}_N$  (et pas uniquement  $\mathbf{c}_j$ ) comme le montre la figure 2. Toutes les relations entre les variables d'intérêt  $r_1, r_2, \dots, r_N$  (ici les résistances des condensateurs) et les variables observées  $\mathbf{c}_1, \dots, \mathbf{c}_N$  (chainettes du signal) peuvent être représentées par un modèle graphique comme le montre la figure 3. Ce modèle permet de spécifier les dépendances existant entre les différentes variables décrivant le système complet. D'un point de vue pratique et pour diminuer la dimension de l'espace des variables d'entrée tout en limitant l'influence du bruit, chaque chainette du signal  $I_{cc}$  sera approximée par un polynôme du second degré. Chaque variable observée  $\mathbf{c}_i$  correspond donc au vecteur des coefficients du polynôme décrivant la  $i$ ème portion du signal.




FIG. 3 – 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 :

$$\mathbf{c} = \mathbf{A} \cdot \mathbf{r} + \mathcal{E}, \quad \mathcal{E} \sim \mathcal{N}(0, \Sigma_{\mathcal{E}}), \quad (1)$$

avec  $\mathbf{c} = [\mathbf{c}_1, \mathbf{c}_2, \dots, \mathbf{c}_N]^t$ ,  $\mathbf{r} = [r_1, r_2, \dots, r_N]^t$ ,  $\mathbf{A}$  une matrice triangulaire inférieure par bloc,  $\Sigma_{\mathcal{E}}$  une matrice diagonale.

D'un point de vue applicatif, cette modélisation offre l'avantage de pouvoir s'adapter à un nombre  $N$  variable de sous-systèmes. Car en apprenant le modèle pour les CdV les plus longs, il est possible d'extraire des sous-modèles pour toutes les tailles de CdV inférieures ( $N' < N$ ).

### 2.2 Apprentissage et inférence

Pour apprendre les paramètres  $\mathbf{A}$  et  $\Sigma_{\mathcal{E}}$  du modèle (1) dans un cadre supervisé, une approche par maximum de vraisemblance est utilisée, en prenant en considération la structure particulière de la matrice de régression.  $\mathbf{A}$  est alors la solution de  $N$  problèmes de moindres carrés. Lorsque  $\mathbf{A}$  a été estimée, une estimation empirique de la variance des résidus permet d'atteindre  $\Sigma_{\mathcal{E}}$ .

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 :

$$\hat{\mathbf{r}} = \mathbf{c}^t \Sigma_{\mathcal{E}}^{-1} \mathbf{A} \Sigma_{\mathbf{r}} \quad , \quad \text{où } \Sigma_{\mathbf{r}} = (\mathbf{A}^t \Sigma_{\mathcal{E}}^{-1} \mathbf{A})^{-1} \quad (2)$$

### 3 Prise en compte de non-linéarités

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 [3] qui sont malheureusement très lourdes en temps de calcul. Plutôt que d'intégrer la non linéarité dans le modèle et donc 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 que nous allons présenter succinctement.

#### 3.1 Analyse canonique régularisée à noyau

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 [2][4]. Dans ce cas, il est cependant nécessaire d'introduire dans le critère (corrélation) un terme de régularisation pour prévenir un sur-apprentissage. 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)

#### 3.2 Prétraitement non linéaire

L'objectif du prétraitement par RKCCA est de trouver de nouvelles variables, transformations non linéaires des variables  $\mathbf{c}_i$ , qui dépendent linéairement de leurs parents  $\boldsymbol{\pi}_i = \{r_1, \dots, r_i\}$ . Ces variables transformées définissent ainsi un nouvel espace d'entrée pour le modèle linéaire présenté dans la partie précédente.

On recherchera donc pour chaque noeud  $\mathbf{c}_i$ , une transformation non linéaire, de corrélation maximale avec une combinaison linéaire de ses parents (cf. figure 4). Le calcul nécessite de résoudre le problème de valeur propre généralisé dual défini par la relation :

$$= \lambda \begin{pmatrix} 0 & \mathbf{K}_{\mathbf{c}_i} (\boldsymbol{\Pi}_i \boldsymbol{\Pi}_i^t) \\ (\boldsymbol{\Pi}_i \boldsymbol{\Pi}_i^t) \mathbf{K}_{\mathbf{c}_i} & 0 \end{pmatrix} \begin{pmatrix} \boldsymbol{\alpha}_i \\ \boldsymbol{\beta}_i \end{pmatrix} \\ = \lambda \begin{pmatrix} (1 - \tau) \mathbf{K}_{\mathbf{c}_i}^2 + \tau \mathbf{K}_{\mathbf{c}_i} & 0 \\ 0 & (\boldsymbol{\Pi}_i \boldsymbol{\Pi}_i^t)^2 \end{pmatrix} \begin{pmatrix} \boldsymbol{\alpha}_i \\ \boldsymbol{\beta}_i \end{pmatrix}, \quad (3)$$

où  $\boldsymbol{\Pi}_i = [\boldsymbol{\pi}_{i1}, \dots, \boldsymbol{\pi}_{iM}]^t$ ,  $\mathbf{K}_{\mathbf{c}_i}$  est la matrice de Gram construite en utilisant un noyau  $K$  sur les données  $[\mathbf{c}_{i1}, \dots, \mathbf{c}_{iM}]^t$ ,  $M$  étant le nombre d'individus.

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

$$\mathbf{s}_i = \mathbf{K}_{\mathbf{c}_i} \cdot \boldsymbol{\alpha}_i. \quad (4)$$

Les combinaisons  $\mathbf{s}_i$  sont alors utilisées comme nouvelles entrées du modèle décrit par l'équation 1, en remplacement des  $\mathbf{c}_i$  (cf. Figure 4).

$$\mathbf{s} = \mathbf{A} \cdot \mathbf{r} + \mathcal{E}, \quad (5)$$

avec  $\mathbf{s} = [\mathbf{s}_1, \dots, \mathbf{s}_N]^t$ .

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.

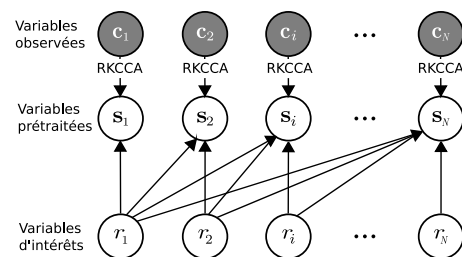


FIG. 4 – Modèle génératif avec un prétraitement par une analyse canonique régularisée à noyau

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 [6] reposant sur la décomposition incomplète de Cholesky de la matrice  $\mathbf{K}_{\mathbf{c}_i}$ . 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  $\mathbf{s}_i$  trouvées par notre prétraitement suivant leur corrélation avec la meilleure combinaison linéaire de variables explicatives. Cette corrélation étant es-

timée 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  $\mathbf{c}$  par  $\mathbf{s}$  dans l'équation (2), soit,

$$\hat{\mathbf{r}} = \mathbf{s}^t \Sigma_{\mathcal{E}}^{-1} \mathbf{A} \Sigma_{\mathbf{s}} \quad , \quad \text{où} \quad \Sigma_{\mathbf{s}} = (\mathbf{A}^t \Sigma_{\mathcal{E}}^{-1} \mathbf{A})^{-1} \quad (6)$$

## 4 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 [5], 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 » [5]. 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 son estimé, et leur coefficient de corrélation.

	EQM	Corr coef
Linéaire Gaussien	0.1018	0.7699
RKCCA (noyau polynomial)	0.0139	0.9684
RKCCA (noyau gaussien)	0.0244	0.9415

TAB. 1 – Résultats sur signaux simulés bruités

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).




FIG. 5 – Evolution de la résistance estimée en fonction de la résistance réelle pour le 9ème condensateur

Nous pouvons observer sur cette figure l'intérêt du prétraitement non linéaire, en particulier pour les faibles va-

leurs de résistance ( $r \simeq 0$ ).

## 5 Conclusion

La méthode proposée dans cet article traite le problème de diagnostic d'un système constitué d'une chaîne de plusieurs sous-systèmes 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 sur la chaîne. L'approche présentée est basée sur un modèle graphique qui offre une représentation et une modélisation appropriée de ce type de problème. 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 noeuds 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. En perspective, nous avons défini de travailler sur des aspects semi-supervisés dans ce modèle.

## Remerciements

Les auteurs remercient la SNCF et en particulier M. Marot pour sa collaboration durant ce projet.

## Références

- [1] P. Aknin, L. Oukhellou, and F. Vilette. Track circuit diagnosis by automatic analysis of inspection car measurements. *WCRR*, 2003.
- [2] 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.
- [3] C. Bishop. *Pattern Recognition and Machine Learning*. Springer, 2006.
- [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] L. Oukhellou, P. Aknin, and E. Delechelle. Infrastructure system diagnosis using empirical mode decomposition and hilbert transform. *ICASSP'06 Toulouse*, 2006.
- [6] J. Shawe-Taylor and N. Cristianini. *Kernel Methods for Pattern Analysis*. Cambridge University Press, June 2004.