



DIAGNOSTIC DE SOUDURES PAR ÉTINCELAGE : UN PROBLÈME DE VALIDATION DE MODÈLES NON-STATIONNAIRES

D. Brie, D. Sauter, M. Tomczak, R. Lorenzini

CRAN - CNRS URA 821, Université de Nancy I, B.P. 239, 54506 VANDOEUVRE CEDEX

RÉSUMÉ

Dans cet article, nous proposons une extension des méthodes locales au problème de la détection de changement dans le degré de non-stationnarité, ou de manière équivalente dans le gain scalaire optimal de l'algorithme LMS. Notre approche se décompose en deux phases: l'apprentissage du gain optimal effectué par un algorithme LMS à gain adaptatif et sa surveillance par un test local associé à l'algorithme précédent. Cette méthode est appliquée à un problème de diagnostic de soudure par étincelage.

ABSTRACT

In this paper, an extension of local tests to the problem of detection of change in the non-stationary degree, is proposed. This problem which is equivalent to detect change in the optimal gain associated to the LMS algorithm is decomposed in two stages : the optimal gain is learned by a LMS algorithm with adaptive gain and then, is monitored by using the local test associated to this algorithm. This approach is applied to a flash welding diagnosis problem.

1. INTRODUCTION

Le soudage par étincelage de tôles est utilisé sur les lignes de laminage afin d'en assurer le fonctionnement continu. Ce procédé se décompose en deux opérations. La première est le chauffage : la tension fournie par le secondaire d'un transformateur est appliquée aux bornes des deux tôles à souder. Elles sont alors rapprochées lentement de manière à ce qu'il se crée un arc électrique permettant de porter le métal à la température de soudage. Au bout d'un temps fixé à l'avance en fonction du type de production, on diminue le rapport de transformation de manière à appliquer aux bornes des tôles une tension dite d'entretien. Les deux tôles sont alors rapprochées très rapidement jusqu'au court-circuit franc : c'est l'opération de forgeage. Un des problèmes majeurs rencontrés sur la ligne est la casse de la soudure car elle entraîne une immobilisation longue et coûteuse. Le but de cette étude est de construire des indicateurs représentatifs de la qualité de la soudure. Il a été montré expérimentalement que les variations de l'impédance de l'ensemble {transformateur, tôles, arc électrique} contiennent des informations relatives à cette qualité. Parmi les différents défauts possibles, nous nous intéressons plus particulièrement à ceux qui se manifestent par un changement au niveau du degré de non-stationnarité. Ce type de changement est principalement causé par un mauvais positionnement des tôles et/ou une modification de leurs caractéristiques métallurgiques. Le deuxième paragraphe permet de poser ce problème de diagnostic comme un problème de validation du gain scalaire optimal de l'algorithme LMS utilisé. Il se décompose en deux phases : d'une part, l'apprentissage du gain scalaire optimal pour lequel on propose

un algorithme LMS à gain adaptatif et d'autre part, la surveillance de ce gain à l'aide d'un test local associé à cet algorithme.

2. POSITION DU PROBLÈME

On considère le modèle linéaire non-stationnaire :

$$y_n = \Phi_n^T \theta_n + \varepsilon_n \quad (1)$$

et on suppose que les non-stationnarités présentes dans le signal sont causées par des variations temporelles lentes du paramètre θ_n et que le bruit de mesure ε_n est indépendant de Φ_n . Les variations lentes de θ_n sont prises en compte par un

hypermodèle du type :

$$\theta_n = \theta_{n-1} + \delta_n \quad (2)$$

où δ_n est un incrément petit, qui peut prendre différentes

formes, selon que l'on considère des variations permanentes déterministes ou aléatoires. On suppose de plus, que δ_n est indépendant de Φ_n et de ε_n . Le degré de non-stationnarité

associé au modèle (1), (2) est défini par [5] :

$$\alpha_n = \left(\frac{P_\Phi d_n^2}{P_\varepsilon} \right)^{1/2} \quad (3)$$

avec:

$$d_n^2 = E(|\delta_n|^2),$$

$$P_\Phi = E(|\Phi_n|^2), \quad P_\varepsilon = E(|\varepsilon_n|^2)$$

On peut noter que la vitesse de variation du modèle ne se mesure pas dans l'absolu mais seulement par rapport au bruit de sortie. Les non-stationnarités lentes sont celles dont le degré



de non-stationnarité est petit devant 1 tandis que les ruptures sont caractérisées par un degré de non-stationnarité supérieur à 1 occasionnellement et petit devant 1 partout ailleurs. Le problème de la détection de rupture de modèle a été largement étudié [1], et l'objectif de cet article est de proposer une approche permettant de détecter des changements autres que des ruptures dans le degré de non-stationnarité. Ce problème, formulé en terme de test d'hypothèses, s'écrit :

$$H_0 : \alpha_n = \alpha_0, \quad \alpha_0 \ll 1$$

$$H_1 : \alpha_n = \alpha_1, \quad \alpha_1 \ll 1$$

On considère à présent que l'estimation adaptative de θ_n est réalisée par un algorithme de type LMS donné par [7] :

$$\hat{\theta}_n = \hat{\theta}_{n-1} + \gamma_n \Phi_n e_n \quad (4)$$

$$e_n = y_n - \Phi_n^T \hat{\theta}_{n-1} \quad (5)$$

Dans le cas d'un LMS à pas constant, le pas optimal dépend du modèle choisi pour décrire les évolutions du paramètre θ_n . Ainsi, dans le cas d'une marche aléatoire, où l'incrément δ_n est une séquence i. i. d. de moyenne nulle et de covariance Q avec $\text{trace}(Q) = d^2$:

$$\gamma_{\text{opt}} = \left(\frac{d^2}{\sigma^2 P_\Phi} \right)^{1/2} = O(\alpha_n) \quad (6)$$

tandis que dans le cas de variations permanentes déterministes ($\delta_n = d$) :

$$\gamma_{\text{opt}} = \left(\frac{d^2}{\sigma^2 P_\Phi} \right)^{1/3} = O(\alpha_n^{2/3}) \quad (7)$$

Compte tenu des relations (6) et (7), il apparaît que le gain optimal peut être considéré comme un paramètre caractérisant la vitesse des non-stationnarités et que le problème de la détection de changement dans le degré de non-stationnarité est équivalent au problème de détection de changement dans le gain optimal. Il est résolu en associant un test local [3] à l'algorithme LMS à gain adaptatif présenté au deuxième paragraphe.

3. LMS A GAIN ADAPTATIF

L'objectif de la phase d'apprentissage est de déterminer le gain scalaire optimal γ , c'est à dire celui qui assure la meilleure capacité de poursuite de l'algorithme adaptatif. Pour cela, définissons l'écart entre le paramètre estimé et le paramètre vrai :

$$\Psi_n = \hat{\theta}_n - \theta_n \quad (8)$$

On a alors

$$e_n = y_n - \Phi_n^T \hat{\theta}_{n-1} = \varepsilon_n + \Phi_n^T \Psi_{n-1}$$

En remplaçant e_n dans l'équation (5), il vient :

$$\hat{\theta}_n = \hat{\theta}_{n-1} - \gamma_n \Phi_n \Phi_n^T \Psi_{n-1} + \gamma_n \varepsilon_n \Phi_n$$

En soustrayant membre à membre avec (2), on obtient :

$$\Psi_n = (I - \gamma_n \Phi_n^T \Phi_n) \Psi_{n-1} + \gamma_n \varepsilon_n \Phi_n - \delta_n$$

On définit alors le gain scalaire optimal comme étant celui qui minimise l'erreur quadratique moyenne :

$$EQM = E(\|\Psi_{n+1}\|^2)$$

Il peut être estimé en utilisant une approche de type gradient stochastique :

$$\gamma_n = \gamma_{n-1} + \eta \frac{\partial(\|\Psi_{n-1}\|^2)}{\partial \gamma_{n-1}}$$

où η est un petit gain. Le gradient instantané est donné par :

$$\begin{aligned} \frac{\partial(\|\Psi_n\|^2)}{\partial \gamma_n} &= 2(-\Phi_n^T \Phi_n \Psi_n + \Phi_n^T \varepsilon_n) \Psi_n \\ &= -2 \Phi_n^T \Psi_n \varepsilon_n \end{aligned}$$

La propagation de la récurrence sur l'écart Ψ_n est alors obtenue en supposant qu'après la période transitoire le paramètre estimé se trouve dans le voisinage du paramètre vrai. On peut alors négliger le terme en γ_n et faire l'approximation suivante [7] :

$$\delta_n \approx -\Phi_n \varepsilon_n$$

On obtient finalement un algorithme LMS à gain adaptatif :

$$\hat{\theta}_n = \hat{\theta}_{n-1} + \gamma_n \Phi_n \varepsilon_n \quad (9)$$

$$e_n = y_n - \Phi_n^T \hat{\theta}_{n-1} \quad (10)$$

$$\hat{\gamma}_n = \hat{\gamma}_{n-1} + \eta \Phi_n^T \Psi_{n-1} \varepsilon_n \quad (11)$$

$$\Psi_n = (I - \gamma_n \Phi_n \Phi_n^T) \Psi_{n-1} + \varepsilon_n \Phi_n \quad (12)$$

qu'on peut écrire sous la forme générale :

$$\begin{bmatrix} \hat{\theta}_n \\ \hat{\gamma}_n \end{bmatrix} = \begin{bmatrix} \hat{\theta}_{n-1} \\ \hat{\gamma}_{n-1} \end{bmatrix} + \begin{bmatrix} \hat{\gamma}_n I & 0 \\ 0 & \eta \end{bmatrix} \begin{bmatrix} \Phi_n \varepsilon_n \\ \Phi_n^T \Psi_{n-1} \varepsilon_n \end{bmatrix}$$

ou

$$\hat{\Theta}_n = \hat{\Theta}_{n-1} + \Gamma H(\hat{\Theta}_{n-1}, \Phi_n, \Psi_{n-1}) \quad (13)$$

4. VALIDATION DU GAIN SCALAIRE

Nous disposons maintenant du gain scalaire optimal γ_0 et le problème est de savoir s'il est toujours caractéristique d'un ensemble de données de taille N . Dans un premier temps examinons le problème de la surveillance globale du paramètre étendu :

$$\Theta_n^T = [\theta_n^T \quad \gamma_n]^T$$

qui peut être posé comme le test d'hypothèses locales suivant :

$$H_0 : \Theta_n = \Theta_0 = [\theta_0^T \quad \gamma_0]^T$$

$$H_1 : \Theta_n = \Theta_0 + \frac{1}{\sqrt{N}} \delta \Theta$$

$$= [\theta_0^T + \frac{1}{\sqrt{N}} \delta \theta^T \quad \gamma_0 + \frac{1}{\sqrt{N}} \delta \gamma]^T$$

où γ_0 et θ_0 sont des valeurs connues (identifiées) du gain scalaire optimal et du paramètre. Ce test peut être résolu grâce au test local associé à l'algorithme adaptatif utilisé. En effet, dans [3], il est montré que la somme cumulée :

$$\begin{aligned} D_N(\Theta_0, \delta \Theta) &= \frac{1}{\sqrt{N}} \sum_{k=1}^N H(\Theta_0, \Theta_0 + \frac{1}{\sqrt{N}} \delta \Theta, \Phi_k, \Psi_{k-1}) \end{aligned}$$

tend asymptotiquement vers une loi normale telle que :

$$H_0 : D_N(\Theta_0, 0) \approx N(0, R(\Theta_0))$$

$$H_1 : D_N(\Theta_0, \delta \Theta) \approx N(-h_\Theta \delta \Theta, R(\Theta_0))$$

Les matrices R et h_Θ sont estimées par :

$$\hat{R} = \frac{1}{N} \sum_{k=1}^N H(\Theta_0, \Theta_0, \Phi_k, \Psi_k) H(\Theta_0, \Theta_0, \Phi_k, \Psi_k)^T = \sigma^2 \Sigma \quad (14)$$

$$h_{\Theta} = E\left(\frac{\partial}{\partial \Theta} H(\Theta_0, \Theta_0, X_k)\right) \approx \Sigma \quad (15)$$

$$\hat{\Sigma} = \frac{1}{N} \begin{bmatrix} \sum_{k=1}^N \Phi_k \Phi_k^T & \sum_{k=1}^N \Phi_k^T \Psi_k \Phi_k^T \\ \sum_{k=1}^N \Phi_k \Psi_k^T \Phi_k & \sum_{k=1}^N (\Phi_k^T \Psi_k)^2 \end{bmatrix} \quad (16)$$

Cette approche transforme le problème de la détection de changement sur le paramètre Θ en un problème de détection de saut de moyenne sur la séquence $D_N(\Theta_0, 0) \approx N(\mu, R)$:

$$H_0 : \mu = 0$$

$$H_1 : \mu = -h_{\Theta} \delta \Theta$$

résolu grâce au test du GLR :

$$S = D_N^T R^{-1} h_{\Theta} (h_{\Theta} R^{-1} h_{\Theta})^{-1} h_{\Theta} R^{-1} D_N \quad (17)$$

La variable S est distribuée selon une loi du χ^2 à $p = \dim(\theta)$ degré de libertés et avec un paramètre de non centralité égal à $\lambda = 0$ sous l'hypothèse H_0 et égal à $\lambda = \delta \Theta^T h_{\Theta}^T R^{-1} h_{\Theta} \delta \Theta$ sous l'hypothèse H_1 . De plus, la puissance du test est une fonction croissante du paramètre de non-centralité.

On désire surveiller les changements sur le paramètre γ indépendamment de tout changement sur le paramètre θ . Ce problème peut se formuler comme le test d'hypothèses suivant :

$$H_0 : \Theta_n = [\theta_n^T \quad \gamma_0]^T$$

$$H_1 : \Theta_n = [\theta_n^T \quad \gamma_0 + \frac{1}{\sqrt{N}} \delta \gamma]^T$$

Le paramètre θ apparaît comme un paramètre de nuisance et la surveillance robuste de γ est résolue en utilisant une approche minimax similaire à celle présentée dans [4]. Considérons la transformation :

$$D_N^{\#} = -h_{\Theta}^T R^{-1} D_N \quad (18)$$

on a $D_N^{\#} \approx N(F \delta \Theta, F)$ avec

$$F = h_{\Theta}^T R^{-1} h_{\Theta} = \sigma^{-2} \Sigma \quad (19)$$

et le test du GLR correspondant est donné par :

$$S = D_N^{\#T} F^{-1} D_N^{\#} \quad (20)$$

Compte tenu du résultat précédent, le problème de la surveillance de γ est équivalent au test :

$$H_0 : \mu = F[\delta \theta, 0]$$

$$H_1 : \mu = F[\delta \theta, \delta \gamma]$$

Définissons alors la partition de la matrice :

$$F = \begin{bmatrix} F_{11} & F_{12} \\ F_{21} & F_{22} \end{bmatrix}$$

Le paramètre de non centralité s'écrit :

$$\lambda = \delta \theta^T F_{11} \delta \theta + 2 \delta \theta^T F_{12} \delta \gamma + F_{22} \delta \gamma^2 \quad (21)$$

On cherche alors le changement $\delta \theta$ le plus défavorable, c'est à dire celui qui minimise la puissance du test ou de manière équivalente le paramètre de non-centralité λ . Comme λ est une forme quadratique, on trouve une solution explicite, qui reportée dans l'équation (21), donne :

$$\lambda = (F_{22} - F_{21} F_{11}^{-1} F_{12}) \delta \gamma^2 = F^* \delta \gamma^2$$

Considérons alors la transformation :

$$D_N^* = \begin{bmatrix} F_{11}^{-1} F_{12} & 1 \end{bmatrix} D_N^{\#} \quad (22)$$

On a

$$H_0 : D_N^*(\Theta_0, 0) \approx N(0, F^*)$$

$$H_1 : D_N^*(\Theta_0, 0) \approx N(-F^* \delta \gamma, F^*)$$

et le test du GLR correspondant est donné par :

$$S^* = D_N^{*T} F^{*-1} D_N^* \quad (23)$$

5. APPLICATION

La phase de modélisation a montré que, vu du primaire, l'ensemble {transformateur, tôles, arc électrique} se comporte comme une impédance dont l'amplitude et la phase varient au cours du temps. Il en résulte que l'intensité circulant dans le circuit primaire, est une sinusoïde de même fréquence que la tension primaire, modulée en phase et en amplitude :

$$y_n = \rho_n \Re(e^{j\varphi_n} u_n) + \varepsilon_n$$

où u_n est la transformée de Hilbert de la tension primaire, $\Re(z)$ est la partie réelle du nombre complexe z et ε_n est un bruit blanc additif supposé suivre une loi normale de moyenne nulle et de variance σ^2 . En posant $u_n = u_{rn} + j u_{cn}$, on obtient le modèle linéaire :

$$y_n = \Phi_n^T \theta_n + \varepsilon_n$$

$$\Phi_n^T = [u_{rn} \quad -u_{cn}] \quad (24)$$

$$\theta_n^T = [\rho_n \cos(\varphi_n) \quad \rho_n \sin(\varphi_n)]$$

Il a été mis en évidence que le type de changements qui nous intéressent se manifeste dans la partie basse tension des signaux intensités primaire. C'est donc cette partie qui a été étudiée (cf. figure 1). D'autres types de défaut se manifestent dans la partie haute tension et dans la partie transitoire mais leur traitement nécessite des approches différentes. A rapport de transformation constant, le paramètre θ_n est inversement proportionnel à l'impédance de l'ensemble {transformateur, tôles, arc électrique}. La phase d'apprentissage du gain optimal a été effectuée sur un signal correspondant à une soudure saine. Pour assurer, d'une part, une capacité de poursuite minimale et d'autre part, la stabilité de l'algorithme, le gain optimal, calculé selon l'équation (11), a été contraint à satisfaire la condition : $0 < \gamma_{\min} \leq \gamma_n \leq \gamma_{\max}$.

Nous avons pu vérifier que la valeur initiale du paramètre θ avait une importance considérable sur l'estimation du gain et que les résultats fournis étaient cohérents si elle était choisie proche de la valeur vraie du paramètre θ . Ce problème a été contourné en figeant la valeur du gain γ pendant les 300 premiers échantillons du signal ceci afin de laisser le temps au paramètre θ de converger et ainsi d'avoir la condition $\hat{\theta}_n \approx \theta_n$ approximativement vérifiée. La figure (2) montre l'évolution temporelle du gain correspondant au signal de la figure (1) et ceci pour différentes valeurs du gain η utilisé dans l'équation (11). Comme attendu, la valeur de η détermine la vitesse de convergence vers le gain optimal ainsi que la précision de l'estimation. C'est sa valeur moyenne, calculée sur les 300 derniers échantillons avec $\eta = 0.0001$ qui a été utilisée comme valeur du gain optimal ($\gamma_{opt} = 0.025$). La procédure de



validation a ensuite été appliquée à un ensemble de 16 signaux correspondant à 5 soudures bonnes et 11 mauvaises. Les résultats sont reportés dans le tableau (1). La colonne Srob donne les résultats obtenus avec le test robuste calculé selon les équations (22), (23), et la colonne Snonrob donne les résultats obtenus sans prendre en compte l'influence du paramètre de nuisance θ , c'est à dire en imposant à la quantité $F_{11}^{-1}F_{12}$ de l'équation (22), d'être nulle. Il apparaît d'une part que la prise en compte du paramètre de nuisance permet d'améliorer sensiblement la qualité de la détection (cf. soudures n° 4, 7, 9, 12) et d'autre part, qu'il est possible de discriminer les bonnes soudures des mauvaises. Ainsi, en fixant (de manière empirique) le seuil de détection à 2, on obtient 1 fausse alarme et 0 non-détection.

6. CONCLUSION

Dans cet article, nous proposons une extension des méthodes locales au problème de la détection de changements dans le degré de non-stationnarité. Les résultats obtenus pour le problème particulier du diagnostic de soudure par étincelage sont encourageants. Cependant, ils ne concernent qu'un type bien particulier de défaut et il apparaît que la résolution globale de ce problème ne pourra se faire que par l'utilisation simultanée d'outils différents, pris en compte par l'intermédiaire d'un système expert. Une autre possibilité offerte par cette approche est la segmentation de signaux en zones ayant un degré de non-stationnarité constant. Ce point, actuellement à l'étude, pourrait être intéressant pour la construction d'algorithmes de poursuite.

RÉFÉRENCES

- [1] M. Basseville, Detecting changes in signals and systems. A survey, Automatica, vol. 23, pp. 309 - 326, 1988
- [2] A. Benveniste et al., Algorithmes adaptatifs et approximations stochastiques, Masson, 1987.
- [3] A. Benveniste et al., The asymptotic local approach to change detection and model validation, IEEE Trans. A. C., vol. 32, pp. 583-592, 1987.
- [4] R. Lorenzini, Mémoire d'ingénieur CNAM - CAMOS, Metz, 31 mars 1993
- [5] O. Macchi et al., Comparaison d'algorithmes adaptatifs en contexte non-stationnaire, Traitement du signal, vol. 6, pp. 333 - 387, 1989
- [6] A. Rougé et al., Optimum robust detection of changes in the AR part of a multivariable ARMA process. IEEE Trans. A. C., vol. 32, pp. 1116-1120, 1987.
- [7] B. Windrow, S. D. Stearn., Adaptive signal processing, Prentice Hall, 1985.

Qualité	n° soud	Srob	Snonrob
B	1	0.2401	0.8364
B	2	0.0447	0.1021
B	3	1.7368	0.8027
B	4	2.7273	3.6139
B	5	0.7372	0.5062
M	6	11.6841	12.0277
M	7	4.2508	2.0182
M	8	4.7374	7.9780
M	9	3.7524	1.5402
M	10	2.0653	0.9609
M	11	15.3996	15.5458
M	12	2.8796	1.1449
M	13	6.3765	5.8794
M	14	7.3735	7.0274
M	15	7.1537	6.940
M	16	9.0702	8.8561

Tableau 1 : surveillance du gain optimal




figure 1 : intensité primaire




figure 2 : intensité primaire, partie basse tension




figure 3 : évolution du gain pour différentes valeurs de η