

# Une approche pour la détection fondée sur une somme cumulée dynamique associée à une décomposition multiéchelle. Application à l'EMG utérin

Mohamad Khalil, Jacques Duchène

Université de Technologie de Troyes  
Laboratoire de Modélisation et Sécurité des Systèmes (LM2S)  
12, rue Marie Curie, B.P. 2060  
10010 Troyes cedex, FRANCE

`mohamad.khalil@univ-troyes.fr, jacques.duchene@univ-troyes.fr`

**Résumé** – Dans ce papier, nous proposons une approche de détection sans connaissance a priori de l'espace des hypothèses. Cette approche est fondée sur la somme cumulée dynamique (DCS) des rapports de vraisemblance généralisés. Elle est appliquée en association avec la décomposition multiéchelle utilisant la transformée en ondelettes. La combinaison de DCS et de la décomposition multiéchelle est très efficace pour la détection de changements en fréquence et en énergie. Une méthode de classification non supervisée fondée sur la comparaison de matrices de variance-covariance a été implantée après la détection. Les matrices sont calculées à partir des niveaux d'échelles les plus pertinents.

**Abstract** – In this paper we propose an approach of change detection with no a priori knowledge of the hypotheses on the process states. This approach is based on a Dynamic Cumulative Sum (DCS) computed from a local generalized likelihood ratio. It is applied in association with multiscale decomposition using wavelet transform. This combination of DCS and multiscale decomposition has been shown to be very efficient for detection of both frequency and energy changes. An unsupervised classification based on comparison between variance-covariance matrices has been implemented after detection. Matrices are computed from selected scales.

## 1 Introduction

Le problème de détection et de classification devient crucial quand les paramètres des hypothèses à détecter ne sont pas connus. Dans la littérature, quand on connaît les paramètres des hypothèses, le rapport de vraisemblance est de détecteur optimal (dans le sens de Newman-Pearson). Quand quelques paramètres restent inconnus, une procédure classique basée sur le rapport de vraisemblance généralisé est utilisée [2].

Dans la majorité des cas, comme dans les applications biomédicales, la détection doit se faire sans connaissance a priori des informations sur les hypothèses à détecter. C'est le cas dans le signal EMG utérin dont les caractéristiques changent d'une femme à l'autre et qui dépend pour chaque femme du terme de grossesse. De ce fait, une base de données unique ne peut pas être définie quels que soient la femme et les termes de grossesse.

Une solution à ce problème, utilisant une méthode de détection multihypothèse a été proposée dans [4]. Dans cette méthode les paramètres d'hypothèses sont appris au fur et à mesure de la détection. L'inconvénient majeur de cette méthode est qu'une nouvelle détection dépend des événements déjà détectés et identifiés.

Dans ce papier nous proposons une nouvelle méthode de détection sans connaissance a priori des paramètres d'hypothèses à détecter. Cette méthode sépare complètement la détection et la classification. Elle est fondée sur le calcul

de sommes cumulées dynamiques (locales) des rapports de vraisemblance entre deux hypothèses estimées avant et après chaque instant  $t$ . Cette méthode est associée à une décomposition multiéchelle utilisant la transformée en ondelettes. Cette décomposition est bien adaptée à la description des signaux EMG utérins et peut être utilisée pour résoudre le problème de classification.

## 2 La détection: algorithme de la somme cumulée dynamique

Soit  $X = (X_t) = (x_{1t}, \dots, x_{at})$  le vecteur d'observation à l'instant discret  $t$ . Supposons que la distribution du processus  $x$  dépende d'un paramètre  $\Theta$ , le problème consiste à détecter le changement en  $\Theta$ . Ce changement peut affecter la variance, le contenu fréquentiel du signal ou les deux en même temps.

Comme dans n'importe quel problème de détection, il est nécessaire de décider quel est le critère à minimiser (probabilité de fausses alarmes, probabilité de détection, retard à la détection...). Dans notre cas (détection dans l'EMG utérin) le retard à la détection n'est pas une de nos priorités car la décision finale n'est pas fondée sur l'instant exact d'arrivée d'un événement spécifique. Nous avons décidé de mettre plutôt en avant la probabilité de détection et de réduire a posteriori la probabilité de fausse alarme en fu-

sionnant les segments successifs classifiés dans une même classe. Dans ce but, la plupart de tests statistiques utilisés par les algorithmes de détection sont construits à base de rapports de vraisemblance et exploitent l'information de Kullback [1][2].

Notre approche de détection est fondée sur une somme cumulée dynamique (DCS : Dynamic Cumulative Sum) des rapports de vraisemblance entre deux hypothèses estimées autour de l'instant de changement  $t$ . Ces hypothèses dynamiques  $H_b^t$  (before) et  $H_a^t$  (after) sont définies en utilisant une fenêtre de taille  $N$  avant et après l'instant  $t$  de la façon suivante:

$$\begin{cases} H_b^t : & X_i; i = \{t - N, \dots, t - 1\} \text{ suit une loi de} \\ & \text{densité de probabilité } f_b^t \\ H_a^t : & X_i; i = \{t, \dots, t + N - 1\} \text{ suit une loi de} \\ & \text{densité de probabilité } f_a^t \end{cases}$$

Les paramètres de l'hypothèse  $H_b^t$  ( $\Theta_b$ ) sont estimés à partir de  $N$  points avant l'instant  $t$  et les paramètres de l'hypothèse  $H_a^t$  ( $\Theta_a$ ) sont estimés à partir de  $N$  points après l'instant  $t$ .

Soient  $t_1, t_2, \dots, t_{p-1}$  les instants de changement déjà estimés jusqu'à l'instant  $t$ . A cet instant  $t$ , nous définissons la somme cumulée dynamique comme la somme des rapports de vraisemblance du dernier instant de changement  $t_{p-1}$  jusqu'à l'instant  $t$ :

$$DCS(H_a^t, H_b^t) = \sum_{j=t_{p-1}}^t \log \frac{f_a^j(X_j)}{f_b^j(X_j)} = \sum_{j=t_{p-1}}^t \log(s_j) \quad (1)$$

Le sens de variation de DCS dépend de la variation de  $s_j$ . En effet, prenons le cas d'un signal qui contient deux segments de paramètres  $\Theta_0$  et  $\Theta_1$  comme indiqué sur la figure 1.a. Soit  $t_M$  le vrai instant de changement. On peut




FIG. 1: (a): la définition des hypothèses instantanées  $H_a^t$  et  $H_b^t$ . (b): l'évolution de la somme cumulée dynamique autour du point de changement  $t_M$ . (c) La fonction de détection

montrer [3] que si  $t < t_M - N$ ,  $E[\log s_t] = 0$ . Si  $t_M > t > t_M - N$ , les paramètres des deux hypothèses instantanées

se modifient et  $E[\log s_t] > 0$ . Quand  $t_M < t < t + N$ , c'est le cas inverse qui se produit:  $E[\log s_t] < 0$ . Enfin si  $t > t_M + N$ , on retrouve  $E[\log s_t] = 0$ . On peut donc constater que la somme cumulée dynamique passe par un maximum à l'instant vrai du changement  $t_M$ . Ce résultat est illustré sur la figure 1.b.

La fonction de détection utilisée pour estimer le point de changement est exprimée par:

$$g(t) = \max_{j=t_{p-1} \dots t} \left[ DCS(H_a^j, H_b^j) \right] - DCS(H_a^t, H_b^t) \quad (2)$$

L'instant d'arrêt est donc défini par:

$$t'_p = \inf\{n > t_{p-1} : g(n) > h\} \quad (3)$$

$t_{p-1}$  est l'instant de changement précédent,  $t_0=1$ . La figure 2.c montre la fonction de détection  $g(t)$  comparée à un seuil  $h$ .

Le  $p^{ieme}$  instant de changement est alors défini par:

$$t_p = \sup\{n < t'_p : g(n) = 0\} \quad (4)$$

La valeur de seuil est dynamique. Elle est fonction du retard à la détection  $\tau = t'_p - t_p$  désiré [3].

Cette méthode est appliquée après décomposition multi-échelle du signal. Le choix de l'ondelette et des échelles est expliqué dans [4].

### 3 Classification et rejet en ligne

La classification consiste à identifier les segments détectés dans le signal. Si les classes sont connues, le problème devient classique et plusieurs méthodes peuvent être utilisées dans la pratique pour résoudre ce problème [1]. Dans le cas de l'EMG utérin, il est difficile d'avoir des classes connues a priori car les caractéristiques du signal changent d'une femme à l'autre et en fonction du terme de grossesse. Cette classification est non supervisée et elle est appliquée en ligne (au fur et à mesure de la détection). Quand un événement est détecté, nous devons décider s'il correspond à une nouvelle hypothèse ou à une hypothèse déjà identifiée. Pour cela, les paramètres de cet événement courant sont comparés avec les paramètres de toutes les hypothèses déjà identifiées utilisant un test de classification. En effet, supposons que jusqu'à l'instant courant  $t$ ,  $M$  hypothèses sont déjà identifiées.  $\Theta_r$ ,  $r = 1 \dots M$  sont les paramètres de ces hypothèses. Appelons  $H_c$  l'hypothèse courante qui correspond à l'événement courant à classifier.  $\Theta_c$  est le paramètre de  $H_c$ . La classification consiste à comparer  $H_c$  avec toutes les hypothèses  $H_r$  pour trouver l'hypothèse la plus proche. Ce test dépend de la modélisation du signal et du type de changement à détecter.

Dans le cas de l'EMG utérin, nous nous sommes intéressés uniquement au cas de la décomposition en ondelettes car c'est celui qui a déjà donné les meilleurs résultats en généralisant les méthodes classiques de détection [4]. Les paramètres des hypothèses sont alors  $\Theta_r = \Sigma_r$ ,  $r = 1 \dots M$ , matrices de variance covariance des hypothèses déjà identifiées et  $\Theta_c = \Sigma_c$ , matrice de l'hypothèse courante.

Nous avons utilisé le test de Box [6]. Ce test appliqué entre  $H_c(\Sigma_c)$  et chaque  $H_r(\Sigma_r)$ ,  $testbox(\Sigma_c, \Sigma_r)$ , est donné par

l'équation suivante :

Si  $\Sigma_c = \Sigma_r$ , alors

$$testbox(\Sigma_c, \Sigma_r) = (1 - c_1) \left[ (n - 2) \text{Log} \left| \frac{n}{n - 2} W \right| - \right. \quad (5)$$

$$\left. \sum_i (n_i - 1) \text{Log} |\Sigma_i| \right] \quad (6)$$

suit une loi de  $\chi^2_\nu$  avec  $\nu = \frac{d(d+1)}{2}$ ,  $c_1 = \frac{2d^2+3d-1}{6(d+1)} \left( \frac{1}{n_{c-1}} + \frac{1}{n_r-1} - \frac{1}{n_c+n_r-2} \right)$ ,  $W = \frac{n_c \Sigma_c + n_r \Sigma_r}{n_c + n_r}$ ,  $i \in \{c, r\}$  et  $n = n_c + n_r$ .

Rappelons que l'hypothèse la plus proche est définie par :

$$H_{pp} : pp = \arg \left[ \min_r (testbox(\Sigma_c, \Sigma_r)) \right], r = 1 \dots M \quad (7)$$

le test de rejet est fondé sur la comparaison de  $testbox(\hat{\Sigma}_c, \hat{\Sigma}_{pp})$  à un seuil  $h_c$  en fixant une probabilité de fausse alarme pour  $testbox$ .

## 4 Résultats et performances

Les performances de cette méthode sont étudiées en utilisant des signaux simulés. Les segments sont générés en utilisant un bruit blanc filtré passe-bande par une banque de filtres de fréquences centrales différentes et de même largeur de bande  $BP$ . Chaque hypothèse  $H_i$  correspond à un segment filtré par un filtre spécifique passe bande de centre  $f_i$ . La distance entre deux hypothèses  $H_i$  et  $H_j$  est définie par  $\delta_{ij} = \frac{f_i - f_j}{BP}$ .

### 4.1 Performances en fonction de la longueur de la fenêtre d'analyse

Il est évident que la longueur de la fenêtre d'analyse doit être choisie la plus petite possible pour limiter le retard global à la détection  $t_p + N - t'_p$  sans augmenter notablement le nombre de fausses alarmes. La fi-




FIG. 2: Courbes COR correspondant à plusieurs valeurs de  $N$  utilisant des signaux synthétiques, représentant la probabilité de détection en fonction de la probabilité de fausses alarmes.




FIG. 3: Détection et classification à partir de signaux simulés utilisant l'ondelette de Coiflet (Daubechies modifiée).

gure 2 montre les courbes COR qui correspondent à  $N = 50, 100, 150, 200, 250$ . Ces courbes COR sont obtenues en utilisant 1000 segments de bruit blanc gaussien distribués dans deux classes selon leur variance (classe 1:  $\sigma_1^2 = \sigma^2$ , classe 2:  $\sigma_2^2 = 4\sigma^2$ ). Une détection satisfaisante est observée à partir  $N = 200$ . Cette valeur de  $N$  sera conservée pour la suite de l'analyse des performances.

### 4.2 Performances de détection/classification sur des signaux simulés

La figure 3 illustre un résultat de détection et de classification sur un signal simulé en utilisant l'ondelette de coiflet 5 (Daubechies modifiée). Dans cet exemple tous les segments sont bien détectés et classifiés selon quatre hypothèses en fonction de leur contenu fréquentiel et de leur énergie.

Les performances de la détection et de la classification sont analysées en traçant des courbes COR pour plusieurs paires  $\{H_i, H_j\}$ , i.e plusieurs distances  $\delta_{ij} = \frac{f_i - f_j}{BP}$ . Les résultats sont montrés sur la figure 4. Les performances de la classification apparaissent acceptables dès que la détection fournit des résultats satisfaisants (par exemple  $\delta_{ij} \geq 0.4$ ). Les performances de l'algorithme de détection DCS ne peuvent pas être comparées facilement avec celles des méthodes classiques décrites précédemment à cause des suppositions initiales liées aux méconnaissances a priori du signal :

- le nombre des hypothèses n'est pas connu a priori
- l'estimation en ligne des paramètres d'hypothèses
- l'absence d'une base de données pour l'apprentissage et pour la détection

Comme nous avons développé un algorithme dans [4] en prenant en compte les mêmes suppositions, l'algorithme DCS améliore cet algorithme de plusieurs façons :

- calcul d'une seule fonction de détection  $g(t)$
- la détection et la classification sont indépendantes. La détection ne dépend plus des événements déjà identifiés.




FIG. 4: Performances de détection (haut) et de classification (bas) pour plusieurs paires  $\{H_i, H_j\}$ , i.e selon  $\delta_{ij}$ . Haut : les abscisses correspondent aux fausses alarmes, les ordonnées correspondent aux détections. Bas : les abscisses correspondent au pourcentage de mal classés, les ordonnées correspondent au pourcentage de bonnes classifications. Pour  $\delta_{ij} = 0.5$ , la classification est exacte.  $N = 200$ .

- comme les paramètres des hypothèses sont calculés récursivement, le temps de calcul a été réduit énormément.

### 4.3 Illustration sur un signal réel

La figure 5 illustre la détection et la classification obtenues pour plusieurs hypothèses utilisant l'ondelette de coiffet. Tous les segments sont bien détectés et classifiés. Pour cet exemple, la classification a été validée par un expert qui a identifié trois hypothèses:  $H_1$ : activité de fond,  $H_2$ : contractions utérines,  $H_3$ : mouvements de bébé.

## 5 Conclusion

Une nouvelle méthode de détection/classification a été présentée dans ce papier. C'est une approche dynamique appliquée sans connaissance a priori des espaces d'hypothèses à détecter. Elle est basée sur la Somme Cumulée Dynamique des rapports de vraisemblance locaux et généralisés estimés dans une fenêtre d'analyse avant et après chaque instant  $t$ . Dans le but de détecter tout changement




FIG. 5: Exemple de détection et classification sur l'EMG utérin.

d'énergie ou de fréquence, cette méthode est développée pour réaliser la détection après décomposition en ondelettes. La classification est faite en comparant les matrices de variance covariance calculées après décomposition en détails.

Les performances de la détection et de la classification ont été étudiées en traçant des courbes COR et en utilisant des signaux simulés présentant différents contenus fréquentiels.

Par rapport à la méthode multihypothèse présentée dans [4], cette méthode présente les avantages de simplicité de programmation, de rapidité et d'indépendance de la détection vis à vis de la classification.

## Références

- [1] M. Basseville and I. Nikiforov. *Detection of abrupt changes, theory and application*, Englewood Cliffs, NJ: Prentice-Hall, Ch. 6, pp. 109-184, 1993.
- [2] B.K. Ghosh and P.K. Sen Handbook of sequential analysis, Marcel Dekker, INc 9, New York, 1991
- [3] M. Khalil, J. Duchêne. Dynamic Cumulative Sum approach for change detection. Soumis à IEEE signal processing, 1999.
- [4] M. Khalil, J. Duchêne, "Detection and classification of multiple events in piecewise stationary signals. Comparison between autoregressive and multiscale approaches" . Signal Processing, vol 75, n3, pp 239-251, 1999
- [5] S. Mallat and S. Zhong, "Characterisation of signals from multiscale edges" , *IEEE Trans. PAMI*, Vol. 14, No. 7, pp. 711-733, 1992.
- [6] G.A.F. Seber. Multivariate Observation, John Wiley & sons, Inc. New York, 1984.