

SEGMENTATION DES SIGNAUX ELECTROMYOGRAPHIQUES DE LONGUE DURÉE- APPLICATION À L'ETUDE DE L'INCONFORT

Wassim El Falou^{1,2}, Mohamad Khalil^{1,3}, Jacques Duchêne², Mustafa Maksoud¹

¹Université Libanaise, Faculté de Génie, Section I, Tripoli, Liban

²Université de Technologie de Troyes, LM2S, 12 rue Marie Curie, 10010 Troyes, France

³Université islamique du Liban, Département Biomédical, Khaldé, Liban
wafalou99@hotmail.com

(Received 22 May 2002 Accepted 12 December 2002)

RESUME

La détection et la segmentation de changement sont les premières étapes dans beaucoup d'applications en traitement des signaux. La plupart des algorithmes de segmentation sont basés sur la théorie de détection et des tests statistiques d'hypothèse. Quand les paramètres des hypothèses sont connus, les chercheurs utilisent un algorithme efficace appelé algorithme CUSUM pour résoudre le problème de la détection. Cet algorithme est basé sur le rapport de logarithme de vraisemblance. L'algorithme de CUSUM est optimal car il optimise le retard à la détection quand le temps moyen entre fausses alarmes tend vers l'infini. Dans beaucoup d'applications, les modifications peuvent affecter l'énergie, la fréquence ou ces deux paramètres en même temps. La détection d'un changement fréquentiel peut être effectuée en utilisant l'algorithme de CUSUM appliqué sur les innovations d'un modèle AR. Les coefficients AR contiennent des informations sur le contenu spectral du signal. Dans la plupart d'applications, les paramètres des hypothèses à détecter sont souvent inconnus et d'autres algorithmes doivent être appliqués pour la détection des changements. Ces algorithmes sont basés sur le calcul d'une somme cumulative dynamique (DCS) du rapport de logarithme de vraisemblance entre deux hypothèses localement estimées. L'estimation de ces hypothèses se fait à chaque instant t en utilisant deux fenêtres glissantes avant et après le temps courant t . La première partie de cet article fournit une vue globale de l'algorithme CUSUM, en se concentrant sur l'algorithme de somme cumulée dynamique. On présentera les propriétés et limites principales de DCS. Ensuite on propose un nouvel algorithme de détection utilisée pour résoudre ces problèmes. Une méthode automatique pour calculer les seuils est également présentée. On montrera ensuite quelques résultats après application de ces méthodes sur les signaux EMG posturaux.

Mots- clés : CUSUM, DCS, information de Kullback-Leibler, signaux EMG

ABSTRACT

Change detection and segmentation are the first steps of many signal processing applications. Most segmentation algorithms are based on the theory of statistical detection and hypothesis testing.

When the parameters of the hypotheses are known an efficient algorithm to solve the detection problem is the CUSUM algorithm based on the log-likelihood ratio. CUSUM algorithm is optimal in the sense that it optimizes the worst detection delay when the mean time between false alarms goes to infinity.

In many applications, modifications can affect energy, frequency, or both. Detection of a change in the frequency content can be performed using the CUSUM algorithm applied on the innovation of an AR modeling, the AR coefficients carrying information about the frequency content of the signal.

In usual applications, the parameters of the hypotheses corresponding to the segments to be detected are often unknown and other algorithms have to be applied for change detection. Such algorithms can be found based on the computation of a Dynamic Cumulative Sum (DCS) of the likelihood ratio between two locally estimated hypotheses. These hypotheses are estimated at each time t using two sliding windows before and after the current time t .

The first part of this paper provides an overview of the CUSUM algorithm, focusing on the Dynamic Cumulative Sum algorithm to describe its main properties and limits. Then a new detection algorithm is proposed to solve these problems. An automatic method to calculate the thresholds is also presented. The application of the segmentation algorithm in postural EMG signals is also presented.

Keywords: CUSUM, DCS, Kullback-Leibler information, EMG signals

INTRODUCTION

Le signal d'électromyographie (EMG) enregistré extérieurement sur la peau produit l'information utile liée au système de commande musculaire. Ses caractéristiques temporelles et spectrales dépendent fortement des conditions physiologiques et environnementales des enregistrements (Merletti *et al.*, 1990). Dans le but de l'évaluation de l'inconfort, il n'y a aucune évidence claire de la pertinence de la surface EMG (SEMG) pour exprimer la fatigue musculaire provoquée par malaise à long terme. Dans ce cas, les muscles sont actionnés dans leur fonction posturale et les enregistrements résultants d'EMG correspondent à une activité de niveau très bas. Le but d'un procédé de segmentation est de détecter l'existence d'une activité réelle d'EMG dans les enregistrements. Dans ce papier on présentera un algorithme de segmentation des signaux EMG long durée dans le cas où les paramètres d'hypothèses sont inconnues, une procédure automatique de choix de seuil est aussi présentée. La validité de cette méthode est démontrée sur plusieurs signaux EMG. Une application sur l'étude de l'inconfort sera présentée.

PROCEDURE DE DETECTION DE CHANGEMENT SPECTRAL DANS LE CAS DES HYPOTHESES CONNUES- ALGORITHME DE SOMME CUMULEE (CUSUM)

L'algorithme de somme cumulée est très performant dans le cas où les paramètres d'hypothèses sont connus. Il a été démontré que l'algorithme CUSUM est optimal dans le

sens qu'il minimise le temps moyen pour la détection, lorsque le temps moyen entre deux fausses alarmes tend vers l'infini (Basseville & Nikiforov, 1993) (Baron, 2000).

La somme cumulée est fondée sur le calcul récursif du rapport de la vraisemblance. La procédure CUSUM peut être considérée comme une séquence de tests répétés autour d'un point de changement k .

L'algorithme CUSUM intuitif se présente comme suit (Basseville & Nikiforov, 1993) (Nikiforov, 1995):

- A un instant k , la somme de logarithme des rapports de vraisemblance est:

$$S_1^k = \sum_{i=1}^k s_i = \sum_{i=1}^k \log \frac{f_{\theta_1}(x_i / x_{i-1}, \dots, x_1)}{f_{\theta_0}(x_i / x_{i-1}, \dots, x_1)} \quad (1)$$

- La fonction de détection à l'instant k :

$$g_k = S_1^k - \min_{1 \leq j \leq k} S_1^j \quad (2)$$

- L'instant d'arrêt est :

$$t_a = \min \{k : g_k \geq h\} \quad (3)$$

Cet algorithme CUSUM peut être écrit par une autre expression plus pratique (Basseville *et al.*, 1993) :

- $g_0 = z \geq 0$ ($z = 0$ souvent)
- $g_k = \max(0, g_{k-1} + s_k)$ (4)
- $t_a = \min \{k : g_k \geq h\}$

Il faut noter que cette formulation de CUSUM est plus efficace en temps de calcul que la première. De plus, elle est plus efficace en espace mémoire (en effet on n'a besoin que de mémoriser g_{k-1} et g_k au lieu des toutes les valeurs de S_1^k dans la première version).

L'algorithme de somme cumulée ne peut être appliquée que dans le cas où les échantillons sont indépendants. Dans notre cas (signaux biomédicaux) les échantillons sont dépendants et c'est pourquoi nous devons modéliser nos signaux pour pouvoir appliquer les algorithmes précédents. L'idée est de faire une modélisation autorégressive du signal original et ensuite d'appliquer la détection sur les innovations (erreurs de prédiction). L'expression du logarithme de vraisemblance devient alors :

$$S(x_1, x_2, \dots, x_j) = \sum_{i=1}^j \log \frac{f_{\theta_1}(x_i / x_{i-1}, \dots, x_1)}{f_{\theta_0}(x_i / x_{i-1}, \dots, x_1)} \quad (5)$$

f_{θ_0} et f_{θ_1} sont des probabilités conditionnelles.

Dans le cas d'un signal modélisé par un modèle AR (p), on peut écrire que :

$$x_i = -\sum_{k=0}^p a_k x_{i-k} + \sigma^2 \quad (6)$$

Une variation dans le signal se manifeste par une variation dans l'une des paramètres du modèle AR. Les paramètres des hypothèses sont alors :

$$\begin{aligned}\theta_0 &= (a_1^0, \dots, a_p^0, \sigma_0^2) \\ \theta_1 &= (a_1^1, \dots, a_p^1, \sigma_1^2)\end{aligned}$$

Il a été démontré que les signaux EMG de surface suivent une loi gaussienne (Merletti *et al.*, 1990). La probabilité conditionnelle s'écrit alors :

$$p_\theta(x_i / x_{i-1}, \dots, x_1) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2\sigma^2}\varepsilon_i^2} \quad (7)$$

Le logarithme de vraisemblance est alors:

$$s_i = \frac{1}{2} \left[\log \frac{\sigma_0^2}{\sigma_1^2} + \frac{(\varepsilon_i^0)^2}{\sigma_0^2} - \frac{(\varepsilon_i^1)^2}{\sigma_1^2} \right] \quad (8)$$

$$\text{avec } \varepsilon_i^j = x_i - \sum_{k=1}^p a_k x_{i-k}, \quad j=0,1 \quad (9)$$

En cherchant S_k , g_k , puis t_a , on peut détecter n'importe quel changement dans les paramètres AR.

METHODES DE DETECTION DES RUPTURES DANS LE CAS D'UN CHANGEMENT A PARAMETRES INCONNUS

En cas d'enregistrements d'EMG, les hypothèses ne sont pas connues a priori et une évaluation des paramètres d'hypothèse est exigée avant détection de changement. En outre ces paramètres ne sont pas stationnaires dans les enregistrements à long terme. Par exemple, si deux hypothèses sont "EMG" ou "bruit", les paramètres attachés à l'hypothèse "EMG" sont censés d'être changer avec le temps et cela est dû à l'indication de fatigue. Ce changement est le facteur principal à analyser dans le travail actuel. Par conséquent l'évaluation des paramètres doit être réalisée tout le long de l'enregistrement, par conséquent localement. Un algorithme de détail (DCS: La somme cumulative dynamique) a été développé la première fois pour associer la détection de changement et une évaluation des paramètres d'hypothèse autour du temps courant t (Khalil & Duchêne, 1999 a,b). Cependant l'application directe de DCS sur des signaux EMG n'est pas appropriée puisque les échantillons successifs d'EMG ne sont pas statistiquement indépendants. Une première approche s'est servie d'une décomposition d'ondelettes avant segmentation, l'algorithme de détection de changement étant appliqué aux niveaux choisis d'échelles. L'algorithme a été appliqué avec succès sur les enregistrements utérins d'EMG (Khalil & Duchêne, 2000). Une approche alternative est présentée ici. Elle est basée sur la modélisation des signaux EMG par un modèle AR. Elle modifie légèrement l'algorithme de DCS afin d'améliorer la détectabilité de changement.

Somme Cumulée dynamique (DCS)

Principe

Soit $X = X_i = (x_1, \dots, x_i)$ le vecteur d'observation jusqu'à l'instant i . Supposons que la distribution du processus X dépend d'un paramètre θ . Ce changement peut affecter la

variance, la distribution fréquentielle du signal ou les deux en même temps. La méthode de somme cumulée dynamique est aussi une méthode construite dans le cas où les paramètres de segmentation sont inconnus. Elle est appliquée aussi dans le cas où on veut suivre des changements locaux dans les signaux.

Cet approche de détection, appelée la Somme Cumulée Dynamique (DCS : Dynamic Cumulative Sum), peut être considérée comme une séquence répétée autour du point de changement k . Elle est fondée sur la somme cumulée locale des rapports de vraisemblance entre deux hypothèses locales estimés autour de l'instant courant i . Ces deux hypothèses dynamique H_a^i (« after i ») et H_b^i (« before i ») sont estimées en utilisant deux fenêtres de longueur N (Figure 1) avant et après l'instant i comme suit :

$$H_b^i : x_j, j = \{i - N, \dots, i - 1\} \text{ suit une loi de probabilité de densité } f_{\theta_b}(x_i / x_{i-1}, \dots, x_1)$$

$$H_a^i : x_j, j = \{i + 1, \dots, i + N\} \text{ suit une loi de probabilité de densité } f_{\theta_a}(x_i / x_{i-1}, \dots, x_1)$$




Figure 1. (a) Exemple d'un signal synthétique contenant un seul point de changement k . Abscisse : nombre des points. Ordonnée : amplitude arbitraire du signal. (b) Evolution de la somme cumulée dynamique autour du point de changement.

Les paramètres de l'hypothèse H_b^i , θ_b^i sont estimés à partir de N points avant l'instant i (fenêtre W_b), et les paramètres de l'hypothèse H_a^i , θ_a^i sont estimés à partir de N points après l'instant i (fenêtre W_a) (Figure 1).

A l'instant i , nous définissons DCS comme la somme des logarithmes de vraisemblance à partir le début jusqu'à l'instant i :

$$DCS(H_a^i, H_b^i) = \sum_{j=1}^i \log \frac{f_{\theta_a}^j(x_j / x_{j-1}, \dots, x_1)}{f_{\theta_b}^j(x_j / x_{j-1}, \dots, x_1)} = \sum_{j=1}^i s_j \quad (10)$$

$s_j = \log \frac{f_{\theta_a}^j(x_j / x_{j-1}, \dots, x_1)}{f_{\theta_b}^j(x_j / x_{j-1}, \dots, x_1)}$, le logarithme du vraisemblance, a un caractère local dans la

mesure où les paramètres de deux hypothèses sont réestimés à chaque pas dans les deux fenêtres de N points autour du point courant i.

Il est été démontré dans (Khalil, 1999; Khalil & Duchêne, 1999) que la fonction DCS arrive à son maximum au temps de changement k. L'évolution de DCS est présentée dans la Figure 1.b.

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

$$g(i) = \max_{1 \leq j \leq i} [DCS(H_a^j, H_b^j)] - DCS(H_a^i, H_b^i) \quad (11)$$

L'instant d'arrêt est:

$$t_s = \inf \{i : g(i) \geq h\} \quad (12)$$

avec h est un seuil fixe.

Le vrai instant de changement est estimé par :

$$k = \sup \{i > 1 : g(i) = 0\} \quad (13)$$

car c'est à partir de cet instant, la fonction g(i) commence à augmenter.

La formulation précédente est une formulation générale de DCS, et dans la suite nous allons exprimée s_j dans le cas des signaux modélisés par un modèle AR.

DCS en cas de changement d'un modèle AR

Dans le cas des signaux modélisés par un modèle AR d'ordre p, l'expression des densités de probabilité conditionnelle sont (cas EMG gaussien):

$$f_{\theta_b}(x_i / x_{i-1}, \dots, x_1) = f_{\theta_b}(\varepsilon_b^i) = \frac{1}{\sqrt{2\pi} \sigma_b} e^{-\frac{(\varepsilon_b^i)^2}{2(\sigma_b)^2}} \quad (\text{Avant l'instant courant } i)$$

$$f_{\theta_a}(x_i / x_{i-1}, \dots, x_1) = f_{\theta_a}(\varepsilon_a^i) = \frac{1}{\sqrt{2\pi} \sigma_a} e^{-\frac{(\varepsilon_a^i)^2}{2(\sigma_a)^2}} \quad (\text{Après l'instant courant } i)$$

avec $\varepsilon_b^i = x_i - \sum_{k=1}^p \hat{a}_b^k x_{i-k}$, $(\sigma_b)^2$ est l'estimée de la variance σ_0^2 du premier modèle AR ,

$\varepsilon_a^i = x_i - \sum_{k=1}^p \hat{a}_a^k x_{i-k}$, $(\sigma_a)^2$ est l'estimée de la variance σ_1^2 du second modèle AR.

L'expression du logarithme du rapport de vraisemblance est donc :

$$DCS(H_a^i, H_b^i) = \sum_{j=1}^i s_j = \sum_{j=1}^i \frac{1}{2} \left[\log \frac{(\hat{\sigma}_a^j)^2}{(\hat{\sigma}_b^j)^2} + \frac{(\varepsilon_a^j)^2}{(\hat{\sigma}_a^j)^2} - \frac{(\varepsilon_b^j)^2}{(\hat{\sigma}_b^j)^2} \right] \quad (14)$$

Lorsqu'on applique DCS dans le cas d'un modèle AR, il est utile de définir une troisième fenêtre qui est utilisée pour calculer les innovations (erreurs de prédiction).

Donc les fenêtres autour de l'instant courant i sont:

$$\begin{cases} W_b^j : i - N - p + 1 \dots i - p \\ W_p^j : i - p + 1 \dots i \\ W_a^j : i + 1 \dots i + N \end{cases}$$

La Figure 2 montre ces trois fenêtres, autour de l'instant i.




Figure 2. Définition des fenêtres pour DCS dans le cas des signaux modélisés par un modèle AR.. Abscisse : nombre des points. Ordonnée : amplitude arbitraire du signal.

La méthode DCS a démontré son efficacité lorsqu'elle est appliquée sur les signaux EMG utérin (Khalil & Duchêne, 2000), et aussi sur les signaux musculaires posturaux (Falou *et al.*, 2001).

Limitations de la méthode DCS

DCS présente quelques limitations qui sont liés à son utilisation dans des configurations spécifiques:

- Comme les fenêtres sont employées pour estimer localement les paramètres d'hypothèse avant et après le temps actuel i , le choix de la largeur de fenêtre a une grande influence sur le procédé de détection
- La propriété de détectabilité n'est plus préservée dans l'algorithme de DCS, et la détection échoue quand les deux hypothèses sont très proches (Figure 3). En fait la fonction de détection se stabilise après N points au delà du temps de changement sans atteindre le seuil.




Figure 3. Illustration d'un changement qui n'est pas détectée par DCS . (En haut) Abscisse : nombre des points. Ordonnée : amplitude arbitraire du signal. (Au milieu) DCS en chaque point. (En bas) fonction de détection en fonction du nombre des points.

On voit bien qu'il est difficile de voir un maximum dans le cas où les deux hypothèses sont proches (voir figure au milieu).

Somme Cumulée Dynamique Modifiée (MDCS)

Principe

Les limitations de la méthode DCS, nous conduisent à définir un nouvel algorithme qui permet de résoudre les problèmes de DCS. L'algorithme est modifié dans deux façons :

- Changement de la taille de la première fenêtre
- Double seuillage

A- Changement de la taille de la première fenêtre :

L'algorithme est aussi basé sur deux fenêtres glissantes W_b^i et W_a^i pour estimer les deux paramètres $\hat{\theta}_b^i$ et $\hat{\theta}_a^i$ à chaque instant i . Comme dans DCS, W_a^i est de taille constante N , mais W_b^i utilise toutes les échantillons de 1 jusqu'au $i-1$. Les deux fenêtres sont définies comme suit :


$$\begin{cases} W_b^i : 1 \dots i - 1 \rightarrow \hat{\theta}_b^i \\ W_a^i : i + 1 \dots t + N \rightarrow \hat{\theta}_a^i \end{cases}$$


Figure 4. Illustrations des fenêtres d'estimations dans MDCS. Abscisse : nombre des points. Ordonnée : amplitude arbitraire du signal.

On a noté que dans le cas d'un modèle AR, on doit aussi utiliser une troisième fenêtre W_p^i pour calculer l'erreur de prédiction ($\varepsilon_i^j = x_i + \sum_{k=1}^p a_k x_{i-k}$).

B- Double seuillage :

L'un des problèmes de DCS est qu'à partir de l'instant de changement et avant l'instant d'arrêt, l'estimation de $\hat{\theta}_b^i$ est erronée (points appartenant à l'autre hypothèse) et cela influe sur la détection. Pour résoudre ce problème, l'idée consiste à utiliser deux seuils dans la fonction de détection:

- Le premier seuil est le seuil bas h_L , lorsque la fonction de détection atteint ce seuil on arrête l'estimation de $\hat{\theta}_b^i$.
- Le second seuil est le seuil haut h_H , qui est le seuil de détection. Lorsque la fonction de détection atteint ce seuil, on arrête la détection, et on estime le vrai temps d'arrêt.

L'expression du logarithme de vraisemblance est :

$$MDCS(H_a^i, H_b^i) = \sum_{j=1}^i \log \frac{f_{\hat{\theta}_a}^j(x_j / x_{j-1}, \dots, x_1)}{f_{\hat{\theta}_b}^j(x_j / x_{j-1}, \dots, x_1)} = \sum_{j=1}^i s_j \quad (16)$$

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

$$g(i) = \max_{1 \leq j \leq i} [MDCS(H_a^j, H_b^j)] - MDCS(H_a^i, H_b^i) \quad (17)$$

L'instant d'arrêt est:

$$t_s = \inf \{i : g(i) \geq h_H\} \quad (18)$$

avec h_H est le seuil haut.

Le vrai instant de changement est estimé par :

$$k = \sup \{i < 1 : g(i) = 0\} \quad (19)$$

Dans le cas d'un modèle AR (gaussien), l'expression du logarithme de vraisemblance est :

$$MDCS(H_a^i, H_b^i) = \sum_{j=1}^i s_j = \sum_{j=1}^i \frac{1}{2} \left[\log \frac{(\hat{\sigma}_a^j)^2}{(\hat{\sigma}_b^j)^2} + \frac{(\varepsilon_a^j)^2}{(\hat{\sigma}_a^j)^2} - \frac{(\varepsilon_b^j)^2}{(\hat{\sigma}_b^j)^2} \right] \quad (20)$$

$\hat{\sigma}_b^j$: Estimation de l'écart type de l'innovation du modèle AR « before »

ε_b^j : Erreur de prédiction à l'instant i calculée par les paramètres AR du modèle « before »

$\hat{\sigma}_a^j$: Estimation de l'écart type de l'innovation du modèle AR « after »

ε_a^j : Erreur de prédiction à l'instant i calculée par les paramètres AR du modèle « after »

Propriétés du nouvel algorithme

Le nouvel algorithme est caractérisé par deux propriétés importantes (Falou *et al.*,; 2001):

- Conservation de la propriété de détectabilité

Sous l'hypothèse H_0 , et lorsque i tend vers infini, $E_{\hat{\theta}_0}[s_i]$ est négatif. En effet lorsque i tend vers l'infini $\hat{\theta}_b^i \rightarrow \theta_0$, et $\hat{\theta}_a^i$ est un estimateur moins efficace de θ_0 et donc

l'espérance de $\log \frac{f_{\hat{\theta}_a}^i(x_j / x_{j-1}, \dots, x_1)}{f_{\hat{\theta}_b}^i(x_j / x_{j-1}, \dots, x_1)}$ est négatif, et alors $E_{\hat{\theta}_0}[s_i] = E_{\hat{\theta}_0} \left[\log \frac{f_{\hat{\theta}_a}^i(x_j / x_{j-1}, \dots, x_1)}{f_{\hat{\theta}_b}^i(x_j / x_{j-1}, \dots, x_1)} \right] < 0$

Sous l'hypothèse H_1 et lorsque la fonction de détection atteint la valeur de seuil bas h_L , on arrête l'estimation de $\hat{\theta}_b$ et on a un estimateur $\hat{\theta}_b = \hat{\theta}_0$, pour l'estimation de $\hat{\theta}_a$ on a $\hat{\theta}_a = \hat{\theta}_1$, et on a alors l'espérance de $\log \frac{f_{\hat{\theta}_1}^i(x_j / x_{j-1}, \dots, x_1)}{f_{\hat{\theta}_0}^i(x_j / x_{j-1}, \dots, x_1)}$ est positif, car l'estimateur $\hat{\theta}_1$

estime mieux θ_1 que θ_0 , et donc $E_{\theta_1}[s_i] = E_{\theta_1}[\log \frac{f_{\hat{\theta}_1}^i(x_j / x_{j-1}, \dots, x_1)}{f_{\hat{\theta}_0}^i(x_j / x_{j-1}, \dots, x_1)}] > 0$.

La (Figure 5) ci contre illustre cette propriété de détectabilité :




Figure 5. Evolution de MDCS autour du point de changement. . (En haut) Abscisse : nombre des points. Ordonnée : amplitude arbitraire du signal. (En bas) MDCS en chaque point.

Cette propriété est très importante, car elle résout la première limitation de DCS, et elle garanti que la fonction de détection augmente indéfiniment sous l'hypothèse H_1 .

- Comparaison entre DCS et MDCS

La comparaison entre DCS et MDCS, en utilisant la courbe COR (courbe opérationnelle du récepteur), montre clairement l'efficacité du nouvel algorithme (voir Figure 6).




Figure 6. Comparaison entre DCS et MDCS par courbes COR sur des signaux simulés.

Ces courbes COR sont tracées en utilisant 1000 segments de bruit blanc, avec un rapport signal sur bruit égale à 2. Le seuil varie donc ce cas de zéro (beaucoup de détection) jusqu'à l'infini (pas de détection).

PROCEDURE GENERALE DE SEGMENTATION ET CHOIX DES SEUILS

La procédure de segmentation est basée sur l'algorithme de somme cumulée modifié. La première phase de cet algorithme consiste à choisir les seuils haut et bas.

Après le choix des seuils, on démarre l'algorithme MDCS dès le début du signal, chaque fois qu'on détecte un changement, on initialise MDCS de l'instant de changement et on recommence jusqu'à la fin de la segmentation du signal.

La nouvelle approche du choix de seuil

L'approche consiste à balayer le signal et à calculer la répartition de la distance de Kullback-Leibler à chaque instant. Cette répartition nous donne une idée sur le seuil puisqu'on a la relation $E_{\theta_1}(s) = K(\theta_1, \theta_0) = h / \tau$ avec h est le seuil et τ est le retard à la détection.

La distance de Kullback-Leibler entre deux densités de probabilité est définie par $K(\theta_0, \theta_1) = \int \text{Ln} \frac{f_{\theta_0}(x)}{f_{\theta_1}(x)} f_{\theta_0}(x) dx$ (Saporta, 1990). Cette distance, dans le cas de deux modèles

AR $\theta_0 = (a_1^0, \dots, a_p^0, \sigma_0^2)$ et $\theta_1 = (a_1^1, \dots, a_p^1, \sigma_1^2)$, peut être exprimée de la façon suivante :

$$K(\theta_1, \theta_0) = -\frac{1}{2} - \frac{1}{2} \ln \frac{\sigma_1^2}{\sigma_0^2} + \frac{1}{2} \frac{\sigma_1^2}{\sigma_0^2} \left[1 + \sum_{k=1}^{\infty} (c_k^{0/1})^2 \right] \quad (21)$$

Les coefficients $c_k^{0/1}$ sont les coefficients du développement de Taylor :


$$\frac{A_0(z)}{A_1(z)} = 1 + \sum_{k=1}^{\infty} c_k^{0/1} z^{-k} \quad (22)$$

La démarche de choix du seuil est la suivante :

- 1- On prend deux fenêtres de longueur N , autour de temps courant i et on calcule la distance de Kullback-Leibler entre ces deux fenêtres. On fait le balayage sur tout le signal pour obtenir une séquence aléatoire s de la répartition de l'information de Kullback-Leibler dans le signal. Le calcul de s peut être fait sur quelques points du signal avec un pas N pour diminuer le temps de ce calcul.
- 2- Un tri de s sera fait pour obtenir une séquence s_t croissante qui regroupe dans sa partie inférieure les valeurs de l'information Kullback-Leibler faible et qui correspondent aux parties du signal où il n'y a pas de changement, et dans sa partie supérieure les valeurs qui correspondent au changement.
- 3- A partir de s_t on prend seulement 90% des points, et on obtient alors une séquence s_b qui correspond à une partie du signal où il n'y a pas de changements. Cette procédure permet de limiter l'influence des grandes valeurs.
- 4- On calcule ensuite la moyenne de somme des carrées de s_b , soit MS_{KL} ce somme.
- 5- On fixe finalement la longueur minimale du segment à détecter. On suppose que N est cette longueur, alors on prend comme valeur du seuil bas comme $h_L = N.K_L.MS_{KL}$, et comme valeur du seuil haut $h_H = N.K_H.MS_{KL}$.

La détermination de K_H et K_L se justifie par simulation sur les mêmes signaux de référence utilisée pour évaluer la courbe COR du chapitre précédente. La segmentation est faite pour des valeurs successives de K_L et K_H et la probabilité de non détection et de fausse alarme est calculée.

La figure suivante donne la variation de l'erreur de segmentation (somme de non détection et des fausses alarmes) pour chaque valeur de K_L et K_H . Le minimum de l'erreur correspond aux valeurs $K_L = 1$ et $K_H = 3$.



**Figure 7. Variation de l'erreur de segmentation suivant le seuil bas et haut. Axe x : K_H ,
Axe y : K_L , Axe z : somme de non détection et des fausses alarmes.
RESULTATS SUR DES SIGNAUX EMG LONG DUREE**

Comme illustration, la segmentation a été appliquée aux signaux EMG enregistrés pendant une expérience (2h30) à long terme évaluant le confort des sièges de voiture par une mesure de fatigue musculaire locale. Chaque expérience a été divisée en 7 phases qui durent entre 10 minutes et 30 minutes.

TABLE 1

Seuils Trouvés sur 14 Signaux (Sujet 1)

	h_L	h_H			h_L	h_H
Seg01	28	83		Seg11	28	83
Seg02	32	94		Seg12	27	80
Seg03	30	88		Seg13	29	86
Seg04	26	77		Seg14	28	83
Seg05	28	82		Seg15	28	84

Seg06	28	83		Seg16	29	87
Seg07	27	81		Seg17	30	88

TABLE 2

Seuils Trouvés sur 14 Signaux (Sujet 2)

	h_L	h_H			h_L	h_H
Seg01	36	106		Seg11	34	100
Seg02	36	106		Seg12	35	103
Seg03	33	99		Seg13	30	90
Seg04	32	95		Seg14	30	90
Seg05	34	101		Seg15	32	96
Seg06	33	97		Seg16	30	90
Seg07	33	97		Seg17	32	94

Dans la table 1 on donne le résultat de calcul du seuil sur 14 signaux, pris par un même sujet, et dans la même condition d'expérimentation. La table 2 contient des seuils pour un autre sujet. On voit bien que la procédure du choix des seuils donne un résultat homogène pour les seuils pour un même sujet, ce qui démontre que ce choix dépend bien des caractéristiques des signaux. On voit aussi que ces seuils sont différents d'un sujet à un autre, ce qui démontre la nécessité d'une telle méthode automatique pour le choix des seuils.

La Figure 8 montre un exemple de segmentation par MDSC pour $k_L=1$ et $k_H=3$.




Figure 8. Exemple de segmentation sur un signal EMG. Abscisse : nombre des points. Ordonnée : amplitude arbitraire du signal. Segments verticales : instant de changement.

Le traitement de signal EMG consiste à prendre les segments détectés et les analyser. La Figure 9 montre deux segments spécifiques, une contenant l'activité EMG et l'autre contenant seulement le bruit.

On voit bien que la méthode de segmentation conduit à détecter ces changements spectraux.




Figure 9. Un exemple de deux segments consécutives : à gauche un segment de bon spectre EMG, à droite un segment fortement bruité. En haut : signaux acquis. En bas : leurs densités spectrales.

CONCLUSION

La détection de changement et la segmentation dans les signaux sont des problèmes classiques dans le traitement des signaux. Elles sont très utiles quand on veut extraire des informations du signal ou le rapport signal sur bruit est faible. Nous avons présenté une méthode de détection dans les signaux EMG quand les paramètres sont inconnus. L'EMG enregistré des muscles posturaux est un bon candidat pour ce genre de traitement à cause faible rapport signaux sur bruit. L'algorithme MDCS a donné des bons résultats pour extraire les parties appropriées du signal. La prochaine consiste à séparer les segments EMG brutes des segments EMG fortement bruités et d'améliorer l'évaluation des paramètres en développant un algorithme plus efficace pour la suppression de bruit dans les segments maintenus.

REMERCIEMENTS

Les auteurs remercient le CNRS libanais pour son aide financière.

REFERENCES

- Basseville, M., and Nikiforov, I. 1993. *Detection of abrupt changes, theory and application*. Englewoods Cliffs, NJ. Prentice Hall.
- Baron, M. I. 2000. Nonparametric adaptive change-point estimation and on-line detection. *Sequential Analysis*, 19: 1-23.
- Falou, W. E., Duchêne, J., Khalil, M., Langeron, Y. 2001. Segmentation avec rejet de signaux EMG posturaux par une méthode locale. *Colloque GRETSI'01*, Toulouse, France.
- Khalil, M. 1999. *Une approche de la détection et de la classification dans les signaux non stationnaires. Application à l'EMG utérin*. Thèse de Doctorat de l'Université de Technologie de Troyes, France.
- Khalil, M., Duchêne, J. 1999. Detection and classification of multiple events in piecewise stationary signals. Comparison between autoregressive and multiscale approaches. *Signal Processing*, 75: 239-251.
- Khalil, M., Duchêne, J. 1999. Une approche de la détection fondée sur une somme cumulée dynamique associée à une décomposition multiéchelle. Application à l'EMG utérin. *Colloque GRETSI 99*, 1049-1052.
- Khalil, M., Duchêne, J. 2000. Uterine EMG Analysis : A dynamic approach for change detection and classification. *IEEE Trans. Biomed. Eng.*, 47: 748-756.
- Merletti, R., Knaflitz, M., De Luca, C.J. 1990. Myoelectric manifestation of fatigue in voluntary and electrically elicited contractions. *J. Appl. Physiol.*, 69.
- Nikiforov, I. 1995. A generalized change detection problem. *IEEE Tran. IT*, 41(1): 171-187.
- Saporta, G. 1990. *Probabilités, Analyses des données et statistiques*. Edition Technip, Paris.