

EXTRACTION DES TYPES D'ÉVÉNEMENTS DANS LES SIGNAUX BIOMÉDICAUX APPLICATION À L'ÉLECTROMYOGRAMME UTÉRIN

Mohamad Khalil¹, Jacques Duchêne¹, Catherine Marque³
Haïssam Ziade², Lamia Youssef², Samer Hamdach²

¹ Université de Technologie de Troyes, LM2S, 12 rue Marie Curie, 10010
Troyes, France

² Université Libanaise, Faculté de Génie, Section I, Tripoli, Liban

³ Université de Technologie de Compiègne, GBM, B.P. 529, 60205 Compiègne,
France

(Received 8 December 1998 Accepted 31 March 2001)

RÉSUMÉ

L'accouchement prématuré, principale cause de morbidité et de mortalité néonatale, demeure un problème majeure en clinique obstétricale. La détection des accouchements prématurés vise au développement d'un système de surveillance des menaces d'accouchement prématuré, basé sur le suivi de la contractilité utérine mesurée au moyen de l'EMG utérin abdominal. Les caractéristiques temporelles et spectrales des bouffées électriques changent au cours du terme. Le but de notre étude est de détecter et classifier les différents types d'événements contenus dans l'EMG utérin à partir des paramètres temporels et spectraux.

La détection et la classification des événements sont réalisées en utilisant une méthode séquentielle qui s'appelle méthode de la somme cumulée (CUSUM) et en introduisant la modélisation autoregressive du signal. Les coefficients autoregressifs contiennent des informations sur le contenu fréquentiel des événements. Ils peuvent être utilisés pour réaliser la classification des événements. L'étude de l'efficacité et de la sensibilité de cette méthode se traduit par le test de sa rapidité à donner des résultats pour une utilisation temps réel, son retard à la détection estimé comme étant la différence entre l'instant de détection donné par le programme et le vrai instant de changement observé sur le signal, et enfin le résultat donné par la classification. Une application temps réel a été réalisée en implantant notre algorithme sur un DSP 96002.

Mots-clés: signaux biomédicaux, électromyogramme utérin

ABSTRACT

Preterm birth, primary cause of perinatal morbidity and neonatal mortality, remains the major problem in obstetrical practice. The detection of the preterm birth opens the way for the development of an ambulatory instrumentation based on uterine EMG for patient monitoring during pregnancy. Temporal and frequencial characteristics of EMG activity change from pregnancy to parturition. The aim of this study is to detect and classify the different types of events included in the uterine EMG using the temporal and spectral parameters of these events.

Detection and classification are achieved by using a sequential method called CUMulative SUM algorithm (CUSUM) and by introducing the autoregressive modulation of signal. Autoregressive coefficients provide us with information concerning the frequency contents of these events. These coefficients are used to achieve the classification problem. Efficiency and sensibility of this method are studied by testing the delay time and the classification results. Delay time is the difference between the instance of detection given by the program and the real instance of change in the signal. Real time application is achieved by implanting our algorithm on the DSP 96002

INTRODUCTION

L'idée de cette étude a été proposée par le Laboratoire de Modélisation et Sécurité des Systèmes (LM2S) de l'Université de Technologie de Troyes (UTT) en France dans le cadre du développement de la recherche au Liban.

Le problème de détection/classification est un problème classique en théorie du signal qui revêt une importance particulière au vu de son caractère pratique. Ce problème devient de plus en plus complexe quand les paramètres des hypothèses sont inconnus. Des références sur ce point peuvent être trouvées dans (Khalil et Duchêne). Dans cet article, les événements contenus dans un signal ont été détectés après connaissance a priori des paramètres d'hypothèses et en utilisant le maximum du rapport de vraisemblance (changement fréquentiel (Lavielle, 1993 ; Baum and Veeravalli, 1994)).

Dans une première partie, le signal EMG utérin est présenté brièvement, ensuite quelques notions sur la théorie de la décision sont données et la modélisation autoregressive du signal est rappelée. La deuxième partie sera consacrée à la méthode de somme cumulée, à l'implantation de cet algorithme et aux résultats obtenus en l'appliquant sur des signaux synthétiques et sur des signaux EMG réels. A la fin de cet article, des conclusions sur les avantages et les limites de la méthode CUSUM sont tirés et des perspectives pour l'améliorer seront présentées.

POSITION DU PROBLEME

L'origine de ce travail est l'analyse et la caractérisation du signal EMG utérin pendant la grossesse. Ce signal a fait l'objet de nombreuses études depuis les années 50. Il apparaît comme un outil capable de fournir d'une manière non invasive, des informations utiles concernant la contractilité utérine. La détection précoce de ces menaces d'accouchements prématurés est un des facteurs déterminants pour le succès des traitements tocolytiques.

L'activité utérine change graduellement au cours des mois de la grossesse : les contractions sont faibles et d'action très localisée à leur apparition puis deviennent de plus en plus fortes, rythmiques et propagées à l'approche du terme. Sur des femmes qui ont accouché à terme (grossesse normale), des auteurs ont montré que l'activité utérine augmente chaque semaine de grossesse (Devedeux *et al.*, 1993). Pour les femmes qui ont accouché prématurément, l'activité augmente plus tôt et demeure supérieure à l'activité associée à une grossesse normale (Marque *et al.*, 1995).

Des études plus récentes, effectuées sur des contractions de fin de grossesse normale comparées à des contractions d'accouchement ont démontré que l'EMG utérin est représentatif de l'efficacité des contractions. Il permet en effet à partir de paramètres temporels et spectraux de les classer en terme de contraction efficace ou inefficace (Devedeux, 1995). Dans certaines situations, une influence perturbatrice des mouvements du fœtus ayant été remarquée, il a fallu caractériser ces artefacts induits par les mouvements actifs fœtaux (MAF) qui présentent des caractéristiques spectrales différentes de celles des contractions recueillies au même terme.

En plus des contractions et des mouvements actifs fœtaux, certains auteurs ont remarqué d'autres types d'événements comme les ondes d'Alvarez qui sont les résultats d'une contraction locale de l'utérus. Il y en a également des ondes qui possèdent une longue durée et des fréquences basses (ondes LDBF: Longue Distance Basse Fréquence).

Dans cet article nous proposons une méthode de détection de tous les événements contenus dans le signal EMG utérin. La détection est accompagnée d'une méthode de classification qui permet de classer chaque événement: contraction ou MAF (Mouvements Actifs Feataux). Des études ultérieures seront faites sur les ondes d'Alvarez et les ondes LDBF.

NOTIONS SUR LA THEORIE DE LA DECISION

Présentation du problème de la décision

Le problème de la détection peut être résumé par une source émettant deux signaux possibles à différents instants. Les signaux S1 et S2 ont, à priori, respectivement les probabilités $P(S1)$ et $P(S2)$ d'avoir été émis. Ces signaux parviennent à l'observateur sous une forme altérée (perturbés avec un bruit), qui en obtient une mesure x qui est aléatoire.

L'observateur va devoir prendre une décision sur la base de cette mesure. Il prendra la décision D1 s'il estime avoir reçu le signal S1 et prendra la décision D2 dans l'autre cas. Il devra donc effectuer une partition de l'espace d'observation x en Z1 et Z2. Si l'observation x est dans Z1, il prendra la décision D1 et inversement.




Figure 1. Problème de la décision.

Définitions

- Pour un problème de détection, il s'agit de choisir l'une des 2 hypothèses suivantes :

$$H_0: x(t) = b(t) \quad \text{bruit de fond ou absence d'un signal}$$

$$H_1: x(t) = s(t) + b(t) \quad \text{présence du signal utile}$$

On définit les 4 situations suivantes :

- Non-détection correcte : choisir H_0 alors que c'est H_0 qui est vraie (D0,H0)
 - Manque à la détection : choisir H_0 alors que c'est H_1 qui est vraie (D0,H1)
 - Détection correcte : choisir H_1 alors que c'est H_1 qui est vraie (D1,H1)
 - Fausse alarme : Choisir H_1 alors que c'est H_0 qui est vraie (D1,H0)
- Rapport de vraisemblance : Si $f(x/H_0)$ désigne la densité de probabilité de la variable aléatoire x sous H_0 et $f(x/H_1)$ celle de x sous H_1 , le rapport de vraisemblance $\Lambda(x)$ est défini par :

$$\Lambda(x) = \frac{f(x / H_1)}{f(x / H_0)}$$

Cette grandeur joue un rôle important dans la théorie de la détection.

- La probabilité de fausse alarme, notée P_{fa} où α , désigne la probabilité de détecter un signal alors qu'il n'y a que du bruit. Ainsi si $f_{H_0}(\lambda)$ désigne la densité de probabilité de la variable aléatoire λ sous H_0 , on peut écrire :

$$\alpha = P_{fa} = \int_{\lambda_0}^{\infty} f_{H_0}(\lambda) d\lambda$$




Figure 2. Illustration mathématique des Pfa et Pd.

- La probabilité de détection, notée P_d ou $1-\beta$, désigne la probabilité de décider qu'un signal est présent et qu'il l'est effectivement. Elle est définie par :

$$1 - \beta = P_d = \int_{\lambda_0}^{\infty} f_{H_1}(\lambda) d\lambda$$

La Figure 2 montre une illustration mathématique de ces deux probabilités.

- Courbes COR (caractéristique opérationnelle du récepteur)
 Une détection revient à comparer un test statistique, souvent basé sur le rapport de vraisemblance, à une valeur seuil λ_0 dépendant de la règle de décision choisie. Pour chaque valeur de λ_0 nous pouvons donc calculer les diverses probabilités conditionnelles. On obtient la courbe COR du récepteur en représentant la probabilité de détection P_d en fonction de la probabilité de fausse alarme P_{fa} , c.à.d. en éliminant λ entre P_d et P_{fa} .
- La courbe COR passe par les point : $(P_{fa} = 0, P_d = 0)_{\Lambda=\infty}$ et $(P_{fa} = 1, P_d = 1)_{\Lambda=0}$

- P_d et P_{fa} sont des fonctions décroissantes de λ
- La concavité de la courbe COR est toujours négative et la courbe est toujours au dessus de la première bissectrice.

Une courbe COR pourrait être représenté comme indiqué sur la Figure 3.




Figure 3. Caractéristique opérationnelle du récepteur.

L'étude de la courbe COR permet de choisir un seuil qui donne le compromis entre la probabilité de détection et celle de fausse alarme.

MODELISATION AUTOREGRESSIVE D'UN SIGNAL

Le signal est le support physique de l'information, son analyse consiste à en extraire un nombre de valeurs caractéristiques, pertinentes de l'information contenue. Les méthodes paramétriques consistent à ajuster un modèle aux données observées. Les paramètres du modèle, en nombre limité, caractériseront le signal. Les modèles de l'estimation spectrale les plus populaires sont : AR(AutoRegressive), MA (Moving Average) et ARMA (AutoRegressive Moving Average). Dans cette étude, on a adopté la modélisation AR à cause de sa simplicité (le calcul des coefficients AR se fait par la résolution d'un système linéaire), de ses performances en reconnaissance des formes et de ses bons résultats en estimation spectrale.

Définitions et formulations

On appelle signal autorégressif d'ordre p un signal x_n engendré par la récurrence :

$$x_n = -\sum_{i=1}^p a_i x_{n-i} + \sigma u_n$$

dans laquelle $u(n)$ représente un bruit blanc gaussien stationnaire de moyenne nulle et de variance unité. Cette récurrence indique qu'un échantillon quelconque x_n est une combinaison linéaire des p échantillons qui le précèdent, combinaison à laquelle il faut ajouter le terme d'excitation.

En faisant la transformation en z de l'équation (1), on obtient :

$$G(z) = \frac{X(z)}{\sigma U(z)} = \frac{1}{\sum_{i=0}^p a_i z^{-i}} \text{ avec } a_0=1$$

Donc $X(z)$ est la réponse d'un filtre autorégressif, de fonction de transfert $G(z)$, à un bruit blanc stationnaire.



x_n peut s'écrire de la façon suivante :

$$x_n = -\sum_{i=1}^p a_i x_{n-i} + v_n \Rightarrow x_n = -\vec{a}^T \vec{x}_n + v_n \tag{1}$$

avec :

$$\vec{a} = [a_1, \dots, a_p]^T, \vec{x}_x = [x_{n-1}, \dots, x_{n-p}]$$

Estimation des paramètres AR

Appelons la matrice de corrélation la quantité :

$$\Gamma = E(\vec{x}_n \vec{x}_n^T)$$

$E(x)$ est l'espérance mathématique de x.

Faisons l'espérance mathématique des 2 termes de l'équation 1 après multiplication par x_n . On obtient:

$$E[\bar{x}_n \bar{x}_n] = -E[\bar{x}_n \bar{x}_n^T] \bar{a} + E[v_n \bar{x}_n]$$

On appelle prédiction linéaire de x_n la valeur \hat{x}_n donnée par :

$$\hat{x}_n = -\sum_{i=1}^p a_i x_{n-i}$$

L'erreur de prédiction, pour un seul échantillon à un instant n , s'écrit :

$$e_n = x_n - \hat{x}_n = -\sum_{i=0}^p a_i x_{n-i}, \text{ avec } a_0=1$$

A l'instant N , les N points x_1, \dots, x_N sont utilisés pour estimer les coefficients du modèle AR en minimisant l'erreur de prédiction globale.

Pour déterminer les coefficients a_i , on minimise la puissance (variance) de l'erreur de prédiction e_k :

$$\rho = E[e_k^2] = \sum_{i=0}^p a_i \sum_{j=0}^p a_j \Gamma(|i-j|)$$

Le minimum de ρ s'obtient pour : $\frac{\partial \rho}{\partial a(i)} = 0, i = 1, \dots, p$

Dans ce cas on obtient :

$$\begin{bmatrix} \Gamma(0) & \Gamma(1) & \dots & \Gamma(p) \\ \Gamma(1) & \Gamma(0) & \dots & \Gamma(p-1) \\ \dots & \dots & \dots & \dots \\ \Gamma(p) & \Gamma(p-1) & \dots & \Gamma(0) \end{bmatrix} * \begin{bmatrix} 1 \\ a(1) \\ \dots \\ a(p) \end{bmatrix} = \begin{bmatrix} \rho_{\min} \\ 0 \\ \dots \\ 0 \end{bmatrix} \quad (2) \quad (Yule-Walker)$$

ρ_{\min} n'est autre que la variance du bruit : $\rho_{\min} = \sigma^2$.

La résolution de ce système nous permet de calculer les paramètres AR et d'estimer la variance des résidus σ^2 . Pour plus d'informations sur cette méthode, il est conseillé de regarder la référence (Kay, 1988) où on peut trouver l'algorithme utilisé dans notre travail qui est celui de Levinson.

La méthode adaptative consiste à trouver un algorithme qui nous permet de calculer les coefficients AR estimés à l'aide de $(N+1)$ échantillons en fonction de ceux estimés à l'aide de N échantillons sans résoudre à nouveau l'équation de Yule-Walker. L'algorithme récursif des moindres carrés donne les coefficients à l'instant

N+1 en fonction de ceux à l'instant N. La relation de récursivité entre les deux est donnée par (Kay, 1988) :

$$A_{(N+1)} = A_{(N)} - e_{(N)}(N+1).C_{(N)}; \text{ avec}$$

$$e(N+1) = x(N+1) + \sum_{i=1}^p a_N(i).x(N+1-i)$$

$$\text{et } C_{(N)} = P_{(N)}.X(N) \dots \text{avec, } P_{(N)} = \Gamma_{(N)}^{-1}$$

METHODE DE DETECTION

Rappelons que le but de ce papier est de trouver une méthode de détection et de classification dans le signal EMG utérin. On cherche donc à détecter les contractions utérines et les différents types d'évènements dans ce signal comme le mouvement de bébé, ondes d'Alvarez et ondes LDBF.

Principe

La méthode utilisée pour faire la détection est une méthode simple et optimale. Elle est basée sur le calcul récursif du rapport de vraisemblance généralisé à chaque instant. Cette méthode s'appelle la méthode de la somme cumulée (CUSUM). Elle est considérée comme une séquence répétée autour du point de changement k caractérisant le changement d'une hypothèse.

Prenons par exemple le cas de deux hypothèses simples H_0 et H_1 . Le test à effectuer est le suivant :

$$\begin{cases} H_0: x_t, t = \{1 \dots k\} \text{ a une densité de probabilité } f_0 \\ H_1: x_t, t = \{k + 1 \dots n\} \text{ a une densité de probabilité } f_1 \end{cases}$$

Dans ce cas le temps d'arrêt est estimée par l'instant N défini par (Basseville *et al.*, 1993; Nikiforov, 1995; Ghosh and Sen, 1991):

$$N = \inf \left\{ n \geq 1 : \max_{1 \leq t \leq n} \sum_{i=t}^n \log \Lambda(x_i) \geq \lambda_0 \right\}$$

$$= \inf \left\{ n \geq 1 : S_n - \min_{1 \leq t \leq n} S_t \geq \lambda_0 \right\}$$

$$\text{avec } S_t = \sum_{i=1}^t \log \Lambda(x_i), S_0 = 0 \text{ et } \Lambda(x_i) = \frac{f_1(x_i)}{f_2(x_i)}$$

La fonction S est une fonction décroissante avant le point de changement puis elle devient croissante après le changement. Donc l'interprétation de cette procédure est très simple : on arrête quand la somme cumulée entre 2 hypothèses atteint le seuil λ_0 . Le retard à la détection sera $\tau = N - k$ (k est le vrai instant de changement). Le choix du seuil a été fait d'une façon empirique.

Application dans le cas Gaussien, échantillons indépendants

Considérons le cas où les échantillons x_t sont statistiquement indépendants et suivent une loi normale de moyenne nulle, de variance σ_0 sous l'hypothèse H_0 et de variance σ_1 sous l'hypothèse H_1 . La densité de probabilité de la variable aléatoire x_i sous l'hypothèse H_j s'écrit :

$$f(x_i | H_j) = \frac{1}{\sigma_j \sqrt{2\pi}} e^{-\frac{x_i^2}{2\sigma_j^2}}$$

Dans ce cas le logarithme du rapport de vraisemblance entre les hypothèses H_0 et H_1 peut s'écrire :

$$\log(R(\eta_i)) = \frac{1}{2} \log \frac{\sigma_0^2}{\sigma_1^2} + \frac{1}{2} x_i^2 \left(\frac{1}{\sigma_0^2} - \frac{1}{\sigma_1^2} \right)$$

et S_n peut être exprimée d'une façon récursive de la façon suivante :

$$S_n = S_{n-1} + \frac{1}{2} \log \frac{\sigma_0^2}{\sigma_1^2} + \frac{1}{2} x_i^2 \left(\frac{1}{\sigma_0^2} - \frac{1}{\sigma_1^2} \right)$$

L'instant de détection sera estimé en utilisant l'expression de N donnée au paragraphe précédent.

Application dans le cas Gaussien, échantillons corrélés

Dans la majorité des cas, les échantillons sont corrélés. On doit utiliser alors la modélisation AR du signal original. Chaque échantillon x_i peut s'écrire sous la forme :

$$x_i = -\sum_{k=1}^p a_k x_{i-k} + \eta_i$$

Ce sont les erreurs de prédiction qui seront introduites dans la formulation de la somme cumulée. Si le signal original x suit une loi Gaussienne, les erreurs de prédiction η_i suivent la même loi (transformation linéaire). De plus elles sont non corrélées, et changent selon les modifications d'amplitude et de fréquence du signal original x .

Dans ce cas le rapport de vraisemblance peut s'écrire sous la forme suivante :

$$\log(R(\eta_i)) = \frac{1}{2} \log \frac{\sigma_0^2}{\sigma_1^2} + \frac{1}{2} \left(\frac{(\eta_i^0)^2}{\sigma_0^2} - \frac{(\eta_i^1)^2}{\sigma_1^2} \right)$$

où σ_0^2 et σ_1^2 sont les variances sous l'hypothèse H_0 et H_1 , respectivement. η_i^j est l'erreur de prédiction de l'hypothèse H_j : $\eta_i^j = z_i + \sum_{k=1}^p a_k^j z_{i-k}$. a_k^j est le k^{ème} paramètre de l'hypothèse H_j .

La somme cumulée S_n peut être exprimée d'une façon récursive :

$$S_n = S_{n-1} + \frac{1}{2} \log \frac{\sigma_0^2}{\sigma_1^2} + \frac{1}{2} \left(\frac{(\eta_n^0)^2}{\sigma_0^2} - \frac{(\eta_n^1)^2}{\sigma_1^2} \right)$$

Généralisation

Dans le cas général, plusieurs hypothèses sont à détecter et à classifier. La méthode de la somme cumulée peut être généralisée pour pouvoir résoudre ce problème. En effet, on suppose qu'on a un nombre fini d'hypothèses (M) connues a priori par leur modèle AR (coefficients AR et variance du bruit résiduel après modélisation). On applique la méthode de détection CUSUM multiple qui consiste à calculer plusieurs sommes cumulées entre l'hypothèse courante et chacune des autres hypothèses connues a priori.

Dans ce cas on définit la fonction de détection g de la façon suivante :

$$g(t, i) = S(t, i) - \min_{0 \leq k \leq t} S(k, i), \quad i = 1 \dots M$$

où $S_t^i = S(t, i)$ est la somme cumulée, à un instant t, entre l'hypothèse courante et l'hypothèse connue H_j , $j=1 \dots M$. Elle peut être exprimée

par $S(t, i) = \sum_{k=1}^t \log \frac{f_c(\eta_k)}{f_i(\eta_k)}$ où f_c est la densité de probabilité de

l'hypothèse courante H_c estimée à chaque instant de détection.

Dans le cas gaussien, cette somme cumulée devient :

$$S(t, i) = S(t-1, i) + \frac{1}{2} \log \frac{\sigma_c^2}{\sigma_i^2} + \frac{1}{2} \left(\frac{(\eta_t^c)^2}{\sigma_c^2} - \frac{(\eta_t^i)^2}{\sigma_i^2} \right)$$

η_t^c est l'erreur de prédiction utilisant les coefficients AR de l'hypothèse courante H_c .

L'instant de changement sera trouvé quand une des fonctions de détection g atteint le seuil λ_0 .

METHODE DE CLASSIFICATION

La classification a été réalisée en comparant les paramètres AR de l'hypothèse courante et ceux de chaque hypothèse connue a priori.

Supposons que M est le nombre d'hypothèses possibles, $A^j = \{a_1^j \dots a_p^j\}$ sont les coefficients AR de l'hypothèse connue H_j , $j = 1 \dots M$, σ_j est l'écart type du bruit résultant après modélisation du signal par le modèle correspondant à l'hypothèse j .

Après chaque instant de détection N , on peut estimer les paramètres AR de l'hypothèse courante $A^c = \{a_1^c \dots a_p^c\}$ en utilisant une fenêtre de longueur K .

La classification de la nouvelle hypothèse détectée (hypothèse courante) est basée sur la distribution de l'erreur de prédiction. En effet, l'erreur de prédiction d'un échantillon x_t correspondant à l'hypothèse H_j est :

$$\eta_t^j = z_t + \sum_{k=1}^p a_k^j z_{t-k}$$

La variance de cette erreur de prédiction sous l'hypothèse j est estimée par :

$$\varepsilon_j = \frac{1}{N} \sum_{k=1}^K \eta_k^2$$

L'erreur de prédiction est un bruit blanc. Utilisant les K échantillons indépendants, on peut calculer la fonction de distribution de la variance de l'erreur de prédiction ε_j comme étant :

$$f(\varepsilon_j) = \left[\frac{1}{\sigma_j \sqrt{2\pi}} e^{-\frac{\varepsilon_j^2}{2\sigma_j^2}} \right]^K$$

La classe la plus proche de l'hypothèse H_c est celle qui correspond au maximum de $f(\varepsilon_j)$. Donc on choisit l'hypothèse dont $f(\varepsilon_j)$ est maximale :

$$classe = Arg \max [f(\varepsilon_j)] \quad j = 1 \dots M.$$

ORGANIGRAMME DE LA DETECTION/CLASSIFICATION

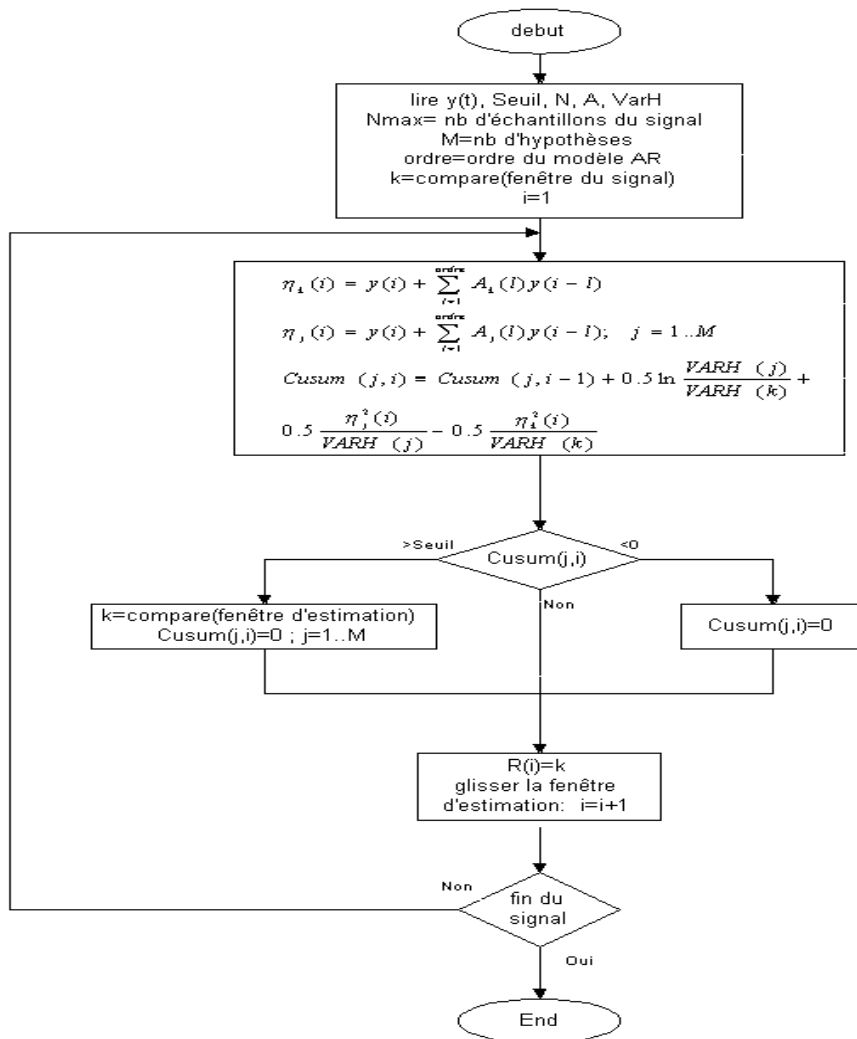


Figure 4. Organigramme de la méthode détection/classification.

Les principaux paramètres utilisés dans cet algorithme sont :

- VARH: vecteur des variances du bruit résiduel après modélisation AR pour chacune des hypothèses.
- A: matrice $[M \times p]$; M et p sont le nombre d'hypothèses et l'ordre du modèle AR respectivement. Chaque ligne j de la matrice A donne les coefficients AR de l'hypothèse j. Cette matrice contient les informations connues a priori.
- Compare: C'est une fonction qui classe l'hypothèse survenue après la détection d'un changement. La classification se fait dans une fenêtre de largeur K suivant le critère du paragraphe précédent.

DISCUSSION, VALIDATION ET PERFORMANCE

Signaux synthétiques

Cette méthode de détection/classification a été appliquée sur des signaux synthétiques. Les segments synthétiques sont générés à partir d'un bruit blanc Gaussien filtré par un filtre passe bande à différentes fréquences centrales. Prenons un exemple sur un signal pouvant contenir 5 types d'événements E0, E1, E2, E3 et E4. Chaque événement est composé de 500 échantillons. La séquence de ces événements dans le signal est : E0, E1, E0, E2, E0, E3, E0, E4. E0 représente la ligne de base (état de repos). Les événements E1, E2, E3, et E4 ont la même énergie mais leur contenu fréquentiel est différent. Après l'application de notre algorithme, pour un seuil égal à 200 et $K=100$, les événements sont bien détectés et classifiés selon leur contenu fréquentiel. Les résultats correspondants sont montrés sur la Figure 5.

Signal , Détection




Figure 5. Résultat de la détection/classification sur des signaux synthétiques : l'amplitude du signal rectangulaire donne la classe de l'événement.

Signaux réels

Notre algorithme est appliqué aussi sur des signaux EMG réels. Nous avons considéré un signal EMG utérin de 14000 échantillons acquis à une fréquence

d'échantillonnage de 16 Hz et qui contient les informations suivantes : bruit, contraction, bruit, mouvement de bébé, bruit, contraction, bruit, mouvement de bébé, comme indiqué sur la Figure 6.




Figure 6. Présentation d'un signal EMG utérin : bruit, CT, bruit, MAF, bruit, CT, bruit, MAF.

Les 3 événements contenus dans le signal sont utilisés pour estimer les paramètres des hypothèses connues à priori. On en déduit la matrice des paramètres qui contient les coefficients AR de chaque hypothèse.

Cette matrice de données est utilisée pour effectuer la détection et la classification dans un autre signal qui contient les mêmes types d'événements. Les figures qui suivent représentent les résultats de détection/classification obtenus par l'application du programme sur quelques segments de ce signal.




Figure 7. Application sur un signal EMG utérin.

La Figure 7 montre que l'algorithme a donné un bon résultat concernant la détection. Les événements détectés après une contraction correspondent à des post-activités. Leur contenu fréquentiel est proche de celui des mouvements actifs foetaux. De ce fait ces événements sont classifiés comme MAF. Avant le début de la deuxième contraction, on a bien un MAF, bien classifié.

Signal , Détection




Figure 8. Application sur un signal EMG utérin.

Sur la Figure 8, les événements sont bien détectés mais il y a quelques événement mal classifiés (MAF et CT); cela vient du fait que le signal contient d'autres types d'événements à cet instant (espace d'hypothèse non exhaustif).

Signal , Détection

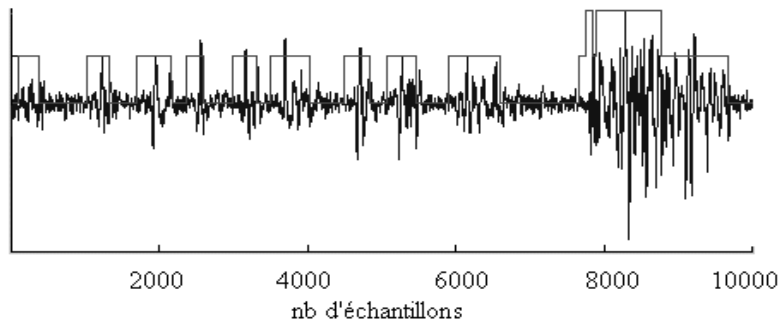


Figure 9. Application sur un signal EMG utérin.

Sur la Figure 9, les événements sont bien détectés et classifiés. Cependant le retard à la détection n'est pas négligeable..

Le problème de la mauvaise classification peut être résolu en ne prenant pas en compte les événements d'une longueur inférieure à K , largeur de la fenêtre d'estimation des paramètres AR. Tout événement plus petit que K échantillons sera concaténé à l'événement précédent, ou suivant. Une nouvelle hypothèse peut également être créée.

CONCLUSION ET PERSPECTIVES

Dans cet article une méthode de détection et de classification appliquée à des signaux biomédicaux non stationnaires a été présentée. La méthode de détection est basée sur le calcul récursif du rapport de vraisemblance généralisé après modélisation autorégressive du signal. La classification est basée sur la comparaison des modèles AR de l'hypothèse détectée et de ceux d'hypothèses connues a priori. Nous avons généralisé le problème de détection au cas d'hypothèses multiples.

La programmation a été faite sous MATLAB 5. L'algorithme a également été implanté sur un DSP 96002 de MOTOROLA. Il donne des résultats similaires et permet une utilisation en temps réel.

L'algorithme a été appliqué à des signaux simulés où il a donné de bons résultats. Il a été appliqué également au signal EMG utérin. Les résultats obtenus ont été satisfaisants pour ce qui concerne aussi bien la détection que la classification avec une proportion de bonne détection égale à 80%.

Les limites de cette méthode viennent principalement de l'utilisation des paramètres AR utilisés pour la classification. Ces paramètres ne sont pas robustes et la base qu'ils forment n'est pas orthogonale. C'est pourquoi il faudrait utiliser d'autres paramètres permettant de mieux caractériser le contenu fréquentiel des événements. C'est l'objet des activités de recherches en cours. La valeur du seuil peut être trouvée à partir de la courbe COR (On trace la probabilité de fausses alarmes en fonction de la probabilité de détection). Le seuil sera choisi en prenant une probabilité de fausses alarmes donnée par l'utilisateur. Actuellement on essaye de chercher des méthodes automatiques pour la détection du seuil.

Finalement, cette méthode globale détection/classification pourrait être encore améliorée en faisant une estimation en ligne de paramètres AR au cours de l'enregistrement et en adaptant les paramètres après chaque détection/classification d'un nouveau événement.

REFERENCES

- Basseville, M., and Nikoiforov, I. 1993. *Detection of abrupt changes, theory and application*. Englewood Cliffs, NJ. Prentice-Hall.
- Baum, C.W. and Veeravalli, V.V. 1994. A sequential procedure for multihypothesis testing. *IEEE Trans. IT*, 40(6):1995-2007.
- Devedeux, D. 1995. Evaluation quantitative de certaines caractéristiques de distribution temps/ fréquence : application à l'EMG utérin. Thèse de doctorat soutenue à l'université de technologie de Compiègne.
- Devedeux, D., Marque, C., Mansour, S., Germain, G., Duchêne, J. 1993. Uterine EMG, a critical review. *Am. J. Obstet. Gynecol.*, 169: 1636-1653.
- Ghosh, B.K. and Sen, P.K 1991. *Handbook of sequential analysis*. Marcel Dekker, Inc 9, New York.
- Kay, S.M. 1988. *Modern spectral estimation, theory and application*. Englewood Cliffs, NJ :Prentice-Hall, USA.
- Khalil, M., Duchêne, J. *Detection and classification of multiple events in piecewise stationary signals. Comparison between autoregressive and multiscale approaches*. Article accepté à être publié dans la revue Signal Processing.
- Marque, C., Gondry, J., Rossi, J., Baaklini, N., Duchêne, J. 1995. Surveillance de grossesses à risque par électromyographie utérine. *RBM*, 17(1): 25-31.
- Lavielle, M. 1993. Detection of changes in the spectrum of a multidimensional process. *IEEE Trans. SP*, 41(2):743-749.
- Nikiforov, I. 1995. A generalized change detection problem. *IEEE Trans. IT*, 41(1):171-187.