

Détection et classification d'évènements en représentation multidimensionnelle

Application sur l'EMG utérin.

Mohamad Khalil⁽¹⁾, Jacques Duchêne⁽¹⁾ et Catherine Marque⁽²⁾

⁽¹⁾Université de Technologie de Troyes LM2S, 12, rue Marie Curie,
B.P. 2060, 10010 Troyes cedex, France

⁽²⁾Université de Technologie de Compiègne, UMR CNRS 6600,
B.P. 529, 60205 Compiègne cedex, France

RÉSUMÉ

L'EMG utérin peut être représenté par un processus AR où plusieurs évènements sont superposés. Dans ce cas, la détection peut être faite en utilisant des algorithmes de détection classiques. Cependant, l'algorithme de classification doit prendre en compte les formes spécifiques de ces évènements superposés. Dans ce travail, la classification est basée sur la décomposition multi-échelle et sur le test multi-hypothèse. Après détection utilisant le modèle AR adaptatif, le signal est décomposé en plusieurs échelles et classifié suivant une matrice de variance-covariance calculée à partir de la décomposition multi-échelle. Cette approche aboutit à deux retards différents pour la détection et la classification. Ils dépendent du seuil de détection et du temps d'estimation de la matrice de variance-covariance, respectivement.

ABSTRACT

Uterine EMG can be represented by a noisy AR process where various events are superimposed. In this case, detection can be achieved by classical sequential algorithms. However, a classification algorithm has to take into account specific features of the superimposed events. In our work, classification is based on multiscale decomposition and multi-hypothesis testing. After detection using adaptive AR modelling, the signal is decomposed in multiple scales and classified regarding its variance-covariance matrix computed from the multiscale decomposition. This approach leads to different delays of detection and isolation, the former being defined by the detection threshold, the latter depending on the estimation time of the covariance matrix.

1 Introduction

La détection des transitions dans les signaux non-stationnaires est un problème important en traitement du signal. Quand les paramètres du signal sont connus, on utilise un détecteur optimal (dans le sens de Neyman Pearson) basé sur le maximum de vraisemblance. Dans le cas où ces paramètres sont inconnus, ils sont estimés en utilisant le maximum du rapport de vraisemblance généralisé du signal inconnu [1] [3]. Les paramètres qu'on doit estimer dépendent du choix du modèle du signal. Donc le choix de la modélisation du signal et l'implantation du détecteur doivent être choisis attentivement. Beaucoup d'auteurs ont utilisé des représentations spécifiques des signaux pour détecter ou caractériser les évènements [6],[15],[12] ou bien détecter des contours dans les images [10].

La transformée en ondelettes permet de représenter les signaux sur plusieurs niveaux d'échelles. Elle est utilisée par de nombreux auteurs pour la détection et la caractérisation de signaux médicaux comme l'ECG [9] l'EMG[8] l'EEG [15] ou encore les potentiels évoqués [16]. Frish [12] a utilisé la représentation multi-échelle du signal avant d'appliquer un détecteur stochastique basé sur le maximum de vraisemblance. D'autres ont utilisé la transformée en ondelettes discrètes ou continues avant d'appliquer le détecteur sur le signal [15].

Le but de notre étude est de détecter les évènements dans les signaux non-stationnaires après modélisation du signal par un modèle AR. Ensuite le signal sera décomposé sur différents niveaux d'échelles, et la classification sera effectuée en faisant un test multihypothèse basé sur la comparaison de matrices de variance-covariance.

2 Description générale du signal

Les signaux électromyographiques observés peuvent être décrits par un processus aléatoire $Y(t)$ de la forme :

$$Y(t) = EMG(t) + \sum_{i=1}^n S_i(t) + n(t) \quad (1)$$

Cette relation modélise l'ensemble des activités significatives (signal utile, tracé de fond, bruit, artefacts...) qui constituent le signal. C'est un modèle variable en fonction de l'état du muscle (repos, contraction) et en fonction du terme de l'analyse (évolution physiologique). $EMG(t)$ peut être considéré comme un processus stationnaire par morceaux. $S_i(t)$ est un signal additif qui correspond à des potentiels brèves ou à des artefacts qui apparaissent à un instant donné (comme le mouvement de bébés, les artefacts de mouvement, les ondes d'al-

varez...). Enfin, les bruits liés à l'environnement, supposés stationnaires, sont regroupés dans le terme $n(t)$. Dans la suite, on va supposer que ce bruit suit une loi approximativement gaussienne.

L'activité utérine de base $EMG(t)$ correspond à l'intégration filtrée de nombreuses activités électriques cellulaires. Chacune de ces activités élémentaires peut être considérée comme un processus aléatoire de loi inconnue, mais supposée identique quelque soit la cellule, et qui peut présenter des changements d'amplitude. Il peut être comme un processus AR à variance variable. Approximativement, on peut supposer que l'effet de sommation induit que le signal $EMG(t)$ suit une loi gaussienne.

Les autres signaux $S_i(t)$ sont généralement courts par rapport au signal $EMG(t)$ (Mouvements fœtaux, ondes d'Alvarez). Leurs formes sont inconnues, et leurs instants d'apparition sont imprédictibles. Leur modélisation n'est pas unique mais on peut dire que la distribution fréquentielle est un élément qui nous permet de distinguer entre ces événements. Notons que la transformée en ondelettes est un outil très intéressant pour la distinction entre ces événements. On peut également supposer que leur apparition va modifier l'erreur de prédiction du modèle $EMG(t)$ seul.

3 Détection et segmentation

3.1 Modèle AR du signal

Le signal $EMG(t)$ est le résultat de l'intégration des activités cellulaires filtrées. Ce filtrage induit donc une dépendance entre les échantillons successifs. La modélisation autorégressive nous permet d'appliquer la détection sur l'erreur de prédiction (bruit blanc) pour laquelle les échantillons successifs sont indépendants au lieu de l'appliquer sur le signal original. Le modèle autorégressif d'ordre P d'un signal discret $Y(n)$ est défini comme la sortie d'un filtre récursif dont l'entrée est un bruit blanc gaussien :

$$Y_t = - \sum_{i=1}^P a_i Y_{t-i} + \eta_t$$

η_t est un bruit blanc gaussien. a_i $i = 1, \dots, P$ sont les coefficients du modèle AR.

La non-stationnarité par segment du signal EMG utérin nécessite de trouver une méthode adaptative pour estimer les paramètres AR et la variance sous chaque hypothèse au fur et à mesure de la détection. En pratique ces coefficients peuvent être estimés au moyen d'algorithmes de moindres carrés, donc par minimisation de l'espérance du carré de l'erreur de prédiction $\sigma^2 = E(\eta_t)^2$, avec ou sans facteur d'oubli [7].

3.2 Méthode de Détection

La méthode utilisée pour la détection est une méthode séquentielle basée sur le calcul récursif du rapport de vraisemblance à chaque instant. Cette méthode s'appelle la méthode de la somme cumulée (CUSUM) [13]. La procédure CUSUM

peut être considérée comme une séquence des tests répétés autour d'un point de changement k . Prenons le cas de deux hypothèses simples H_0 et H_1 , le test à effectuer est le suivant :

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

l'instant de détection est défini par [2] :

$$\begin{aligned} N &= \inf \left\{ n \geq 1 : \max_{1 \leq j \leq n} \sum_{i=j}^n \log R(\eta_i) \geq h \right\} \\ &= \inf \left\{ n \geq 1 : S_n - \min_{0 \leq j \leq n} S_j \geq h \right\} \end{aligned} \quad (2)$$

avec $S_i = \sum_{t=1}^i \log R(\eta_t)$ et $S_0 = 0$ et $R(\eta_t) = \frac{f_1(\eta_t)}{f_0(\eta_t)}$. La connaissance des distributions sous chaque hypothèse nous permet d'appliquer ce test de CUSUM qui présente les avantages d'optimalité et de simplicité de mise en oeuvre. Dans le cas d'hypothèse gaussienne, la densité de probabilité peut s'écrire :

$$f_j(\eta_i/H_j) = \frac{1}{\sqrt{2\pi}\sigma_j} e^{-\frac{\eta_i^2}{2\sigma_j^2}} \quad (3)$$

σ_j et η_i^j sont la variance et les innovations sous l'hypothèse H_j . Dans ce cas :

$$\log(R(\eta_i)) = \frac{1}{2} \log \frac{\sigma_j^2}{\sigma_k^2} + \frac{1}{2} \left(\frac{(\eta_i^j)^2}{\sigma_j^2} - \frac{(\eta_i^k)^2}{\sigma_k^2} \right). \quad (4)$$

Vu sous l'angle de la segmentation, on a modifié la fonction de CUSUM S_n pour tenir compte de la fin du segment à détecter :

$$S_n = \begin{cases} 0 & \text{si } S_n < 0 \\ S_{n-1} + \log R(\eta_n) & \text{si } 0 \leq S_n \leq h \\ h & \text{si } S_n > h \end{cases} \quad (5)$$

La valeur du seuil a été choisie à partir de la courbe COR obtenue sur quelques données de référence. Une contraction sera détectée quand S atteint la valeur du seuil et ensuite redescend à 0 ; l'instant de début est l'instant où S_n commence à augmenter. L'instant de fin sera estimé par le dernier instant où $S_n = \text{seuil}(h)$.

Les variances sous chaque hypothèse sont estimées d'une façon adaptative au cours de la détection et cela pour prendre en compte la non-stationnarité des signaux.

4 Classification

4.1 Analyse multi-échelle

La transformée en ondelettes permet d'analyser efficacement des signaux où se combinent des phénomènes d'échelles très différents [11]. La transformée en ondelette continue d'un signal $Y(t)$ prend la forme :

$$T_x^\psi(a, b) = \int_{-\infty}^{\infty} Y(t) \psi_{ab}(t) dt \quad (6)$$

où

$$\psi_{ab}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (7)$$

est l'ondelette analysante. Elle est localisée en temps et en fréquence. Nous sommes concernés par la transformée en ondelettes discrètes, donc pour des valeurs discrètes de a et b . En particulier nous supposons que a prend la forme 2^m et b prend la forme $n \cdot 2^m$. Dans ce cas cette transformée s'appelle la transformée dyadique en ondelettes et la transformation s'écrit :

$$T_x^\psi(n, m) = \int_{-\infty}^{\infty} Y(t) \psi_{mn}(t) dt \quad m, n \in \mathbb{Z} \quad (8)$$

où

$$\psi_{mn}(t) = 2^{m/2} \psi(2^m t - n) \quad (9)$$

Ces équations donnent la décomposition du signal sur les différentes échelles ; m indique le niveau d'échelle et en faisant varier n , on translate cette ondelette sur le signal.

L'analyse multirésolution consiste à décomposer le signal $s(n)$ en l'utilisant l'ondelette ψ et sa fonction d'échelle ϕ . A l'aide de ces deux fonctions on peut décomposer le signal en détails et approximations. La fonction d'échelle $\phi_{mn}(t)$ peut être déduite de l'ondelette mère $\phi(t)$ et peut s'écrire de la façon suivante :

$$\phi_{mn}(t) = 2^{m/2} \phi(2^m t - n) \quad (10)$$

Le filtre associé à la fonction d'échelle $\phi(t)$ est un filtre passe bas, tandis que le filtre associé à de l'ondelette $\psi(t)$ est un filtre passe bande [5]. Les formules de calcul des coefficients des détails et des approximations peuvent s'écrire :

$$a_x(n, m) = \int_{-\infty}^{\infty} Y(t) \phi_{mn}(t) dt \quad (11)$$

$$d_x(n, m) = \int_{-\infty}^{\infty} Y(t) \psi_{mn}(t) dt \quad (12)$$

Les événements significatifs dans le signal apparaissent comme des détails bien localisés dans le temps.

4.2 Algorithme de classification

Soit H_c l'hypothèse correspondant à un nouveau segment quand un changement est détecté. Calculons M CUSUM entre H_c et chaque hypothèse H_p isolée précédemment, $p = 1 \dots M$:

$$Cusum(H_c, H_p) = \sum_i \frac{f_c(\eta_i)}{f_p(\eta_i)}, \eta_i \in H_c \quad (13)$$

Dans ce cas :

$$s = \text{Arg}[\min_p (Cusum(H_c, H_p))], p = 1 \dots M \quad (14)$$

donne l'hypothèse précédente la plus proche pour décrire H_c . Il faut décider maintenant si $H_c = H_s$ ou non, pour cela on a plusieurs possibilités :

- La classification peut être réalisée en comparant la somme cumulée $Cusum(H_c, H_s)$ à un seuil donné. Cependant, la distribution de cette somme cumulée n'est pas connue, D'où la difficulté de définir un tel seuil de rejet de distance [4].

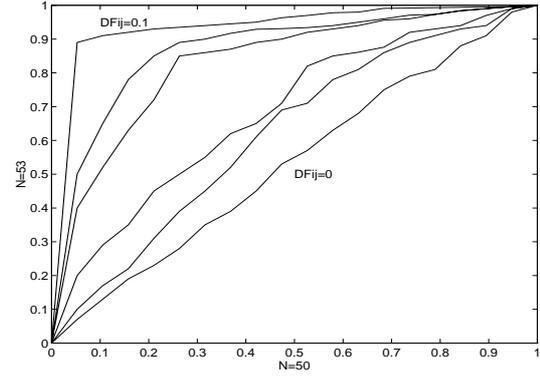


FIG. 1 — Caractéristique Opérationnelle de Récepteur (COR) $\{H_i, H_j\}$, i.e suivant $\delta_{ij} = \frac{f_i - f_j}{BP}$

- La classification peut être faite en fonction des formes spécifiques des événements détectés. La décomposition multiéchelle fournit sous une forme explicite des informations concernant la distribution fréquentielle de ces événements. Après la détection de ces événements, il est possible de calculer la matrice de variance-covariance des segments selon les échelles sélectionnées. La dimension de la matrice dépend du nombre des niveaux d'échelle. Si deux événements présentent des distribution d'énergie différentes sur les niveaux d'échelles, alors leurs matrices de variance-covariance seront différentes. De plus, des tests statistiques sont disponibles pour comparer ces deux matrices.

Parmi plusieurs tests possibles, nous avons choisi le test de Box [14] qui est défini par :

Si $(\Sigma_1 = \Sigma_s) = (\Sigma_2 = \Sigma_c)$, alors

$$\left(1 - \frac{2p^2 + 3p - 1}{6(p+1)} \cdot \left(\sum_{i=1}^2 \frac{1}{n_i - 1} - \frac{1}{n-2}\right)\right) \cdot \left[(n-2) \text{Log} \left| \frac{n}{n-2} W \right| - \sum_{i=1}^2 (n_i - 1) \text{Log} |\Sigma_i| \right] \quad (15)$$

suit une loi χ_2 de $\frac{p(p+1)}{2}$ ddl, avec

$$W = \frac{n_1 \Sigma_1 + n_2 \Sigma_2}{n_1 + n_2} \quad (16)$$

p est le nombre des niveaux échelle choisis, n_i $i = \{1, 2\}$ est le nombre des points qui définissent chaque hypothèse H_c et H_s . Nous avons utilisé la matrice de variance covariance normalisée. Dans ce cas, les segments qui ont des énergies différentes mais la même distribution fréquentielle seront classifiés dans un même hypothèse. Cette méthode présente l'avantage de classier sur des niveaux d'échelle spécifiques présélectionnés. Cependant, elle ne resoud pas le problème de non connaissance du risque de deuxième espèce.

5 Résultat et conclusion

La détection et la classification sont appliquées sur des signaux simulés : Les segments sont générés en utilisant un bruit blanc gaussien filtré passe bande, par une banque de filtres de

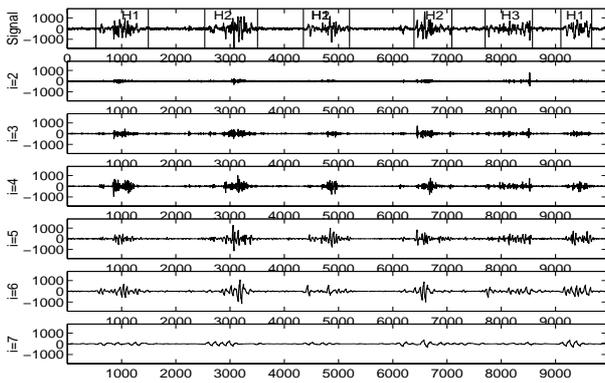


FIG. 2 — Détection et classification dans l'EMG utérin après décomposition (Ondelette : Daubechies 2, échelles : 2...7)

fréquences centrales différentes.

Chaque hypothèse H_i correspond à un filtre spécifique de centre f_i . La figure 1 donne les résultats obtenus pour différents écarts entre fréquences centrales, i.e suivant $\delta_{ij} = \frac{\Delta F_{ij}}{BP} = \frac{f_j - f_i}{BP}$, BP est la bande passante du filtre.

Cette méthode de détection a été appliquée sur quelques signaux EMG utérin. La détection a été faite en utilisant une modélisation AR(10). L'ondelette de Daubechies a été utilisée, et ce signal a été décomposé sur 5 échelles. Tous les événements sont bien classifiés suivant leur contenu fréquentiel. Le résultat de détection-classification est montré sur la figure 2. Cependant, cet exemple reste uniquement illustratif. Une base de donnée des événements identifiés doit être construite et validée avant de tester cette méthode dans des conditions réelles et de regarder sa capacité à classier les événements sur l'EMG utérin.

De plus, la méthode de détection et de classification est basée sur le retour automatiquement à l'hypothèse H_0 . Enfin la détection de $S_i(t)$ a été faite pour l'instant de la même manière que $EMG(t)$. Alors que ces événements sont de nature différente et peuvent survenir pendant une contraction. Donc cette méthode peut être améliorée pour permettre une détection des événements superposés quelque soit l'état de processus.

Références

- [1] Barkat M. Signal, Detection and estimation. Boston London, 434p, 1991.
- [2] Basseville M. et Nikiforov I. Detection of abrupt changes, theory and applications. Prentice Hall, Information and system Sciences Series, USA,528p, 1993.
- [3] Baum C.W and Veeravalli V.V. "A sequential procedure for multihypothesis testing". IEEE Trans. on IT, vol.40, N°6, pp.1995-2007, 1994.
- [4] Dibuisson B. Diagnostic et reconnaissance de forme, Hermès ed., paris, 1990.
- [5] Flandrin P, Temps fréquence. Hermès ed., paris, 1993.
- [6] Kadambe S. and Bartels G. "Application of the wavelet transform for pitch detection of speech signals". IEEE, Trans. on IT, vol. 38, N°2,pp.917-924, 1992.

- [7] Kay S.M. Modern spectral estimation, theory & application. Englewood Cliffs USA, 1988.
- [8] Lamotte T., Priez A. et all, "Détection et caractérisation en temps différé de sauts de dynamique : application à la segmentation de l'EMG". 15 ème colloque Gresti-Juan-Les-Pins, 1995.
- [9] Li C. Zheng C. and Tai C., "Detection of ECG characteristic points using wavelet transforms". IEEE, Trans. Biomed. Eng., vo.42, N°1, 1995, PP.21-29.
- [10] Mallat S. and Zhong S, "Characterisation of signals from multiscale edges". IEEE, Trans on PAMI, vol. 14, N°7,pp.711-733, 1992.
- [11] Meyer Y. Jafard S. and Rioul O. "L'analyse par ondelettes". Pour la science, sept. 1987
- [12] Fisher M. and Messer H. "The use of the wavelet transform in the detection of unknown transient signal". IEEE, Trans. on IT, vol. 38, N°2, pp.893-897, 1992.
- [13] Nikiforov I.V, "A generalized change detection problem". IEEE, Trans. on IT, vol. 41, N°1, pp.171-187, 1995.
- [14] Seber G.A.F. Multivariate observations. John Wiley & Sons, Inc. Canada, 1984.
- [15] Senhadji L. Bellanger J.J and Carraut G., "Détection temps échelle d'évènements paroxystiques intercritiques en électroencephalogramme". Traitement du signal, vol. 12, N°4, pp.357-371, 1995.
- [16] Thakor N.V "multiresolution wavelet analysis of Evoked Potentials". IEEE Trans. Biomed. Eng., Vol. 40, No 11, 1993.