

Segmentation automatique de signaux issus d'un accéléromètre triaxial en période de marche

Laurent OUDRE, Alexandre LUNG-YUT-FONG, Pascal BIANCHI

TELECOM ParisTech - TSI
37-39 rue Dareau, 75014 Paris, France
{oudre, lung, bianchi}@telecom-paristech.fr

Résumé – Cet article présente une analyse comparée de différentes méthodes pour la segmentation automatique de signaux d'accélérométrie enregistrés pendant une période de marche sur tapis. Plus précisément, notre but est de repérer les changements dans la vitesse et la pente du tapis roulant, en utilisant uniquement l'information fournie par un accéléromètre triaxial fixé soit à la ceinture soit au tibia du sujet. Nous avons testé différentes représentations du signal, ainsi que plusieurs méthodes de détection de ruptures. Les meilleures performances obtenues sur notre corpus (constitué de 24 sujets) sont de 79% de bonne détection pour le capteur tibia et 72% pour le capteur ceinture.

Abstract – This article presents a comparison between different change points detection methods used for the segmentation of accelerometer signals recorded during continuous treadmill walking. More precisely, we aim at detecting the change in speed and incline of the treadmill, only by using the information given by a triaxial accelerometer located either on the waist or the shin of the subject. We have tested several signal representation along with several change points detection methods. The best performances obtained on our corpus (composed of 24 subjects) are 79% of good detection with the shin sensor and 72% with the waist sensor.

1 Introduction

La surveillance de la dépense énergétique est indispensable pour le suivi et le traitement des personnes obèses. Néanmoins, la plupart des méthodes fiables pour évaluer le niveau d'activité physique (telle que l'eau doublement marquée) sont onéreuses et contraignantes pour le patient. Ainsi, de plus en plus de travaux s'intéressent à des méthodes non-intrusives d'évaluation de la dépense énergétique, se reposant sur l'utilisation de capteurs tels que des accéléromètres. Une des activités qui consomme le plus d'énergie est aussi l'une des plus courantes : il s'agit de la marche. Néanmoins, la dépense énergétique en période de marche dépend énormément de la vitesse et de la pente du terrain [1]. Afin d'évaluer de façon plus précise le niveau d'activité physique, il faut donc être capable de diviser une période de marche continue en différents segments de vitesse et pente constante.

Bien que de nombreuses méthodes existent pour la classification des signaux de marche selon leur pente par exemple [2, 3, 4], elles supposent dans la plupart des cas que la segmentation a déjà été faite (le plus souvent à la main). Nous comparons ici plusieurs méthodes de segmentation existantes non spécifiques aux signaux de marche, et introduisons une nouvelle approche pour la détection de ruptures dans la vitesse et la pente basée sur un modèle de structure fréquentielle adapté à l'activité de marche.

La section 2 présente tout d'abord le protocole expérimental pour l'enregistrement des signaux. La section 3 décrit les deux types de représentations du signal que nous avons considérées.

TABLE 1 – Exemple de séquence d'activités

Activité	Début	Fin
Marche à plat à 3.3 km/h	10 :56 :00	11 :01 :00
Marche à plat à 4.4 km/h	11 :01 :00	11 :06 :00
Marche à plat à 5.5 km/h	11 :08 :00	11 :13 :00
Marche en pente à 4.4 km/h (pente de 5%)	11 :14 :30	11 :19 :30
Marche en pente à 4.4 km/h (pente de 10%)	11 :19 :30	11 :24 :30

La section 4 introduit les différentes méthodes de détection de ruptures multiples que nous avons utilisées, certaines d'entre elles étant nouvelles. Enfin, les résultats sont présentés et analysés dans la section 5.

2 Protocole expérimental

On a demandé à 24 sujets sains et volontaires de marcher sur un tapis roulant pendant 20 ou 25 minutes. Durant ces expériences, les sujets portaient à la ceinture et au tibia un accéléromètre (MotionPod), développé par MOVEA, permettant d'enregistrer les accélérations selon 3 axes (vertical, médio-latéral et antéro-postérieur) avec une fréquence d'échantillonnage de 100 Hz. Un opérateur changeait soit la vitesse soit la pente du tapis environ toutes les 5 minutes (ce qui donne 3 ou 4 changements par sujet). Un exemple de séquence d'activités est présenté sur le Tableau 1. Il faut préciser ici que les vitesses considérées ici sont appropriées pour des sujets sains, mais seraient probablement plus lentes pour des sujets âgés ou obèses.

3 Représentations du signal

Nous avons testé deux représentations du signal, qui permettent de mettre en évidence certaines propriétés des signaux de marche.

- **A. Transformée de Fourier à court terme (TFCT).** Nous avons calculé une TFCT à partir du signal d'accélération antéro-postérieur, en ne gardant que les bins fréquentiels correspondant aux fréquences pertinentes pour des signaux de marche (0.5Hz à 5Hz) [5]. En pratique, les calculs ont été faits avec des fenêtres de 1024 échantillons (soit 10s) avec un recouvrement de 75%.
- **B. Vecteur de caractéristiques.** Il peut être intéressant de travailler avec des caractéristiques reflétant des propriétés physiologiques de l'activité de marché. Nous avons donc travaillé sur un ensemble de 12 caractéristiques calculées dans le domaine temporel à partir des trois composantes des signaux d'accélérométrie et décrites dans [3]. Les signaux sont préalablement divisés en trames de 3.6s, avec un recouvrement de 5/6. En notant respectivement a_{ML} , a_V et a_{AP} les accélérations médio-latérale, verticale et antéro-postérieure, on calcule pour chaque trame :
 - moyennes de $a_{ML} + a_V$, a_{AP} et a_V
 - écarts-type de $a_{AP} + a_V$ et a_{ML}
 - médiane de a_V
 - 95-quantile de a_{ML}
 - nombre de changements de signe dans a_{ML} et a_V
 - corrélations croisées entre a_{ML} , a_{AP} et a_V .

L'interprétation de ces caractéristiques dans un contexte de marche est présentée dans [5].

4 Méthodes de détection de ruptures

4.1 Méthodes 1&2 : Détection de ruptures dans le paramètre de non-centrage d'une distribution multivariée et non-centrée du chi-2. Application à la TFCT.

Focalisons nous dans un premier temps sur la détection d'une rupture unique. La méthode que l'on utilise ici est inspirée de celle proposée dans [6], reposant sur le rapport de vraisemblance généralisé. Considérons une séquence de N vecteurs aléatoires indépendants de taille F , que l'on notera $\{\mathbf{y}_n\}_{1 \leq n \leq N}$. Supposons que les F composantes sont aussi indépendantes et que \mathbf{y}_n suit une loi du chi-2 non centrée à l degrés de liberté et de paramètre de non-centrage $\boldsymbol{\theta}_n$. Cette densité sera notée $p_{\boldsymbol{\theta}_n}(\mathbf{y}_n)$.

Considérons tout d'abord le cas d'une rupture unique : on suppose qu'il existe au plus une rupture dans $[1 : N]$. Les différentes hypothèses peuvent être écrites de la façon suivante :

$$\mathbf{H}_0 \quad \boldsymbol{\theta}_n = \boldsymbol{\theta} \quad 1 \leq n \leq N \quad (1)$$

$$\mathbf{H}_k \quad \boldsymbol{\theta}_n = \boldsymbol{\theta}^0 \quad 1 \leq n \leq k \quad (2)$$

$$\boldsymbol{\theta}_n = \boldsymbol{\theta}^1 \quad k+1 \leq n \leq N \quad (3)$$

où les paramètres $\boldsymbol{\theta}$, $\boldsymbol{\theta}^0$ and $\boldsymbol{\theta}^1$ sont supposés inconnus, ainsi que l'éventuel point de rupture k . En utilisant l'hypothèse de distribution du chi-2 non centrée, on peut estimer certains paramètres :

$$\hat{\boldsymbol{\theta}}^0 = \frac{1}{k} \sum_{n=1}^k \mathbf{y}_n - l \quad \hat{\boldsymbol{\theta}}^1 = \frac{1}{N-k} \sum_{n=k+1}^N \mathbf{y}_n - l \quad (4)$$

Si l'on suppose maintenant qu'il existe une et une seule rupture sur l'intervalle $[1 : N]$, l'indice de cette rupture est donné par :

$$\hat{k} = \operatorname{argmax}_k \sum_{n=k+1}^N \log \frac{p_{\hat{\boldsymbol{\theta}}^1}(\mathbf{y}_n)}{p_{\hat{\boldsymbol{\theta}}^0}(\mathbf{y}_n)} \quad (5)$$

Cette rupture est conservée si le rapport entre la vraisemblance généralisée qu'un changement ait lieu à \hat{k} ($\mathbf{H}_{\hat{k}}$) et la vraisemblance généralisée qu'il n'y ait pas de changement (\mathbf{H}_0) est supérieur à un seuil empirique. En pratique, on calcule le logarithme de ce rapport :

$$M(\hat{k}) = \sum_{n=1}^{\hat{k}} \log p_{\hat{\boldsymbol{\theta}}^0}(\mathbf{y}_n) + \sum_{n=\hat{k}+1}^N \log p_{\hat{\boldsymbol{\theta}}^1}(\mathbf{y}_n) - \sum_{n=1}^N \log p_{\hat{\boldsymbol{\theta}}}(\mathbf{y}_n). \quad (6)$$

On conclut que si $M(\hat{k}) > M^*$ (où M^* est un seuil empirique choisi comme précisé dans la section 5), alors il existe un point de rupture, et que l'indice de ce point est \hat{k} .

Cette approche est généralisée à la détection de plusieurs ruptures en estimant les points de rupture de façon itérative, comme décrit dans [7]. Nous appliquons notre méthode de détection de rupture unique pour estimer la première et la dernière rupture, puis nous appliquons l'algorithme de façon itérative sur la séquence comprise entre ces deux points, jusqu'à ce que plus aucune rupture ne soit détectée.

4.1.1 Méthode 1 : Application à une TFCT (classique)

Appelons $x_{f,n} \in \mathbb{C}$ la valeur de la TFCT pour la frame $n \in [1 : N_f]$ et le bin fréquentiel $f \in [1 : F]$. Si l'on suppose que

$$x_{f,n} \sim \mathcal{CN}(\mu_{f,n}, \sigma^2) \quad (7)$$

où $\mathcal{CN}(\mu, \sigma^2)$ désigne la distribution Gaussienne circulaire complexe de moyenne μ et de variance σ^2 .

Alors, si l'on note $v_{f,n} = \frac{2|x_{f,n}|^2}{\sigma^2}$ et $\theta_{f,n} = \frac{2|\mu_{f,n}|^2}{\sigma^2}$, on a :

$$v_{f,n} \sim \chi^2(\theta_{f,n}, 2). \quad (8)$$

où $\chi^2(\theta, l)$ désigne une loi du chi-2 non centrée à l degrés de liberté et de paramètre de non-centrage θ .

La méthode 1 consiste en l'application directe de la technique de détection de rupture précédemment décrite à la séquence d'observations $\mathbf{v}_n = [v_{1,n}, \dots, v_{F,n}]'$.

4.1.2 Méthode 2 : Modélisation de la structure fréquentielle des signaux de marche (structurée)

En observant les TFCT calculées sur des périodes de marche, l'on s'aperçoit que le spectre présente une série de pics fré-

quantiels, localisés à des multiples d'une fréquence fondamentale de bin f_0 . En supposant que le spectre de la fenêtre d'analyse présente un lobe principal suffisamment étroit pour éviter le recouvrement, nous pouvons définir le modèle de structure harmonique suivant :

$$\mathbb{E}[v_{f,n}] = \sum_{h=1}^H \rho_{h,n} |W(f - hf_0)|^2 \quad (9)$$

où $W(f)$ désigne la transformée de Fourier de la fenêtre d'analyse w , H désigne le nombre total d'harmoniques et $\rho_{h,n}$ l'amplitude de l'harmonique h sur la trame n .

La méthode 2 est une variante de celle décrite dans la Section 4.1.1, où l'équation (4) est remplacée par :

$$\hat{f}^0 = \underset{f}{\operatorname{argmax}} \frac{1}{k} \sum_{n=1}^k v_{f,n} \quad \hat{\rho}_h^0 = \frac{1}{k} \sum_{n=1}^k v_{h\hat{f}^0,n} \quad (10)$$

$$\hat{\theta}^0 = \sum_{h=1}^H \hat{\rho}_h^0 |W(f - h\hat{f}^0)|^2 - l \quad (11)$$

4.2 Méthode 3 : Détection de ruptures non paramétrique basée sur le rang (dynMKW)

La méthode non paramétrique que nous considérons ici est introduite et décrite dans [8]. Cette méthode ne faisant aucun hypothèse sur la distribution des observations, elle peut être utilisée à la fois sur la TFCT et sur les caractéristiques. De plus, contrairement aux méthodes 1&2, cette approche ne dépendant pas de paramètres annexes.

Soit $\{y_n\}_n$ une séquence de N observations de dimension F . Supposons qu'il existe $K - 1$ points de ruptures dans $[1 : N]$, qui seront notés k_1, \dots, k_{K-1} avec pour convention que $k_0 = 0$ et $k_K = N$. Introduisons le terme

$$r_{f,n} = \sum_{n'=1}^N \mathbf{1}_{\{y_{f,n'} \leq y_{f,n}\}} - \frac{N}{2} \quad (12)$$

dont le premier terme représente le rang de $y_{f,n}$ et

$$\bar{r}_{f,j} = \frac{1}{k_{j+1} - k_j} \sum_{n=k_j+1}^{k_{j+1}} r_{f,n} \quad (13)$$

comme le rang moyen du j^{me} groupe de la f^{me} dimension.

Définissons la statistique

$$T(k_1, \dots, k_{K-1}) = \frac{1}{N^2} \sum_{j=0}^{K-1} (k_{j+1} - k_j) \bar{\mathbf{r}}_j' \hat{\Sigma}^{-1} \bar{\mathbf{r}}_j, \quad (14)$$

où $\bar{\mathbf{r}}_j = [\bar{r}_{1,j}, \dots, \bar{r}_{F,j}]'$ et $\hat{\Sigma}$ est une matrice de taille $F \times F$ définie par :

$$\hat{\Sigma}_{f,f'} = \frac{1}{N^2} \sum_{n=1}^N r_{f,n} r_{f',n}. \quad (15)$$

Si l'on suppose que le nombre de ruptures est connu, et que le signal peut être segmenté en K groupes, les indices des différents changements peuvent être estimés en maximisant (14) :

$$(\hat{k}_1, \dots, \hat{k}_{K-1}) = \underset{0 < k_1 < \dots < k_{K-1} < N}{\operatorname{argmax}} T(k_1, \dots, k_{K-1}). \quad (16)$$

L'optimisation de ce critère est réalisé par programmation dynamique [9] et le nombre de segments est estimé de façon heuristique [8].

4.3 Méthode 4 : Détection de ruptures dans la moyenne d'une distribution Gaussienne multivariée (dynGAU)

Cette méthode est une adaptation de la méthode présentée dans la section 4.2, dans le cas où les données sont supposées présenter une distribution Gaussienne.

En écrivant $\tilde{\mathbf{y}}_n = \mathbf{y}_n - \sum_{n'=1}^N \mathbf{y}_{n'}$, l'unique changement apporté à la méthode précédente consiste à calculer la statistique décrite dans (14) en remplaçant le terme $\bar{r}_{f,j}$ dans (13) par :

$$\bar{r}_{f,j} = \frac{1}{k_{j+1} - k_j} \sum_{n=k_j+1}^{k_{j+1}} \tilde{y}_{f,n} \quad (17)$$

et $\hat{\Sigma}_{f,f'}$ dans (15) par :

$$\hat{\Sigma}_{f,f'} = \frac{1}{N^2} \sum_{n=1}^N \tilde{y}_{f,n} \tilde{y}_{f',n}. \quad (18)$$

5 Résultats

5.1 Evaluation des méthodes 1&2

Un exemple de détection est présenté sur la Figure 1. On s'aperçoit que, bien que toutes les méthodes semblent parvenir à détecter les changements de vitesse (qui correspondent aux 3 premières ruptures), seule la méthode 2 (structurée) détecte le changement de pente (uniquement sur le capteur tibia). Cela peut s'expliquer par le fait qu'un changement de vitesse semble se manifester par un changement de la fréquence fondamentale, alors qu'une rupture dans la pente semble agir sur les amplitudes relatives des différentes harmoniques. Puisque la méthode 2 (structurée) estime de façon explicite ces amplitudes, il est logique qu'elle soit plus à même de repérer les changements de pente. En ce qui concerne le choix du capteur, de meilleurs résultats semblent être obtenus avec le capteur tibia.

5.2 Résultats généraux

On calculé les précisions (pourcentage de ruptures correctes parmi les ruptures détectées) et les rappels (pourcentage des ruptures annotées ayant été détectées) pour les différents capteurs, représentations du signal, et méthodes de détection de rupture : ces scores sont présentée sur la Table 2. The seuil empirique utilisé pour les méthodes 1&2 a été choisi pour donner une précision d'approximativement 50% (qui est la précision moyenne obtenue avec les méthodes 3 & 4).

Ces résultats montrent qu'en travaillant sur la TFCT et le capteur tibia, les meilleurs résultats sont en effet obtenus grâce à la méthode 2 (structurée) (79% des ruptures sont détectées).

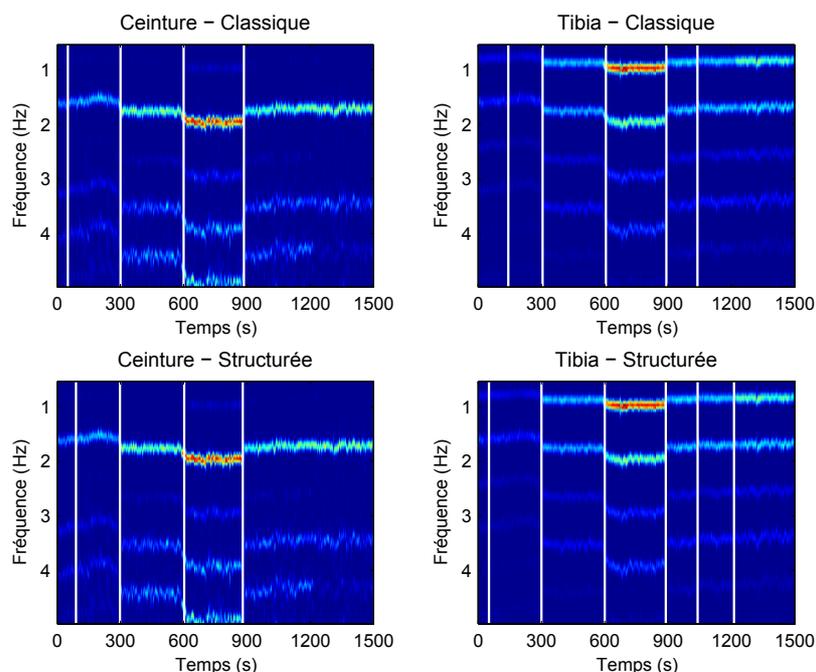


FIGURE 1 – Détection de ruptures sur la TFCT grâce aux méthodes 1 & 2. Les ruptures présentes dans les fichiers d’annotation sont localisées à 300, 600, 900 et 1200 secondes. Les 5 périodes ainsi définies sont les mêmes que celles présentées sur le Tableau 1.

		Ceinture		Tibia	
		p	r	p	r
(A) TFCT	(1) classique	0.50	0.72	0.49	0.77
	(2) structurée	0.46	0.65	0.49	0.79
	(3) dynMKW	0.50	0.67	0.51	0.71
	(4) dynGAU	0.50	0.63	0.47	0.61
(B) Caractéristiques	(3) dynMKW	0.51	0.69	0.57	0.79
	(4) dynGAU	0.49	0.66	0.57	0.73

TABLE 2 – Précisions et rappels obtenus sur le corpus de 24 sujets

Néanmoins, lorsque l’on travaille sur le capteur ceinture, il faut alors utiliser des méthodes plus générales (méthode 1 (72%)) car le modèle de structure fréquentielle est moins adapté. Lorsque l’on utilise la représentation par vecteur de caractéristiques, les meilleures performances sont obtenues en utilisant la méthode non-paramétrique 3 (dynMKW) donnant respectivement 69% et 79% de bonne détection pour les capteurs ceinture et tibia.

6 Conclusion

Nous avons présenté et évalué plusieurs approches pour la segmentation de signaux d’accélérométrie durant une période de marche continue sur un tapis. Sur notre corpus constitué de 24 sujets, 72% des changements de pente ou de vitesse ont été correctement détectés en travaillant sur le capteur ceinture, et 79% avec le capteur tibia. Une perspective directe de ces travaux serait leur adaptation à des périodes de marche libre, où les changements devraient être plus difficilement détectables que sur tapis.

Références

- [1] P. Terrier, K. Aminian, and Y. Schutz, “Can accelerometry accurately predict the energy cost of uphill/downhill walking?” *Ergonomics*, vol. 44, no. 1, pp. 48–62, 2001.
- [2] K. Aminian, P. Robert, E. Jequier, and Y. Schutz, “Estimation of speed and incline of walking using neural network,” *IEEE Transactions on Instrumentation and Measurement*, vol. 44, no. 3, pp. 743–746, 1995.
- [3] N. Wang, E. Ambikairajah, S. Redmond, B. Celler, and N. Lovell, “Classification of walking patterns on inclined surfaces from accelerometry data,” in *Proceedings of the International Conference on Digital Signal Processing (DSP)*, 2009, pp. 1–4.
- [4] M. Sekine, T. Tamura, T. Togawa, and Y. Fukui, “Classification of waist-acceleration signals in a continuous walking record,” *Medical Engineering & Physics*, vol. 22, no. 4, pp. 285–291, 2000.
- [5] M. Henriksen, H. Lund, R. Moe-Nilssen, H. Bliddal, and B. Danneskiold-Samsrø, “Test-retest reliability of trunk accelerometric gait analysis,” *Gait & Posture*, vol. 19, no. 3, pp. 288–297, 2004.
- [6] M. Basseville and I. Nikiforov, *Detection of abrupt changes: theory and application*. Prentice-Hall, Inc., 1993, ch. 2.6 - Off-line change detection, pp. 57–61.
- [7] C. Inclin and G. Tiao, “Use of cumulative sums of squares for retrospective detection of changes of variance,” *Journal of the American Statistical Association*, vol. 89, no. 427, pp. 913–923, 1994.
- [8] A. Lung-Yut-Fong, C. Lévy-Leduc, and O. Cappé, “Robust retrospective multiple change-point estimation for multivariate data,” *ArXiv e-prints (1102.1796)*, 2011.
- [9] S. Kay, *Fundamentals of statistical signal processing: detection theory*, 1993.