

Méthodes par graphe pour la reconnaissance d'activités à partir des signaux de capteurs de mouvements portés par la personne

Abbas ATAYA¹, Pierre JALLON¹, Pascal BIANCHI²

¹CEA LETI - MINATEC CAMPUS
17 rue des Martyrs, 38054 Grenoble Cedex 9, France

²TELECOM Paristech - TSI
37 rue Dareau, 75014 Paris, France
abbas.ataya@cea.fr, pierre.jallon@cea.fr
bianchi@telecom-paristech.fr

Résumé – La reconnaissance des activités physiques à partir de capteurs de mouvement est un problème de classification. Dans la littérature, la majorité des méthodes utilisent l'approche classique qui consiste à extraire des signaux accéléométriques des caractéristiques, puis utiliser un algorithme de *machine learning* pour leur associer l'activité pratiquée. Implicitement, les activités sont supposées former une séquence i.i.d.. Dans cet article, une nouvelle méthode est proposée basée sur l'hypothèse que cette séquence n'est pas i.i.d. mais corrélée temporellement. L'algorithme de classification SVM est donc modifié pour prendre en compte cette hypothèse et l'apport de cette modification est évalué à partir d'une base de données de 18 sujets sains.

Abstract – Physical activity recognition using motion sensors can be viewed as a classification problem. In the literature, the vast majority of methods follow a classical approach that consists of applying a *machine learning* algorithm on a vector of features extracted from accelerometer signals in order to identify afterwards the different practiced activities. This approach implicitly supposes that the activities constitute an i.i.d. sequence. In this paper, a new method is proposed based on the hypothesis that this sequence is not i.i.d. but rather a time correlated one. The SVM classification algorithm is then modified in order to take into account this hypothesis and the contribution of this modification is then evaluated on 18 healthy subjects.

1 Introduction

Les capteurs accéléométriques sont des capteurs sensibles à leurs orientations par rapport au champ gravitationnel et à leurs accélérations propres. Les récents progrès technologiques ont permis de miniaturiser ces capteurs, les rendant acceptables pour des applications biomédicales liées au mouvement [1]. Ces capteurs permettent donc d'estimer l'orientation des membres sur lesquels ils sont fixés lorsque ces membres sont statiques ou pseudo-statiques [2] ou encore estimer des gestes lors de phases dynamiques. Les applications biomédicales les plus couramment étudiées sont les applications liées à l'estimation de l'activité physique pour la prévention de l'obésité et des maladies associées (HTA, diabète,...) où l'on cherche à estimer la posture de la personne [3], l'estimation de la dépense énergétique via la détection de présence de mouvement ainsi que les applications liées aux maladies neuronales dont les symptômes sont souvent des mouvements anormaux où l'on cherche à reconnaître des gestes [4].

Les résultats présentés dans ce papier concerne les premières applications et plus précisément l'estimation des activités d'une personne à partir du signal d'un capteur accéléométrique tri-axial porté à la ceinture. Ce problème a donné lieu à de nom-

breuses publications présentées dans l'article de synthèse de Preece [5]. Dans la grande majorité des contributions, si l'activité d'une personne à l'instant m est notée $A(m)$, la variable aléatoire $A(m)$ est supposée être une variable indépendante temporellement. Une hypothèse plus réaliste est de supposer que cette variable $A(m)$ est corrélée temporellement. Cette corrélation peut être modélisée en utilisant une chaîne de Markov d'ordre 1. Le choix des valeurs des probabilités de transition permet de définir des contraintes temporelles entre les états formant ainsi un graphe.

Si les caractéristiques extraites du signal accéléométrique pour estimer l'activité à l'instant m sont concaténées dans un vecteur $O(m)$, une manière naturelle de prendre en compte la modélisation de la séquence $A(m)$ est de modéliser le couple de variables $\{A, O\}$ par un modèle de Markov caché de premier ordre [6, 7]. Avec ce formalisme, l'algorithme de classification sous-jacent est l'algorithme *Naive Bayes*. A chaque instant m la probabilité de chacune des activités d'intérêt est la suivante :

$$\forall i \in \{0, \dots, N-1\}, p(O(m)|A(m) = i),$$

où N représente le nombre d'activités d'intérêt. Si la séquence d'activité est modélisée par une séquence i.i.d., la classification

est alors effectuée comme suit :

$$\forall m, \hat{A}(m) = \arg \max_{A(m)} p(A(m))p(O(m)|A(m)).$$

Si la séquence d'activité est modélisée par une chaîne de Markov d'ordre 1, pour une séquence d'observations de M échantillons $O(0 : M - 1) = \{O(0), \dots, O(M - 1)\}$, $\hat{A}(0 : M - 1)$ est estimée comme suit :

$$\arg \max_{A(0 : M-1)} \left[p(A(0)) \prod_{m=1}^{M-1} p(A(m)|A(m-1)) \right] \times \left[\prod_{m=0}^{M-1} p(O(m)|A(m)) \right] \quad (1)$$

Dans son papier comparatif sur les algorithmes de classification appliqués au problème de la reconnaissance d'activité physique [8], Altun a montré que l'algorithme SVM était celui qui donnait les meilleures performances. Dans ce papier, on propose donc d'étendre ce formalisme pour renforcer par un graphe les décisions prises par un algorithme SVM (support vector machine) [9]. Dans la partie 2, l'extension générale à d'autres classifieurs est présentée. Le cas des algorithmes SVM est traité en partie 3. Des résultats de validation sont présentés dans la partie 4 et la partie 5 conclut cette contribution.

2 Modèles de Markov cachés et méthodes par graphe

2.1 Modèles de Markov cachés

Un modèle de Markov caché est un processus stochastique bivarié $\{A, O\}$. Le premier processus $A(m)$ est modélisé par une chaîne de Markov et non observé en général. On supposera de plus que cette variable prend des valeurs discrètes dans l'ensemble $\{0, \dots, N - 1\}$ où N est le nombre d'activités d'intérêt. Ce processus est entièrement décrit par les lois d'initialisations $\forall i \in \{0, \dots, N - 1\}, \pi_i = p(A(0) = i)$ et les lois de transitions $\forall (i, j) \in \{0, \dots, N - 1\}^2, a_{i,j} = p(A(m) = j|A(m-1) = i)$. Dans les méthodes par graphe, ce processus modélise les différentes activités ainsi que les dépendances qui existent entre elles. En particulier pour modéliser la stabilité des activités dans le temps, les probabilités de rester dans le même état sont choisies proches de 1, i.e. $a_{i,i} = 1 - \epsilon$, avec ϵ étant une valeur très proche de 0.

Le second processus est un vecteur de caractéristiques extraites du signal $O(m)$ à l'instant m . Ce processus est supposé être un processus indépendant temporellement conditionné à l'état $A(m)$. Il est entièrement décrit par les probabilités d'observations $\forall i \in \{0, \dots, N - 1\}, p(O(m)|A(m) = i)$.

Dans le cadre des méthodes par graphe, pour une séquence de M observations $O(0 : M - 1)$, la séquence des activités pratiquées correspondante est estimée comme suit :

$$\hat{A}(0 : M - 1) = \arg \max_{A(0 : M-1)} p(A(0 : M - 1), O(M - 1)) \quad (2)$$

En utilisant les propriétés des modèles de Markov cachés énoncées ci-dessus, cette équation se ré-écrit comme (1). Dans le terme de droite de (1), deux termes apparaissent. Le premier ne dépend que des lois d'initialisations et de transitions de la variable cachée $A(m)$, le second dépend des probabilités d'observations du vecteur $O(m)$ conditionnées à l'état.

2.2 Extension à d'autres algorithmes de classification

La classification utilisée avec des modèles de Markov cachés peut être analysée comme suit : à chaque instant une mesure de confiance dans chacune des hypothèses $A(m) = i, i \in \{0, \dots, N - 1\}$ est estimée via les probabilités d'observations $\forall i \in \{0, \dots, N - 1\}, p(O(m)|A(m) = i)$. La prise de décision est ensuite réalisée en pondérant ces mesures de confiance par les contraintes existantes entre les activités et qui sont décrites par les probabilités de transitions.

L'extension à d'autres algorithmes de classification se fait donc par le remplacement dans (1) des termes $\{p(O(m)|A(m))\}_m$ par des mesures de confiances dans les activités à chaque instant $\phi(O(m)|A(m))$, ou plus généralement $\phi(O(0 : M - 1)|A(m))$, estimées par d'autres algorithmes de classification. Ces mesures de confiance se comportent comme une fonction densité de probabilité et doivent satisfaire les propriétés suivantes :

$$H1- \forall i, \forall m, \phi(O(0 : M - 1)|A(m) = i) \geq 0$$

$$H2- \forall i, \forall m, \phi(O(0 : M - 1)|A(m) = i) \text{ croît avec la confiance que l'on accorde à l'hypothèse } A(m) = i$$

L'équation (1) est alors modifiée comme suit :

$$\hat{A}(0 : M - 1) = \arg \max_{A(0 : M-1)} p(A(0)) \prod_{m=1}^{M-1} p(A(m)|A(m-1)) \times \prod_{m=0}^{M-1} \phi(O(0 : M - 1)|A(m)) \quad (3)$$

Tout comme (1), cette optimisation peut être faite en utilisant l'algorithme de Viterbi [10].

3 Application aux algorithmes de classification SVM

Dans cette section, l'application de la méthode par graphe aux algorithmes de classification SVM est présentée. Le cas de deux classes est d'abord considéré pour introduire la fonction $\phi(O(0 : M - 1)|A(m))$, puis le cas multi classes est décrit.

3.1 Introduction au cas bi-classes

Dans les algorithmes de classification de type SVM, les deux classes sont séparées par un hyperplan déterminé lors d'une phase d'apprentissage. Si w est le vecteur normal à l'hyperplan

séparateur, b l'offset et $O(m)$ le vecteur d'observation à classifier, la décision est prise selon le signe du critère :

$$J(m) = w^T \cdot O(m) + b$$

où \cdot^T est l'opérateur du transposition. Les résultats présentés s'étendent directement au cas où un noyau serait utilisé dans l'algorithme SVM.

$J(m)$ est une mesure signée de la distance entre le point à classer $O(m)$ et l'hyperplan séparateur. Par simplicité, on notera $J_{0,1}(m)$ cette distance lorsque la classe 0 est décidée si $J(m) > 0$ et $J_{1,0}(m) = -J_{0,1}(m)$. Les fonctions de confiance suivantes peuvent être utilisées :

$$\phi(O(0 : M - 1) | A(m) = 0) = \frac{1 + \tanh(J_{0,1}(m)/2)}{2}$$

$$\phi(O(0 : M - 1) | A(m) = 1) = \frac{1 + \tanh(J_{1,0}(m)/2)}{2}$$

Les fonctions de confiance ϕ ainsi définies vérifient bien les deux hypothèses H1 et H2.

3.2 Extension aux cas multi-classes

Le cas multi-classes est traité par extension de la méthode *Un-Contre-Un*. Pour chaque couple de classe $(i, j) \in \{1, \dots, N\}^2$ avec $i \neq j$, un hyperplan est estimé lors de la phase d'apprentissage. Lors de la phase de détection, deux mesures de confiance $J_{i,j}(m)$ et $J_{j,i}(m)$ sont calculées. Les fonctions $\phi(O(m) | A(m))$ sont alors calculées comme suit, $\forall i \in \{1, \dots, N\}$,

$$\phi(O(m) | A(m) = i) = \sum_{j \neq i} \frac{1 + \tanh(J_{i,j}(m)/2)}{2}$$

4 Validation de la méthode

Les performances de l'algorithme présenté ont été estimées sur une base de données d'activités supervisées avec 18 acquisitions correspondantes à 18 sujets. Chacune de ces personnes devait réaliser une série d'activités scénarisées en portant un accéléromètre tri-axial au niveau de la ceinture permettant ainsi de mesurer les accélérations selon les 3 axes de l'espace. Pour chacun des 18 sujets, environ 80 minutes de signaux ont été enregistrées. Les activités suivantes ont été annotées par l'équipe médicale qui a supervisé et organisé cette campagne d'acquisitions : debout, assis, allongé et marche. Les transitions entre les différentes activités n'ont pas été prises en compte lors de l'annotation à cause de leurs brèves durées comparée à celles des activités d'intérêt.

Les capteurs échantillonnent à 200Hz, produisant ainsi un signal numérique de dimension 3 à cette fréquence. Ce signal est ensuite décimé à 5Hz. Le vecteur $O(m)$ utilisé pour la classification correspond simplement à la valeur en sortie du décimateur prise à l'instant m . Pour chacun des 18 signaux de la base de données, les paramètres de l'algorithme SVM sont estimés par apprentissage sur les 17 autres réalisations. La séquence

sans graphe	avec graphe
$P = 0.85$	$P = 0.90$

TABLE 1 – Performances globales sans et avec graphe.

sur laquelle les performances sont estimées ne fait donc pas partie des séquences d'apprentissage. Les fonctions ϕ calculées à partir des résultats de classification, définissent alors des mesures de confiance pour chaque état décrit dans le graphe. Le problème d'optimisation de (3) est ensuite résolu pour trouver la séquence d'états la plus vraisemblable. Les performances sont ensuite estimées pour chacune des séquences via le taux de bonne détection global de l'algorithme (le ratio entre le nombre de bonnes décisions et le nombre total de décisions) et la matrice de confusion. Si P_i est la performance de l'algorithme estimée pour le sujet i , les performances globales des algorithmes sont alors obtenues en moyennant les performances des 18 séquences.

$$P_i = \frac{1}{M_i} \sum_{m=0}^{M_i-1} \delta[\hat{A}_i(m) - A_i(m)] \quad (4)$$

où M_i est la taille du signal, $A_i(m)$ la séquence d'états annotée, $\hat{A}_i(m)$ la séquence estimée, et $\delta[n]$ est la fonction de Dirac qui vaut 1 si $n = 0$ et 0 sinon. Ces résultats sont ensuite moyennés pour établir un critère global de performances :

$$P = \frac{1}{18} \sum_{i=1}^{18} P_i \quad (5)$$

Comme illustré dans le tableau 1, le taux de bonne détection global P passe de 85% de bonne détection sans graphe à 90% avec un graphe.

La matrice de confusion offre une mesure plus précise des résultats : c'est une matrice carrée de dimension $N \times N$ (N étant le nombre total de classes) dont les coefficients $C_{i,j}$ sont l'estimation empirique de la probabilité que l'activité correspondant à l'état j soit détectée lorsque l'activité i est exercée.

$$C_{i,j} = \frac{\sum_{m=0}^{M_i-1} \delta[A(m) = i] \delta[\hat{A}(m) = j]}{\sum_{m=0}^{M_i-1} \delta[A(m) = i]} \quad (6)$$

Les matrices de confusion obtenues sont décrites dans le tableau 2 avec un algorithme SVM sans graphe et dans le tableau 3 avec un graphe. On remarque qu'avec la méthode SVM sans graphe l'état marche est confondu avec l'état debout dans 18.7% des cas. Cela peut être dû au fait que l'état debout partage certaines caractéristiques temporelles avec l'état marche. Par exemple, il est très probable qu'une personne effectuant de la marche soit détectée comme étant debout pour quelques instants si elle marchait lentement. Le graphe favorisant les activités stables dans le temps a montré une augmentation importante du taux de bonne détection de l'état marche où l'on trouve qu'avec le graphe celui-ci est mieux détecté de 10%. On note aussi que l'état assis est détecté comme debout dans 10% des cas lorsque l'on n'utilise pas un graphe et dans 9% des cas quand on renforce les décisions par un graphe. Cette légère amélioration s'avère être normale vu la forte dépendance entre

		État Estimé			
		Debout	Marche	Allongé	Assis
État annoté	Debout	90.5	7.7	0	1.8
	Marche	18.7	78.3	0.8	2.2
	Allongé	0	0.8	97.7	1.5
	Assis	10.1	5.7	7.4	76.8

TABLE 2 – Performances obtenues en utilisant un algorithme de classification SVM sans graphe.

		État Estimé			
		Debout	Marche	Allongé	Assis
État annoté	Debout	93	5.5	0	1.5
	Marche	9.9	88.4	0.7	1
	Allongé	0	1.1	98.2	0.7
	Assis	9	5	6	80

TABLE 3 – Performances obtenues en utilisant un algorithme de classification SVM avec un graphe.

la distinction de ces 2 états et le type de la posture assise adoptée par les différents sujets (assis voûté, assis droit etc...). Dans la plupart des cas, une personne assise est légèrement inclinée par rapport à l'axe longitudinal mais dans le cas où la personne est assise avec le dos droit la possibilité que l'état assis soit confondu avec l'état debout augmente. Pour tous les états estimés avec un graphe, on constate une amélioration de détection qui est due à la restriction des transitions parasites qui peuvent intervenir dans les séquences estimées en utilisant la méthode SVM seule (Figure 1).

5 Conclusion

Cet article a proposé une méthode par graphe appliquée avec un algorithme de classification type SVM afin d'estimer l'activité physique de la personne à partir des signaux issus d'un accéléromètre tri-axial placé à la ceinture. Un taux de bonne détection global de 90% a été finalement obtenu avec la méthode présentée comparé à 85% quand la méthode de base est appliquée (SVM seule). Les performances ont été calculées sur des signaux issus de 18 sujets sains. Chacun de ces signaux dure environ 80 minutes et contient les mesures d'accélération selon les 3 axes de l'espace. L'amélioration de détection constatée est principalement due à la prise en compte des dépendances temporelles qui existent naturellement dans les séquences d'activités.

Références

[1] P.H. Veltink, HansB.J. Bussmann, W. de Vries, WimL.J. Martens, and R.C. Van Lummel. Detection of static and dynamic activities using uniaxial accelerometers. *IEEE*

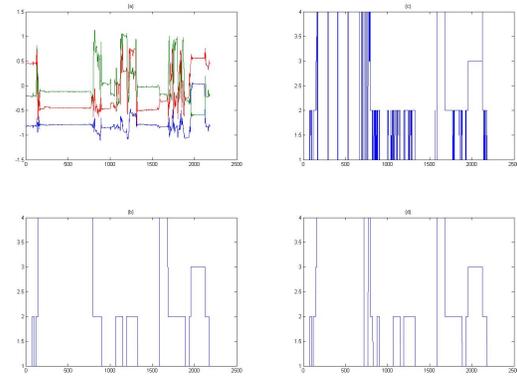


FIGURE 1 – Résultats obtenus pour sujet # 1. (a) Les signaux accélérométriques. (b) Signal d'annotation (1-Debout, 2-Marche, 3-Allongé, 4-Assis). (c-d) Séquences estimées en utilisant SVM sans graphe et avec graphe respectivement.

Transactions on Rehabilitation Engineering, 4(4) :375–385, December 1996.

- [2] Pietro Picerno, Andrea Cereatti, and Aurelio Cappozzo. A spot check for assessing static orientation consistency of inertial and magnetic sensing units. *Gait & Posture*, 2011.
- [3] Susan L. Murphy. Review of physical activity measurement using accelerometers in older adults : Considerations for research design and conduct. *Preventive Medicine*, 48(2) :108 – 114, 2009.
- [4] G. Becq, S. Bonnet, L. Minotti, M. Antonakios, R. Guillemaud, and P. Kahane. Collection and exploratory analysis of attitude sensor data in an epilepsy monitoring unit. *29th IEEE EMBS*, 2007.
- [5] Stephen J Preece, John Y Goulermas, Laurence P J Kenney, Dave Howard, Kenneth Meijer, and Robin Crompton. Activity identification using body-mounted sensors : a review of classification techniques. *Physiological Measurement*, 30(4) :R1, 2009.
- [6] Lawrence R. Rabiner. Tutorial on hidden markov models and selected applications in speech recognition. *Proceedings of the IEEE*, 77(2) :257–286, 1989.
- [7] P. Jallon. A graph based algorithm for postures estimation based on accelerometers data. In *EMBC*, 2010.
- [8] Orkun Tunçel Kerem Altun, Billur Barshan. Comparative study on classifying human activities with miniature inertial and magnetic sensors. *Pattern Recognition*, 2010.
- [9] Shawe-Taylor J. Cristianini, N. An introduction to support vector machines and other kernel-based methods. *An Introduction to Support Vector Machines*, 2000. Cambridge University Press, Cambridge, UK.
- [10] A.J. Viterbi. Error bounds for convolutional codes and an asymptotically optimum decoding algorithm. *IEEE Trans. Inform. Theory*, 13(2) :260–269, 1967.