

APPRENTISSAGE STATISTIQUE POUR L'ACTIMÉTRIE DU PIÉTON À PARTIR DE DONNÉES INERTIELLES

Bertrand Beaufiles ¹ & Frederic Chazal ² & Marc Grelet ³ & Bertrand Michel ⁴

^{1,3}*Sysnav*

57 Rue de Montigny, 27200 Vernon, France

^{1,2,4}*Inria Saclay*

Équipe DataShape

1 Rue Honoré d'Estienne d'Orves, 91120 Palaiseau, France

⁴*École Centrale de Nantes*

Département Informatique et Mathématiques

1 Rue de La Noe, 44300 Nantes, France

*Email addresses : ¹bertrand.beaufiles@sysnav.fr, ²frederic.chazal@inria.fr,
³marc.grelet@sysnav.fr, ⁴bertrand.michel@ec-nantes.fr*

Résumé. L'entreprise Sysnav conçoit, développe et commercialise des solutions de navigation robustes aux défauts du GPS pour différents marchés professionnels comme la navigation pour piétons ou véhicules terrestres et pour le médical avec notamment l'actimétrie utilisée pour l'évaluation de l'état clinique pour des maladies se traduisant par des troubles du mouvement. Le système de capteurs positionné à la cheville, destiné à suivre les patients quotidiennement, recueille les données inertielles à une fréquence de 130 Hz. Face à la quantité et la grande diversité des mouvements, nous avons recours à des algorithmes d'apprentissage supervisés afin de détecter les déplacements et d'interpréter les activités.

Mots-clés. Apprentissage et classification, analyse des données, fouille de données.

Abstract. Sysnav designs, develops and markets navigation solutions robust to GPS faults for various professional markets such as pedestrian or land vehicles navigation and for medical applications, including the actimetry that is used to assess the clinical states of diseases resulting in movement disorders. The ankle-based sensor system, designed to monitor patients daily, samples the inertial data at a frequency of 130 Hz. Given the amount of data and the variety of movements, we use supervised learning algorithms to detect movement and to interpret activities.

Keywords. Machine learning and classification, data analysis, data mining.

1 Introduction

Des capteurs magnétiques et inertiels sont aujourd’hui présents dans de multiples objets de l’électronique grand public, le plus souvent sous forme connectée. C’est par exemple le cas dans les smartphones et certaines montres. Avec la multiplication de ces objets, l’analyse et l’exploitation des données de capteurs de mouvement sont devenues un enjeu scientifique, technique et économique important. Au delà des applications grand public, qui doivent se satisfaire des possibilités offertes par des dispositifs à base de capteurs très bas coûts et rarement calibrés, plusieurs domaines d’activité plus spécialisés s’intéressent à la conception de dispositifs capables de mesurer précisément et de manière fiable des caractéristiques particulières des mouvements humains, comme l’industrie pharmaceutique. La technologie magnéto-inertielle de Sysnav permet la reconstruction fiable de mouvements donnant accès à des variables non disponibles à partir de capteurs plus standards. L’ActiMyo, système de capteurs (magnétomètre, accéléromètre, gyromètre) destiné à suivre les patients DMD (myopathie de Duchenne) ou FHS (dystrophie facio-scapulo-humérale) est le seul équipement actuel qui apporte une aide au diagnostic.

Certaines caractéristiques de la marche sont des facteurs représentatifs de l’évolution de la maladie. Dans ce contexte, il est primordial de pouvoir détecter précisément les foulées dans les enregistrements de l’ActiMyo positionné à la cheville. Ceci doit permettre dans un second temps d’extraire des variables informatives sur l’état du patient comme la vitesse, la longueur et l’activité du pas réalisé.

Par ailleurs, plusieurs séances avec des patients équipés de l’ActiMyo ont été filmées par les médecins. En effet, il existe aujourd’hui des tests standardisés qui permettent le suivi de l’état du patient comme le test de 6 minutes durant lequel il doit parcourir la plus grande distance en marchant et le test des 4 marches qui correspond à monter 4 marches le plus rapidement possible. De ce fait nous disposons d’enregistrements dans lesquels nous pouvons identifier les phases de marche, course, montée et descente d’escaliers. Cela nous conduit à adopter une stratégie de classification supervisée.

Dans ce travail, nous décrivons les différentes techniques développées pour la détection des pas et la classification d’activité. Notamment l’approche innovante basée sur la modélisation du balancement du pied lors d’une foulée.

2 Pattern de référence fonctionnel univarié

Le cycle d'une foulée se découpe en deux phases (Figure 1) : à partir du pied au sol, le pied est balancé vers l'arrière (stance) puis vers l'avant (swing). Dans une direction du gyromètre, ces deux phases se distinguent par un changement de signe des données recueillies (vitesse de rotation positive en phase de stance et négative en phase de swing).




Figure 1: Phases de la marche (www.optogait.com).

Nous souhaitons construire un pattern de référence caractérisant le swing pour chaque activité à partir de notre base de données. Nous avons affecté un label k aux différentes activités que nous voulons détecter. On note $f_{l,k}$ la fonction associée au $l^{\text{ème}}$ swing de l'activité k et f_k la fonction associée au pattern de référence de l'activité k telles que $f_{l,k}$ et f_k sont définies sur l'intervalle $[0, 1]$ dans \mathbb{R} . On suppose que le pattern de référence f_k peut être approché par toutes les fonctions $f_{l,k}$ de la même activité en ajustant ces dernières avec un coefficient multiplicateur réel $a_{l,k}$:

$$f_k = a_{l,k} \times f_{l,k} + \epsilon_l. \quad (1)$$

Nous supposons que les fonctions appartiennent à un espace fonctionnel E muni d'une norme $\|\cdot\|$. Les observations sont les fonctions $f_{l,k}$ et nous souhaitons calculer les estimateurs \hat{f}_k et $\hat{a}_{l,k}$ qui sont déterminés par minimisation des moindres carrés sous contraintes (\mathcal{P}) :

$$\hat{a}_{l,k} = \underset{a_{l,k} \in \mathbb{R}_+^*}{\operatorname{argmin}} \|a_{l,k} f_{l,k} - f_k\|, \quad (2)$$

$$\hat{f}_k = \underset{f_k \in E, \|f_k\|=1}{\operatorname{argmin}} \sum_l \|\hat{a}_{l,k} f_{l,k} - f_k\|. \quad (3)$$

Afin de résoudre le problème (\mathcal{P}), nous supposons qu'il existe une base orthonormée (e_1, \dots, e_p) pour la norme $\|\cdot\|$ telle que dans cette base on peut écrire les fonctions de manière unique. En pratique nous utilisons les polynômes de Lagrange ([1]) mais d'autres

bases de fonctions peuvent être choisies comme la base de Fourier. On pose :

$$f_k = \sum_{u=1}^p \gamma_u e_u, \quad (4)$$

$$f_{l,k} = \sum_{u=1}^p \alpha_{l,u} e_u. \quad (5)$$

Soient $\Lambda_l = (\alpha_{l,1}, \dots, \alpha_{l,p})^t$ et la matrice A symétrique définie par $A_{ij} = \sum_l \frac{\alpha_{l,i} \alpha_{l,j}}{\|\Lambda_l\|_2^2}$, la solution du problème (\mathcal{P}) est donnée par :

$$\hat{\alpha}_{l,k} = \frac{\sum_{u=1}^p \alpha_{l,u} \gamma_u}{\sum_{u=1}^p \alpha_{l,u}^2}, \quad (6)$$

$$\hat{f}_k = \pm \sum_{u=1}^p \omega_{p,u} e_u, \quad (7)$$

où ω_p est le vecteur propre de A associé à sa plus grande valeur propre. Comme le swing est caractérisé par des valeurs négatives, on choisira en pratique la solution de l'Équation 7 qui prendra des valeurs négatives.

Cette étude du swing nous a permis d'extraire plusieurs features utiles non seulement pour la détection des pas mais également pour leur attribuer une activité parmi "petits déplacements" (piétinement, pas chassés, marche arrière etc.) "marche", "course", "descente d'escaliers" et "montée d'escaliers". Elles viennent compléter un ensemble de plusieurs centaines de features utilisées pour l'apprentissage statistique.

3 Apprentissage statistique supervisé pour la reconnaissance d'activité

La base de données construite comprend des données des consultations des patients que nous avons complétées avec des enregistrements personnels. Au total nous disposons de près de 6000 pas répartis dans les 5 activités (Tableau 1).

Labels	Activités	Nombres de pas
1	Petit déplacement	1292
2	Marche	1243
3	Course	882
-10	Descente d'escaliers	1232
+10	Montée d'escaliers	1287

Table 1: Description de la base de données.

Nous avons testé plusieurs algorithmes d'apprentissage statistique supervisé dont les forêts aléatoires réputées performantes en grande dimension, SVM (Support Vector Machine), régression LASSO ainsi que des algorithmes de boosting comme Adaboost et GBT (Gradient Boosting Tree [2]). Nous avons évalué leur performance grâce à la méthode de validation croisée (10-fold cross-validation [3]). L'algorithme retenu présentant les meilleurs résultats est le GBT.

Le principe du boosting est d'itérativement se focaliser sur les observations difficiles à prédire. Pour l'algorithme GBT l'idée générale consiste à calculer une série d'arbres de décision ([4]) (très) simples et d'aggréger les résultats pour minimiser une fonction de coût. Soit f_n la fonction de prédiction à l'itération n qui pondère n arbres $f_n = \omega_1^n Tree_1 + \dots + \omega_n^n Tree_n$. On construit un nouvel arbre $Tree_{n+1}$ qui minimise la fonction de coût considérée $L(f_{n+1})$ où $f_{n+1} = \omega_1^{n+1} Tree_1 + \dots + \omega_n^{n+1} Tree_n + \omega_{n+1}^{n+1} Tree_{n+1}$. Les arbres construits restent identiques au cours des itérations, seuls les poids changent. Nous représentons les résultats de la validation croisée sous forme de matrice de confusion (Tableau 2).

	Predicted 1	Predicted 2	Predicted 3	Predicted +10	Predicted -10
Actual 1	1138	6	0	0	0
Actual 2	17	1218	0	7	1
Actual 3	0	1	881	0	0
Actual +10	0	2	0	1230	0
Actual -10	0	0	0	0	1287

Table 2: Matrice de confusion pour le GBT par validation croisée.

Les erreurs commises entre les classes 1 et 2 sont à pondérer car la frontière entre un "petit déplacement" et de la "marche" n'est pas clairement définie. La reconnaissance d'activité est essentiellement utilisée pour déterminer si un patient court ou prend encore les escaliers. En ce sens, nous obtenons une erreur de moins de 0.2%.

Bibliographie

- [1] Jean-Paul Berrut, Lloyd N. Trefethen (2004), *Barycentric Lagrange Interpolation*, SIAM (Society for Industrial and Applied Mathematics) Review.
- [2] J. H. Friedman (2002), *Stochastic gradient boosting*, Computational Statistics and Data Analysis **38**.
- [3] M. Stone (1974), *Cross-validatory choice and assessment of statistical predictions*, J. Royal Stat. Soc., 36(2), 111–147.
- [4] L. Breiman, J. Friedman, R. Olshen, C. Stone (1984), *Classification and Regression Tree*.