



HAL
open science

Suivi de trajectoires des personnes âgées dans des environnements fermés

Daniel Alshamaa, Aly Chkeir, Farah Mourad-Chehade

► **To cite this version:**

Daniel Alshamaa, Aly Chkeir, Farah Mourad-Chehade. Suivi de trajectoires des personnes âgées dans des environnements fermés. Journées d'Etude sur la TéléSanté, Sorbonne Universités, May 2019, Paris, France. hal-02161067

HAL Id: hal-02161067

<https://hal.science/hal-02161067>

Submitted on 20 Jun 2019

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Suivi de trajectoires des personnes âgées dans des environnements fermés

Daniel ALSHAMAA¹, Aly CHKEIR¹, Farah MOURAD-CHEHADE¹

¹Institut Charles Delaunay, Université de Technologie de Troyes Troyes, France

daniel.alshamaa@utt.fr, aly.chkeir@utt.fr, farah.chehade@utt.fr

Résumé – Le suivi de trajectoires des personnes âgées est très important pour les aider le plus vite possible. Le présent article propose une méthode de suivi de trajectoires pour localiser des personnes âgées en temps réel dans des environnements fermés. Le modèle de mobilité est basé sur les modèles de Markov cachés. Ce modèle sert à estimer la trajectoire de la personne. Nous présentons dans cet article un modèle de mobilité en utilisant les modèles de Markov cachés. Ce modèle est combiné par un modèle d’observation. Ce dernier utilise les puissances des signaux WiFi reçus des points d’accès dans l’environnement. Les performances de la méthode proposée sont validées par des expérimentations sur des données réelles.

Abstract – Tracking of elderly people is indispensable in order to assist them as fast as possible. In this paper, we propose a trajectory tracking technique to localize elderly people in real time in indoor environments. A mobility model is constructed, based on the hidden Markov models, to estimate the trajectory followed by each person. The mobility model is combined to an observation model using measurements from the network. Here, we use the power of the WiFi signals received from surrounding Access Points installed in the building. The combination between the mobility model and the measurements result in tracking of elderly people. Real experiments are realized to evaluate the performance of the proposed approach.

1 Introduction

La localisation des capteurs dans un réseaux de capteurs sans fil (RCSF) est primordiale pour un grand nombre d’applications [1, 2]. Nous nous intéressons dans cet article à la localisation des personnes âgées. Dans cette application, la détermination de la zone où se trouve la personne âgée est suffisante, sans besoin de localisation exacte. Pour cette raison, nous abordons le problème de localisation par zonage. Les méthodes de localisation basées sur les RSSIs sont considérées les plus populaires puisqu’elles présentent de nombreux avantages du point de vue de leur simplicité ainsi que du coût de matériel. Certaines de ces techniques exploitent l’atténuation de la puissance du signal avec la distance parcourue pour estimer les distances séparant les capteurs. Cependant, ces techniques ne sont pas toujours efficaces, puisque les signaux sont sensibles à la présence du bruit et des interférences. D’autres méthodes s’appuient sur la technique du fingerprinting qui consiste à collecter des informations du réseau pour construire une base de données à utiliser pour la localisation [3].

Le suivi de trajectoires est une application très populaire des RCSFs. Il consiste à estimer de manière récursive la position d’un nœud mobile (MN). En utilisant un modèle de mobilité qui décrit le mouvement du MN, nous pouvons d’abord prédire son état futur à partir de son état actuel. Ensuite, l’état prédit est mis à jour en utilisant les observations du réseau, à savoir, un modèle d’observation. Plusieurs méthodes de fusion de données peuvent être utilisées pour combiner les in-

formations de mobilité et les observations. Le filtre de Kalman (KF) [4] peut être utilisé dans le cas d’un modèle d’observation linéaire. Dans le cas de la non-linéarité, le filtre de Kalman étendu (EKF) et le filtre de Kalman sans parfum (UKF) peuvent être utilisés [5]. Cependant, de telles approches effectuent des linéarisations et des approximations conduisant à une performance sous-optimale et parfois à la divergence. Le filtre particulaire (PF) [6] est également utilisé pour le suivi de trajectoires. Un tel filtre a plus de potentiel que le filtre de Kalman dans le cas de bruits non gaussiens et de modèles non linéaires. Cependant, la génération d’échantillons et l’étape de ré-échantillonnage rendent les algorithmes employant ce filtre plus complexes en termes de calculs que le filtre de Kalman. Plusieurs techniques de suivi utilisant des informations de mobilité ont été proposées dans la littérature. En plus des mesures de *Received Signal Strength Indicator* (RSSI), ces techniques emploient un modèle de mobilité pour affiner l’estimation de la position grâce à sa position antécédente.

Dans ce papier, nous effectuons le suivi de trajectoires en combinant un modèle d’observation et un modèle de mobilité. En utilisant la technique de fingerprinting, nous définissons un modèle d’observation pour donner une première estimation de la zone du MN. Ensuite, nous combinons cette première estimation à un modèle de mobilité pour obtenir une estimation plus affinée de la zone du MN. Dans ce but, un modèle de mobilité, basé sur les modèles de Markov cachés, est proposé. Nous évaluons la performance de la méthode proposée par des expérimentations sur des données réelles.

Cet article est organisé comme suit. La section suivante présente la problématique. Puis, le modèle d'observation est présenté. Ensuite, le modèle de mobilité est expliqué, en décrivant la mise en oeuvre des modèles de Markov cachés pour le suivi de trajectoires. Finalement, la méthode est illustrée au travers d'expérimentations pour la localisation indoor des personnes âgées.

1.1 Problématique

Soient N_Z le nombre de zones de la région cible, notées Z_j , $j = 1, 2, \dots, N_Z$, N_{AP} le nombre de points d'accès (APs), notés AP_k , $k = 1, 2, \dots, N_{AP}$ et ρ_t le vecteur de RSSIs reçu par le MN à l'instant t des APs détectés. Soit v_{max} la vitesse maximale du MN dans le milieu couvert. Dans notre application, v_{max} est la vitesse maximale prévue du mouvement des personnes âgées dépendantes à l'intérieur. L'objectif de l'algorithme proposé est de trouver une fonction $\mathbb{T} : \mathbb{R}^{N_{AP}} \rightarrow [0, 1]^{N_Z}$ telle que $\mathbb{T}(\rho_t) = (\mathcal{W}_t(Z_1), \dots, \mathcal{W}_t(Z_{N_Z}))$, où $\mathcal{W}_t(Z_j)$ est le niveau de confiance d'avoir le MN dans chacune des zones Z_j , $j = 1, 2, \dots, N_Z$ à l'instant t .

D'une part, la méthode profite de la mobilité du MN pour donner une première estimation de sa zone. Le MN est supposé se déplacer avec une vitesse inférieure ou égale à la vitesse maximale v_{max} . Sur cette base, nous pouvons avoir une idée des destinations possibles du MN selon l'architecture de la région cible et le temps d'exécution de l'algorithme de localisation. Le modèle de mobilité est basé sur les modèles de Markov cachés et utilise la trajectoire du MN pour le suivre. Ce modèle attribue une masse $m_{\mathbb{M},t}(\cdot)$ à chaque zone.

D'autre part, le modèle d'observation attribue une autre masse $m_{\mathbb{O},t}(\cdot)$ dans le cadre de l'estimation par noyau, ou encore *kernel density estimate* (KDE). La masse du modèle de mobilité est combinée avec celle du modèle d'observation pour attribuer un niveau de confiance $\mathcal{W}_t(\cdot)$ à chaque zone.

2 Modèle d'observation

Le modèle d'observation utilise les RSSIs reçus des points d'accès pour estimer la zone du capteur mobile. Dans une phase préliminaire, des échantillons sont collectés en mesurant les RSSIs de tous les APs dans chaque zone. Soit $\rho_{j,k,\ell}$, $\ell \in \{1, \dots, N_j\}$, l'ensemble des échantillons collectés dans la zone Z_j par rapport à AP_k . En temps réel, pour un nouvel échantillon ρ_t de taille N_{AP} , le modèle d'observation attribue une masse $m_{\mathbb{O},t}(\cdot)$ à chaque zone Z_j , $j \in \{1, \dots, N_Z\}$. Pour ce faire, l'estimation par noyau [7] est employée pour construire une distribution $Q(\cdot)$ en modélisant les RSSIs de chaque zone par rapport à tous les APs,

$$Q_{Z_j}(\cdot) = \frac{1}{N_j} \sum_{\ell=1}^{N_j} \frac{1}{h_{j,1} \dots h_{j,N_{AP}}} \prod_{k=1}^{N_{AP}} \mathcal{K}\left(\frac{\cdot - \rho_{j,k,\ell}}{h_{j,k}}\right), \quad (1)$$

où $\mathcal{K}(\cdot)$ est le noyau et $h_{j,k}$ est le paramètre de lissage de zone Z_j par rapport à AP_k . Le noyau est choisi comme la densité

d'une fonction gaussienne standard [8],

$$\mathcal{K}(u) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}u^2}. \quad (2)$$

Le paramètre de lissage $h_{j,k}$ est estimé en maximisant la fonction de vraisemblance [9], $h_{j,k} = \operatorname{argmax}_h ML_{j,k}(h)$, dont $ML_{j,k}(h)$ est calculée comme [9]

$$ML_{j,k}(h_{j,k}) = \frac{1}{N_j} \sum_{\ell=1}^{N_j} \log \left[\sum_{\ell' \neq \ell} \mathcal{K}\left(\frac{\rho_{j,k,\ell'} - \rho_{j,k,\ell}}{h_{j,k}}\right) \right] - \log[(N_j - 1)h_{j,k}]. \quad (3)$$

La masse attribuée à chaque zone par le modèle d'observation à tout instant t est alors calculée par

$$m_{\mathbb{O},t}(Z_j) = \frac{Q_{Z_j}(\rho_t)}{\sum_{i=1}^{N_Z} Q_{Z_i}(\rho_t)} \quad (4)$$

3 Modèle de mobilité


Dans ce modèle, nous profitons de la trajectoire du MN pour le suivre. L'objectif est de détecter une transition d'une zone à une autre dans une période de temps. Pour ce faire, nous utilisons les modèles de Markov cachés (HMM) [10] pour déterminer une probabilité que le MN a suivi une certaine trajectoire. Chaque HMM Λ est définie par trois paramètres, $\Lambda = (A, B, \pi)$, où A est la matrice de transition, B est le modèle d'émission et π est le vecteur d'états initiaux. Quand une séquence d'états $S = \{s_1, \dots, s_\alpha\}$ est déterminée, nous pouvons observer une séquence $R = \{R_1, \dots, R_\alpha\}$. Nous nous intéressons à la probabilité $P(R|\Lambda)$, qui désigne la probabilité d'observer la séquence R pour un modèle Λ donné [11].

Nous construisons des HMMs, notés Λ_{ij} , $i, j \in \{1, \dots, N_Z\}$, où Λ_{ij} est un HMM de N_S -états correspondant à une transition de la zone Z_i à la zone Z_j . Le paramètre N_S est le nombre d'états et est choisi par l'utilisateur. Dans la phase offline, une région de transition est construite entre chaque paire de zones voisines, comme le montre la figure 1(a). Cette région est divisée en N_S états. A chaque état, des mesures de RSSIs sont recueillies. Les trajectoires sont créées en sélectionnant aléatoirement une mesure dans chaque état, comme le montre la figure 1(b). Les paramètres de chaque HMM $\Lambda_{ij} = (A, B, \pi)$ sont calculés comme suit :


- La matrice de transition A de taille $N_S \times N_S$ est définie comme suit,

$$A = \begin{pmatrix} \frac{1}{2} & \frac{1}{2} & 0 & 0 & \dots & 0 \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} & 0 & \dots & 0 \\ 0 & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & \frac{1}{2} & \frac{1}{2} \end{pmatrix}$$

- Le modèle d'émission de chaque séquence est calculé en modélisant les mesures de RSSIs de chaque séquence par une distribution multi-dimensionnelle en utilisant l'équation (1).



(a) Construction des régions de transition entre chaque paire de zones voisines.



(b) Création d'un HMM de N_S -états à partir des trajectoires dans la région de transition.

FIG. 1: Illustration of the architecture of the HMM-based mobility model.

- Le vecteur π est défini par $\pi = [\frac{1}{N_S}, \dots, \frac{1}{N_S}]$.

L'objectif de ce modèle est d'associer une masse ou preuve indiquant que le MN a suivi une certaine trajectoire, qui est une transition d'une zone à une autre. Une fois une séquence $R = \{R_1, \dots, R_\alpha\}$ est détectée, chaque HMM Λ_{ij} attribue une probabilité que le MN a suivi la trajectoire correspondante à cet HMM. Les probabilités $P(R|\Lambda_{ij}), i, j \in \{1, \dots, N_Z\}$, sont calculées en utilisant les équations (5) à (14).

Pour un HMM à N_S -états Λ et une séquence d'observation R , l'objectif est d'évaluer la probabilité d'observer la séquence $P(R|\Lambda)$. Étant donné une séquence d'état $S = \{s_1, \dots, s_\alpha\}, 1 \leq \alpha \leq N_S$, nous calculons la probabilité jointe de la séquence observée et la séquence d'état,

$$P(R, S|\Lambda) = P(R|S, \Lambda) \times P(S|\Lambda). \quad (5)$$

C'est le produit de la probabilité de la séquence d'observation R sachant S et la probabilité de la séquence d'état sachant le modèle. le premier terme est obtenu de la matrice d'émission B ,

$$P(R|S, \Lambda) = \prod_{f=1}^{\alpha} b_{s_f}(R_f). \quad (6)$$

Le second terme est obtenu à partir de la matrice de transition A ,

$$P(S|\Lambda) = \prod_{f=1}^{\alpha} a_{s_{f-1}s_f}. \quad (7)$$

La probabilité $P(R|\Lambda)$ est déduite par la sommation de $P(R, S|\Lambda)$ sur toutes les séquences d'état possibles S [12],

$$P(R|\Lambda) = \sum_{\text{for all } S} P(R, S|\Lambda) = \sum_{\text{for all } S} \prod_{f=1}^{\alpha} a_{s_{f-1}s_f} b_{s_f}(R_f). \quad (8)$$

Le nombre total des trajectoires augmente avec la taille de la séquence. C'est pour cela qu'un algorithme *forward-backward* est adopté pour obtenir $P(R|\Lambda)$ et donc réduire la complexité algorithmique [12]. L'expression de l'équation (8) peut se transformer comme suit,

$$P(R|\Lambda) = \sum_{y=1}^{N_S} P(R_1, \dots, R_f, s_f = y|\Lambda) \cdot P(R_{f+1}, \dots, R_\alpha | s_f = y, \Lambda). \quad (9)$$

La probabilité d'observer la séquence peut alors être déterminée par un calcul progressif et régressif des probabilités,

$$g_f(y) = P(R_1, \dots, R_f, s_f = y|\Lambda). \quad (10)$$

$$h_f(y) = P(R_{f+1}, \dots, R_\alpha | s_f = y, \Lambda). \quad (11)$$

Les probabilités des équations (10) et (11) peuvent être calculées respectivement,

$$g_{f+1}(y) = \left[\sum_{x=1}^{N_S} g_f(x) a_{xy} \right] b_y(R_{f+1}); \quad (12)$$

$$h_f(y) = \sum_{x=1}^{N_S} a_{yx} b_x(R_{f+1}) h_{f+1}(x). \quad (13)$$

La probabilité $P(R|\Lambda)$ est alors donnée par

$$P(R|\Lambda) = \sum_{y=1}^{N_S} g_f(y) h_f(y). \quad (14)$$

C'est la probabilité d'observer une séquence R d'une taille α sachant un HMM à N_S -états Λ .

Ainsi, la probabilité de transition entre toutes paires de zones est déterminée. Nous définissons le coefficient $p_{ij}, i, j \in \{1, \dots, N_Z\}$, de Z_i à Z_j comme suit,

$$p_{ij} = \begin{cases} P(R|\Lambda_{ij}), & \text{si } i \neq j; \\ 1 - \sum_{j=1}^{N_Z} P(R|\Lambda_{ij}), & \text{si } i = j. \end{cases} \quad (15)$$

Enfin, les probabilités associées par les HMMs sont propagées à l'instant suivant. La confiance attribuée par ce modèle de suivi \mathbb{T} à chaque zone Z_j est calculée comme suit,

$$\mathcal{W}_t(Z_j) = \sum_{i=1}^{N_Z} m_{\mathbb{O}, t-1}(Z_i) \times p_{ij}, \quad (16)$$

où $m_{\mathbb{O}, t-1}(Z_i)$ est la masse associée par le modèle d'observation $\mathbb{O}(\cdot)$ à l'instant $t-1$.

4 Expérimentations

Cette section évalue les performances de la méthode de suivi de trajectoires que nous venons de proposer. Nous considérons 10 trajectoires de 50 observations chacune. Dans notre application, nous nous intéressons à la localisation des personnes âgées dépendantes. Pour cela, nous considérons une vitesse maximale $v_{max} = 1m/s$, un nombre d'états $N_S = 10$ et une longueur de séquence $\alpha = 8$. Les tableaux 1 montrent l'influence du modèle de mobilité lors de la combinaison avec le modèle d'observation, sur les performances de la méthode de suivi de trajectoires. Nous pouvons voir que le modèle de mobilité améliore la précision de la localisation pour les deux expérimentations. Nous étudions l'impact de la longueur de la séquence α . Nous remarquons que la précision de l'approche proposée augmente lors de l'augmentation de la taille de la séquence observée α . Cependant, l'augmentation de la taille de la séquence induit une augmentation de la complexité du calcul. La méthode proposée est comparée à d'autres méthodes de localisation telles que les k-plus proches voisins pondérés (WKNN), la connectivité, les réseaux de neurones et les machines à vecteur support sont considérées. Le tableau 4 montre la précision de l'approche proposée dans les deux expérimentations en comparaison avec les méthodes de localisation mentionnées. La méthode proposée surpasse les autres en termes de précision avec un temps d'exécution plus grand.

TAB. 1: Influence du modèle de mobilité sur la performance de la méthode de suivi dans l'expérimentation 1.

Méthode	Expérimentation 1	
	précision (%)	temps d'exécution (s)
Modèle d'observation	79.77	0.1104
méthode de suivi	87.74	0.1944

TAB. 2: Influence du modèle de mobilité sur la performance de la méthode de suivi dans l'expérimentation 2.

Méthode	Expérimentation 2	
	précision (%)	temps d'exécution (s)
Modèle d'observation	80.44	0.1479
méthode de suivi	89.43	0.2138

5 Conclusion

Cet article a présenté une méthode de suivi de trajectoires pour des personnes âgées dans des environnements fermés. La méthode combine un modèle d'observation et un modèle de mobilité. Le premier utilise les RSSIs pour attribuer une masse à chaque zone et le deuxième est basé sur les modèles de Markov cachés et attribue une autre masse. Les deux masses sont combinées pour déterminer la zone du capteur mobile à chaque instant. Des expérimentations pour localiser des personnes âgées dans un réseau de capteurs sans fil en utilisant la technologie WiFi ont montrées l'efficacité de la méthode proposée, surpassant

TAB. 3: Influence de la taille de la séquence α sur la performance de la méthode de suivi.

α	Expérimentation 1		Expérimentation 2	
	accuracy (%)	online time (s)	accuracy (%)	online time (s)
2	80.60	0.1308	81.81	0.1507
4	82.19	0.1430	84.22	0.1662
6	84.42	0.1725	87.76	0.1877
8	87.74	0.1944	89.43	0.2138
10	87.97	0.2486	90.54	0.2503

TAB. 4: Comparaison de la méthode proposée avec différentes techniques de localisation.

Method	Expérimentation 1		Expérimentation 2	
	accuracy (%)	online time (s)	accuracy (%)	online time (s)
WKNN	83.78	0.0982	84.28	0.1265
Connectivité	84.29	0.1107	86.67	0.1338
NN	84.72	0.1466	85.82	0.1866
SVM	85.55	0.1559	86.47	0.1912
Proposé	87.74	0.1944	90.54	0.2503

des méthodes de l'état de l'art.

6 Remerciements

Les auteurs souhaitent remercier le "FEDER" et la région "Grand Est" pour financer ce méta-projet, "Chaire SilverTech".

Références

- [1] J. Ko, C. Lu, M. B. Srivastava, J. A. Stankovic, A. Terzis, and M. Welsh, "Wireless sensor networks for healthcare," *Proceedings of the IEEE*, vol. 98, no. 11, pp. 1947–1960, 2010.
- [2] H. Alemdar and C. Ersoy, "Wireless sensor networks for healthcare: A survey," *Computer Networks*, vol. 54, no. 15, pp. 2688–2710, 2010.
- [3] S. Mahfouz, F. Mourad-Chehade, P. Honeine, J. Farah, and H. Snoussi, "Kernel-based machine learning using radio-fingerprints for localization in WSNs," *IEEE Transactions on Aerospace and Electronic Systems*, vol. 51, no. 2, pp. 1324–1336, 2015.
- [4] S. Mahfouz, F. Mourad-Chehade, P. Honeine, J. Farah, and H. Snoussi, "Target tracking using machine learning and Kalman filter in wireless sensor networks," *IEEE Sensors Journal*, vol. 14, no. 10, pp. 3715–3725, 2014.
- [5] L. Zhang, Y. H. Chew, and W.-C. Wong, "A novel angle-of-arrival assisted extended kalman filter tracking algorithm with space-time correlation based motion parameters estimation," in *International Wireless Communications and Mobile Computing Conference (IWCMC)*, pp. 1283–1289, IEEE, 2013.
- [6] F. Hong, Y. Zhang, Z. Zhang, M. Wei, Y. Feng, and Z. Guo, "WaP: Indoor localization and tracking using WiFi-assisted particle filter," in *IEEE Conference on Local Computer Networks (LCN)*, pp. 210–217, IEEE, 2014.
- [7] A. Elgammal, R. Duraiswami, D. Harwood, and L. S. Davis, "Background and foreground modeling using nonparametric kernel density estimation for visual surveillance," *Proceedings of the IEEE*, vol. 90, no. 7, pp. 1151–1163, 2002.
- [8] A. Eckert-Gallup and N. Martin, "Kernel density estimation (KDE) with adaptive bandwidth selection for environmental contours of extreme sea states," in *OCEANS MTS/IEEE Monterey*, pp. 1–5, IEEE, 2016.
- [9] J. Habbema and J. Hermans, "Selection of variables in discriminant analysis by F-statistic and error rate," *Technometrics*, vol. 19, no. 4, pp. 487–493, 1977.
- [10] S. R. Eddy, "Hidden markov models," *Current Opinion in Structural Biology*, vol. 6, no. 3, pp. 361–365, 1996.
- [11] M. Oudelha and R. N. Aïnon, "HMM parameters estimation using hybrid baum-welch genetic algorithm," in *International Symposium in Information Technology (ITSIM)*, pp. 542–545, IEEE, 2010.
- [12] Y. Yen, M. Fauty, and R. Cole, "Speech recognition using neural networks with forward-backward probability generated targets," in *IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP)*, vol. 4, pp. 3241–3244, IEEE, 1997.