



HAL
open science

Modèle semi-paramétrique RSSI/distance pour le suivi d'une cible dans les réseaux de capteurs sans fil

Sandy Mahfouz, Farah Mourad-Chehade, Paul Honeine, Joumana Farah,
Hichem Snoussi

► To cite this version:

Sandy Mahfouz, Farah Mourad-Chehade, Paul Honeine, Joumana Farah, Hichem Snoussi. Modèle semi-paramétrique RSSI/distance pour le suivi d'une cible dans les réseaux de capteurs sans fil. Actes du 25-ème Colloque GRETSI sur le Traitement du Signal et des Images, 2015, Lyon, France. hal-01965988

HAL Id: hal-01965988

<https://hal.science/hal-01965988v1>

Submitted on 27 Dec 2018

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.

Modèle semi-paramétrique RSSI/distance pour le suivi d'une cible dans les réseaux de capteurs sans fil

Sandy MAHFOUZ¹, Farah MOURAD-CHEHADE¹, Paul HONEINE¹, Joumana FARAH², Hichem SNOUSSI¹

¹Institut Charles Delaunay (UMR CNRS 6281), Université de technologie de Troyes, France

²Faculté de Génie, Université Libanaise, Roumieh, Liban

{sandy.mahfouz, farah.mourad, paul.honeine, hichem.snoussi}@utt.fr
joumanafarah@ul.edu.lb

Résumé – Le présent article introduit deux principales contributions au domaine des réseaux de capteurs sans fil. La première consiste à modéliser la relation entre les distances séparant les capteurs et la puissance des signaux échangés entre ces capteurs, cette dernière étant désignée par RSSI (pour *Received Signal Strength Indicator*). Pour cela, un formalisme semi-paramétrique est proposé en combinant un modèle physique de propagation avec un terme non linéaire estimé par les méthodes à noyaux. Quant à la seconde contribution, elle consiste à suivre une cible se déplaçant dans le réseau en utilisant le modèle RSSI/distance estimé. La position de la cible est obtenue en combinant les informations d'accélération et les distances estimées, séparant la cible des capteurs. Pour ce faire, deux approches différentes sont développées, en s'appuyant sur un filtrage de Kalman et un filtrage particulaire.

Abstract – This paper introduces two main contributions to the wireless sensor network domain. The first one consists of determining, using a semi-parametric model, the relationship between the distances separating sensors and the received signal strength indicators (RSSIs) of the signals exchanged by these sensors in a network. As for the second contribution, it consists in tracking a moving target in the network using the estimated RSSI/distance model. The target's position is estimated by combining acceleration information and the estimated distances separating the target from sensors having known positions, using either a Kalman or a particle filter.

1 Introduction

L'une des problématiques principales des réseaux de capteurs sans fil est la géolocalisation des capteurs qui s'avère primordiale pour la plupart des applications. Typiquement, les cibles reçoivent des signaux diffusés par des capteurs dans le réseau et mesurent leurs puissances (RSSIs). Plusieurs techniques exploitent l'atténuation de l'intensité du signal avec la distance parcourue pour estimer les distances séparant les capteurs. Néanmoins, l'estimation de la distance à l'aide des RSSIs est un défi majeur, puisque celles-ci sont sensibles à la présence du bruit et des interférences. Un modèle populaire pour caractériser la relation RSSI/distance est le modèle de propagation logarithmique, dit modèle d'Okumura-Hata [6]. Ce modèle est largement utilisé en raison de sa simplicité, malgré ses limitations et le fait qu'il ne prend pas en compte les caractéristiques du milieu, tels que les murs et les planchers.

Une fois que les distances sont estimées à partir des RSSIs, elles sont combinées en utilisant par exemple la trilatération ou la triangulation [3] pour localiser la cible. Nous pouvons également utiliser des méthodes basées sur le filtrage qui aident à lisser la trajectoire de la cible et donc à réduire l'erreur d'estimation, comme par exemple le filtre de Kalman (FK) [8]. Une méthode basée sur ce filtre est proposée par [2], où les auteurs localisent d'abord la cible à l'aide de l'algorithme des

K plus proches voisins, et puis combinent ces estimations aux accélérations de la cible, à l'aide du FK. Les auteurs de [5] proposent une méthode de suivi qui utilise le filtre de Kalman afin de corriger la position de la cible estimée à l'aide d'un modèle basé sur les méthodes à noyaux. Un autre filtre utilisé pour le suivi est le filtre particulaire (FP) [1, 4].

Dans cet article, nous introduisons un modèle semi-paramétrique qui permet d'estimer les distances séparant les capteurs à l'aide des puissances des signaux échangés (RSSIs) dans les réseaux de capteurs sans fil. Ce modèle est une combinaison du modèle de propagation physique d'Okumura-Hata avec une composante non linéaire additionnelle, estimée par les méthodes à noyaux. Le modèle prend en entrée la puissance du signal échangé entre deux capteurs et donne en sortie la distance qui les sépare. Ensuite, en se basant sur les distances estimées séparant la cible des capteurs à positions connues, nous proposons deux méthodes pour localiser la cible. La première combine les distances estimées avec l'information sur les accélérations de la cible à l'aide d'un filtre de Kalman [8]. La seconde permet de suivre la cible à l'aide d'un filtre particulaire [1], des accélérations et des distances estimées.

La Section 2 décrit brièvement l'approche proposée. Le modèle semi-paramétrique RSSI/distance est décrit dans la Section 3. Ensuite, les Sections 4 et 5 montrent comment résoudre le problème de suivi respectivement avec le filtre

de Kalman et le filtre particulaire. Finalement, la Section 6 présente les performances de l'approche proposée, avec une comparaison à l'état de l'art.

2 Description de la méthode

Nous considérons un environnement de dimensions δ , avec par exemple $\delta = 2$ pour un environnement à deux dimensions, et N_s capteurs ayant des positions connues, notées $\mathbf{s}_i = (s_{i,1} \dots s_{i,\delta})^\top$, $i \in \{1, \dots, N_s\}$. Basée sur la technique de fingerprinting, l'approche consiste à construire une base de données *offline*, à utiliser par la suite en temps réel, pour estimer les distances séparant la cible des N_s capteurs. Ensuite, les distances estimées seront utilisées pour localiser la cible.

Pour construire cette base de données, nous considérons N positions de référence, notées $\mathbf{p}_\ell = (p_{\ell,1} \dots p_{\ell,\delta})^\top$, $\ell \in \{1, \dots, N\}$. Les capteurs diffusent régulièrement des signaux dans la région étudiée. En posant un capteur consécutivement à chacune des positions de référence, il serait possible de mesurer les RSSIs des signaux qu'il reçoit. Soit $\boldsymbol{\rho}_{\mathbf{p}_\ell} = (\rho_{\mathbf{s}_1, \mathbf{p}_\ell} \dots \rho_{\mathbf{s}_{N_s}, \mathbf{p}_\ell})^\top$ le vecteur des RSSIs des signaux envoyés par les N_s capteurs et mesurés à la position \mathbf{p}_ℓ et soit $\mathbf{d}_{\mathbf{p}_\ell} = (d_{\mathbf{s}_1, \mathbf{p}_\ell} \dots d_{\mathbf{s}_{N_s}, \mathbf{p}_\ell})^\top$ le vecteur des distances séparant \mathbf{p}_ℓ des N_s capteurs. Un ensemble d'apprentissage de N couples $(\boldsymbol{\rho}_{\mathbf{p}_\ell}, \mathbf{d}_{\mathbf{p}_\ell})$ est ainsi obtenu. La phase d'apprentissage consiste à trouver un ensemble de N_s modèles semi-paramétriques $\chi_i: \mathbb{R} \mapsto \mathbb{R}$, $i \in \{1, \dots, N_s\}$. Chaque modèle prend en entrée la mesure de RSSI du signal envoyé par le capteur à la position \mathbf{s}_i , et reçu à une position \mathbf{p}_ℓ , $\ell \in \{1, \dots, N\}$, et donne en sortie la distance $d_{\mathbf{s}_i, \mathbf{p}_\ell}$ séparant \mathbf{s}_i de \mathbf{p}_ℓ . La définition des modèles χ_i sera détaillée dans la section suivante. Les modèles estimés seront stockés au niveau de la cible pour qu'elle les utilise en temps réel par la suite.

Soit $\mathbf{x}(k) = (x_1(k) \dots x_\delta(k))^\top$ la position de la cible à un pas de temps k . La cible mesure en temps réel le vecteur des RSSIs des signaux reçus des N_s capteurs, tel que $\boldsymbol{\rho}_{\mathbf{x}(k)} = (\rho_{\mathbf{s}_1, \mathbf{x}(k)} \dots \rho_{\mathbf{s}_{N_s}, \mathbf{x}(k)})^\top$. L'estimé de la distance séparant la cible du capteur à la position \mathbf{s}_i , notée $\hat{d}_{\mathbf{s}_i, \mathbf{x}(k)}$, $i \in \{1, \dots, N_s\}$, est alors obtenue en utilisant le modèle χ_i comme suit : $\hat{d}_{\mathbf{s}_i, \mathbf{x}(k)} = \chi_i(\rho_{\mathbf{s}_i, \mathbf{x}(k)})$. D'un autre côté, la cible est supposée être équipée d'un gyroscope et d'un accéléromètre qui mesurent respectivement son orientation et ses accélérations. Le problème de suivi de cible est ensuite résolu de deux façons différentes, en utilisant à la fois les distances estimées et les données inertielles de la cible. La première solution est donnée à la Section 4, où les accélérations sont combinées aux distances à l'aide du filtre de Kalman afin d'estimer la position de la cible. Ensuite, une deuxième solution est présentée à la Section 5, où la résolution du problème de suivi se fait à l'aide du filtre particulaire. Dans ce qui suit, nous notons $\mathbf{D} = (\mathbf{d}_{\mathbf{p}_1} \dots \mathbf{d}_{\mathbf{p}_N})$ la matrice de taille $N_s \times N$, ayant $d_{\mathbf{s}_i, \mathbf{p}_\ell}$ pour son (i, ℓ) -ème entrée, $\mathbf{d}_{\mathbf{p}_\ell}$ pour son ℓ -ème colonne et $\mathbf{D}_{i,*}$ la transposée de la i -ème ligne de \mathbf{D} , avec $\mathbf{D}_{i,*} = (d_{\mathbf{s}_i, \mathbf{p}_1} \dots d_{\mathbf{s}_i, \mathbf{p}_N})^\top$, $i \in \{1, \dots, N_s\}$.

3 Modèle semi-paramétrique

L'objectif maintenant est de définir l'ensemble des modèles χ_i , $i \in \{1, \dots, N_s\}$, en utilisant l'ensemble d'apprentissage déjà défini. Chaque modèle χ_i doit associer à toute mesure de RSSI $\rho_{\mathbf{s}_i, \mathbf{p}_\ell}$, $\ell \in \{1, \dots, N\}$, la distance correspondante $d_{\mathbf{s}_i, \mathbf{p}_\ell}$. Les modèles proposés sont semi-paramétriques. En effet, chaque modèle est une combinaison du modèle physique d'Okumura-Hata [6] avec une composante non linéaire, définie à l'aide des méthodes à noyaux. Ce terme non linéaire permet de compenser les facteurs qui ont été négligés par le modèle physique, tels que les pertes dues aux obstacles physiques et autres interférences, permettant ainsi une meilleure modélisation de la relation RSSI/distance.

Le modèle physique de propagation caractérise la relation RSSI/distance comme suit :

$$\rho_{\mathbf{s}_i, \mathbf{p}_\ell} = \rho_0 - 10 n_p \log_{10} \frac{d_{\mathbf{s}_i, \mathbf{p}_\ell}}{d_0}, \quad (1)$$

où $\rho_{\mathbf{s}_i, \mathbf{p}_\ell}$ est la puissance du signal envoyé par le capteur à la position \mathbf{s}_i et reçu par un capteur à la position \mathbf{p}_ℓ , ρ_0 la puissance mesurée à une distance de référence d_0 et n_p le paramètre de perte qui dépend du type de canal de transmission..

Soit $\psi_i(\cdot)$ la fonction qui associe à toute mesure de RSSI $\rho_{\mathbf{s}_i, \mathbf{p}_\ell}$ le logarithme de la distance $\log_{10}(d_{\mathbf{s}_i, \mathbf{p}_\ell})$. Nous définissons cette fonction comme une somme d'un modèle linéaire déduit de (1) et d'un modèle non linéaire comme suit :

$$\psi_i(\cdot) = a \rho_{\mathbf{s}_i, \mathbf{p}_\ell} + b + \psi_{i, \text{nlin}}(\rho_{\mathbf{s}_i, \mathbf{p}_\ell}),$$

où a et b sont des inconnues à estimer. En se basant sur le théorème de représentation [7], nous proposons d'écrire le terme non linéaire sous forme d'une combinaison de noyaux :

$$\psi_{i, \text{nlin}}(\cdot) = \sum_{\ell=1}^N \gamma_{\ell, i} \kappa(\rho_{\mathbf{s}_i, \mathbf{p}_\ell}, \cdot),$$

où $\kappa: \mathbb{R} \times \mathbb{R} \mapsto \mathbb{R}$, et $\gamma_{\ell, i}$, $\ell \in \{1, \dots, N\}$, sont des paramètres à déterminer. Les $N + 2$ paramètres a , b , et $\boldsymbol{\gamma}_i = (\gamma_{1, i} \dots \gamma_{N, i})^\top$ sont ensuite estimés en minimisant l'erreur quadratique sur l'ensemble d'apprentissage, comme suit :

$$\frac{1}{N} \sum_{\ell=1}^N \varepsilon_\ell^2 + \eta_i \|\psi_{i, \text{nlin}}\|_{\mathcal{H}}^2, \quad (2)$$

où η_i est un paramètre de régularisation permettant d'atteindre un compromis entre la justesse de la solution et sa complexité. La fonction coût ε_ℓ est donnée par :

$$\varepsilon_\ell = \log_{10} d_\ell - a \rho_{\mathbf{s}_i, \mathbf{p}_\ell} - b - \sum_{j=1}^N \gamma_{j, i} \kappa(\rho_{\mathbf{s}_i, \mathbf{p}_j}, \rho_{\mathbf{s}_i, \mathbf{p}_\ell}).$$

La résolution de ce problème d'optimisation permet de trouver un système linéaire de la forme $\mathbf{B} = \mathbf{A}\mathbf{X}$, avec :

$$\mathbf{X} = \begin{bmatrix} a \\ b \\ \boldsymbol{\gamma}_i \end{bmatrix}, \mathbf{B} = \begin{bmatrix} \mathbf{1}^\top \boldsymbol{\Lambda}_i \\ \boldsymbol{\Lambda}_i \\ \boldsymbol{\Lambda}_i^\top \boldsymbol{\rho}_i \end{bmatrix},$$

$$\mathbf{A} = \begin{bmatrix} \mathbf{1}^\top \boldsymbol{\rho}_i & N & \mathbf{1}^\top \mathbf{K}_i \\ \boldsymbol{\rho}_i & \mathbf{1} & \mathbf{K}_i + \eta_i \mathbf{N} \mathbf{I} \\ \boldsymbol{\rho}_i^\top \boldsymbol{\rho}_i & \mathbf{1}^\top \boldsymbol{\rho}_i & \boldsymbol{\rho}_i^\top \mathbf{K}_i \end{bmatrix}$$

où \mathbf{K}_i est la matrice de taille $N \times N$, ayant pour (u, u') -ème entrée $\kappa(\rho_{s_i, p_u}, \rho_{s_i, p_{u'}})$, avec $u, u' \in \{1, \dots, N\}$, $\boldsymbol{\rho}_i$ est le vecteur de taille $N \times 1$, ayant ρ_{s_i, p_ℓ} pour ℓ -ème entrée, avec $\ell \in \{1, \dots, N\}$, $\mathbf{1}$ est le vecteur des uns de taille $N \times 1$ et $\boldsymbol{\Lambda}_i$ est le vecteur de taille $N \times 1$, ayant $\log_{10} d_{s_i, p_\ell}$ pour ℓ -ème entrée. Après avoir trouvé les paramètres du modèle en utilisant $\mathbf{X} = (\mathbf{A}^\top \mathbf{A})^{-1} \mathbf{A}^\top \mathbf{B}$, il est possible d'estimer n'importe quelle distance séparant un capteur à la position s_i d'une cible à la position $\mathbf{x}(k)$ à l'aide de la mesure de RSSI comme suit :

$$\chi_i(\rho_{s_i, \mathbf{x}(k)}) = 10^{\psi_i(\rho_{s_i, \mathbf{x}(k)})} = 10^{\log_{10} d_{s_i, \mathbf{x}(k)}}. \quad (3)$$

4 Solution à l'aide du filtre de Kalman

Dans cette section, nous proposons d'estimer la position de la cible en combinant ses accélérations instantanées aux distances la séparant des capteurs du réseau à l'aide du filtre de Kalman. Les distances sont estimées à l'aide du modèle semi-paramétrique défini à la section précédente. Nous proposons un modèle d'état d'ordre trois pour décrire la trajectoire de la cible. Ce modèle est basé sur l'hypothèse que les accélérations de la cible varient linéairement entre deux pas de temps consécutifs $k-1$ et k , avec une pente égale à $\frac{\gamma(k) - \gamma(k-1)}{\Delta t}$, où $\boldsymbol{\gamma}(k) = (\gamma_1(k) \dots \gamma_\delta(k))^\top$ est le vecteur d'accélérations à un pas de temps k et Δt est l'intervalle de temps séparant deux pas de temps consécutifs. Par conséquent, nous pouvons estimer de manière récursive le vecteur vitesse $\boldsymbol{\nu}(k)$ comme suit :

$$\boldsymbol{\nu}(k) = \boldsymbol{\nu}(k-1) + \boldsymbol{\gamma}(k-1) \Delta t + \frac{\boldsymbol{\gamma}(k) - \boldsymbol{\gamma}(k-1)}{\Delta t} \frac{\Delta t^2}{2}. \quad (4)$$

Nous obtenons la position de la cible en intégrant (4) :

$$\begin{aligned} \mathbf{x}(k) &= \mathbf{x}(k-1) + \boldsymbol{\nu}(k-1) \Delta t + \boldsymbol{\gamma}(k-1) \frac{\Delta t^2}{2} \\ &+ \frac{\boldsymbol{\gamma}(k) - \boldsymbol{\gamma}(k-1)}{\Delta t} \frac{\Delta t^3}{6}. \end{aligned} \quad (5)$$

Nous pouvons ainsi trouver $\mathbf{x}(k)$ à tout pas de temps k en utilisant les accélérations mesurées. Afin de prendre en compte l'imprécision des mesures accélérométriques, nous ajoutons à (5) un bruit $\boldsymbol{\theta}(k)$, suivant une distribution normale, de moyenne zéro et de matrice de covariance $\mathbf{Q}(k)$. Les détails du calcul de $\mathbf{Q}(k)$ se trouvent dans [5]. La relation entre $\mathbf{x}(k)$ et $\mathbf{x}(k-1)$ étant linéaire, nous pouvons écrire le modèle d'état suivant :

$$\mathbf{x}(k) = \mathbf{x}(k-1) + \mathbf{B}(k) + \boldsymbol{\theta}(k), \quad (6)$$

où $\mathbf{B}(k) = \boldsymbol{\nu}(k-1) \Delta t + \boldsymbol{\gamma}(k-1) \frac{\Delta t^2}{2} + \frac{\boldsymbol{\gamma}(k) - \boldsymbol{\gamma}(k-1)}{\Delta t} \frac{\Delta t^3}{6}$. Ensuite, pour définir un modèle linéaire d'observation, nous utilisons les différences des carrés des distances $d_{s_i, \mathbf{x}(k)}^2$; nous obtenons ainsi un modèle de la forme suivante :

$$\mathbf{z}_{\text{KF}}(k) = \mathbf{H} \mathbf{x}(k) + \mathbf{n}(k), \quad (7)$$

où $\mathbf{n}(k)$ est un bruit additif, suivant une distribution normale de moyenne zéro et de matrice covariance \mathbf{R} estimée comme dans [5]. Le vecteur des observations $\mathbf{z}_{\text{KF}}(k)$ est donné par :

$$\begin{pmatrix} d_{s_1, \mathbf{x}(k)}^2 - d_{s_{N_s}, \mathbf{x}(k)}^2 + \sum_{v=1}^{\delta} s_{N_s, v}^2 - \sum_{v=1}^{\delta} s_{1, v}^2 \\ \vdots \\ d_{s_{N_s-1}, \mathbf{x}(k)}^2 - d_{s_{N_s}, \mathbf{x}(k)}^2 + \sum_{v=1}^{\delta} s_{N_s, v}^2 - \sum_{v=1}^{\delta} s_{N_s-1, v}^2 \end{pmatrix}$$

Ensuite, la matrice \mathbf{H} est donnée par :

$$\mathbf{H} = 2 \begin{pmatrix} s_{N_s, 1} - s_{1, 1} & \dots & s_{N_s, \delta} - s_{1, \delta} \\ \vdots & & \vdots \\ s_{N_s, 1} - s_{N_s-1, 1} & \dots & s_{N_s, \delta} - s_{N_s-1, \delta} \end{pmatrix}$$

Maintenant que nous avons défini les deux équations linéaires (6) et (7), nous procédons à l'estimation de la position de la cible à chaque pas de temps k à l'aide du FK. Ce filtre prédit d'abord la position de la cible à l'aide de l'estimation de sa position précédente et de l'équation d'état (6), comme suit :

$$\hat{\mathbf{x}}^-(k) = \hat{\mathbf{x}}(k-1) + \mathbf{B}(k),$$

où $\hat{\mathbf{x}}(k-1)$ est la position de la cible à $k-1$ estimée par le filtre, avec $\hat{\mathbf{x}}(0)$ supposée connue. Ensuite, l'estimation de la covariance est mise à jour telle que $\mathbf{T}^-(k) = \mathbf{T}(k-1) + \mathbf{Q}(k)$, où $\mathbf{T}(k-1)$ est l'estimation de la covariance à $k-1$ et $\mathbf{T}(0)$ est nulle puisque l'état initial est connu. La dernière étape de filtrage consiste à corriger les quantités prédites en utilisant l'équation d'observation (7). Nous obtenons alors :

$$\hat{\mathbf{x}}(k) = \hat{\mathbf{x}}^-(k) + (\mathbf{z}_{\text{KF}}(k) - \hat{\mathbf{x}}^-(k)) \mathbf{G}(k)$$

$$\mathbf{T}(k) = (\mathbf{I} - \mathbf{G}(k)) \mathbf{T}^-(k),$$

où \mathbf{I} est la matrice identité et $\mathbf{G}(k) = \mathbf{T}^-(k) (\mathbf{T}^-(k) + \mathbf{R})^{-1}$ est le gain optimal de Kalman.

5 Solution à l'aide du filtre particulaire

L'objectif maintenant est de trouver la position de la cible en combinant, à l'aide du filtre particulaire, les accélérations de la cible aux distances estimées par les modèles semi-paramétriques. A la différence du FK, le modèle d'observation du FP peut être non linéaire et par suite, nous prenons comme observations les distances estimées séparant la cible des capteurs comme suit :

$$\mathbf{z}_{\text{PF}}(k) = \mathbf{d}_{\mathbf{x}(k)},$$

où $\mathbf{d}_{\mathbf{x}(k)} = (d_{s_1, \mathbf{x}(k)} \dots d_{s_{N_s}, \mathbf{x}(k)})^\top$. Pour résoudre le problème à l'aide du FP, nous générons N_p particules autour de la position initiale $\mathbf{x}(0)$ considérée comme connue. Ces particules notées $\mathbf{x}^n(0)$ ont des poids initiaux égaux : $w^n(0) = \frac{1}{N_p}$, $n \in \{1, \dots, N_p\}$. En partant de la position initiale, les particules $\mathbf{x}^n(k)$ à un pas de temps k sont estimées en utilisant le modèle d'état (6) :

$$\mathbf{x}^n(k) = \mathbf{x}^n(k-1) + \mathbf{B}(k) + \boldsymbol{\theta}(k).$$

Les poids des particules sont mis à jour suivant les distances observées [4] par $w^n(k) = \frac{1}{\|\mathbf{d}_{\mathbf{x}^n(k)} - \mathbf{z}_{\text{PF}}(k)\|} w^n(k-1)$, où

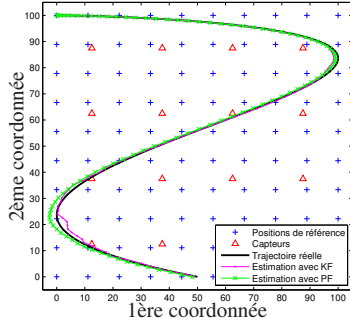


FIGURE 1 – Estimation de la trajectoire.

$\|\mathbf{d}_{\mathbf{x}^n(k)} - \mathbf{z}_{\text{PF}}(k)\|$ est la distance entre $\mathbf{z}_{\text{PF}}(k)$ et $\mathbf{d}_{\mathbf{x}^n(k)}$. Les poids ainsi obtenus sont ensuite normalisés.

La dernière étape est l'étape de rééchantillonnage, où les particules ayant des poids négligeables sont remplacées par de nouvelles particules créées autour des particules ayant des poids plus importants. Le passage à cette étape se fait lorsque le nombre effectif de particules N_{eff} devient inférieur à un seuil N_{th} , avec $N_{\text{eff}} = \frac{1}{\sum_{n=1}^{N_p} (w^n(k))^2}$. Notons que N_{th} est habituellement égal à 10% du nombre de particules N_p . Finalement, la position de la cible au pas de temps k est donnée par :

$$\hat{\mathbf{x}}(k) = \sum_{n=1}^{N_p} w^n(k) \mathbf{x}^n(k).$$

Cet algorithme est plus complexe en terme de calculs que la méthode basée sur le FK, vu toutes les particules à définir et l'étape de rééchantillonnage ; cependant, il est plus robuste quand les erreurs sur les distances ne sont plus Gaussiennes.

6 Simulations

Dans cette section, nous évaluons les performances de l'approche proposée et nous comparons nos résultats à ceux obtenus en utilisant une méthode récemment proposée dans [2]. Pour cela, considérons la trajectoire de la FIGURE 1, où 100 positions de référence et 16 capteurs sont uniformément générés dans une région de $100\text{m} \times 100\text{m}$. Les RSSIs sont obtenues à l'aide du modèle (1), avec $n_p = 4$ et $\rho_0 = 1\text{dB}$, auquel nous ajoutons un bruit additif Gaussien de moyenne nulle et d'écart-type égal à 10% de l'écart-type des RSSIs et donc de 1.08dB. Nous ajoutons également du bruit aux accélérations d'écart-type égal à 5% de celui des accélérations. Les distances sont estimées à l'aide des modèles semi-paramétriques, utilisés avec un noyau gaussien, et la trajectoire est ensuite estimée à l'aide du filtre de Kalman et du filtre particulaire. Une erreur moyenne de 0.89m est obtenue en utilisant le FK et de 1.05m en utilisant le FP (avec $N_p = 50$). Les deux méthodes donnent donc une estimation quasi exacte des positions de la cible.

Ensuite, nous comparons notre méthode à celle de [2] (notée WKNN+Kalman). La trajectoire est estimée en utilisant la méthode des K plus proches voisins (WKNN) pour la même

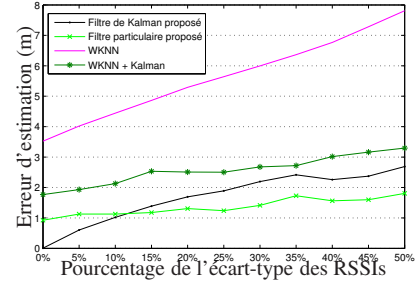


FIGURE 2 – Erreur en fonction du bruit sur les RSSIs.

configuration que le paragraphe précédent, avec 8 voisins comme dans [2]. L'erreur obtenue est de 4.57m. Les positions estimées sont combinées aux accélérations à l'aide d'un filtre de Kalman ayant un modèle d'état d'ordre deux [2] ; l'erreur est alors réduite à 2.15m, qui reste cependant très supérieure à celle de l'approche proposée. De plus, la FIGURE 2 montre les erreurs sur la trajectoire estimée pour différents niveaux de bruit sur les RSSIs. Nous pouvons voir que notre approche donne toujours de meilleurs résultats. Le FP est d'autant plus performant que le FK quand l'erreur sur les RSSIs augmente.

7 Conclusion

Cet article propose une approche originale pour le suivi de cible dans les réseaux de capteurs. Un modèle semi-paramétrique caractérisant la relation RSSI/distance est introduit, et permet d'estimer les distances séparant la cible des capteurs. Ces distances sont combinées aux accélérations instantanées de la cible en utilisant un filtrage de Kalman ou un filtrage particulaire. L'approche proposée s'est avérée robuste face au bruit et plus performante comparée à l'état-de-l'art. Les travaux futurs y apporteront des améliorations, notamment en termes de sélection des RSSIs à utiliser pour l'estimation.

Références

- [1] N. G. Branko Ristic, Sanjeev Arulampalam. *Beyond the Kalman Filter : Particle Filters for Tracking Applications*. Artech House Publishers, February 2004.
- [2] E. Chan, G. Baciu, and S. C. Mak. Using wi-fi signal strength to localize in wireless sensor networks. In *WRI Int. Conf. on Communications and Mobile Computing*, volume 1, pages 538–542, 2009.
- [3] J. Esteves, A. Carvalho, and C. Couto. Generalized geometric triangulation algorithm for mobile robot absolute self-localization. In *IEEE International Symposium on Industrial Electronics, ISIE '03*, volume 1, pages 346–351 vol. 1, 2003.
- [4] M. Farmani, H. Moradi, and M. Asadpour. A hybrid localization approach in wireless sensor networks using a mobile beacon and inter-node communication. In *IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems*, pages 269–274, May 2012.
- [5] 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*, 14(10):3715–3725, Oct 2014.
- [6] A. Medeis and A. Kajackas. On the use of the universal Okumura-Hata propagation prediction model in rural areas. *Vehicular Conference Proceedings*, 3, 2000.
- [7] B. Schölkopf, R. Herbrich, and A. J. Smola. A generalized representer theorem. In *Proc. of the 14th Conf. on Computational Learning Theory and 5th European Conf. on Computational Learning Theory*, pages 416–426, UK, 2001. Springer-Verlag.
- [8] G. Welch and G. Bishop. "An Introduction to the Kalman Filter." <http://www.cs.unc.edu>, UNC-Chapel Hill, TR95-041, February 2001.