

Fusion de données capteurs en vue de la localisation absolue d'un robot mobile par une méthode basée sur la théorie des possibilités. Comparaison avec le filtre de Kalman

Sensors data fusion for the absolute localisation of a mobile robot by a possibility theory based method. Comparison with Kalman filter

par Hichem MAAREF¹, Mourad OUSSALAH², Claude BARRET¹

¹ CEMIF-Groupe Systèmes Complexes 40, rue du Pelvoux 91020 Evry cedex France
Tél : 01 69 47 75 54 Fax : 01 69 47 75 99
e-mail : maaref|cbarret@cemif.univ-evry.fr

² K. U. Leuven, PMA, Celestijnenlaan 3000B B-3001 Heverlee, Belgique
e-mail : Oussalah.Mourad@mail.mech.kuleuven.ac.be

résumé et mots clés

Pour améliorer l'autonomie d'un système mobile, il est nécessaire de pouvoir déterminer précisément sa position. Dans cet article, une méthode basée sur la théorie des possibilités a été développée dans le cadre applicatif de la localisation d'un robot mobile miniature à partir de données odométriques et extéroceptives dans un environnement balisé. La modélisation des données est réalisée dans le cadre de la théorie des possibilités qui fournit des outils intéressants de représentation de l'imprécision et de l'incertitude. De plus, les contraintes souples qui régissent cette théorie permettent un choix étendu pour la combinaison des informations issues des différentes sources, allant du mode conjonctif au mode disjonctif en passant par le mode compromis. Nous nous sommes particulièrement intéressés ici à la règle de combinaison adaptative proposée par Dubois et Prade. Une chaîne complète de fusion des données odométriques et extéroceptives sous forme de distributions de possibilité est ainsi proposée et mise en œuvre pour la localisation aussi bien en simulation que par des expériences réelles. Cette méthode fait l'objet d'une comparaison détaillée avec la méthode du filtrage de Kalman. Alors que la méthode de Kalman réalise une fusion par moyenne pondérée par l'incertitude liée aux informations (fusion par minimisation de la variance) la méthode possibiliste privilégie, elle, la redondance des informations fournies par les sources (fusion par concordance). Malgré ces différences fondamentales, les résultats obtenus par les deux approches sont assez voisines et la méthode possibiliste possède a priori une meilleure robustesse pour traiter des données conflictuelles.

Fusion de données, distribution de possibilités, règle de combinaison adaptative, robot mobile, localisation.

abstract and key words

In order to improve autonomous system, it is necessary to determine accurately its position. In this paper, a method based on possibility theory has been developed in the experimental framework of the localisation of a miniature mobile robot from odometry reading and exteroceptive sensors into an environment equipped with beacons. The data are modelled in the setting of the possibility theory which provides interesting tools of representing imprecision and uncertainty. A comparison with a classical

method (Kalman filter) taken as a reference is realised. Basically, the fusion procedure by Kalman filtering method can be seen as a weighted average by the information uncertainties. Its principle is to favour the information with low uncertainty (i.e. low variance) and to realise a fusion by "minimisation of variance". On the other hand, the adaptive combination rule used in the possibilistic method takes into account the level of conflict between the sources and favour the redundancy of the information which are in agreement. Then, it is rather a fusion by "agreement". In spite of these fundamental discrepancies, the outcomes of simulation and/or of experiences on the real robot, obtained by both methods are satisfactory and quite close.

Data fusion, possibility distribution, adaptive combination rule, mobile robot, localisation.

1. introduction

L'un des principaux problèmes en robotique mobile est la localisation précise d'un robot mobile dans un environnement connu, ou partiellement connu. En effet, la capacité de se localiser est le préambule minimal pour toute application robotique, quel que soit son degré de complexité. Malheureusement, l'imprécision des capteurs odométriques (qui comptent le nombre de tours des roues) ne permet pas un positionnement suffisamment correct du robot. Les recherches actuelles portent donc sur l'utilisation de capteurs infrarouges ou ultrasonores pour mesurer des distances par rapport à des objets connus de l'environnement et affiner ainsi la position grossièrement obtenue par les capteurs odométriques. On parle alors de localisation « absolue » par opposition à la localisation « relative » qui n'utilise que des informations de vitesse et d'accélération intégrées sur le temps et pour laquelle l'imprécision augmente progressivement.

Les méthodes classiquement utilisées pour la localisation absolue sont basées sur des approches probabilistes. Or, les limitations de ces approches ont été largement mises en évidence, en particulier dans des cas d'informations pauvres [Dubois 94]. La théorie des possibilités peut être utilisée pour remédier à ces limitations. L'idée de l'utiliser pour la fusion de données a été proposée récemment par Dubois et Prade [Dubois 92] et étudiée dans un cadre théorique. Peu de réalisations concrètes ont été testées pour traiter des données physiques. Ce papier présente une méthode de localisation absolue entièrement basée sur la théorie des possibilités. Cette méthode a été comparée au filtrage de Kalman en simulation et par des expérimentations réelles.

La localisation, étant réalisée à partir d'informations issues de plusieurs capteurs, fait appel à des concepts de fusion multisensorielle.

Dans un système multicapteur, la fusion permet :

- de compenser les limites d'un capteur par les observations d'autres capteurs;
- d'exploiter l'effet de redondance des informations capteurs. On obtient ainsi un renforcement ou un affaiblissement des informations suivant qu'elles s'accordent ou non;
- d'exploiter l'effet de complémentarité des données en considérant que certains domaines peuvent être observés par un capteur,

mais pas d'autres. Pour un niveau hiérarchique donné (fusion au niveau des données, des caractéristiques ou de la décision [Dasarathy 97]), l'opération de fusion s'effectue en plusieurs étapes [Hall 97] :

- i) Corrélation : détermination des relations entre les différentes données.
- ii) Association ou mise en correspondance : chaque mesure se trouve associée à l'entité correspondante (le résultat de l'étape de corrélation est évidemment utilisé).
- iii) Alignement : les observations ou les données sont ramenées dans un même référentiel spatial et temporel.
- iv) Combinaison : seules les données obtenues après alignement et qui sont en accord avec l'étape d'association sont combinées pour obtenir une meilleure représentation de l'estimation correspondant à l'attribut avec lequel i) a été réalisée. On notera par ailleurs que l'étape ii) peut être imbriquée à l'intérieur de iii). Par conséquent, trois étapes sont nécessaires pour toute opération de fusion : alignement, mise en correspondance (ou association) et combinaison. On utilisera également les notions suivantes :
 - fusion statique : quand le résultat de l'opération de fusion est obtenu indépendamment des états antérieurs. On exploite alors uniquement les données de l'instant courant.
 - fusion dynamique : quand le résultat tient compte des états antérieurs. Tout processus de fusion ayant une formulation itérative rentre dans ce contexte.

2. rappel sur la théorie des possibilités

La théorie des possibilités a été définie par Zadeh [Zadeh 78] et développée par Dubois et Prade [Dubois 88] à partir de la théorie des sous-ensembles flous [Zadeh 65]. C'est un outil mathématique qui permet une gestion efficace de l'imprécision et de l'incertitude qui peuvent être inhérentes à certaines données. Elle est donc parfaitement adaptée à notre cas puisque les informations collectées par un robot mobile, qu'elles soient d'ordre odométrique, infrarouge ou ultrasonore sont toujours entachées de bruit et d'erreurs.

2.1. distributions de possibilité

La théorie des possibilités consiste à représenter l'information dont on dispose sur un paramètre x par une distribution de possibilité π_x [Zadeh 78]. π_x est une application du domaine S de x dans $[0, 1]$. Pour tout élément s de S , on appellera $\pi_x(s)$ le « degré de possibilité » pour que $x = s$. $\pi_x(s) = 0$ signifie donc qu'il est totalement impossible que x vaille s et $\pi_x(s) = 1$ indique que rien n'empêche x de valoir s . On suppose qu'au moins une valeur de S est la valeur de x , ce qui se traduit par $\pi_x(s) = 1$ pour au moins un élément s de S (on parle alors de distribution normalisée).

Connaissant une distribution de possibilité π_x , on définit alors le degré de possibilité $\Pi(B)$ permettant d'évaluer la confiance que l'on peut avoir sur l'affirmation « $x \in B$ », avec $B \subset S$.

$\Pi(B)$ est définie par :

$$\Pi(B) = \sup_{s \in B} \{\pi_x(s)\} \quad (1)$$

Le degré de nécessité $N(B)$ est la mesure duale définie par :

$$N(B) = 1 - \Pi(\bar{B}) = \inf_{s \notin B} \{1 - \pi_x(s)\} \quad (2)$$

Plusieurs interprétations possibles des distributions de possibilité ont été présentées par D. Dubois et H. Prade [Dubois 94]. On peut ainsi concevoir la théorie des possibilités soit indépendamment de l'approche probabiliste, soit comme une généralisation de cette dernière.

Pour pouvoir manipuler des variables représentées dans le cadre de la théorie des possibilités, on a recours au principe d'extension de Zadeh [Zadeh 75] qui permet d'étendre les opérations mathématiques classiques à des quantités floues. Le problème posé est le suivant : étant données X_1, \dots, X_n n variables définies par leur distribution de possibilité π_1, \dots, π_n , et f une application de \mathfrak{X}^n dans \mathfrak{Y} , quelle est la distribution de possibilité π associée à $Y = f(X_1, \dots, X_n)$? Le principe d'extension indique qu'il faut déterminer, pour chaque valeur y de Y , tous les n -uplets (x_{i1}, \dots, x_{in}) tels que $y = f(x_{i1}, \dots, x_{in})$. On a alors

$$\pi(y) = \sup(\min\{\pi_1(x_{i1}), \dots, \pi_n(x_{in})\}) \quad (3)$$

2.2. évaluation de l'imprécision et de l'incertitude

L'imprécision et l'incertitude sont inhérentes à tout système de mesure. Nous adoptons ici le point de vue selon lequel, pour une information donnée, l'imprécision concerne le contenu de l'information (la mesure est d'environ 17cm), alors que l'incertitude concerne la validité de cette information par rapport à une référence extérieure (il est possible que la mesure soit de 17cm). Dans le cas où cette information serait supportée par une distribution de

possibilités, il est clair que l'étendue du support de la distribution, sauf s'il est infini, donne une indication sur l'imprécision de cette information. L'incertitude ou inversement, la certitude, peut être quantifiée de deux manières :

– soit en considérant les poids probabilistes associés à chacun des ensembles alpha-coupes A_{α_i} [Dubois 88] (imprécision) dans le sens où une distribution de probabilité modélise des données précises mais incertaines,

– soit en considérant la nécessité associée à ce même ensemble alpha-coupe.

Considérons la représentation en alpha-coupe de la distribution de possibilités. Pour une distribution normalisée, on a :

$$A_{\alpha_1} \subset A_{\alpha_2} \subset \dots \subset A_{\alpha_n} \text{ où } 1 = \alpha_1 \geq \alpha_2 \geq \dots \geq \alpha_n \geq \alpha_{n+1} = 0 \quad (4)$$

On peut associer à chaque ensemble A_{α_i} le poids :

$$p_i = \alpha_i - \alpha_{i+1} \quad (5)$$

Les poids p_i vérifient bien la propriété :

$$\sum_i p_i = \sum_i (\alpha_i - \alpha_{i+1}) = 1 \quad (6)$$

Ces poids forment donc une loi de probabilité discrète.

Ainsi, la première approche consiste à représenter l'imprécision par A_{α_i} et l'incertitude associée par p_i , d'où le couple (A_{α_i}, p_i) .

Dans la seconde approche l'imprécision est toujours représentée de la même manière, alors que l'incertitude est donnée par $N(A_{\alpha_i}) = 1 - \alpha_{i+1}$ d'où le couple $(A_{\alpha_i}, N(A_{\alpha_i}))$.

Finalement, la distribution de possibilités π peut être représentée sous forme d'un ensemble de paires imprécision / certitude décrites par les ensembles alpha-coupes et le poids affecté à chacun d'eux ou bien le degré de nécessité associé.

Par ailleurs, la notion de fiabilité est une imperfection qui est liée à la qualité des capteurs fournissant des données physiques. En fait, elle est généralement englobée dans la notion d'incertitude dans le cadre de la logique propositionnelle et la fusion d'opinions d'experts.

3. fusion d'informations en théorie des possibilités

Supposons que l'information reflétée par chaque source i soit supportée par une distribution de possibilités. Soit N le nombre de sources (i allant de 1 à n). Ces distributions peuvent être combinées conjonctivement ou disjonctivement, ce qui correspond




Figure 1. – Exemple de détermination de la distribution résultante de trois distributions. a) distributions intermédiaires b) distribution finale.

respectivement à une intersection ou une union des distributions sources :

$$\forall s \in S, \pi_{\wedge}(s) = \bigcap_{i=1}^n \pi_i(s) \quad \text{et} \quad \pi_{\vee}(s) = \bigcup_{i=1}^n \pi_i(s) \quad (7)$$

Les opérateurs d'union et intersection couramment utilisés sont respectivement le max et le min, mais si on est moins exigeant sur la préservation des propriétés classiques des opérateurs ensemblistes, l'utilisation d'autres opérateurs de type *t*-conorme et *t*-norme est envisageable. La combinaison conjonctive suppose que les sources sont fiables, ou du moins certaines d'entre elles. La combinaison disjonctive, quant à elle, est moins contraignante en terme de fiabilité, dans le sens où elle nécessite seulement qu'une seule source soit fiable. Evidemment, pour le cas particulier où on sait à l'avance qu'il n'y a aucune source fiable dans le processus de fusion, une autre attitude raisonnable consiste à choisir l'ignorance totale comme résultat de combinaison ($\forall s, \pi_x(s) = 1$).

Un autre type de combinaison, intermédiaire entre les précédents, consiste à considérer le cas où on sait qu'il y a *K* sources fiables parmi les *N*, sans toutefois pouvoir les identifier. Cette combinaison se résume à considérer tous les sous-ensembles à *k* éléments (qui sont susceptibles d'être les *K* sources fiables), à combiner conjonctivement les éléments de ces sous-ensembles (considérés comme fiables), puis à combiner disjonctivement le résultat de chacune de ces combinaisons intermédiaires (attitude de prudence pour ne pas perdre un de ces sous-ensembles censé contenir l'information vraie). On aboutit alors à la formulation suivante, appelée *combinaison quantifiée* :

$$\forall x, \pi_{(k)}(x) = \max_{K \subseteq N, |K|=k} \min_{i \in K} \pi_i(x) \quad (8)$$

L'utilisation d'un seul mode de combinaison figé n'est pas toujours souhaitable. Il est en effet intéressant d'évoluer du mode conjonctif, quand les sources s'avèrent fiables et non-conflictuelles, vers un mode disjonctif lorsqu'elles s'avèrent par contre conflictuelles (ou non fiables). Dans ce but, Dubois et Prade

[Dubois 94] ont développé une règle de combinaison adaptative qu'on appellera par la suite « règle RDEP ».

Le principe est de déterminer deux valeurs *n* (optimiste) et *m* (pessimiste) encadrant l'ensemble des sources fiables. Ces valeurs correspondent respectivement au nombre maximum de sources (distributions) ayant une intersection non nulle de leur support -c'est-à-dire susceptibles d'être en concordance- et au nombre maximum de sources (distributions) ayant une intersection non nulle de leur noyau -c'est-à-dire en concordance totale-.

De plus, on suppose qu'une fois ces deux valeurs déterminées, on ne sait pas distinguer les sources qui sont fiables de celles qui ne le sont pas. On utilise alors la combinaison quantifiée. La règle s'écrit :

$$\pi(x) = \max \left(\frac{\pi_{(n)}(x)}{h(n)}, \min (\pi_{(m)}(x), 1 - h(n)) \right) \quad (9)$$

avec

$$h(n) = \sup[h(K), [K] = n], \quad (10)$$

$$h(K) = \sup_x \left[\min_{i \in K} \pi_i(x) \right], \quad (11)$$

$$m = \sup[|K|, h(K) = 1], \quad (12)$$

$$n = \sup[|K|, h(K) > 0], \quad (13)$$

h(K) désigne la plus grande intersection entre les sources appartenant au sous-ensemble *K* de l'ensemble *N* des sources. *h(n)* exprime la plus grande intersection non nulle du plus grand nombre de sources possibles. Ce terme traduit aussi la concordance entre les différentes distributions.

La figure 1 montre un exemple d'application de la règle RDEP. Les distributions à combiner sont π_1 , π_2 et π_3 . Dans la figure 1a les combinaisons quantifiées $\pi_{(2)}$ et $\pi_{(3)}$ correspondent respectivement à $\pi_{(m)}$ et $\pi_{(n)}$. En effet, il y a deux distributions dont les noyaux s'intersectent et trois dont les supports s'intersectent. Nous avons également représenté la distribution normalisée $\frac{\pi_{(3)}}{h(3)}$.

Le résultat final est donné sur la figure 1b.

On peut noter que, dans le cas de combinaison de distributions en conflit, cette règle peut poser dans certains cas des problèmes de robustesse vis à vis de la forme des distributions, qui peuvent engendrer un dysfonctionnement du point de vue de la valeur défuzzifiée de la distribution résultante. Ceci a motivé l'investigation d'autres formulations de la règle adaptative [Zunino 97] [Maaref 98]. Cependant, dans le cadre de l'application décrite ici où toutes les situations conflictuelles ont été éliminées à priori, nous conservons la formulation de base de cette règle.

4. cadre expérimental

L'étude a été réalisée sur un robot miniature (Khepera[®]) développé à l'Ecole Polytechnique Fédérale de Lausanne (EPFL) [Mondada 93]. Ce robot (figure 2) est de dimensions très petites (55 mm de diamètre avec un entraxe de 50.4 mm et de 30 mm d'hauteur). Il est supporté par deux roues motrices et deux balles de téflon. Il est équipé de huit capteurs infrarouge qui sont disposés d'une façon à peu près circulaire autour du robot et permettent des mesures de distance entre 1 et 5 cm. Ces capteurs peuvent aussi être utilisés uniquement en réception avec une portée d'environ 20 cm, en utilisant des sources externes d'émission infrarouge. Ces sources sont réalisées par des balises actives constituées par des diodes électroluminescentes. Ces balises sont fixes, de position précisément connue et leur activation est commandée par le PC via le port parallèle. La figure 3 résume le montage utilisé.

Les commandes en vitesse et en orientation sont envoyées au robot suivant la connaissance que l'on possède sur sa position afin d'accomplir sa tâche (atteindre les différents sous-but). Le principe des expériences est de faire naviguer le robot et de comparer au bout d'un certain temps sa position réelle et la position après correction par les méthodes testées. La différence constitue l'erreur de localisation. La trajectoire idéale est déterminée à partir d'un

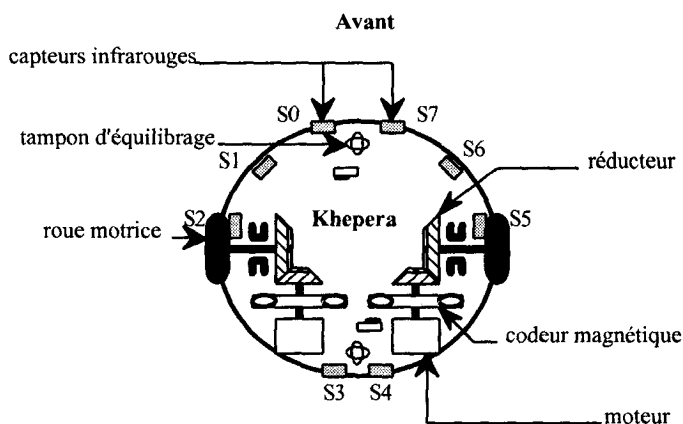


Figure 2. – Structure physique du robot Khepera[®].

certain nombre de points intermédiaires choisis de sorte que la portée des capteurs (distance robot - balise) soit respectée. Dans ces expériences, chaque diode émettrice est excitée successivement pendant un temps très court, avec un temps mort de quelques dixièmes de secondes entre l'éclairement de deux diodes. Ceci assure l'absence d'interférences entre les signaux mesurés. La mise en correspondance écho-capteur est triviale puisqu'on sait à chaque instant quelle balise est actionnée et quel capteur est déclenché (le plus excité).

Par ailleurs, pour des raisons qui sont dues aussi bien à la faible puissance émise par la diode qu'aux limites des récepteurs de Khepera, les observations ne permettent pas d'obtenir directement des informations sur la direction du robot. En conséquence, par la suite, on ne s'intéresse qu'à corriger les coordonnées x et y du centre du robot. Son orientation ne sera estimée que par l'odomètre.

5. application à la fusion de données capteurs

Nous nous proposons de tester la fusion possibiliste pour déterminer une meilleure estimation de la position absolue du robot miniature dans l'environnement balisé défini précédemment. Pour cette application, nous attacherons une grande importance à la modélisation des capteurs infrarouges et odométrique et nous présenterons les tests effectués en statique et en dynamique, aussi bien en simulation qu'en implémentation réelle. Dans les deux cas, l'influence du nombre de balises et de l'imprécision initiale sera étudiée.

5.1. principe général de la solution possibiliste

La figure 4 représente l'algorithme général de la méthode. Il est composé de trois parties :

1) L'estimation odométrique (mesures proprioceptives) : les capteurs odométriques fournissent des déplacements élémentaires des roues du robot l_k^q et l_k^d dans le repère mobile (lié au robot) entre deux instants d'échantillonnages. Ces distances sont représentées par des distributions de possibilités grâce à l'étape de modélisation décrite dans le paragraphe 5-5-1. Afin d'estimer l'état du système, c'est-à-dire la configuration du robot (définie dans un plan par ses coordonnées x , y et son cap θ) par rapport à son environnement, il est nécessaire de définir un modèle d'évolution du véhicule. Pour un robot mobile, plusieurs modèles d'état sont possibles selon les approximations faites sur la trajectoire du robot (approximation par un arc de cercle, un segment, etc..). Le modèle d'évolution




Figure 3. – Montage utilisé pour les expérimentations.

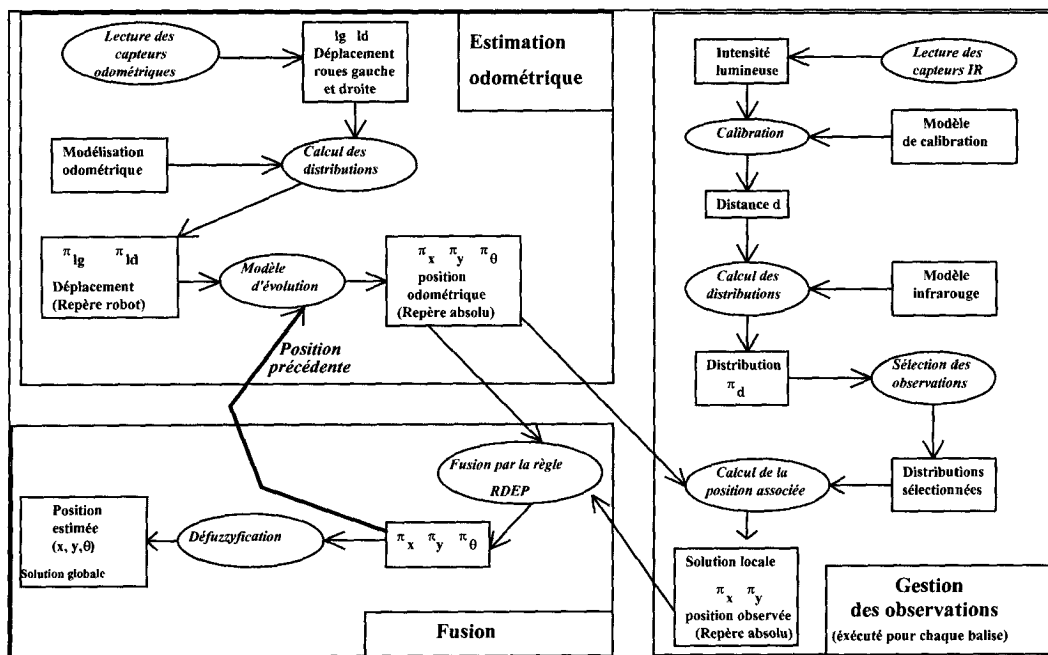


Figure 4. – Algorithme général de la méthode.

que nous avons utilisé est le suivant :

$$\begin{cases} x_{k+1} = x_k + \frac{l_k^g + l_k^d}{2} \times \cos(\theta_k) \\ y_{k+1} = y_k + \frac{l_k^g + l_k^d}{2} \times \sin(\theta_k) \\ \theta_{k+1} = \theta_k + \frac{l_k^d - l_k^g}{D} \end{cases} \quad (14)$$

où D désigne l'entraxe (distance entre les deux roues).

Ces équations supposent que la trajectoire parcourue par le robot entre deux instants successifs est assimilée à un segment de droite pour l'accroissement linéaire et à un arc de cercle pour $\Delta\theta_k$.

Chaque variable coordonnée est déterminée sous forme d'une distribution de possibilités par application du principe d'extension

de Zadeh. La mise en œuvre directe de cet outil pose des problèmes pratiques à cause de la nécessaire discrétisation des domaines des variables. Nous avons donc préféré utiliser la méthode de Dong [Dong 87a] [Dong 87b] pour manipuler les distributions de possibilité. Cette méthode est basée non pas sur la discrétisation des univers de discours, mais sur celle de l'intervalle $[0, 1]$ des degrés de possibilité, c'est-à-dire sur une représentation sous forme d'alpha-coupe des distributions.

2) La gestion des observations (mesures extéroceptives) : chaque balise permet d'obtenir une estimation sur les variables d'état (coordonnées x et y de la position absolue du robot définies dans le même repère, qui est celui où sont définies les coordonnées des balises) en tenant compte de la donnée odométrique. En effet, après une étape de calibration, chaque balise renvoie une distance

représentée par une distribution de possibilités grâce au modèle adopté décrit au paragraphe V-5-2. Une étape de sélection est au préalable appliquée pour éviter les situations conflictuelles (§ V-2). Ensuite, ayant l'estimation odométrique, chaque distance est transformée par l'étape d'alignement (§ V-3) dans le repère absolu en coordonnées x et y et ceci à l'aide du principe d'extension de Zadeh de sorte que ces coordonnées soient représentées par des distributions de possibilités.

3) La fusion : la méthode possibiliste développée permet une correction de la position estimée d'après les capteurs odométriques en fonction des observations fournies par les capteurs infrarouges. Le processus de correction consiste à utiliser la règle de fusion adaptative présentée au paragraphe III pour combiner ces positions et la position estimée.

Nous précisons par la suite où et comment dans ce schéma sont effectuées les opérations principales décrites au § I : association, alignement et combinaison.

5.2. association

L'étape d'association ou de mise en correspondance des données avec les capteurs correspondants est directement contrôlée par l'utilisateur. En effet, via le port parallèle, on peut décider du capteur et de la diode à déclencher. De plus, les diodes sont actionnées successivement.

Cependant, dans le but d'homogénéiser le résultat avec celui de la méthode de Kalman, nous avons introduit une phase de sélection des données (correspondant à la fonction « sélection des observations » de la figure 4). Dans cette dernière, seules les données dont les supports des distributions de possibilités s'intersectent sont considérées. Autrement dit, toutes les situations conflictuelles sont éliminées *a priori*.

5.3. alignement (solutions locales)

Le problème est de donner une indication sur la position du robot à partir de l'information de distance (d) fournie par une diode (correspondant à la fonction « calcul de la position associée » de la figure 4). Pour ce faire, nous nous servons de la position odométrique M_0 (donnée dans un repère absolu) du robot. Nous choisissons comme nouvelle position du robot M (solution locale) issue de l'information fournie par la diode, le point M aligné avec M_0 et situé à une distance d de la diode (figure 5). Ce choix correspond à la position la plus proche de la position odométrique située à la distance d de la diode. De façon plus formelle, si on désigne par (x_a, y_a) les coordonnées de la balise A par rapport au repère absolu Oxy , (x_0, y_0) les coordonnées de la position odométrique dans ce même repère et d la distance renvoyée par le capteur infrarouge (diodes), la position de M de coordonnées x

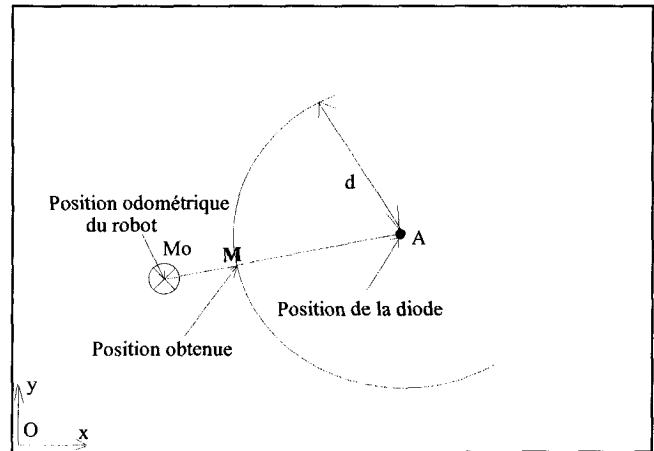


Figure 5. – Illustration de la première estimation de la position à partir de la position de la diode et de la position odométrique.

et y représentant la solution locale (position du robot) vue par la balise A est donnée par :

$$\begin{cases} x = x_a + \frac{(x_a - x_0) \times d}{\sqrt{(x_0 - x_a)^2 + (y_0 - y_a)^2}} \\ y = y_a + \frac{(y_a - y_0) \times d}{\sqrt{(x_0 - x_a)^2 + (y_0 - y_a)^2}} \end{cases} \quad (15)$$

Les calculs sont faits pour chaque balise disponible en utilisant le principe d'extension de Zadeh. Dans l'équation (15), les variables sont manipulées sous la forme de distributions de possibilités hormis les coordonnées (x_a, y_a) qui sont exprimées par des singletons.

5.4. combinaison (solution globale)

Après avoir déterminé les solutions associées à chacune des diodes (position absolue du robot vue par une diode) indépendamment les unes des autres, l'étape suivante consiste maintenant à fusionner ces solutions individuelles pour en extraire une solution globale (correspondant à la fonction « fusion par la règle RDEP » de la figure 4). Cette combinaison est effectuée par le biais de la règle RDEP de combinaison adaptative. On obtient ainsi une distribution de possibilités correspondant à la position sur x et une correspondant à celle sur y (figure 6). Afin d'extraire une valeur numérique de ces distributions, on effectue une défuzzification par la méthode du centre de l'aire.

5.5. modélisation possibiliste des informations capteurs

Au cours de l'ensemble des opérations décrites précédemment, les objets manipulés sont des distributions de possibilités. Cela suppose que l'on dispose au départ d'une représentation des données

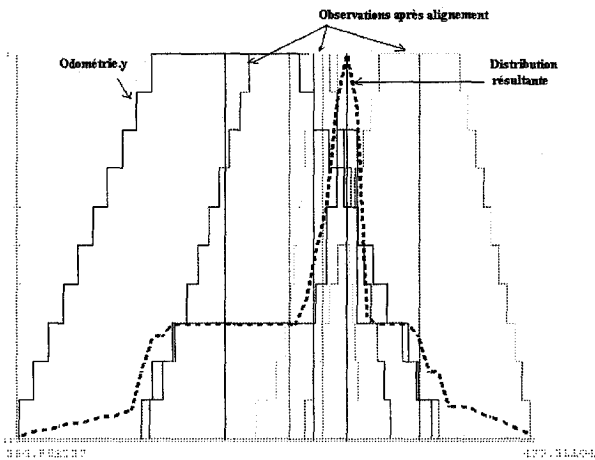


Figure 6. – Exemple de distributions correspondant à l'estimation de la position sur y .

capteurs associant à chaque mesure une distribution de possibilités. Cette distribution représente le degré de possibilité avec lequel la mesure d est égale à la vraie valeur de la distance dv . Naturellement, plus le capteur est de bonne qualité, plus la distribution est spécifique (proche d'une distribution précise et certaine). La démarche adoptée consiste à effectuer une analyse statistique des données capteurs à partir des relevés expérimentaux.

5.5.1. capteur odométrique

La forme retenue pour les distributions de possibilités associées aux déplacements l_k^g et l_k^d des roues gauche et droite du robot consiste en une structure d'ensembles emboîtés (représentation en alpha-coupes) (figure 7).

En pratique le problème revient à trouver les ensembles A_i correspondant à un certain choix des niveaux d'alpha-coupes. Pour notre cas, afin de simplifier la manipulation et la représentation, nous avons restreint notre choix par les contraintes suivantes :

- i) limiter à trois le nombre de niveaux d'alpha-coupes;
- ii) obtenir des ensembles A_i les plus distincts possible;
- iii) obtenir des distributions symétriques;
- iv) avoir des bornes des ensembles A_i proportionnelles au terme central v (pour tenir compte du fait que l'imprécision d'une mesure odométrique augmente avec la distance parcourue).

Nous avons alors effectué une série de tests statistiques. Ces derniers consistent à faire parcourir au robot en ligne droite des distances connues dv_i (de 5 à 60 cm), chaque opération étant répétée plusieurs fois. Nous relevons, dans chaque cas, la position réelle du robot et sa position odométrique (x, y et θ).

On obtient ainsi pour chaque valeur vraie dv_i un ensemble de données odométriques mesurées, rangées suivant le tableau 1 ci-après :




Figure 7. – Distribution choisie pour les mesures odométriques : distances parcourues par les deux roues gauche et droite du robot l_k^g et l_k^d .

Tableau 1. – Mesures odométriques.

Valeur vraie	données odométriques associées				
dv_1	d_{11}	d_{12}	d_{13}	...	d_{1n_1}
dv_2	d_{21}	d_{22}	d_{23}	...	d_{2n_2}
\vdots	\vdots	\vdots	\vdots	...	\vdots
dv_i	d_{i1}	d_{i2}	d_{i3}	...	d_{in_i}
\vdots	\vdots	\vdots	\vdots	...	\vdots
dv_n	d_{n1}	d_{n2}	d_{n3}	...	d_{nn_n}

Nous déterminons en premier lieu le centre v de la distribution. Il suffit pour cela d'effectuer pour chaque valeur dv_i , la moyenne des différentes données odométriques associées. On obtient ainsi un décalage systématique qui, sur l'axe du déplacement, est pratiquement constant en valeur relative pour tout dv_i et est égal à 3.5 %¹, c'est-à-dire :

$$v = d_{moy} - 0.035d_{moy}. \tag{16}$$

En termes de données statistiques, il est raisonnable de supposer qu'on est d'autant plus certain de l'occurrence d'un événement que ce dernier se répète pendant les différentes séries de tests.

Ainsi, la détermination de la distribution de possibilités revient à déterminer deux niveaux de possibilités λ_1 et λ_2 ($2 > 1$) (le troisième étant le niveau 1) et les paramètres α_1, α_2 et α_3 délimitant les ensembles alpha-coupes correspondants tels que pour chaque dv_i :

- 100 % des données associées $[d_{ij} \dots d_{in_i}]$ sont à l'intérieur de l'intervalle $[dv_i(1 - \alpha_1); dv_i(1 + \alpha_1)]$.
- $(1 - \lambda_1)$ 100 % de $[d_{ij} \dots d_{in_i}]$ sont à l'intérieur de $[dv_i(1 - \alpha_2); dv_i(1 + \alpha_2)]$.

1. Ce paramètre tient compte aussi bien du décalage systématique des données odométriques que de l'influence exercée par l'inertie du fil reliant le robot au PC.

- $(1 - \lambda_2) 100 \%$ de $[d_{ij} \dots d_{in_i}]$ appartiennent à $[dv_i(1 - \alpha_3); dv_i(1 + \alpha_3)]$.

En outre, la contrainte i) impose que $\alpha_1 - \alpha_2$ et $\alpha_2 - \alpha_3$ soient aussi larges que possible.

On teste alors toutes les combinaisons à deux éléments des neuf niveaux allant de 0.1 à 0.9 (programme itératif).

La meilleure solution obtenue est $\lambda_1 = 0.3$ et $\lambda_2 = 0.6$. En termes de confiance, cela veut dire que :

- Dans 40 % des cas, la vraie valeur se trouve à l'intérieur de l'ensemble délimité par $v - \alpha_3 \cdot v$ et $v + \alpha_3 \cdot v$.
- Dans 70 % des cas, cette valeur est à l'intérieur de l'ensemble délimité par $v - \alpha_2 \cdot v$ et $v + \alpha_2 \cdot v$.
- Dans tous les cas, la vraie valeur est à l'intérieur de l'ensemble délimité par $v - \alpha_1 \cdot v$ et $v + \alpha_1 \cdot v$.

v est la donnée obtenue à partir de la lecture odométrique après élimination du décalage systématique.

Les paramètres $(\alpha_1, \alpha_2, \alpha_3)$ sont fixes et identiques pour l_k^g et l_k^d . Nous avons trouvé les valeurs suivantes : $\alpha_1 = 2.6\%$, $\alpha_2 = 1.4\%$ et $\alpha_3 = 0.6\%$.

5.5.2. capteur infrarouge

Il faut tout d'abord calibrer chaque capteur de sorte que sa sortie corresponde à une distance. Plusieurs tests ont été effectués à différentes distances en relevant chaque fois une moyenne d'une dizaine de mesures. Ceci permet de réduire significativement l'influence des bruits de mesure. Nous obtenons la courbe de calibration de la figure 8 où une approximation polynomiale de degré quatre permet un bon lissage des points.

Afin de déterminer la distribution de possibilité correspondant à chaque distance, une nouvelle série d'acquisitions est effectuée en utilisant cette fois-ci les résultats issus de la calibration. A

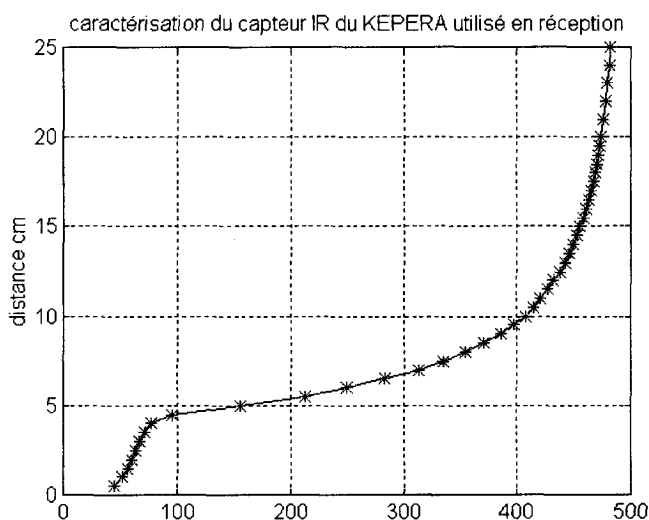


Figure 8. – Calibration d'un capteur infrarouge : distance en cm en fonction de la réponse capteur (0 à 500).




Figure 9. – Distribution de possibilités obtenue pour un capteur IR. d est la distance renvoyée par le capteur.

l'inverse des relevés odométriques, les résultats des tests sont très proches les uns des autres (évidemment pour une même distance). Le premier critère i) du paragraphe précédent relatif à la séparation la plus nette possible entre les différents sous-ensembles A_i est alors très difficile à vérifier pour plusieurs niveaux d'alpha-coupes. C'est pourquoi nous avons préféré conserver ici une simple représentation trapézoïdale (figure 9).

Cette représentation signifie que, dans la majorité des cas, la distance vraie est située dans un intervalle de 0.5 % autour de la distance mesurée (moyenne de 10 mesures) et qu'en aucun cas la mesure vraie n'est à l'extérieur d'un intervalle de 1 % autour de la mesure.

5.6. résultats expérimentaux

5.6.1. conditions générales

Afin de valider l'approche décrite précédemment, nous avons effectué une série de tests avec le robot miniature Khepera[®], aussi bien en simulation qu'en implémentation réelle. La simulation est très proche du cadre expérimental et offre l'avantage de pouvoir aisément faire des essais systématiques de l'influence des différents paramètres. Ainsi, nous disposons d'une trajectoire idéale générée par un ensemble de sous-buts intermédiaires. Les mesures relatives aux capteurs infrarouges sont simulées à partir de la distance en pixel entre la position réelle et la position de la diode, augmentée d'un bruit gaussien. La position odométrique est simulée à partir du modèle cinématique de l'odométrie du robot. Nous disposons alors à chaque instant d'échantillonnage de la position odométrique estimée et de la position réelle. La position initiale du robot (figure 10) est déterminée à partir de la position vraie ajoutée d'un bruit centré dont la variance σ^2 définit l'erreur initiale.

Les résultats de cette application seront ensuite comparés avec ceux obtenus en utilisant une méthode de filtrage de Kalman considérée comme la méthode de référence et une discussion comparative des caractéristiques des deux algorithmes sera effectuée.




Figure 10. – Trajectoire utilisée pour les tests de correction finale (en simulation).




Figure 11. – Représentation de la distribution associée à la position initiale.

Les études portant sur l'utilisation du filtrage de Kalman pour la localisation absolue d'un robot mobile sont nombreuses. La méthode que nous avons utilisée ici est la version séquentielle non-linéaire manipulant des distributions de probabilités gaussiennes représentant la méthode la plus usitée [Durieu 96]. Une description de la modélisation des bruits utilisés est donnée en annexe.

Dans l'approche de Kalman, σ représente l'écart type initial sur x et y permettant de déterminer la matrice de variance-covariance initiale ($\sigma_{xx} = \sigma_{yy} = \sigma$) du modèle d'état relatif à l'odométrie. De même, dans l'approche possibiliste, σ représente le paramètre déterminant la distribution de possibilités initiale, représentée sur la figure 11, avec lequel le modèle odométrique est initialisé. La distribution est centrée sur la valeur p (coordonnée en x ou y) obtenue à partir de la valeur vraie ajoutée d'un bruit gaussien de variance σ^2 . L'erreur finale est représentée par la distance entre la position estimée par l'algorithme et la position vraie.

Plusieurs scénarios de tests sont possibles suivant qu'on décide de faire une localisation statique (en fin de parcours) ou dynamique (à chaque déplacement). Nous étudierons particulièrement l'influence du nombre de balises et des conditions initiales.

5.7. tests en fin de parcours

Le test consiste à laisser naviguer le robot jusqu'à son point final, puis à appliquer l'algorithme de localisation pour déterminer l'erreur en fin de parcours. C'est-à-dire que le processus de fusion n'est déclenché qu'une fois que le robot est complètement immobilisé. Par conséquent, à l'instant où le robot s'est arrêté, le modèle d'état du filtre de Kalman associé correspond au modèle statique (sans aucun mouvement). L'erreur relative à ce modèle est ainsi uniquement liée à la position initiale qui correspond ici à la position de fin de parcours déduite à partir du modèle odométrique, qui, quant à lui, est régi par les équations du modèle d'évolution où l'état initial représente cette fois-ci l'instant du début de mouvement du robot. Les équations d'observations correspondent à la distance euclidienne entre chaque balise et la position courante du robot.

5.7.1. simulation

La figure 12 illustre la différence entre les performances des deux méthodes (la méthode possibiliste est meilleure pour une ordonnée positive). On voit clairement que la méthode possibiliste n'est supérieure au filtre de Kalman que dans le cas où l'erreur initiale est importante et le nombre de balises faible. Ce cas correspond effectivement aux interprétations intuitives des deux formalismes. En effet, le filtre de Kalman (ou d'une façon plus générale une méthode probabiliste) est bien adapté quand l'information est riche (beaucoup de balises, peu d'incertitude) alors que la théorie des possibilités est bien adaptée pour les situations pauvres (moins de balises, plus d'incertitude).

Nous pouvons comparer également les variances associées aux deux méthodes. Dans l'approche de Kalman, la variance du résultat est donnée par la diagonale de la matrice de variance-covariance après correction. Dans l'approche possibiliste, nous




Figure 12. – Comparaison Kalman/Possibilités en simulation avec correction finale.

Tableau 2. – Comparaison des variances des résultats des deux méthodes pour différentes valeurs de la variance initiale dans le cas de deux balises.

Variance initiale σ^2 (mm ²)	Variance du résultat : méthode de Kalman.		Variance du résultat : méthode possibiliste.	
	Sur x	Sur y	Sur x	Sur y
30	15.3	5.6	25.5	33.7
100	30.1	17.8	67.2	48.2
500	75.6	34.8	126.8	121.8
1200	118.9	109.8	137.8	124.7
4000	213.8	198.8	218.6	186.9

Tableau 3. – Comparaison des variances des résultats des deux méthodes pour différentes valeurs de la variance initiale dans le cas de cinq balises.

Variance initiale σ^2 (mm ²)	Variance du résultat : méthode de Kalman		Variance du résultat : méthode possibiliste.	
	Sur x	Sur y	Sur x	Sur y
30	5.3	5.6	15.1	23.2
100	10.4	8.1	33.2	30.1
500	14.6	19.2	91.8	79.2
1200	24.5	28.2	126.3	92.7
4000	32.7	41.9	187.5	123.4

appliquons la transformation possibilités \rightarrow probabilités logarithmique de Klir [Klir 88] pour déterminer la distribution de probabilités associée à chacune des distributions de possibilités résultantes sur x et y . Ensuite, nous déterminons la variance associée à chacune de ces distributions de probabilités. Nous résumons les résultats dans les tableaux 2 et 3 pour respectivement le cas de deux ou cinq balises, suivant différentes valeurs de la variance initiale.

On peut ainsi noter que :

– Les variances des deux approches ne sont comparables que dans le cas d'un faible nombre de balises et d'une variance initiale importante, ce qui est conforme aux résultats précédents sur les erreurs de localisation.

– La variance du résultat est toujours inférieure à la variance initiale dans le cas de l'approche de Kalman et diminue avec le nombre de balises utilisées. Ceci est dû au fait que la méthode de Kalman est un estimateur à variance minimale dans le sens où la variance du résultat diminue après chaque itération. En outre, comme les erreurs du modèle d'observation sont fixes et sont donc, le plus souvent, inférieures à la variance initiale σ^2 , la variance va également décroître avec le nombre de balises (le résultat le plus précis, i.e., ayant la plus petite variance, se trouve privilégié).

Dans l'approche possibiliste, ce phénomène n'est pas garanti (cf. 1^{ère} ligne du tableau 2). En effet, ni la règle de fusion, ni la transformation possibilités \rightarrow probabilités ne font intervenir un quelconque critère de minimisation de la variance. Seule la concor-

dance entre les différentes sources est prise en considération par le résultat final.

5.7.2. expériences réelles

De la même manière que précédemment, on fait parcourir une trajectoire au robot à partir d'une position initiale. A la fin de son parcours, on détermine sa position en fusionnant sa position odométrique avec les observations des balises infrarouges. On fait également varier le nombre de balises actionnées. On obtient les résultats des figures 13 et 14. La figure 13 montre l'influence de




Figure 13. – Comparaison Kalman/Possibilités en fonction de l'erreur initiale dans le cas où cinq balises sont utilisées.




Figure 14. – Comparaison Kalman/Possibilités en fonction du nombre de balises utilisées pour la correction en fin de parcours pour une variance initiale importante (3600).

l'erreur initiale sur l'estimation. Les courbes sont la moyenne des résultats obtenus après 50 essais sur une trajectoire rectiligne, les cinq balises étant utilisées en fin de parcours. La figure 14, quant à elle, montre l'influence du nombre de balises dans le cas d'une erreur initiale importante. Ces résultats confirment globalement les résultats de simulation. Cependant, dans la figure 13, on observe une diminution des performances du filtre de Kalman dans le cas où l'erreur initiale est très faible. Ceci est dû au fait que, comme σ est faible, il est en de même pour la matrice de variance-covariance, le filtre de Kalman accorde alors une importance prépondérante au résultat de la prédiction au détriment des observations.

5.8. tests en ligne

Contrairement au cas précédent, le processus de fusion est déclenché cette fois-ci à chaque déplacement élémentaire et une correction en ligne de la position est effectuée. Une évaluation de l'écart est réalisée entre la position ainsi estimée et la position vraie en fin de trajectoire.

5.8.1. simulation

Il est clair, comme le montre la figure 15, que ces conditions sont très favorables à la méthode de Kalman. En effet, cela vient du fait que cette méthode est un outil fait, par excellence, pour l'utilisation en ligne. Même avec un faible nombre de balises, comme on répète la mesure et l'acquisition plusieurs fois, l'information s'enrichit de plus en plus, et ainsi on ne peut plus parler de situation pauvre comme dans le cas précédent.




Figure 15. – Comparaison Kalman/Possibilités en simulation avec correction en ligne.

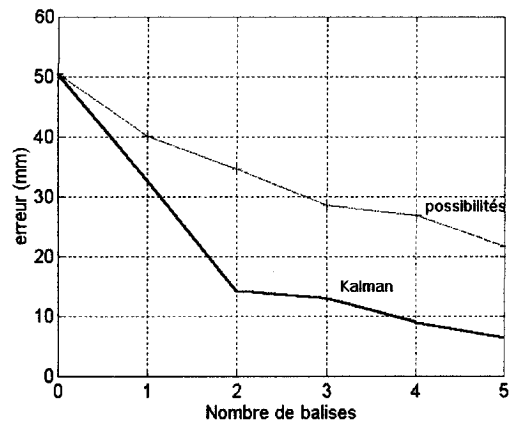


Figure 16. – Comparaison Kalman/Possibilités dans le cas d'une trajectoire réelle rectiligne avec une variance initiale de 100.

5.8.2. Expériences réelles

La trajectoire est une ligne droite et le nombre de balises déclenchées à chaque instant peut varier de un à cinq. De plus, la correction ne s'effectue pas tout le long de la trajectoire, mais sur une courte portion située dans la zone d'influence des diodes qui a été déterminée par une étape préalable, en testant la réponse des capteurs. Les résultats (figure 16) confirment grossièrement ceux de la simulation.

6. analyse et discussion

Pour analyser plus en détail certains résultats obtenus dans la section précédente, nous proposons ici une vision comparative des deux méthodes en nous intéressant successivement aux entrées, au mode de fonctionnement et aux sorties des deux systèmes.

6.1. entrées du système

Du point de vue de l'homogénéisation des données à l'entrée du système, les deux formalismes sont très similaires. Dans la méthode possibiliste, sont combinées la donnée odométrique et les solutions locales. Chacune de ces solutions locales résulte de la mise en correspondance de la donnée odométrique avec l'observation relative à cette solution. Les entrées sont les distributions correspondant à l'odométrie et aux données balises qui seront utilisées pour déterminer les paramètres à estimer sous forme de distributions. Pour le filtre de Kalman, les entrées sont l'état prédit du vecteur d'état et l'observation à l'instant courant. L'état prédit n'est autre que le résultat donné par le modèle odométrique.

On remarque d'après le système d'état que la solution relative à l'observation courante est dépendante de la solution relative à l'observation précédente. Cela veut dire que, si on considère chaque solution locale comme un expert, alors l'expert i ne donne son avis sur sa solution qu'après avoir consulté les autres experts qui ont déjà donné leur avis. Ceci constitue une différence avec la méthode possibiliste, où les différents avis sont donnés indépendamment les uns des autres. Cependant, dans le modèle de Kalman, une erreur sur une observation peut affecter toutes les entrées du système, surtout si l'observation erronée est la première observation. La cohérence des observations est donc une condition nécessaire, car, dans le cas contraire, le filtre effectuera une moyenne pondérée avec une donnée éloignée des autres. Par contre, le modèle possibiliste, à cause de cette propriété d'indépendance, n'est guère sensible à ce phénomène. En revanche, si on a des mesures en bonne cohérence, le filtre de Kalman possède un caractère de renforcement des solutions locales qui est un atout. C'est ce qui se passe avec la plupart des expériences réalisées ici avec Khepera[®].

6.2. fonctionnement du système

Dans le filtre de Kalman, les données sont traitées afin d'obtenir la meilleure estimation de l'état du système minimisant la variance sur l'état estimé. Ainsi, il effectue une correction de la prédiction proportionnelle à l'écart entre la valeur mesurée et la mesure prédite à partir du modèle d'observation en fonction des erreurs d'observation et d'état. Par ailleurs, si la matrice de covariance d'état est faible, la meilleure estimation est fournie par la prédiction. En effet, dans ce cas, la matrice de covariance d'état est moins importante que celle de l'observation. L'observation tend alors à être toujours ignorée par le filtre. De même si l'erreur de mesure est trop faible l'estimation du filtre tend à ignorer le résultat de la prédiction, pour se satisfaire uniquement de l'estimation tirée du vecteur d'observation. En d'autres termes, si la variance d'observation est grande par rapport à celle d'état, le filtre n'accorde que peu de confiance aux observations. Inversement, si la variance d'état est grande par rapport à celle d'observation, le filtre accordera alors plus de confiance à l'observation.

Pour résumer, le filtre agissant comme une moyenne pondérée entre la prédiction et l'observation, une bonne estimation est obtenue dans le cas où les deux conditions suivantes sont satisfaites :

- Elimination des observations aberrantes.
- Cohérence des observations avec le vecteur d'état du point de vue de leurs matrices de variance-covariance associées.

Dans le modèle possibiliste, la combinaison des informations réalisée par le biais de la règle adaptative accorde une importance primordiale à la zone de consensus entre les différentes entrées. C'est-à-dire que, contrairement au filtre de Kalman, la méthode ne s'intéresse pas à la notion de variance ou de précision des distributions initiales.

Par ailleurs les méthodes basées sur la théorie des probabilités capturent plutôt la notion de variabilité aléatoire et elles sont incapables d'agréger des informations ou des opinions conflictuelles : par exemple dans le cas d'informations provenant de plusieurs capteurs distincts, de natures diverses dont certains fonctionnent mal, la moyenne pondérée est contestable.

6.3. sorties du système

Un dernier élément de comparaison entre l'approche possibiliste et celle de Kalman concerne la forme des sorties obtenues. Dans la méthode de Kalman appliquée à des distributions gaussiennes, on obtient directement en sortie l'estimation de l'état du système et la variance de cette estimation (matrice de covariance).

Dans la méthode possibiliste, on propage du début jusqu'à la fin du processus, des distributions de possibilités. Usuellement on extrait des distributions finales une information numérique par une procédure de défuzzyfication, en cherchant par exemple le centre de gravité de la distribution. On peut en outre obtenir une indication sur la précision de l'estimation possibiliste, en considérant par exemple la spécificité ou la non-spécificité de la distribution de possibilités, ou encore effectuer une transformation possibilités/probabilités et chercher la variance associée à la distribution de probabilité résultante.

6.4. autres remarques

Du point de vue de l'implémentation algorithmique, la méthode de Kalman est aisée, car elle se réduit à de simples opérations d'arithmétique matricielle. La méthode possibiliste, telle que nous l'avons mise en œuvre, est beaucoup plus lourde. Cette complexité vient principalement de l'application du principe d'extension, même en utilisant la méthode de Dong. Afin d'alléger la méthode possibiliste, on pourrait par exemple utiliser une représentation paramétrique des distributions de possibilités tout en tolérant certaines simplifications du point de vue de la modélisation de données.

On peut noter aussi que la méthode de Kalman utilisée ici correspond à une approche asymétrique (conditionnement séquentiel) puisqu'elle est obtenue à partir des probabilités conditionnelles. La méthode possibiliste adoptée est basée sur une approche symétrique où les solutions locales sont combinées de façon parallèle.

7. conclusion

Nous avons développé une méthode de localisation absolue d'un robot mobile basée sur la théorie de possibilités en utilisant la règle de fusion proposée par Dubois et Prade. Par rapport à la méthode classique du filtrage de Kalman, la méthode possibiliste repose sur une approche différente pour résoudre le problème. En effet, la fusion des informations dans la méthode du filtrage de Kalman peut se voir comme une moyenne pondérée par l'incertitude liée aux informations. Le principe consiste à accorder plus de poids aux informations dont l'incertitude est faible (i.e. variance faible). Il s'agit donc d'une fusion par « minimisation de la variance ». Par contre la règle de combinaison adaptative utilisée dans la méthode possibiliste s'intéresse plus à la redondance des différentes sources en accordant plus de poids aux informations qui se répètent. Il s'agit donc plutôt d'une fusion par « concordance ». Elle n'impose aucune contrainte sur les bruits et la linéarité du processus. Le but des expériences réalisées était ici de comparer dans un cas simple la méthode possibiliste à celle du filtrage de Kalman, considérée comme la référence pour de tels problèmes. On peut en tirer les conclusions suivantes :

- Dans les situations d'informations riches, le filtrage de Kalman est sans conteste supérieur, d'autant plus que ce dernier a été largement favorisé, car toutes les situations aberrantes ont été éliminées *a priori*.

- Par contre, dans le cas de situations pauvres, la méthode possibiliste peut parvenir à de meilleurs résultats.

Des expériences sont en cours pour, d'une part, évaluer les performances des deux méthodes en fonction de la modélisation des erreurs et, d'autre part, manipuler des données conflictuelles. En effet, la méthode possibiliste est conceptuellement dédiée à gérer ces situations (cas qui n'a pas été traité dans cette application).

Annexe : modélisation des bruits

Pour pouvoir appliquer les équations du filtre de Kalman, il faut déterminer les bruits associés aux modèles d'état et d'observation. Pour modéliser le bruit d'état nous avons besoin de comparer le résultat issu des équations du modèle d'état, qui représente l'évolution de l'odométrie, et les positions réelles du robot. On tient compte ainsi aussi bien de l'erreur sur le modèle mathématique

que des glissements des roues du robot. Afin que les mesures soient décorréliées, les estimations trouvées seront en général légèrement majorées.

En fait, pour représenter le bruit des capteurs odométriques, nous avons utilisé le modèle proposé par Opderbecke [Opderbecke 94]. Ce modèle suppose que chaque capteur odométrique est soumis à un bruit blanc d'écart-type σ défini par :

$$\sigma(l) = \sqrt{\sigma_0^2 + (\varepsilon_0 \times l)^2} \quad (17)$$

avec l la distance parcourue par la roue, σ_0 une constante caractérisant l'erreur de quantification des codeurs répartie entre plus ou moins un demi-incrément et ε_0 une constante de proportionnalité avec la distance.

Cette formule est ensuite utilisée pour déterminer l'évolution théorique des écarts type dans le cas d'un mouvement rectiligne :

- Sur l'axe de la trajectoire,

$$\sigma_x(k) = \sigma(\ell_0) \sqrt{\frac{k}{2}}; \quad (18)$$

- Sur l'axe perpendiculaire,

$$\sigma_y(k) = \frac{\sqrt{2}}{D} \times l \times \sigma(\ell_0) \times \sum_{n=1}^k \sqrt{n}; \quad (19)$$

avec k le nombre d'itérations et l_0 la distance parcourue pendant une itération.

Pour valider le modèle, on fait naviguer le robot sur plusieurs trajets rectilignes en répétant plusieurs fois la mesure. On pourra ainsi déterminer la variance (sur l'axe du déplacement et l'axe perpendiculaire) pour chaque distance en assimilant l'erreur à l'écart entre la donnée du modèle odométrique et la position réelle du robot. En effectuant le lissage des données trouvées par les formulations précédentes, on peut déduire une estimation des paramètres σ_0 et ε_0 .

La modélisation du bruit d'observation doit tenir compte d'une part des conditions externes (principalement les conditions de luminosité) et de l'imprécision avec laquelle sont connues les variables d'état (position du robot). Pour ce faire, une campagne de mesures est effectuée pour différentes distances (à chaque fois la mesure considérée est la moyenne d'une dizaine de mesures). Ces mesures sont réalisées aussi bien dans des conditions de luminosité normale que dans le noir, ce qui nous permet d'éliminer à chaque fois la composante liée au bruit de lumière. On détermine aussi (par répétition plusieurs fois de la campagne de mesures) à chaque distance la variance associée. La fonction de lissage permettant de donner la variance pour chaque distance, sera majorée pour tenir compte de l'effet d'imprécision sur les variables d'état.

Ces variances ont également été utilisées dans les applications de simulation pour bruiteur artificiellement les données.

BIBLIOGRAPHIE


- [Dasarathy 97] V. B. Dasarathy, *Sensor fusion potentiel exploitation -innovative architecture and illustrative applications*, Proc. of IEEE Vol. 85, pp. 24-39, 1997.
- [Dubois 88] D. Dubois, H. Prade, *Théorie des possibilités : application à la représentation des connaissances en informatique*, Masson, 1988.
- [Dubois 92] D. Dubois, H. Prade, *Combinaison of fuzzy information in the framework of possibility theory*, in *Data Fusion in Robotics and Machine Intelligence*, pp 481-505, M. A. Abidi et R. C. Gonzalez, Academic press, 1992.
- [Dubois 94] D. Dubois, H. Prade, *Possibility theory and data fusion in poorly informed environments*, Control Engineering Practice, vol. 2, pp 811-823, 1994.
- [Durieu 96] C. Durieu, M. J. Aldon, D. Meizel, *La fusion de données multisensorielle pour la localisation en robotique mobile*, Traitement de Signal, vol.13, n°2, pp. 144-165, 1996.
- [Dong 87a] W.M. Dong, F.S. Wong, *Fuzzy weighted averages and implementation of the extension principle*, Fuzzy Sets and Systems Vol. 21, pp 183-199, 1987.
- [Dong 87b] W.M. Dong, H.C. Shah, *Vertex method for computing functions of fuzzy variables*, Fuzzy Sets and Systems Vol. 24, pp. 65-78, 1987.
- [Hall 97] D. Hall, J. Llinas, *An introduction to multisensor data fusion*, Proc. of IEEE, pp.112-148, pp. 6- 23, 1997.

- [Klir 88] G. J. Klir, T. A. Folger, *Fuzzy sets uncertainty and information*, Prentice Hall, 1988.
- [Maaref 98] H. Maaref, M. Oussalah, C. Barret, *Vers une règle de combinaison progressive dans le cadre de la théorie des possibilités*, LFA'98, Rennes, 1998.
- [Mondada 93] F. Mondada, E. Franzi, P. Lenne, *Mobile robot miniaturization : a tool for investigation in control algorithms*, Int. Symposium on Experimental Robotics, Kyoto, Japan, 1993.
- [Opderbecke 94] J.Opderbecke, *Localisation d'un robot mobile par fusion de données multisensorielles dans un environnement structuré*, Thèse de Doctorat de l'Université de Paris VI, janvier 1994.
- [Zadeh 65] L. A. Zadeh, *Fuzzy sets*, Information and Control, Vol. 8, pp 338-353, 1965.
- [Zadeh 75] L. A. Zadeh, *The concept of linguistic variable and its application to approximate reasoning*, Partie 1, 2 et 3, Informations Sciences 8 (pp 199-249 et 301-357) et 9 (pp 43-80), 1975.
- [Zadeh 78] L. A. Zadeh, *Fuzzy sets as a basis for a theory of possibility*, Fuzzy Sets and Systems, Vol. 1, pp 3- 28, 1978.
- [Zunino 97] G. Zunino, A.M. Jolly-Desodt, D. Jolly, *Une nouvelle règle adaptative de fusion de données imparfaites*; AGIS'97, Angers, 1997

Manuscrit reçu le 2 avril 1998.


LES AUTEURS

Hichem MAAREF



Hichem Maaref est docteur es-sciences depuis 1990. Il est actuellement maître de conférences à l'université d'Evry Val d'Essonne. Ses travaux de recherche au sein du groupe Systèmes Complexes du CEMIF s'intéressent aux méthodes de traitement des données imprécises et incertaines et à leurs applications à la navigation de robots mobiles autonomes et à la fusion multisensorielle.

Mourad OUSSALAH



Mourad Oussalah est titulaire d'un DEA SPI (1994) de l'université de Créteil et d'un doctorat en robotique obtenu en 1998 à l'université d'Evry Val d'Essonne. Il est actuellement en post-doc à l'université de Leuven et travaille dans le cadre du projet Action Sensing. Ses travaux de recherche traitent des problèmes liés à la modélisation de connaissances, à l'identification et à la gestion de l'incertitude ainsi qu'à la fusion de l'information.

Claude BARRET



Claude Barret est docteur d'Etat en Electronique de l'Université d'Orsay (1981). Depuis 1985 il est professeur à l'université d'Evry Val d'Essonne où il dirige principalement au sein du laboratoire CEMIF les activités concernant le contrôle flou, le traitement de données imprécises et incertaines et la modélisation par apprentissage.