

INITIALISATION SANS RETARD D'AMERS SLAM PAR MESURES ANGULAIRES

Joan SOLÀ*

Directeurs de thèse : André MONIN et Michel DEVY

Laboratoire d'accueil :
LAAS - CNRS

Etablissement d'inscription :
Institut National Polytechnique de Toulouse

Résumé

En robotique mobile, on appelle SLAM (de l'anglais Simultaneous Localization And Mapping) le problème de la construction d'une carte de l'environnement simultanée à la localisation. La grande majorité des solutions existantes utilisent des capteurs qui observent l'environnement en fournissant à chaque instant directions et distances aux amers perçus. Lors de l'utilisation de caméras vidéo, ces distances ne sont plus disponibles, et l'observabilité s'obtient par l'acquisition séquentielle dans le temps de mesures prises en différents points de vue ce qui conduit naturellement à des systèmes à retards. Nous proposons une méthode originale pour inclure l'information disponible initialement, même si celle-ci n'est que partielle, permettant une utilisation immédiate, pour une meilleure localisation.

Mots-clés

SLAM, vision, observabilité partielle, initialisation sans retard

1 INTRODUCTION

Le problème de la modélisation de l'environnement simultanée à la localisation est fondamental en robotique mobile. Il consiste à construire de façon incrémentale une carte de l'environnement et à s'y localiser simultanément. La solution originale [Smith 87] utilisait un Filtre de Kalman Étendu (FKE) pour fusionner les données acquises par des scanners laser ou d'autres capteurs d'angle et de distance. On nomme cette technique SLAM-FKE à Observabilité Totale.

Aujourd'hui, il existe beaucoup d'autres techniques très performantes qui arrivent à travailler en temps réel, dans des environnements très larges et en trois dimensions. Mais elles reposent sur l'utilisation de capteurs qui ne sont pas trop indiqués : les scanners laser sont chers, grands, délicats et lourds. Par contre, une simple caméra vidéo peu chère, robuste, fiable et petite nous fournit une immense quantité d'information spatiale. Le prix que l'on en paye est la perte d'une dimension du monde que nous souhaitons observer : la distance aux objets perçus. L'utilisation d'un tel capteur, qui ne peut mesurer que des directions dans l'espace, conjointement avec un noyau de fusion du type FKE, nous amène au SLAM-FKE par Mesures Angulaires (SLAM-FKE-MA).

Une des opérations les plus délicates dans le SLAM-FKE-MA est l'initialisation des amers –leur introduction dans la carte. Le FKE a besoin des représentations Gaussiennes de toutes les variables aléatoires de la carte (la position et l'orientation du robot et la position de chacun des amers). En plus, leurs variances doivent être petites pour bien approcher les différentes fonctions non linéaires impliquées dans le système par des morceaux linéaires. À partir d'une seule observation d'un amer il n'est pas possible de définir un estimé de sa position qui respecte cette règle fondamentale. Cette estimation est seulement possible via des mesures successives depuis différents points de vue, au moment où l'on aura accumulé une base suffisante pour une bonne triangulation (Fig. 1).

*jsola@laas.fr

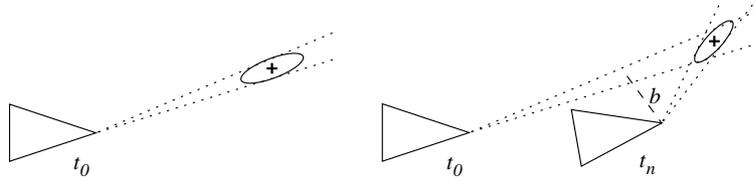


FIG. 1: Initialisations d’amers. *Gauche* : Immédiate en SLAM à Observabilité Totale. *Droite* : Par triangulation en SLAM par Mesures Angulaires. La base est marquée b .

Ce raisonnement conduit naturellement à des systèmes qui doivent *attendre* jusqu’à ce que cette base soit disponible. La réf. [Davison 03] utilise un Filtre Particulaire pour estimer la distance, qui n’est pas corrélée avec le reste de la carte. L’initialisation est reportée au moment où la variance sur cette distance est suffisamment petite pour permettre une représentation gaussienne. Dans [Bailey 03], des positions passées du robot sont stockées dans la carte, avec ses observations associées, et un test de gaussiennité est évalué sur la Fonction de Distribution de Probabilité (FDP) de la position de l’amer résultante de combiner la première et la dernière mesure. L’initialisation est aussi retardée au moment où ce test est validé, et toutes les autres mesures sont alors utilisées pour raffiner et corriger la carte entière. Ces méthodes souffrent de deux inconvénients : elles ont besoin d’un critère pour décider si la base est suffisante, et elles introduisent un retard à l’initialisation.

L’élimination du critère et du retard s’avère un sujet intéressant. Le critère est très souvent lourd à calculer, et le système devient plus robuste sans lui car on évite des décisions binaires irréversibles. Sans le retard, nous aurons à disposition des informations sur l’amer, même partielles, qui pourront être utilisées comme des références angulaires. Nous aurons aussi la possibilité d’inclure des amers qui se trouvent très proches de l’axe d’avancement du robot, pour lesquels la base mettrait trop de temps à grossir. Ce dernier point est très important pour des applications en extérieurs dans lesquelles les véhicules suivent des trajectoires rectilignes et les caméras regardent naturellement en avant.

Le seul travail qui propose une méthode sans retard dont on a connaissance est [Kwok 04]. Il définit un ensemble d’hypothèses sur la position de l’amer le long du rayon optique sur lequel il a été observé pour la première fois, et il les inclut toutes dans la carte comme s’il s’agissait d’amers différents. Dans les observations postérieures, l’hypothèse la plus vraisemblable va être utilisée pour la correction, et un Test de Rapports Séquentiel va permettre d’en rejeter les fausses. La solution est très proche de celle proposée dans cet article, mais l’approche n’est pas justifiée, la façon dont les hypothèses sont initialisées n’est pas précisée, et des questions fondamentales de convergence et consistance de la solution ne sont pas abordées, même pas mentionnées.

On va montrer que la solution propre au problème d’initialisation sans retard implique l’abandon du FKE (Fig. 2 *gauche*) et que, tout en suivant un raisonnement multi-hypothèse, il nous conduit à la création d’un ensemble pondéré de cartes, une pour chaque hypothèse (Fig. 2 *centre*), qui devra être traité avec des algorithmes de Filtrage à Somme de Gaussiennes (FSG) [Alspach 72], pour lesquels la complexité de calcul grossit de manière multiplicative avec le nombre d’hypothèses. Cette solution est intraitable en temps réel et en conséquence elle ne pourra jamais être embarquée dans un vrai robot.

La méthode que l’on présente est une approximation au FSG permettant une initialisa-

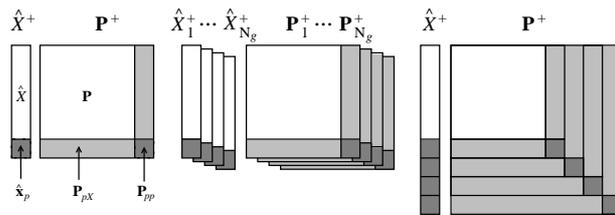


FIG. 2: Initialisations d’amers. *Gauche* : SLAM-FKE ; *Centre* : SLAM-FSG ; *Droite* : SLAM-PFI.

tion non retardée avec un grossissement seulement additif de la taille du problème (Fig. 2 droite). À la première observation d'un amer, le robot ne connaît que le rayon optique où il se trouve. Ce rayon, avec ses variances associées, définit une FDP conique. Celle-ci est approchée de manière minimale par une série géométrique de gaussiennes, qui sont introduites dans la carte sous forme d'amers différents. Comme approximation à la solution multi-carte, cette représentation mono-carte souffre des risques d'*inconsistance* et *divergence*, que l'on discute. Pour les minimiser nous introduisons le Partage Fédératif de l'Information (PFI), qui constitue la contribution principale de ce travail. Finalement nous définissons un critère simple et conservateur pour éliminer les faux membres du rayon. On présente quelques résultats des simulations pour illustrer la pertinence de la méthode.

La suite de l'article est la suivante. La section 2 donne la base nécessaire et pose le problème. Les contributions sont développées en section 3. La section 4 présente les résultats des simulations et l'article termine avec une discussion en section 5.

2 LA PROBLÉMATIQUE DE L'INITIALISATION

2.1 UN PEU DE SLAM-FKE À OBSERVABILITÉ TOTALE

La carte SLAM est représentée par un vecteur aléatoire contenant la position et l'orientation du robot et la position de chacun des amers :

$$X = \begin{bmatrix} X_v \\ X_M \end{bmatrix} \quad (1)$$

où $X_v^\top = [\mathbf{r}_v^\top, \mathbf{q}_v^\top]$ est l'état du robot contenant position et orientation et $X_M^\top = [\mathbf{x}_1^\top, \dots, \mathbf{x}_n^\top]$ est l'ensemble des positions des amers. Dans un cadre FKE, la densité *a posteriori* est approchée par une gaussienne avec moyenne et matrice des covariances¹ définies par

$$\hat{X} = \begin{bmatrix} \hat{X}_v \\ \hat{X}_M \end{bmatrix} \quad \mathbf{P} = \begin{bmatrix} \mathbf{P}_{vv} & \mathbf{P}_{vM} \\ \mathbf{P}_{Mv} & \mathbf{P}_{MM} \end{bmatrix} \quad (2)$$

Les fonctions d'évolution du robot et d'observation de l'amer i sont²

$$X_v^+ = \mathbf{f}(X_v, \mathbf{u}) \quad \mathbf{y}_i = \mathbf{h}(X_v, \mathbf{x}_i) + v \quad (3)$$

où \mathbf{u} est un vecteur de commandes ou odométrie supposé gaussien de moyenne $\hat{\mathbf{u}}$ et variance \mathbf{U} , et v est un bruit blanc gaussien de variance \mathbf{R} . Les équations de prédiction et correction sont bien celles du FKE :

$$\begin{aligned} \hat{X}_v^+ &= \mathbf{f}(\hat{X}_v, \hat{\mathbf{u}}) & \mathbf{Z}_i &= \mathbf{H}_i \mathbf{P} \mathbf{H}_i^\top + \mathbf{R} \\ \mathbf{P}_{vv}^+ &= \mathbf{F}_v \cdot \mathbf{P}_{vv} \cdot \mathbf{F}_v^\top + \mathbf{F}_u \cdot \mathbf{U} \cdot \mathbf{F}_u^\top & \mathbf{K}_i &= \mathbf{P} \mathbf{H}_i^\top \cdot \mathbf{Z}_i^{-1} \\ \mathbf{P}_{vM}^+ &= \mathbf{F}_v \cdot \mathbf{P}_{vM} & \mathbf{P}^+ &= \mathbf{P} - \mathbf{K}_i \mathbf{Z}_i \mathbf{K}_i^\top \\ \mathbf{P}_{MM}^+ &= \mathbf{P}_{MM} & \hat{X}^+ &= \hat{X} + \mathbf{K}_i \cdot (\mathbf{y}_i - \mathbf{h}(\hat{X}_v, \hat{\mathbf{x}}_i)) \end{aligned} \quad (4)$$

où³ $\mathbf{F}_v = \partial \mathbf{f} / \partial X_v^\top |_{(\hat{X}_v, \hat{\mathbf{u}})}$, $\mathbf{F}_u = \partial \mathbf{f} / \partial \mathbf{u}^\top |_{(\hat{X}_v, \hat{\mathbf{u}})}$ et $\mathbf{H}_i = \partial \mathbf{h} / \partial X^\top |_{(\hat{X})}$.

2.1.1 Initialisation des amers dans SLAM-FKE

L'initialisation consiste à inclure la position de l'amer \mathbf{x}_p dans la carte X selon

$$X^+ = \begin{bmatrix} X \\ \mathbf{x}_p \end{bmatrix} \quad (5)$$

¹Toute matrice de covariances est définie symétrique, d'où $\mathbf{P}_{vM} = \mathbf{P}_{Mv}^\top$. Par la suite et pour n'importe quelle matrice de covariances, on ne fera mention qu'à un seul terme hors la diagonal.

²La notation A^+ se lit *la valeur actualisée de A*, pour A quelconque.

³La barre verticale | se lit *évalué en*.

et à définir la FDP de ce nouvel état –la carte résultante– conditionnée à l’observation \mathbf{y}_p . Cette tâche est facilement aboutie à partir de la première observation donnée par $\mathbf{y}_p = \mathbf{h}(X_v, \mathbf{x}_p) + v$ car toutes les composantes concernées de l’état sont observées. La méthode classique [Newman 99] réalise le changement de variable

$$\mathbf{w}_p = \mathbf{h}(X_v, \mathbf{x}_p) \quad (6)$$

dont on mesure $\mathbf{y}_p = \mathbf{w}_p + v$. Elle définit la fonction \mathbf{g} , inverse de \mathbf{h} , pour obtenir une expression analytique de \mathbf{x}_p

$$\mathbf{x}_p = \mathbf{g}(X_v, \mathbf{w}_p). \quad (7)$$

Dans les cas où \mathbf{P}_{vv} et \mathbf{R} sont petites on peut écrire

$$\mathbf{x}_p \approx \mathbf{g}(\hat{X}_v, \mathbf{y}_p) + \mathbf{G}_v(X_v - \hat{X}_v) + \mathbf{G}_w(\mathbf{w}_p - \mathbf{y}_p) \quad (8)$$

avec $\mathbf{G}_v = \partial \mathbf{g} / \partial X_v^\top |_{(\hat{X}_v, \mathbf{y}_p)}$ et $\mathbf{G}_w = \partial \mathbf{g} / \partial \mathbf{w}_p^\top |_{(\hat{X}_v, \mathbf{y}_p)}$. On peut alors considérer \mathbf{x}_p approximativement gaussienne avec moyenne et covariances définies par

$$\begin{aligned} \hat{\mathbf{x}}_p &= \mathbf{g}(\hat{X}_v, \mathbf{y}_p) \\ \mathbf{P}_{pX} &= \mathbf{G}_v \cdot \mathbf{P}_{vX} \\ \mathbf{P}_{pp} &= \mathbf{G}_v \cdot \mathbf{P}_{vv} \cdot \mathbf{G}_v^\top + \mathbf{G}_w \cdot \mathbf{R} \cdot \mathbf{G}_w^\top \end{aligned} \quad (9)$$

où $\mathbf{P}_{vX} = [\mathbf{P}_{vv} \quad \mathbf{P}_{vM}]$. La FDP de la carte augmentée est finalement spécifiée par

$$\hat{X}^+ = \begin{bmatrix} \hat{X} \\ \hat{\mathbf{x}}_p \end{bmatrix} \quad \mathbf{P}^+ = \begin{bmatrix} \mathbf{P} & \mathbf{P}_{pX}^\top \\ \mathbf{P}_{pX} & \mathbf{P}_{pp} \end{bmatrix}. \quad (10)$$

2.2 SLAM-FSG : L’APPROCHE EXACT EST INTRAITABLE

Nous montrons que l’initialisation non retardée nous amène au FSG. Dans le cas des observations uniquement angulaires les mesures n’ont pas d’informations de distance et la procédure d’initialisation n’est plus si simple. Nous séparons la partie métrique⁴ s de l’angulaire \mathbf{b}_p et écrivons

$$\mathbf{w}_p = \begin{bmatrix} \mathbf{b}_p \\ s \end{bmatrix} \quad (11)$$

de sorte que la mesure est maintenant $\mathbf{y}_p = \mathbf{b}_p + v$. Cela nous conduit à la redéfinition de \mathbf{g}

$$\mathbf{x}_p = \mathbf{g}(X_v, \mathbf{b}_p, s) \quad (12)$$

où tout excepte la métrique s peut être considéré gaussien.

Les valeurs *a priori* de s couvrent l’intervalle $s \in (0, \infty)$, mais les connaissances sur l’application courante peuvent le réduire à $s \in [s_{min}, s_{max}]$. Cet intervalle définit une FDP uniforme $p(s)$ qui n’est suffisamment petite pour permettre des linéarisations de \mathbf{g} , et la méthode d’initialisation du SLAM-FKE n’est plus valable. Pour résoudre le problème nous devons définir une nouvelle représentation non gaussienne pour $p(s)$ et chercher une alternative au FKE pour la gérer. Nous proposons l’approximation par somme de gaussiennes

$$p(s) \approx \sum_{j=1}^{N_g} c_j \cdot \Gamma(s - s_j; \sigma_j^2) \quad (13)$$

où $\Gamma(s - s_j; \sigma_j^2) = \exp(-(s - s_j)^2 / 2(\sigma_j^2)) / \sqrt{2\pi}\sigma_j$.

L’approximation à somme de gaussiennes peut être regardée comme une distribution à deux niveaux. D’abord on doit choisir j avec probabilité $P(j) = c_j$ et, conditionnellement

⁴La grandeur non observée n’est pas forcément une distance. Dans le cas de la vision, par exemple, elle est normalement une profondeur. Pour regrouper les différentes interprétations on utilisera le substantif *métrique*.

à j , la métrique s est gaussienne avec moyenne s_j et variance σ_j^2 . Alors, on peut construire une carte gaussienne pour l'hypothèse j qui contient un amer \mathbf{x}_p^j à une certaine métrique s_j . Avec (12) et la procédure vue en 2.1.1 nous obtenons

$$\begin{aligned}\hat{\mathbf{x}}_p^j &= \mathbf{g}(\hat{X}_v, \mathbf{y}_p, s_j) \\ \mathbf{P}_{pX}^j &= \mathbf{G}_v^j \mathbf{P}_{vX} \\ \mathbf{P}_{pp}^j &= \mathbf{G}_v^j \mathbf{P}_{vv} \mathbf{G}_v^{j\top} + \mathbf{G}_b^j \mathbf{R} \mathbf{G}_b^{j\top} + \mathbf{G}_s^j \sigma_j^2 \mathbf{G}_s^{j\top}\end{aligned}\quad (14)$$

avec $\mathbf{G}_v^j = \partial \mathbf{g} / \partial X_v |_{(\hat{X}_v, \mathbf{y}_p, s_j)}$, $\mathbf{G}_b^j = \partial \mathbf{g} / \partial \mathbf{b}_p |_{(\hat{X}_v, \mathbf{y}_p, s_j)}$ et $\mathbf{G}_s^j = \partial \mathbf{g} / \partial s |_{(\hat{X}_v, \mathbf{y}_p, s_j)}$. La carte hypothétique j est alors

$$\hat{X}_j = \begin{bmatrix} \hat{X} \\ \hat{\mathbf{x}}_p^j \end{bmatrix} \quad \mathbf{P}_j = \begin{bmatrix} \mathbf{P} & \mathbf{P}_{pX}^{j\top} \\ \mathbf{P}_{pX}^j & \mathbf{P}_{pp}^j \end{bmatrix}\quad (15)$$

et la FDP de la carte résultante est la somme pondérée des cartes gaussiennes

$$p(X^+ | \mathbf{y}_p) = \sum_{j=1}^{N_g} c'_j \cdot \Gamma(X^+ - \hat{X}_j; \mathbf{P}_j).\quad (16)$$

Notons que l'on aura N_g cartes pour chaque nouvel amer à initialiser, et on aura N_g^m cartes dans le cas de l'initialisation de m amers. La gestion d'une telle carte nous obligerait à utiliser le FSG standard, mais le grossissement multiplicatif de la taille du problème rend cette solution intraitable.

3 SLAM PAR PARTAGE FÉDÉRATIF DE L'INFORMATION

Il nous faut trouver une alternative au FSG qui soit de complexité acceptable. Pour cela, et toujours dans le même raisonnement multi-hypothèse, nous pouvons considérer que chaque hypothèse sur la distance correspond à un amer différent. Nous pouvons alors les initialiser tous dans la même carte gaussienne en utilisant la méthode standard pour le SLAM-FKE de la section 2.1.1. Le résultat est une carte qui a grossi de manière additive, dont on a évité l'indésirable effet multiplicatif.

Tout a l'air bien. Mais le problème arrive lors du traitement des observations postérieures de l'amer : on ne sait pas quelle hypothèse est la bonne. Toutes se trouvent dans la même carte, corrélées avec le reste d'informations modélisées, et l'utilisation des observations pour corriger en utilisant ces mauvaises hypothèses peut conduire à la divergence de toute la carte, effet catastrophique qui est en plus irréversible. Alternativement, le FKE exigeant des bruits d'observation mutuellement décorrelés, l'utilisation de la même mesure pour corriger sur chaque hypothèse rendra la carte inconsistante.

La méthode PFI proposée s'appuie sur des évaluations de vraisemblance pour pondérer l'effet des différentes corrections. Elle permet la minimisation des risques de divergence et d'inconsistance. La vraisemblance accumulée est aussi utilisée pour détecter et éliminer les fausses hypothèses.

Nous allons d'abord proposer une représentation minimale pour la FDP de la métrique non observée qui va minimiser le nombre d'hypothèses. Ensuite nous allons détailler la méthode d'initialisation PFI, qui pourrait être vue comme un raccourci pour la méthode plus propre du SLAM-FSG.

3.1 LE RAYON : UNE SÉRIE GÉOMÉTRIQUE DE GAUSSIENNES

Nous souhaitons une représentation minimale de (13). Pour cela, observons la réalisation générale de (7)

$$\mathbf{x}_p = \mathbf{r}_v + s \cdot \mathbf{R}_v(\mathbf{q}_v) \cdot \text{dir}(\mathbf{b}_p)\quad (17)$$

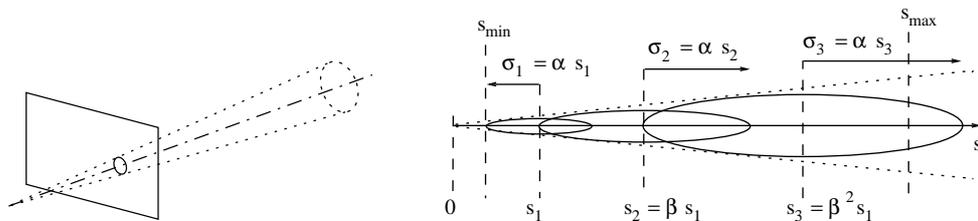


FIG. 3: Le rayon conique : une série géométrique de gaussiennes

où $\text{dir}(\mathbf{b}_p)$ est un vecteur directeur dans le repère du robot défini par \mathbf{b}_p ; $\mathbf{R}_v(\mathbf{q}_v)$ est la matrice de rotation associée à l'orientation du robot; et s est la métrique non connue.⁵ Notons que \mathbf{b}_p est inversement proportionnel à s . Il est montré en [Kronham 98, Peach 95] que dans ces cas le FKE n'est pertinent que pour des ratios $\alpha_j = \sigma_j/s_j$ suffisamment petits (jusqu'à 30% en pratique), car ils déterminent la validité des linéarisations. Cela se satisfait en définissant $p(s)$ comme série géométrique de gaussiennes avec $\alpha_j = \alpha = \text{constante}$:

$$p(s) = \sum_{j=1}^{N_g} c_i \cdot \Gamma(s - \beta^{j-1} s_1, (\beta^{j-1} \sigma_1)^2). \quad (18)$$

Un aperçu de la série avec ses paramètres est montré dans la Fig. 3. À partir des limites $[s_{min}, s_{max}]$ et les choix du ratio α et de la base géométrique β , nous devons déterminer le premier terme (s_1, σ_1) et le nombre de termes N_g . On impose les conditions $s_1 - \sigma_1 = s_{min}$ et $s_{N_g} + \sigma_{N_g} \geq s_{max}$ pour obtenir

$$\begin{aligned} s_1 &= (1 - \alpha)^{-1} \cdot s_{min} \\ \sigma_1 &= \alpha \cdot s_1 \\ N_g &= 1 + \text{ceil} \left[\log_{\beta} \left(\frac{1 - \alpha}{1 + \alpha} \cdot \frac{s_{max}}{s_{min}} \right) \right] \end{aligned} \quad (19)$$

où $\text{ceil}(x)$ est l'entier immédiatement supérieur à x .

La base géométrique β détermine l'uniformité de la série. La Fig. 4 montre des FDP obtenues pour différents valeurs de α et β . Une discussion plus détaillée sur l'effet de ces paramètres a été réalisée en parallèle avec ce travail et peut se trouver dans [Lemaire 05]. Le couple $(\alpha, \beta) = (0.3, 3)$ définit une série qui se trouve un peu loin de la distribution uniforme original, mais l'expérience nous a montré que les performances globales ne sont pas dégradées et le nombre de termes est ainsi minimisé.

La Table 1 montre le nombre de gaussiennes pour trois applications typiques. Notez comme, grâce à la série géométrique, augmenter le rapport s_{max}/s_{min} par un facteur 10 implique juste l'addition de deux membres.

3.2 LA GESTION DE LA CARTE SLAM

Bien que l'amer soit introduit dans la carte sous forme de rayon, l'objectif du SLAM-PFI est d'arriver à déterminer sa position sous forme d'une seule gaussienne. Entre-temps, on

⁵Soient $\mathbf{b}_p = (u, v)$ les coordonnées métriques d'un pixel dans une caméra à distance focale f . Nous avons $\text{dir}(\mathbf{b}_p) = [u/f, v/f, 1]^T$. La métrique s correspond à la profondeur de l'amer.

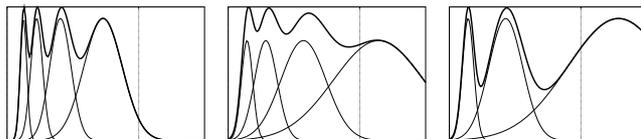


FIG. 4: Distributions géométriques pour $s_{min}/s_{max} = 10$: Gauche : $(\alpha, \beta) = (0.2, 1.8)$. Centre : $(\alpha, \beta) = (0.3, 2)$. Droite : $(\alpha, \beta) = (0.3, 3)$. La ligne pointillée est placée à s_{max} .

TAB. 1: Nombre de gaussiennes pour $\alpha = 0.3$ et $\beta = 3$.

<i>Scenario</i>	s_{min} (m)	s_{max} (m)	$\frac{s_{max}}{s_{min}}$	N_g
Intérieur	0.5	5	10	3
Extérieur	1	100	100	5
Longue portée	1	1000	1000	7

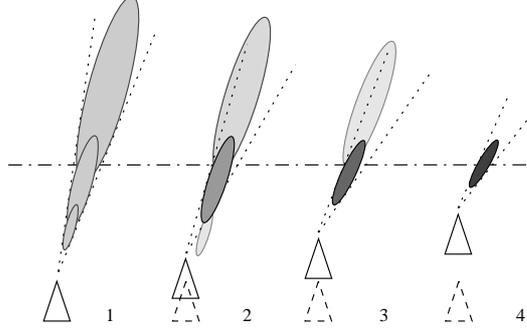


FIG. 5: Corrections du rayon en 4 poses consécutives. Le niveau de gris indique la Vraisemblance Accumulée utilisée pour détecter les fausses hypothèses. La ligne en point et trait est la vraie métrique de l'amer.

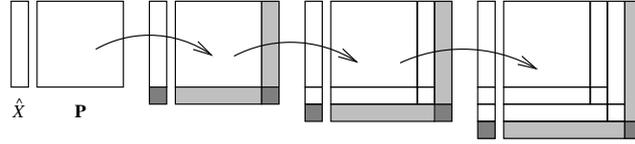


FIG. 6: Initialisation séquentielle du rayon pour $N_g = 3$. Chaque flèche représente une initialisation du type SLAM-FKE.

peut utiliser l'information angulaire que ce rayon nous donne. Les opérations spécifiques au SLAM-PFI sont regroupées en trois étapes : l'inclusion de tous les membres du rayon dans la carte; les postérieures corrections en utilisant le Partage Fédératif de l'Information; et l'élimination successive des mauvais termes. La Fig. 5 donne un aperçu compact du procédé.

3.2.1 Initialisation itérative du rayon

Comme on l'a déjà indiqué, nous introduisons toutes les hypothèses qui forment le rayon dans une seule carte gaussienne. Tous les membres sont empilés dans le même vecteur d'état aléatoire comme s'ils représentaient des amers différents :

$$X^{+\top} = \begin{bmatrix} X^\top & \mathbf{x}_p^{1\top} & \dots & \mathbf{x}_p^{N_g\top} \end{bmatrix} \quad (20)$$

Une méthode itérative est utilisée pour construire sa moyenne et sa covariance (Fig. 6). Les membres sont empilés d'un en un en appliquant de forme itérative la méthode du SLAM-FKE en section 2.1.1, dont le couple $\{s_j; \sigma_j^2\}$ est considéré comme une mesure de la métrique. Le résultat est :

$$\hat{X}^+ = \begin{bmatrix} \hat{X} \\ \hat{\mathbf{x}}_p^1 \\ \vdots \\ \hat{\mathbf{x}}_p^{N_g} \end{bmatrix} \quad \mathbf{P}^+ = \begin{bmatrix} \mathbf{P} & \mathbf{P}_{pX}^{1\top} & \dots & \mathbf{P}_{pX}^{N_g\top} \\ \mathbf{P}_{pX}^1 & \mathbf{P}_{pp}^1 & & \\ \vdots & & \ddots & \\ \mathbf{P}_{pX}^{N_g} & & & \mathbf{P}_{pp}^{N_g} \end{bmatrix}. \quad (21)$$

Initialement, toutes les hypothèses ont la même crédibilité et leur poids doit être uniforme. Nous discuterons plus en avant l'évolution de ces poids, qui vont refléter la Vraisemblance

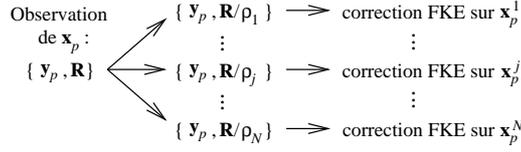


FIG. 7: Corrections de la carte via Partage Fédératif de l'Information

Accumulée (VA) de chaque hypothèse avec les observations. Pour l'instant limitons nous à écrire le vecteur uniforme des VA que l'on doit initialiser associé au nouveau rayon :

$$\Lambda = [\Lambda_1 \quad \cdots \quad \Lambda_{N_g}] \quad ; \quad \Lambda_j = 1/N_g. \quad (22)$$

3.2.2 Corrections de la carte par Partage Fédératif de l'Information

Celle-ci est l'étape la plus délicate. Nous avons une carte complètement corrélée avec toutes les hypothèses dedans, de manière qu'une correction sur une hypothèse a un effet sur toute la carte. Si cette hypothèse est fausse, cet effet pourra faire *diverger* la carte.

Naturellement, on aimerait utiliser l'observation pour corriger la carte à la bonne hypothèse. Comme on ne la connaît pas, on est obligés d'agir sur chacune d'elles. Cela implique le risque d'*inconsistance* : si l'on incorpore la même information plusieurs fois (rappel que l'on a une unique observation pour toutes les hypothèses!), la covariance \mathbf{P} de la carte va diminuer selon l'application multiple des équations de correction (4), fait qui conduit à une surestimation de X .

La méthode proposée s'inspire du Filtre Fédératif (FF) en [Foxlin 02] pour gérer ces problèmes. Le FF est un filtre de Kalman décentralisé qui permet un traitement parallélisé de l'information. Dans le cas où cette information vient d'une unique source, comme c'est le cas, le FF applique le Principe de Reproduction des Mesures [Tupysev 98] pour surmonter l'*inconsistance*. Ce principe peut se résumer comme suite : La correction de l'estimation d'une variable aléatoire par un ensemble de couples $\{\mathbf{y}; \mathbf{R}_j\}$ est équivalente à une correction unique par $\{\mathbf{y}; \mathbf{R}\}$ si

$$\mathbf{R}^{-1} = \Sigma \mathbf{R}_j^{-1} \quad (23)$$

C'est ce qui est fait par le PFI. L'idée (Fig. 7) est de partager l'information fournie par le couple d'observation $\{\mathbf{y}_p; \mathbf{R}\}$ entre toutes les hypothèses. En prenant $\mathbf{R}_j = \mathbf{R}/\rho_j$, la condition (23) se satisfait si $\Sigma \rho_j = 1$.

Le risque de *divergence* est aussi géré par le PFI. Nous avons besoin d'un profil particulier pour ρ_j qui privilège les corrections sur les hypothèses les plus vraisemblables. Un moyen flexible de le faire c'est prendre $\rho_j \propto \lambda_j^n$, où λ_j est la vraisemblance de l'hypothèse j avec l'observation \mathbf{y}_p :

$$\lambda_j = \exp(-0.5 \cdot \mathbf{z}_j \mathbf{Z}_j^{-1} \mathbf{z}_j^\top) / \sqrt{2\pi |\mathbf{Z}_j|} \quad (24)$$

avec $\mathbf{z}_j = \mathbf{y}_p - \mathbf{h}(\hat{X}_v, \hat{\mathbf{x}}_p^j)$, $\mathbf{Z}_j = \mathbf{H}^j \mathbf{P}^j \mathbf{H}^{j\top} + \mathbf{R}$ et $\mathbf{H}^j = \partial \mathbf{h} / \partial X^\top |_{(\hat{X}_v, \hat{\mathbf{x}}_p^j)}$. Ces deux conditions sur ρ_j conduisent à⁶

$$\rho_j = \lambda_j^n / \sum_{i=1}^N \lambda_i^n. \quad (25)$$

Le paramètre n est une mesure du privilège que l'on veut donner aux hypothèses fortes devant les faibles. Des valeurs indiqués sont compris entre $n = 1$ et $n = 3$.⁷

⁶En fait, une autre alternative est utiliser la VA Λ_j , définie dans la section suivante, à la place de λ_j dans le calcul de ρ_j . L'option ici choisie permet de ne pas accumuler des possibles inexactitudes du passé dans cette étape délicate.

⁷Et ne corriger que sur l'hypothèse la plus vraisemblable, comme c'est fait en [Kwok 04], vient à prendre $n \rightarrow \infty$.

3.2.3 Élimination des mauvais membres du rayon

Pour permettre au rayon de se condenser vers une unique gaussienne, nous introduisons un critère pour éliminer les membres à très basse vraisemblance. Ce critère peut se définir très conservateur pour s'assurer de ne pas éliminer des hypothèses valides.

Comme dans le FSG standard, le poids de chaque hypothèse est actualisé à chaque observation avec sa mesure de vraisemblance λ_j . À un instant donné, ce poids intègre tout historique de crédibilité de son hypothèse. C'est pour cette raison que l'on parle de Vraisemblance Accumulée (VA), que l'on note Λ_j . Elle évolue selon

$$\Lambda_j^+ = \Lambda_j \cdot \lambda_j. \quad (26)$$

et elle est ensuite normalisée de sorte que $\sum_j \Lambda_j = 1$.

Nous utilisons un simple seuil sur les VA qui dépend du nombre courant de membres N . On conclut qu'un membre du rayon ne peut correspondre au vrai amer, et à ce moment là on l'efface de la carte, si

$$\Lambda_j < \tau/N \quad (27)$$

où $\tau \in [0.001 \ 0.1]$, typiquement 0.01. Pour des raisons d'efficacité, nous appliquerons les éliminations *avant* les corrections. Quand $N = 1$, on dit que le rayon est *condensé* en une seule gaussienne et nous nous retrouvons de nouveau dans le SLAM-FKE.

4 RÉSULTATS DES SIMULATIONS

Diverses simulations ont été effectuées avec une réalisation à deux dimensions pour valider les méthodes proposées. Les figures suivantes illustrent les résultats de ces simulations. Les vrais amers sont représentés par des petites croix. Des ellipses petites ou élongées représentent la région 3σ pour les estimés gaussiens des amers. Les trajectoires estimées sont dessinées en ligne pointillée.

Trois scénarios différents ont été simulés. Dans le premier (Fig. 8, *gauche*), le robot parcourt une trajectoire circulaire pendant deux tours dans un cloître carré d'environ vingt mètres de largeur, où les colonnes sont les amers. Les vitesses linéaire et angulaire sont 1m/s et 1rad/s respectivement. Les erreurs de l'odométrie sont simulés avec l'addition des bruits blancs correspondants de 0.3m/s et 0.3rad/s. Des mesures angulaires sont acquises tous les 100ms par un capteur qui regarde en avant avec un champ de vue de $\pm 45^\circ$ et une précision de 1° . Le test de consistance (Fig. 8, *droite*) montre la région 3σ de l'estimation de la position du robot versus la vraie erreur.

Le deuxième scénario (Fig. 9, *gauche*) simule un environnement d'extérieur d'une largeur de 180x180m contenant 60 amers distribués aléatoirement. Le robot parcourt une trajectoire circulaire d'environ 80m de diamètre à une vitesse de 2m/s linéaire et 0.05rad/s angulaire. Les erreurs d'odométrie sont 0.3m/s et 0.3rad/s respectivement. Des mesures sont prises tous les 100ms par un capteur angulaire possédant un champ de vue de $\pm 30^\circ$ et une précision de 0.5° . La trajectoire résultante d'intégrer les données de l'odométrie est montrée en ligne de points et traits alternés.

La troisième simulation (Fig. 9, *droite*) utilise le scénario précédant pour réaliser une trajectoire rectiligne.

5 DISCUSSION

Dans ce travail nous avons présenté une méthode à retard nul pour initialiser des amers dans le cadre du SLAM-FKE-MA. On a montré que la solution complète à cette question conduit à une représentation SLAM multi-carte et implique l'adoption des techniques de filtrage à complexité trop élevée. Du fait qu'aujourd'hui un système SLAM doit être conçu pour travailler en temps réel, ces techniques tombent hors d'intérêt. Nous proposons une méthode pour surmonter le problème en générant une représentation mono-carte dont toutes les hypothèses sur la position de l'amer perçu y sont introduites. Cette représentation permet d'être traitée en ligne, mais étant une approximation, elle implique la prise en charge de quelques risques. Ces risques ont été identifiés et examinés dans l'objectif de trouver des

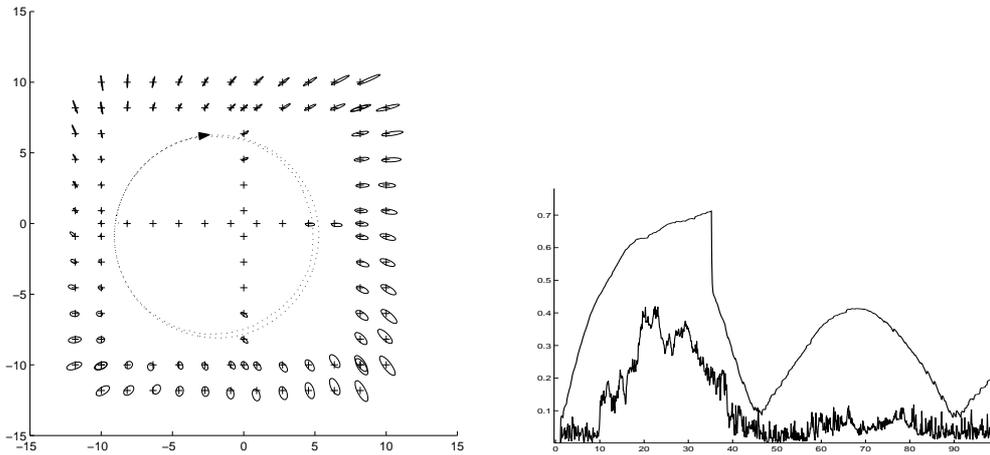


FIG. 8: Simulation d'intérieur. *Gauche* : Boucle fermée circulaire. *Droite* : Test de consistance : Région 3σ de l'estimation de l'erreur sur la position du robot (*haut*) vs. vraie erreur (*bas*).

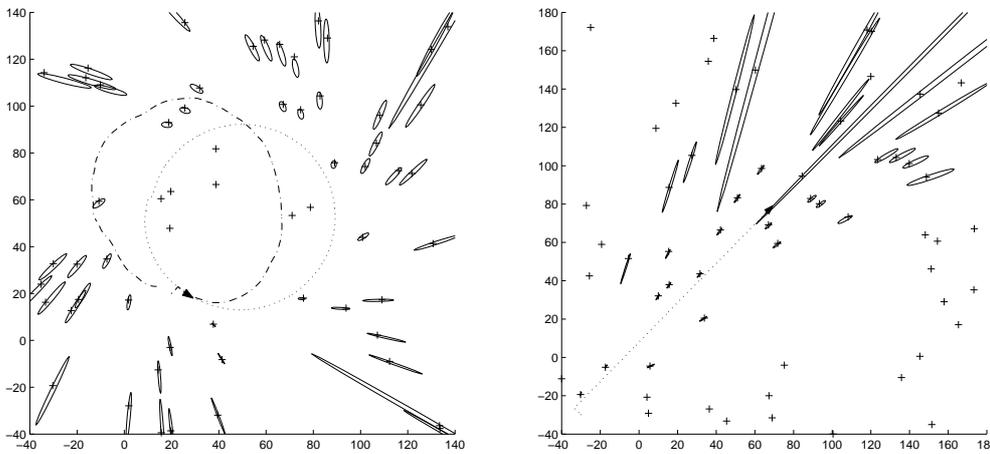


FIG. 9: Simulation dans un environnement d'extérieur large. *Gauche* : Boucle fermée circulaire. *Droite* : Trajectoire droite.

moyens pour les minimiser et rendre les algorithmes proposés suffisamment sûrs pour être utilisés dans des vraies tâches de robotique.

Le degré relativement élevé d'introspection mathématique, qui n'a pas été retrouvé dans beaucoup d'autres travaux sur le sujet, doit permettre la recherche d'autres raccourcis qui pourront éventuellement battre les performances de la méthode SLAM-PFI. Dans cet article nous avons utilisé des idées qui sont à la base du Filtre Fédératif, notamment le Principe de Reproduction des Mesures, avec des résultats excellents. Une autre possibilité que nous avons déjà détecté c'est d'approcher la FDP multi-carte par une mono-carte qui respecte moyenne et covariance originales. Cela conduira à pondérer les gains de Kalman proportionnellement aux VA de chaque hypothèse.

Des simulations ont montré que l'initialisation non retardée est indiquée pour des robots utilisant des caméras avec un champ de vue réduit et qui regardent en la direction d'avancement. Celles-ci sont des situations très délicates qui ont été souvent évitées par les travaux précédents, mais qui s'avèrent très intéressantes pour des applications en extérieurs, non seulement pour des robots mais aussi –et très particulièrement– pour des véhicules intelligents en environnements routiers.

Des expériences réelles utilisant la vision et l'algorithme SLAM-PFI complet en 3D sont en train d'être réalisées. On espère que les résultats vont confirmer la pertinence de ce travail.

Références

- [Alspach 72] D. L. Alspach & H. W. Sorenson. *Nonlinear Bayesian Estimation Using Gaussian Sum Approximations*. In IEEE transactions on automatic control, 1972.
- [Bailey 03] T. Bailey. *Constrained Initialisation for Bearing-Only SLAM*. IEEE International Conference on Robotics and Automation, 2003.
- [Davison 03] A.J. Davison. *Real-Time Simultaneous Localisation and Mapping with a Single Camera*. In Proc. International Conference on Computer Vision, Nice, October 2003.
- [Foxlin 02] E. M. Foxlin. *Generalized Architecture for Simultaneous Localization, Auto-Calibration, and Map-building*. In IEEE/RSJ Conf. on Intelligent Robots and Systems, 2002.
- [Kronham 98] T.R. Kronham. *Bearing Only target motion analysis based on a multihypothesis Kalman Filter and adaptative ownship motion control*. In IEEE Proceedings on Radar Sonar and Navigation, volume 145, pages 247–252, 1998.
- [Kwok 04] N. M. Kwok & G. Dissanayake. *An efficient Multiple Hypothesis Filter for Bearing-Only SLAM*. In IEEE/SRJ International Conference on Intelligent Robotics and Systems, Sendai, Japan, 2004.
- [Lemaire 05] T. Lemaire, S. Lacroix & J. Solà. Experiments with a bearing-only slam algorithm. Unpublished, 2005.
- [Newman 99] Paul Newman. *On the Structure and Solution of the Simultaneous Localisation and Map Building Problem*. Thèse de doctorat, Australian Centre for Field Robotics - The University of Sydney, March 1999.
- [Peach 95] N. Peach. *Bearing-only tracking using a set of range-parametrised extended Kalman filters*. In IEEE Proceedings on Control Theory Applications, volume 142, pages 73–80, 1995.
- [Smith 87] R. Smith & P. Cheeseman. *On the Representation and Estimation of Spatial Uncertainty*. The International Journal of Robotics Research, vol. 5, no. 4, pages 56–68, 1987.
- [Tupysev 98] V. A. Tupysev. *A Generalized Approach to the Problem of Distributed Kalman Filtering*. In AIAA Guidance, Navigation and Control Conference, Boston, 1998.