

PROPOSITION DE SUJET DE THESE

Intitulé : Filtrage particulaire par noyau reproduisant pour la navigation robuste de drones

Référence : **TIS-DTIS-2026-36**
(à rappeler dans toute correspondance)

Début de la thèse : : 01/10/2026

Date limite de candidature : 31/12/2026

Mots clés

Navigation, drone, filtrage particulaire, RKHS

Profil et compétences recherchées

Etudiant grande école d'ingénieurs et universités

Mathématiques Appliquées orientées Probabilités et Statistiques

La navigation autonome des drones constitue un enjeu majeur pour des applications variées, allant de l'inspection d'infrastructures à la logistique, la surveillance environnementale ou encore les opérations en zones contestées. La fiabilité de ces missions dépend directement de la qualité des algorithmes de navigation embarqués, capables de fusionner en temps réel des données issues de capteurs hétérogènes [3].

Pour des missions de courte durée, une navigation inertielle peut suffire. En revanche, sur des durées longues, il devient indispensable d'intégrer des mesures de recalage et d'utiliser des algorithmes de fusion de données robustes. Traditionnellement, cette fusion repose sur le filtre de Kalman étendu (EKF) [3,10], adapté aux systèmes faiblement non linéaires et aux incertitudes gaussiennes. Cependant, ses performances se dégradent lorsque les modèles présentent de fortes non-linéarités, ou lorsque les incertitudes sont non gaussiennes voire multimodales.

Le filtrage particulaire, formalisé dans les années 90 [1,2,11], constitue une alternative intéressante. En s'appuyant sur des méthodes de Monte-Carlo séquentielles, il permet de traiter des distributions arbitraires sans hypothèses restrictives. Toutefois, on observe en pratique des divergences du filtre particulaire dues aux approximations Monte-Carlo successives (surtout lorsqu'il y a incohérence entre la densité prédictive et la vraisemblance) aussi bien dans l'évaluation des intégrales que dans l'étape de ré-échantillonnage [2].

C'est dans ce contexte que les espaces de Hilbert à noyau reproduisant (RKHS) apportent une nouvelle perspective [4–8]. En représentant les distributions de probabilité sous forme de vecteurs (généralement de dimension infinie) dans un espace de Hilbert (kernel mean embeddings), ils permettent de réaliser les mises à jour bayésiennes par de simples opérations linéaires, ce qui offre une formulation plus contrôlée que les approches particulières classiques [4], une représentation précise des incertitudes [5] et des garanties théoriques de consistance et de convergence des estimateurs [6–8]. Par ailleurs, le formalisme RKHS permet de contourner le fléau de la dimension : alors que la précision des méthodes particulières classiques se dégrade rapidement et que le coût de calcul croît fortement avec la dimension de l'espace d'état, l'estimation des embeddings en RKHS bénéficie de bornes d'erreur uniformes et indépendantes de la dimension [9,12,13]. Il devient ainsi possible d'obtenir des performances stables, même dans des espaces d'état de grande dimension, à condition que le noyau choisi capture adéquatement la géométrie intrinsèque des données.

Ces avancées récentes ouvrent la voie à une nouvelle génération de filtres particulaires exploitant la puissance du formalisme RKHS pour la navigation robuste de drones.

Objectifs de la thèse

La thèse visera à développer un nouveau cadre de filtrage particulaire basé sur les RKHS, combinant la robustesse des méthodes de Monte-Carlo face aux erreurs de modèles avec les garanties de convergence théoriques offertes par le formalisme RKHS.

Les principaux objectifs seront :

- Étudier et développer de nouveaux filtres particulaires dans les espaces de Hilbert à noyau reproduisant (RKHS) ;
- Analyse théorique : établir des résultats de consistance, de stabilité et des bornes d'erreur, en exploitant les outils de la Maximum Mean Discrepancy (MMD), de la théorie des noyaux caractéristiques, et en étudiant l'impact du choix du noyau sur le fléau de la dimension ;
- Évaluation numérique : comparer les performances du filtre particulaire RKHS à celles d'un filtre particulaire classique, sur des scénarios représentatifs de navigation de drones (missions longues, pertes GNSS, recalage multimodal).
- Implémentation embarquée et temps réel : étudier les compromis entre précision et coût de calcul à l'aide de méthodes d'approximation modernes, telles que l'inférence variationnelle (mean-field et ses variantes [14]), les approximations low-rank issues des méthodes parcimonieuses pour GPs [15] et approximation de Nyström [16], ou encore les approches plus récentes de type Stein Variational Gradient Descent (SVGD) [17].

Références

- [1] Doucet, A., de Freitas, N., & Gordon, N. (2001). Sequential Monte Carlo Methods in Practice. Springer.
- [2] Ristic, B., Arulampalam, S., & Gordon, N. (2004). Beyond the Kalman Filter: Particle Filters for Tracking Applications. Artech House.
- [3] Gustafsson, F. (2010). Statistical Sensor Fusion. Studentlitteratur.
- [4] Fukumizu, K., Song, L., & Gretton, A. (2013). Kernel Bayes' Rule: Bayesian Inference with Positive Definite Kernels. Journal of Machine Learning Research.
- [5] Song, L., Huang, J., Smola, A., & Fukumizu, K. (2009). Hilbert Space Embeddings of Conditional Distributions with Applications to Dynamical Systems. ICML.
- [6] Kanagawa, M., Fukumizu, K., & Gretton, A. (2016). Filtering with State–Observation Examples via Kernel Monte Carlo Filter. NeurIPS.
- [7] Grunewälder, S., Lever, G., Baldassarre, L., Patterson, S., Gretton, A., & Pontil, M. (2012). Conditional Mean Embeddings as Regressors. ICML.
- [8] Sriperumbudur, B. K., Gretton, A., Fukumizu, K., Schölkopf, B., & Lanckriet, G. R. G. (2010). Hilbert Space Embeddings and Metrics on Probability Measures. JMLR.
- [9] Gretton, A., Borgwardt, K. M., Rasch, M., Schölkopf, B. & Smola, A. (2012). A kernel Two-Sample Test. Journal of Machine Learning Research, 13, 723-773.
- [10] Jazwinski, A. H. (1970). Stochastic Processes and Filtering Theory. Academic Press.
- [11] Kitagawa, G. (1996). Monte Carlo Filter and Smoother for Non-Gaussian Nonlinear State Space Models. Journal of Computational and Graphical Statistics, 5(1), 1–25.
- [12] Lederer, J. (2017). Uniform Error Bounds for Kernel Mean Estimation. Foundations of Computational Mathematics, 17, 971–1010.
- [13] Bach, F. (2017). Breaking the Curse of Dimensionality with Convex Neural Networks. Journal of Machine Learning Research, 18(19), 1–53.
- [14] Blei, D. M., Kucukelbir, A., & McAuliffe, J. D. (2017). Variational Inference: A Review for Statisticians. Journal of the American Statistical Association, 112(518), 859–877.
- [15] Quiñonero-Candela, J., & Rasmussen, C. E. (2005). A Unifying View of Sparse Approximate Gaussian Process Regression. JMLR, 6, 1939–1959.
- [16] Alaoui, A. and Mahoney, M.W. (2015). Fast randomized kernel ridge regression with statistical guarantees. Advances in neural information processing systems (NeurIPS), 28
- [17] Liu, Q., & Wang, D. (2016). Stein Variational Gradient Descent: A General Purpose Bayesian Inference Algorithm. NeurIPS.

Collaborations envisagées

Laboratoire d'accueil à l'ONERA	Directeur de thèse
Département : Traitement de l'information et Systèmes	Nom : Karim Dahia
Lieu (centre ONERA) : Palaiseau	Laboratoire : ONERA DTIS
Contact : Athénais Gautier	Tél. : 01 80 38 66 26
Tél. : 01 80 38 68 22 Email : athenais.gautier@onera.fr	Email : karim.dahia@onera.fr

Pour plus d'informations : <https://www.onera.fr/rejoindre-onera/la-formation-par-la-recherche>