



**HAL**  
open science

# Contributions en commande et estimation pour robots autonomes et systèmes aérospatiaux

Julien Marzat

► **To cite this version:**

Julien Marzat. Contributions en commande et estimation pour robots autonomes et systèmes aérospatiaux. Automatique / Robotique. Université Paris Saclay, 2019. tel-02491926

**HAL Id: tel-02491926**

**<https://theses.hal.science/tel-02491926>**

Submitted on 26 Feb 2020

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

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

# HABILITATION À DIRIGER DES RECHERCHES

## CONTRIBUTIONS EN COMMANDE ET ESTIMATION POUR ROBOTS AUTONOMES ET SYSTÈMES AÉROSPATIAUX

Julien MARZAT

Soutenue publiquement le 18 octobre 2019 devant un jury composé de :

<i>Président</i>	Hugues Mounier	Professeur, CentraleSupélec
<i>Rapporteurs</i>	Philippe Bonnifait	Professeur, Université de Technologie de Compiègne
	Vincent Cocquempot	Professeur, Université de Lille
	Michel Kinnaert	Professeur, Université Libre de Bruxelles
<i>Examineurs</i>	François Guérin	Maître de Conférences, HDR, Université du Havre
	Pascal Morin	Professeur, Université Pierre et Marie Curie



# Salutations scientifiques

Merci à l'ensemble du Jury – Philippe, Vincent, François, Michel, Pascal, Hugues – d'avoir évalué ce travail positivement et pour les échanges constructifs lors de la soutenance. Un grand merci à tous les collègues et étudiants listés ci-dessous, qui ont contribué activement aux travaux décrits dans ce mémoire.

## Chercheurs

Mathieu Balesdent, ONERA  
Anthelme Bernard-Brunel, ONERA  
Sylvain Bertrand, ONERA  
Philippe Bidaud, ONERA  
Frédéric Damongeot, ONERA  
Florian Dietrich, ONERA  
Alexandre Eudes, ONERA  
Bruno Hérissey, ONERA  
Guy Le Besnerais, ONERA  
Julien Moras, ONERA  
Jérôme Morio, ONERA  
Gérard Ordonneau, ONERA  
Hélène Piet-Lahanier, ONERA  
Aurélien Plyer, ONERA  
Jean-Michel Roche, ONERA  
Martial Sanfourche, ONERA  
Ioannis Sarras, ONERA  
Lucien Vingert, ONERA  
Antoine Abauzit, ex-ONERA  
Joseph Defretin, Probayes, ex-ONERA  
Yohan Rochefort, ex-ONERA, Sagem  
Michel Kieffer, L2S CentraleSupélec  
Eric Walter, L2S CentraleSupélec  
Pascal Morin, ISIR Sorbonne Université  
Tiago Gonçalves, ex-ISIR, Thales Research & Technology  
Tarek Raïssi, CNAM  
Nicolas Langlois, IRSEEM

François Farago, CNES  
Marco Galeotta, CNES  
Serge Le Gonidec, ArianeGroup  
Fabio Morbidi, MIS Amiens  
El Mustapha Mouaddib, MIS Amiens  
Yann Dumortier, ex-INRIA, Safran  
Christophe Baujault, ECE Paris  
Frédéric Ravaut, ECE Paris  
François Saïdi, ECE Paris

## **Doctorants et Post-doctorants (anciens et actuels)**

Arthur Kahn, Parrot Drones  
Alessandra Iannetti, ITER  
Hélène Roggeman, EasyMile  
Maxime Derome, Renault  
Duc-Kien Phung  
Elinirina Irena Robinson, NASA  
Camille Sarotte  
Sergio Perez Roca  
Nicolas Merlinge  
Esteban Restrepo-Ochoa  
Guillaume Hardouin

## **Stagiaires**

Noé Bolin, Guillaume Broussin, Denis De Oliveira, Cédric Durantin, Tomasz Gorecki, Sofiane Kraiem, Raphaël Ladousse, Sami Naamane, Gaëtan Pelletier, Nathan Piasco, Mathieu Touchard.

## **Ceux que j’aurais malencontreusement oubliés**

Toutes mes excuses !

## **Remerciements spéciaux**

Vanessa, Victor, c’est aussi pour vous.

# Table des matières

<b>Salutations scientifiques</b>	<b>i</b>
<b>Table des matières</b>	<b>iii</b>
<b>1 Synthèse des activités de recherche</b>	<b>1</b>
1.1 Curriculum Vitae . . . . .	1
1.2 Activités de recherche . . . . .	2
1.3 Participation et coordination de projets . . . . .	6
1.4 Rayonnement scientifique . . . . .	7
1.5 Liste des publications . . . . .	8
1.6 Activités pédagogiques . . . . .	14
<b>2 Diagnostic de défauts et pronostic à base de modèles dynamiques</b>	<b>17</b>
2.1 Health and Usage Monitoring System (HUMS) . . . . .	17
2.2 Diagnostic à base de modèles pour les systèmes aérospatiaux . . . . .	20
2.2.1 Principes . . . . .	20
2.2.2 Méthodes exploitant l'information de commande . . . . .	23
2.2.3 Diagnostic et commande tolérante aux défaillances – application à un modèle de satellite . . . . .	29
2.2.4 Moteur fusée à ergols liquides . . . . .	33
2.3 Pronostic à base de modèles pour les véhicules aéronautiques . . . . .	42
2.3.1 Modélisation probabiliste des incertitudes . . . . .	45
2.3.2 Modélisation par intervalle des incertitudes . . . . .	49
<b>3 Navigation autonome mono et multi-robots</b>	<b>53</b>
3.1 Algorithmes de localisation et cartographie à base de stéréo-vision . . . . .	55
3.2 Commande mono-véhicule . . . . .	59
3.2.1 Exploration autonome d'une zone inconnue par un robot mobile . . . . .	59
3.2.2 Navigation autonome tenant compte de la qualité de la localisation basée vision . . . . .	63
3.2.3 Partenariat Recherche Industrie ONERA-SNCF . . . . .	68

## TABLE DES MATIÈRES

---

3.2.4	Projet Européen FP7 EuRoC . . . . .	77
3.3	Commande multi-véhicules . . . . .	80
3.3.1	Commande prédictive multifonctions pour flottes . . . . .	80
3.3.2	Localisation de source par une flotte . . . . .	84
3.3.3	Localisation collaborative basée vision en formation . . . . .	91
3.3.4	Estimation et guidage coopératif pour suivi de cible . . . . .	94
3.3.5	Projet EDA EuroSWARM . . . . .	96
<b>4</b>	<b>Méthodes d'optimisation et d'estimation à base de krigeage</b>	<b>99</b>
4.1	Algorithmes d'optimisation . . . . .	101
4.1.1	Optimisation robuste au sens du minimax . . . . .	101
4.1.2	Optimisation sous contraintes . . . . .	106
4.2	Estimation à base de krigeage . . . . .	108
4.2.1	Applications en réglage automatique et conception . . . . .	108
4.2.2	Estimation de probabilité d'évènement rare . . . . .	110
4.2.3	Estimateur de dérivées . . . . .	111
	<b>Conclusions et Perspectives</b>	<b>114</b>
	<b>Bibliographie</b>	<b>119</b>

# Chapitre 1

## Synthèse des activités de recherche

### 1.1 Curriculum Vitae

Julien MARZAT

Né le 21/08/1986

Union libre, 1 enfant

- Depuis 2011 : Docteur Ingénieur d'études et de recherches en automatique  
ONERA - The French Aerospace Lab, Palaiseau, France  
Département Traitement de l'Information et Systèmes (DTIS)  
[julien.marzat@onera.fr](mailto:julien.marzat@onera.fr)  
+33 1 80 38 66 50  
Page perso : <http://julien.marzat.free.fr>  
Copernic Lab : <http://www.onera.fr/copernic>  
ONERA DTIS : <https://www.onera.fr/dtis>
- 2008 - 2011 : Doctorant en Automatique, Diagnostic, Systèmes  
ONERA Palaiseau  
DCPS (Conception et évaluation des Performances des Systèmes)  
Laboratoire des Signaux et Systèmes  
(L2S, CNRS - CentraleSupélec - Université Paris Sud XI)  
*Diagnostic des systèmes aéronautiques et réglage automatique pour la comparaison de méthodes*, Thèse soutenue le 4 novembre 2011
- 2008 : Ingénieur ENSEM Nancy  
(Ecole Nationale Supérieure d'Electricité et de Mécanique)  
Option Ingénierie des Systèmes automatisés  
Master Recherche Automatique, Diagnostic, Sécurité (INPL Nancy)  
Stage Ingénieur recherche (*Estimation temps réel du flot optique*)  
à l'INRIA Rocquencourt, équipe IMARA (5 mois)

## 1.2 Activités de recherche

Mes travaux de recherche au **Département Traitement de l'Information et Systèmes (DTIS) de l'ONERA** portent sur les méthodes de commande, d'estimation et d'optimisation numérique appliquées aux robots autonomes et systèmes aérospatiaux. Ces sujets se complètent pour contribuer à la définition et la validation d'algorithmes embarquables sur véhicules terrestres et aériens, afin de leur permettre de réaliser en toute sécurité des missions de plus en plus autonomes et à large échelle. La recherche appliquée conduite dans le département couvre un large spectre de travaux, depuis la définition de concepts et méthodes via des thèses ou des collaborations académiques jusqu'à la réalisation de prototypes et au transfert vers l'industrie ou les donneurs d'ordre étatiques après une montée en TRL<sup>1</sup> de ces développements initiaux (Figure 1.1).

Dans la continuité de ma thèse soutenue en 2011 [1], une activité sur le diagnostic des systèmes à base de modèles dynamiques et d'observateurs d'état se poursuit (Chapitre 2). Ce thème se développe significativement dans l'industrie aérospatiale : nous étudions désormais l'application de ces techniques aux moteurs de fusée à ergols liquides, et nous commençons également à explorer le domaine prometteur du diagnostic prédictif de l'état de santé des systèmes.

Une large part des travaux se consacre aux méthodes de guidage pour les robots autonomes (Chapitre 3), en particulier les mini-drones et robots à roues. Les techniques de commande étudiées reposent principalement sur la commande prédictive non linéaire, dont la flexibilité permet d'aborder de nombreuses problématiques. Les sujets traités sont d'une part la commande coopérative de flottes de véhicules, et d'autre part la commande et le filtrage à partir de mesures issues de multiples capteurs embarqués (stéréovision, centrale inertielle, lidar). En collaboration avec des collègues spécialisés en traitement d'image, nous menons une activité expérimentale en robotique permettant de valider ces approches pour la navigation des robots terrestres et mini-drones en milieu encombré et sans GPS. Cela fait l'objet de nombreuses démonstrations de capacités nouvelles de navigation et vol autonome dans le cadre de projets industriels et de recherche.

Enfin, car l'automatique est fortement liée à l'optimisation de fonctions de coût, nous nous intéressons aux méthodes numériques d'optimisation globale à partir d'un méta-modèle de krigeage et en particulier à leur application au réglage automatique d'algorithmes et au développement de techniques d'estimation (Chapitre 4).

La Figure 1.2 présente la production scientifique en fonction des années (jusqu'à fin 2018), classées suivant les 4 catégories principales qui feront l'objet de la description des travaux : diagnostic et pronostic ; commande mono-véhicule ; commande multi-véhicules ; optimisation et estimation. Le Tableau 1.1 résume les encadrements de thèses passés ou en cours, associés aux thèmes de recherche, et le Tableau 1.2 les encadrements de stages de Master. Les travaux les plus significatifs seront décrits dans les chapitres suivants.

---

1. *Technology Readiness Level*

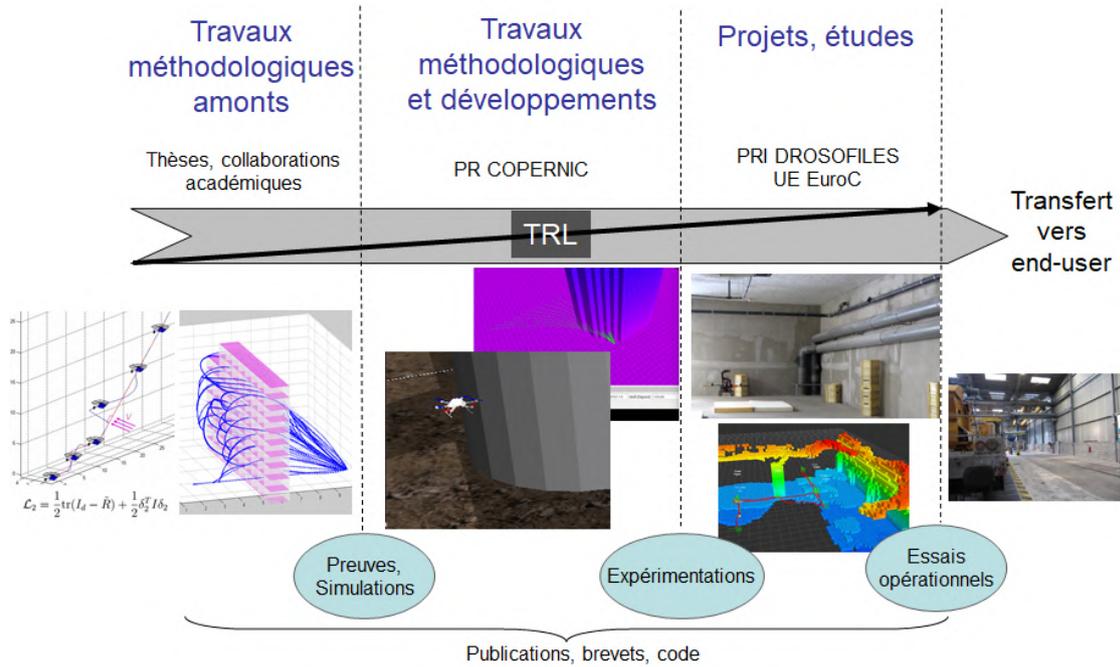


FIGURE 1.1 – Illustration de la démarche de recherche appliquée conduite à l’ONERA (merci à S. Bertrand)

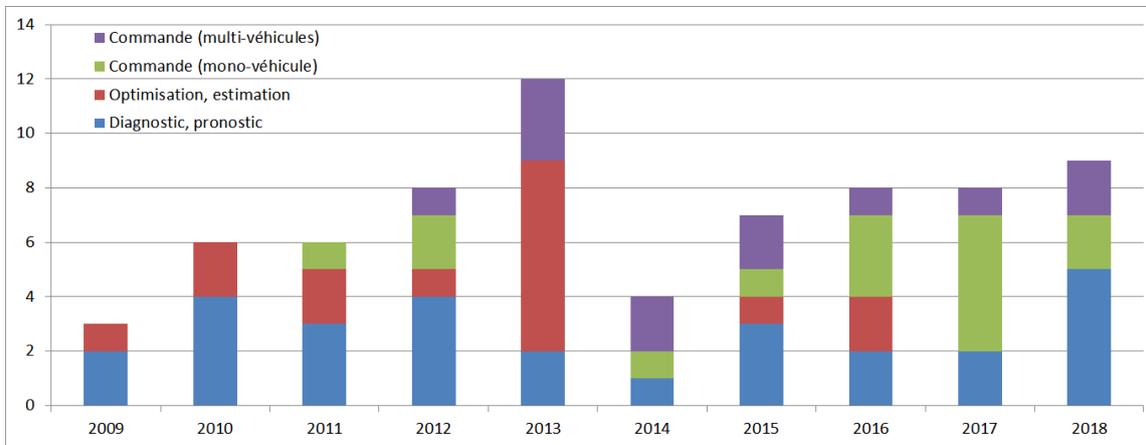


FIGURE 1.2 – Répartition des publications par thématique de recherche

Tableau 1.1 – Encadrements de thèses

Années	Doctorant	Thème et titre	Avancement	Organismes
2012 - 2015	Arthur Kahn	Commande multi-véhicules <i>Commande coopérative reconfigurable pour la recherche d'extremum</i>	Soutenue fin 2015	ONERA, Centrale- Supélec
2013 - 2016	Alessandra Iannetti	Diagnostic et pronostic <i>Méthodes de diagnostic pour un moteur fusée à ergols liquides</i>	Soutenue fin 2016	ONERA, CNES
2014 - 2017	Hélène Roggeman	Commande mono-véhicule <i>Amélioration de performance de la navigation basée vision pour la robotique autonome : une approche par couplage vision/commande</i>	Soutenue fin 2017	ONERA
2015 - 2018	Elinirina Robinson	Diagnostic et pronostic <i>Filtering and uncertainty propagation methods for model-based prognosis</i>	Soutenue fin 2018	ONERA, CNAM
2016 - 2019	Camille Sarotte	Diagnostic et pronostic <i>Amélioration des processus de surveillance et reconfiguration pour les moteurs fusée à ergols liquide</i>	Soutenue fin 2019	ONERA, CNES
2017 - 2020	Sergio Perez Roca	Commande (moteur fusée) <i>Commande en régime transitoire de moteurs fusées</i>	En cours	ONERA, IRSEEM, CNES, Ariane- Group
2018 - 2021	Esteban Restrepo Ochoa	Commande multi-véhicules <i>Coordination multi-objectifs de systèmes multi-drones dans des environnements dynamiques</i>	En cours	ONERA, Centrale- Supélec
2018 - 2021	Guillaume Hardouin	Commande multi-véhicules <i>Scanners RoBotisés pour la Numérisation Automatique du Patrimoine</i>	En cours	ONERA, MIS Amiens

Tableau 1.2 – Encadrements de stages

Année	Stagiaire	Thème(s)	Sujet
2018	Esteban Restrepo-Ochoa (M2, ENSAM)	Commande mono-véhicule	Guidage robuste d'un drone miniature en présence d'obstacles dynamiques
2018	Sofiane Kraiem (M2, ENSEIRB-MATMECA)	Commande mono-véhicule	Système de geofencing local pour drone miniature en espace restreint
2018	Denis De Oliveira (M2, Supaero)	Commande mono-véhicule	Security bubble for UAVs in cluttered environment
2017	Noé Bolin (M1, EC Lyon)	Commande multi-véhicules	Flotte de drones pour l'exploration et la cartographie : expérimentations
2016	Raphaël Ladousse (M2 Paris-Sud)	Commande multi-véhicules	Implémentation de méthodes distribuées de commande d'une flotte de robots
2015	Gaëtan Pelletier (M2 Mines Douai)	Commande multi-véhicules	Développement d'une plateforme multi-robots e-puck
2015	Nathan Piasco (M2 UPMC)	Commande multi-véhicules	Estimation coopérative à base de vision pour un essaim de drones
2015	Elinirina Robinson (M2 ENSIP)	Diagnostic et pronostic	Diagnostic prédictif à base de modèles pour les véhicules aéronautiques
2014	Florian Dietrich (M2 ENSEM)	Commande multi-véhicules	Robotics experiments of advanced cooperative guidance laws
2014	Cédric Durantin (M2 IFMA)	Optimisation, estimation	Constrained Kriging-based optimization
2014	Hélène Roggeman (M2 INPG)	Commande mono-véhicule	MPC-based autonomous exploration with a mobile robot
2013	Mathieu Touchard (M2 INPG)	Commande multi-véhicules	Cooperative guidance of NXT mobile robots
2013	Guillaume Broussin (M2 INSA CVL)	Commande multi-véhicules	Cooperative guidance of NXT mobile robots
2012	Arthur Kahn (M2 UPMC)	Commande multi-véhicules	Cooperative guidance for formation flight
2012	Tomasz Gorecki (M2 Mines Paris)	Commande multi-véhicules	Cooperative guidance for exploration
2011	Sami Naamane (M2 UPMC)	Optimisation, estimation	Kriging-based optimization for Model Predictive Control

### 1.3 Participation et coordination de projets

Le tableau ci-dessous résume les principaux projets dans lesquels les travaux décrits ont été menés, avec le thème de recherche associé et le rôle que j’y ai occupé.

Tableau 1.3 – Projets de recherche

Années	Nom du projet	Rôle	Thème(s)	Partenaires
2008 - 2011	Thèse J. Marzat	Doctorant	Diagnostic, optimisation	ONERA, CentraleSupélec
2013 - ...	Moteur Fusée	Co-responsable	Diagnostic, commande	ONERA, CNES
2011 - ...	Etudes DGA	Contributeur	Commande, estimation	ONERA, DGA
2014 - 2017	COPERNIC	Co-responsable	Commande mono-véhicule	ONERA (interne)
2014 - 2017	FP7 EUROC	Responsable	Commande mono-véhicule	ONERA, UPMC, RTE, ETH Zürich
2015 - 2019	DROSOFILES	Contributeur	Commande mono-véhicule	ONERA, SNCF
2016 - 2018	EDA EuroSWARM	Contributeur	Commande multi-véhicules	ONERA, Cranfield, FOI, Univ Patras
2016 - 2018	CODA	Co-responsable	Commande multi-véhicules	ONERA (Carnot)
2017 - 2020	GUIMAUVE	Responsable	Commande multi-véhicules	ONERA (interne)
2018 - 2020	PHYDIAS	Responsable de lot	Estimation	DGAC

Tableau 1.4 – Encadrements de chercheurs postdoctoraux

Années	Post-Doctorant	Thème et titre	Co-encadrants
2015 - 2016	Duc-Kien Phung	Commande mono-véhicule <i>GPU-based Model Predictive Control</i>	B. Hérisse, S. Bertrand (ONERA DTIS)
2016 - 2017	Ioannis Sarras	Commande multi-véhicules <i>Distributed Localization and Guidance for fleets of autonomous vehicles</i>	H. Piet-Lahanier, S. Bertrand (ONERA DTIS)

## 1.4 Rayonnement scientifique

### Activités de reviewer (10 articles par an en moyenne)

- Proc. IMechE, Part G : Journal of Aerospace Engineering (depuis 2009)
- IEEE Transactions on Automatic Control (depuis 2012)
- IEEE Transactions on Systems, Man and Cybernetics – Systems (depuis 2013)
- International Journal of Control (depuis 2013)
- Aerospace Science and Technology (depuis 2015)
- AIAA Journal on Guidance, Control and Dynamics (depuis 2015)
- International Journal of Micro-Air Vehicles (depuis 2016)
- IEEE Transactions on Aerospace and Electronic Systems (depuis 2017)
- Conférences IFAC : World Congress, Automatic Control in Aerospace, SYSID, Safeprocess
- Conférences IEEE : CDC, IROS, ICRA, SysTol, ICSC, ECMR

### Activités éditoriales et Jurys

- Editeur Associé section Fault-Tolerant Systems pour [IEEE Transactions on Aerospace and Electronic Systems](#) (depuis 2019)
- Editeur invité d'un numéro spécial « [Estimation and control for MAV navigation in GPS-denied cluttered environments](#) » dans l'International Journal of Micro-Air Vehicles, paru en juin 2018.
- Membre du comité de programme [ECMR 2019 \(European Conference on Mobile Robots\)](#).
- Organisation session invitée « Model-based Methods and Algorithms for Safety and Efficiency Enhancement of Aerospace Systems » avec Christophe Combastel (IMS Bordeaux) à IFAC Safeprocess 2018.
- Examineur dans le Jury de thèse de Carlos Vina (ISIR Sorbonne Université, directeur de thèse : Pascal Morin), *Laser-based sensor fusion for the tele-operation and control of mini-drones*, 18 décembre 2017.

### Communauté nationale

Participation et présentations aux réunions de groupes de travail des [GDR MACS](#), [GDR Robotique](#) et [GDR MASCOT-NUM](#), et autres séminaires en milieu académique.

1. [Mises en oeuvre expérimentales de lois de commande prédictive pour des drones et robots roulants autonomes](#), Journée du GT Commande Prédictive Non Linéaire (CPNL) du GDR MACS, ONERA Châtillon, 4 juin 2018
2. [Autonomous navigation in industrial cluttered environments using embedded stereo-vision](#), Aerial Robotics Workshop, Paris Le Bourget, 9 mars 2017

3. Eléments de robustesse aux défauts de capteurs pour les véhicules aériens autonomes, JAMACS'16, Villeneuve d'Ascq, 15 novembre 2016
4. Reconfigurable cooperative control for extremum seeking, GT UAV Aerial Robotics Workshop, ENSAM Paris, 8 décembre 2015
5. Model Predictive Control for Cooperative Guidance of Autonomous Vehicles, ICODE Seminar, Centrale-Supelec, Gif-sur-Yvette, 12 juin 2015
6. Réglage robuste d'hyperparamètres à partir de simulations complexes : application au diagnostic en aéronautique Commission Automatique SUPELEC, Gif-sur-Yvette, 4 avril 2012
7. Estimation à erreurs bornées et guidage-pilotage des aéronefs autonomes en milieu perturbé, Journée du Groupe de travail MEA (méthodes ensemblistes pour l'automatique), 2 février 2012
8. Méthodes de détection et isolation de défauts pour les systèmes aéronautiques autonomes, Journée du groupe de travail Sûreté, Surveillance, Supervision (S3) du GDR MACS, 18 novembre 2010

## Responsabilités administratives

- Depuis 2017 : Co-responsable de la thématique scientifique « Robotique et Autonomie » au conseil scientifique du département ONERA DTIS.
- En 2015 : Co-responsable de la thématique « Commande et Estimation » pour l'évaluation scientifique du département ONERA DCPS, en lien avec l'évaluation HCERES de l'ONERA.

## 1.5 Liste des publications

2 mémoires, 3 chapitres d'ouvrages, 14 revues internationales à comité de lecture, 40 conférences internationales à comité de lecture, 9 autres conférences internationales. [Google Scholar](#) : 760 citations, H-index = 11 (les publications **en gras** y contribuent). [Recensement arrêté au 20 juin 2019]

### Mémoires

- [1] J. Marzat. Diagnostic des systèmes aéronautiques et réglage automatique pour la comparaison de méthodes. PhD thesis, University Paris-Sud XI, France, 2011.
- [2] J. Marzat. Estimation temps réel du flot optique. Master's thesis, INPL Nancy, France, 2008.

## Chapitres d'ouvrage

- [3] A. Eudes, J. Marzat, M. Sanfourche, J. Moras, and S. Bertrand. Autonomous and safe inspection of an industrial warehouse by a multi-rotor MAV. In *Field and Service Robotics*, pages 221–235. Springer, Cham, 2018.
- [4] A. Abauzit and J. Marzat. A multiple-observer scheme for fault detection, isolation and recovery of satellite thrusters. In *Advances in Aerospace Guidance, Navigation and Control*, pages 199–214. Springer, Berlin, Heidelberg, 2013.
- [5] J. Marzat, H. Piet-Lahanier, F. Damongeot, and E. Walter. Tuning and comparing fault diagnosis methods for aeronautical systems via Kriging-based optimization. In *Progress in Flight Dynamics, Guidance, Navigation, Control, Fault Detection and Avionics*, volume 6, pages 363–374. Torus Press, 2013.

## Revue internationale à comité de lecture

- [6] E. I. Robinson, J. Marzat, T. Raïssi, Filtering and uncertainty propagation methods for model-based prognosis of fatigue crack growth in fiber reinforced titanium matrix composites, *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part A : Civil Engineering*, 2018
- [7] I. Sarras, J. Marzat, S. Bertrand, and H. Piet-Lahanier. Collaborative multiple micro air vehicles' localization and target tracking in gps-denied environment from range-velocity measurements. *International Journal of Micro Air Vehicles*, 10(2) :225-239, 2018.
- [8] J. Marzat. A missile guidance law tolerant to unestimated evasive maneuvers. *Aircraft Engineering and Aerospace Technology*, 89(2) :314–319, 2017.
- [9] J. Marzat, E. Walter, and H. Piet-Lahanier. A new expected improvement algorithm for continuous minimax optimization. *Journal of Global Optimization*, 64(4) :785–802, 2016.
- [10] **C. Durantin, J. Marzat, and M. Balesdent. Analysis of multi-objective kriging-based methods for constrained global optimization. *Computational Optimization and Applications*, 63(3) :903–926, 2016.**
- [11] P. Bidaud, L. Burlion, H. De Plinval, T. Loquen, J. Marzat, and C. Pralet. Dealing with complexity through advanced control techniques. *AerospaceLab Journal*, 12 :1–18, 2016.
- [12] M. Balesdent, J. Morio, and J. Marzat. Recommendations for the tuning of rare event probability estimators. *Reliability Engineering and System Safety*, 133 :68–78, 2015.
- [13] **S. Bertrand, J. Marzat, H. Piet-Lahanier, A. Kahn, and Y. Rochefort. MPC strategies for cooperative guidance of autonomous vehicles. *AerospaceLab Journal*, (8) :1–18, 2014.**
- [14] A. Iannetti, J. Marzat, H. Piet-Lahanier, G. Ordonneau, and L. Vingert. Development of modelbased fault diagnosis algorithms for MASCOTTE cryogenic test bench. *Journal of Physics : Conference Series*, 570(7), 2014.
- [15] J. Morio, D. Jacquemart, M. Balesdent, and J. Marzat. Optimisation of interacting particle system for rare event estimation. *Computational Statistics and Data Analysis*, 66 :117–128, 2013.
- [16] **M. Balesdent, J. Morio, and J. Marzat. Kriging-based adaptive importance sampling algorithms for rare event estimation. *Structural Safety*, 44 :1–10, 2013**

[17] J. Marzat, H. Piet-Lahanier, and E. Walter. Worst-case global optimization of black-box functions through Kriging and relaxation. *Journal of Global Optimization*, 55 :707–727, 2013.

[18] J. Marzat, H. Piet-Lahanier, F. Damongeot, and E. Walter. Model-based fault diagnosis for aerospace systems : a survey. *Proceedings of the IMechE, Part G : Journal of Aerospace Engineering*, 226(10) :1329–1360, 2012.

[19] J. Marzat, H. Piet-Lahanier, F. Damongeot, and E. Walter. Control-based fault detection and isolation for autonomous aircraft. *Proceedings of the IMechE, Part G : Journal of Aerospace Engineering*, 226(5) :510–531, 2012.

## Conférences internationales à comité de lecture

[20] J. Marzat, A. Eudes, A. Bernard-Brunel, M. Sanfourche, S. Bertrand, Collision-free MAV tele-operation along a reference trajectory in indoor cluttered environment, *IROS Workshop Vision-based Drones : What’s Next ?*, Madrid, Spain, 2018.

[21] C. Sarotte, J. Marzat, H. Piet-Lahanier, M. Galeotta, G. Ordonneau, Fault Detection and Isolation with Fluid Mechanics Constraints For Cryogenic Combustion Bench Cooling Circuit, *Annual Conference of the Prognostics and Health Management Society*, Philadelphie, PA, USA, 2018.

[22] E. I. Robinson, J. Marzat, and T. Raïssi. Model-based prognosis of fatigue crack growth under variable amplitude loading. In *Proceedings of the 10th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes*, Warsaw, Poland, 2018.

[23] C. Sarotte, J. Marzat, H. Piet-Lahanier, A. Iannetti, M. Galeotta, and G. Ordonneau. Actuator fault tolerant system for cryogenic combustion bench cooling circuit. In *Proceedings of the 10th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes*, Warsaw, Poland, 2018.

[24] J. Marzat, H. Piet-Lahanier, and S. Bertrand. Cooperative fault detection and isolation in a surveillance sensor network : a case study. In *Proceedings of the 10th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes*, Warsaw, Poland, 2018.

[25] H. Roggeman, J. Marzat, M. Derome, M. Sanfourche, A. Eudes, and G. Le Besnerais. Detection, estimation and avoidance of mobile objects using stereo-vision and model predictive control. In *Proceedings of the 1st International Workshop on Vision for UAVs at ICCV*, Venice, Italy, 2017.

[26] H. Roggeman, J. Marzat, A. Bernard-Brunel, and G. Le Besnerais. Autonomous exploration with prediction of the quality of vision-based localization. In *Proceedings of the 20th IFAC World Congress*, Toulouse, France, pages 10763–10768, 2017.

[27] E. I. Robinson, J. Marzat, and T. Raïssi. Model-based prognosis using an explicit degradation model and inverse FORM for uncertainty propagation. In *Proceedings of the 20th IFAC World Congress*, Toulouse, France, pages 14807–14812, 2017.

[28] E. I. Robinson, J. Marzat, and Raïssi T. Interval observer design for unknown input estimation of linear time-invariant discrete-time systems. In *Proceedings of the 20th IFAC World Congress*, Toulouse, France, pages 4082–4087, 2017.

[29] J. Marzat, S. Bertrand, A. Eudes, M. Sanfourche, and J. Moras. Reactive MPC for autonomous MAV navigation in indoor cluttered environments : Flight experiments. In *Proceedings*

of the 20th IFAC World Congress, Toulouse, France, pages 16566–16572, 2017.

[30] D.-K. Phung, B. Herisse, J. Marzat, and S. Bertrand. Model predictive control for autonomous navigation using embedded graphics processing unit. In Proceedings of the 20th IFAC World Congress, Toulouse, France, pages 12389–12394, 2017.

[31] I. Sarras, J. Marzat, S. Bertrand, and H. Piet-Lahanier. Collaborative multi-vehicle localization with respect to static/dynamic target from range and velocity measurements. In Proceedings of the International Conference on Unmanned Aircraft Systems, Miami FL, USA, pages 850–859, 2017.

[32] E. I. Robinson, J. Marzat, and Raïssi T. Model-based prognosis algorithms with uncertainty propagation : application to a fatigue crack growth. In Proceedings of the 3rd International Conference on Control and Fault-Tolerant Systems, Barcelona, Spain, pages 458–465, 2016.

[33] A. Iannetti, J. Marzat, H. Piet-Lahanier, and G. Ordonneau. Automatic tuning strategies for model-based diagnosis methods applied to a rocket engine demonstrator. In Proceedings of the 3rd European Conference of the Prognostics and Health Management Society, Bilbao, Spain, pages 1–8, 2016.

[34] H. Roggeman, J. Marzat, A. Bernard-Brunel, and G. Le Besnerais. Prediction of the scene quality for stereo vision-based autonomous navigation. In Proceedings of the 9th IFAC Symposium on Intelligent Autonomous Vehicles, Leipzig, Germany, pages 94–99, 2016.

[35] **N. Piasco, J. Marzat, and M. Sanfourche. Collaborative localization and formation flying using distributed stereo-vision. In Proceedings of the IEEE International Conference on Robotics and Automation, Stockholm, Sweden, pages 1202–1207, 2016.**

[36] A. Kahn, J. Marzat, H. Piet-Lahanier, and M. Kieffer. Global extremum seeking by Kriging with a multi-agent system. In Proceedings of the 17th IFAC Symposium on System Identification, Beijing, China, pages 526–531, 2015.

[37] A. Iannetti, J. Marzat, H. Piet-Lahanier, G. Ordonneau, and L. Vingert. Fault diagnosis benchmark for a rocket engine demonstrator. In Proceedings of the 9th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes, Paris, France, pages 895–900, 2015.

[38] A. Kahn, J. Marzat, H. Piet-Lahanier, and M. Kieffer. Cooperative estimation and fleet reconfiguration for multi-agent systems. In Proceedings of the 3rd IFAC Workshop on Multi-vehicle Systems, Genova, Italy, pages 11–16, 2015.

[39] H. Roggeman, J. Marzat, M. Sanfourche, and A. Plyer. Embedded vision-based localization and model predictive control for autonomous exploration. In IROS Workshop on Visual Control of Mobile Robots (ViCoMoR), Chicago IL, USA, pages 13–20, 2014.

[40] J. Marzat, H. Piet-Lahanier, and A. Kahn. Cooperative guidance of LEGO mindstorms NXT mobile robots. In 11th International Conference on Informatics in Control, Automation and Robotics, Vienna, Austria, volume 2, pages 605–610, 2014.

[41] **F. Briggs, Y. Huang, et al. The 9th annual MLSP competition : New methods for acoustic classification of multiple simultaneous bird species in a noisy environment. In Proceedings of the IEEE International Workshop on Machine Learning for Signal Processing, Southampton, UK, 2013.**

[42] J. Marzat, H. Piet-Lahanier, and E. Walter. Kriging-based estimation of time derivatives

via FIR filtering. In Proceedings of the IEEE International Workshop on Machine Learning for Signal Processing, Southampton, UK, 2013.

[43] T. Gorecki, H. Piet-Lahanier, J. Marzat, and M. Balesdent. **Cooperative guidance of UAVs for area exploration with final target allocation. pages 260–265, 2013.**

[44] H. Piet-Lahanier, A. Kahn, and J. Marzat. Cooperative guidance laws for maneuvering target interception. In Proceedings of the 19th IFAC Symposium on Automatic Control in Aerospace, Würzburg, Germany, pages 301–306, 2013.

[45] A. Kahn, J. Marzat, and H. Piet-Lahanier. Formation flying control via elliptical virtual structure. In Proceedings of the IEEE International Conference on Networking, Sensing and Control, Paris Evry, France, pages 158–163, 2013.

[46] J. Marzat, E. Walter, and H. Piet-Lahanier. A new strategy for worst-case design from costly numerical simulations. In Proceedings of the American Control Conference, Washington DC, USA, pages 3997–4002, 2013.

[47] J. Marzat, E. Walter, F. Damongeot, and H. Piet-Lahanier. Robust automatic tuning of diagnosis methods via an efficient use of costly simulations. In Proceedings of the 16th IFAC Symposium on System Identification, Brussels, Belgium, pages 398–403, 2012.

[48] J. Marzat and H. Piet-Lahanier. Design of nonlinear MPC by Kriging-based optimization. In Proceedings of the 16th IFAC Symposium on System Identification, Brussels, Belgium, pages 1490–1495, 2012.

[49] J. B. Devaud, S. Najko, P. Le Nahédic, C. Maussire, E. Zante, and J. Marzat. Full design of a low-cost quadrotor UAV by student team. In Proceedings of the IEEE International Conference on System Engineering and Technology, Bandung, Indonesia, 2012.

[50] S. Bertrand, J. Marzat, M. Carton, C. Chaix, P. Varela, R. Waroux, G. De Ferron, and R. Laurel. A low-cost system for indoor motion tracking of unmanned aerial vehicles. In Proceedings of the Seventh IEEE International Conference on Intelligent Sensors, Sensor Networks and Information Processing, Adelaide, Australia, pages 574–579, 2011.

[51] J. Marzat, E. Walter, H. Piet-Lahanier, and F. Damongeot. Réglage automatique et comparaison de méthodes de diagnostic par krigeage. In Actes des Quatrièmes Journées Doctorales du GDR MACS, Marseille, France, 2011.

[52] J. Marzat, E. Walter, and H. Piet-Lahanier. Min-max hyperparameter tuning with application to fault detection. In Proceedings of the 18th IFAC World Congress, Milan, Italy, pages 12904–12909, 2011.

[53] J. Defretin, J. Marzat, and H. Piet-Lahanier. **Learning viewpoint planning in active recognition on a small sampling budget : a Kriging approach. In Proceedings of the 9th IEEE International Conference on Machine Learning and Applications, ICMLA 2010, Washington DC, USA, pages 169–174, 2010.**

[54] J. Marzat, E. Walter, H. Piet-Lahanier, and F. Damongeot. **Automatic tuning via Kriging-based optimization of methods for fault detection and isolation. In Proceedings of the IEEE Conference on Control and Fault-Tolerant Systems, SysTol’10, Nice, France, pages 505–510, 2010.**

[55] J. Marzat, H. Piet-Lahanier, F. Damongeot, and E. Walter. Fault diagnosis for nonlinear aircraft based on control-induced redundancy. In Proceedings of the IEEE Conference on Control and Fault-Tolerant Systems, SysTol’10, Nice, France, pages 119–124, 2010.

[56] J. Marzat, H. Piet-Lahanier, F. Damongeot, and E. Walter. Nonlinear FDI based on state derivatives, as provided by inertial measurement units. In *Proceedings of the 8th IFAC Symposium on Nonlinear Control Systems, Bologna, Italy*, pages 951–956, 2010.

[57] J. Marzat, H. Piet-Lahanier, and E. Walter. Détection et isolation de défauts par analyse des contraintes géométriques de guidage-pilotage. In *Actes de la Sixième Conférence Internationale Francophone d’Automatique, CIFA 2010, Nancy, France, 2010*.

[58] J. Marzat, H. Piet-Lahanier, F. Damongeot, and E. Walter. A new model-free method performing closed-loop fault diagnosis for an aeronautical system. In *Proceedings of the 7th Workshop on Advanced Control and Diagnosis, ACD’2009, Zielona Gora, Poland, pages 1–6, 2009*.

[59] J. Marzat, Y. Dumortier, and A. Ducrot. Real-time dense and accurate parallel optical flow using CUDA. In *Proceedings of the 17th International Conference in Central European Computer Graphics, Visualization and Computer Vision, Plzen, Czech Republic, pages 105–111, 2009*.

## Conférences internationales sur abstract

[60] S. Perez Roca, J. Marzat, H. Piet-Lahanier, N. Langlois, M. Galeotta, F. Farago, S. Le Gonicc, Derivation and Analysis of a Dynamic Model for Transient Control of Liquid-Propellant Rocket Engines, 9th International Conference on Mechanical and Aerospace Engineering (ICMAE), Budapest, Hungary, July 10-13, 2018.

[61] A. Iannetti, J. Marzat, H. Piet-Lahanier, C. Sarotte, and Ordonneau G. Promising HMS approaches for liquid rocket engines. In 7th European Conference for Aerospace Sciences (EU-CASS), Milan, Italy, 2017.

[62] N. Merlinge, J. Marzat, and L. Reboul. Optimal guidance and observer design for target tracking using bearing only measurements. In 16th ONERA-DLR Aerospace Symposium, Oberpfaffenhofen, Germany, 2016.

[63] A. Iannetti, S. Palerm, J. Marzat, H. Piet-Lahanier, and G. Ordonneau. A new HMS for the MASCOTTE cryogenic test bench. In *Space Propulsion, Roma, Italy, 2016*.

[64] A. Iannetti, S. Palerm, J. Marzat, H. Piet-Lahanier, and G. Ordonneau. HMS developments for the rocket engine demonstrator Mascotte. In *Proceedings of the 51st AIAA/SAE/ASEE Joint Propulsion Conference, Orlando FL, USA, 2015*.

[65] J. Marzat, J. Moras, A. Plyer, A. Eudes, and P. Morin. Vision-based localization, mapping and control for autonomous MAV : EuRoC challenge results. In 15th ONERA-DLR Aerospace Symposium (ODAS), Toulouse, France, 2015.

[66] H. Piet-Lahanier, J. Marzat, and E. Walter. Robust minimax design from costly simulations. In 11th International Conference on Structural Safety and Reliability, New York, USA, 2013.

[67] H. Piet-Lahanier, Y. Rochefort, S. Bertrand, and J. Marzat. Application of cooperative guidance methods to missile or UAV flocks. In *Deep Strike, Barcelona, Spain, 2012*.

[68] J. Marzat, H. Piet-Lahanier, F. Damongeot, and E. Walter. Autonomous fault diagnosis : state of the art and aeronautical benchmark. In *3rd European Conference for Aero-Space Sciences, Versailles, France, 2009*.

## 1.6 Activités pédagogiques

Depuis le doctorat, je poursuis une activité d'enseignant vacataire (environ 90h par an) centrée sur l'automatique et la robotique au CNAM (Mastère spécialisé Robotique) et à l'ECE Paris (Option d'Approfondissement Robotique et Majeure Santé). Pendant la thèse, une collaboration en informatique avec l'IUT Velizy et l'ESILV a également été active. L'ensemble représente plus de 800h cumulées de septembre 2009 à janvier 2019.

### CNAM Paris

Le CNAM Paris a ouvert en 2014 un mastère spécialisé intitulé « **Systèmes Mécatroniques et Robotiques** ». Ce parcours propose aux étudiants la possibilité de se spécialiser dans le domaine de la modélisation et la commande des systèmes robotiques, l'architecture de contrôle des systèmes multitâches et l'électronique embarquée. Dans ce cadre, je suis responsable du module **ROB201 « Modélisation et commande de systèmes robotiques »** qui présente la modélisation des robots mobiles et les techniques de base en commande linéaire et estimation d'état appliquées à la robotique, en particulier pour la navigation autonome avec évitement d'obstacle. Une particularité de ce cours est d'être appliqué directement sur une plateforme robotique Lego Mindstorms EV3 (1 robot par groupe de 2 étudiants, cf Figure 1.3a) exploitant **le framework open-source Java LeJOS**, ce qui permet d'appréhender les contraintes d'implémentation embarquée liées à la robotique.

2018 - 2019 : 60 heures M2 (mastère spécialisé), Automatique pour la Robotique mobile.  
2017 - 2018 : 52 heures M2 (mastère spécialisé), Automatique pour la Robotique mobile.  
2016 - 2017 : 44 heures M2 (mastère spécialisé), Automatique pour la Robotique mobile.  
2015 - 2016 : 44 heures M2 (mastère spécialisé), Automatique pour la Robotique mobile.  
2014 - 2015 : 44 heures M2 (mastère spécialisé), Automatique pour la Robotique mobile.

### ECE Paris (Ecole Centrale d'Electronique)

Depuis 2009, je suis responsable du module « Automatique » dans l'Option d'Approfondissement « Robotique » à l'ECE Paris. Les options d'approfondissements permettent aux étudiants d'appréhender un secteur porteur ou une expertise dans les technologies de pointe en dernière année d'école (M2). Dans ce cadre, ce module permet à des étudiants ayant principalement une formation en systèmes embarqués ou en informatique d'acquérir les fondamentaux de la robotique mobile (modélisation, capteurs et actionneurs, principe de localisation) et d'obtenir un complément théorique en automatique et en estimation (représentation d'état, commande multivariable, filtre de Kalman), tout en mettant en œuvre ces concepts directement lors des TP (navigation autonome d'une plateforme Mindstorms EV3). Une introduction au middleware open-source ROS, devenu incontournable en robotique expérimentale aujourd'hui, est également proposée.

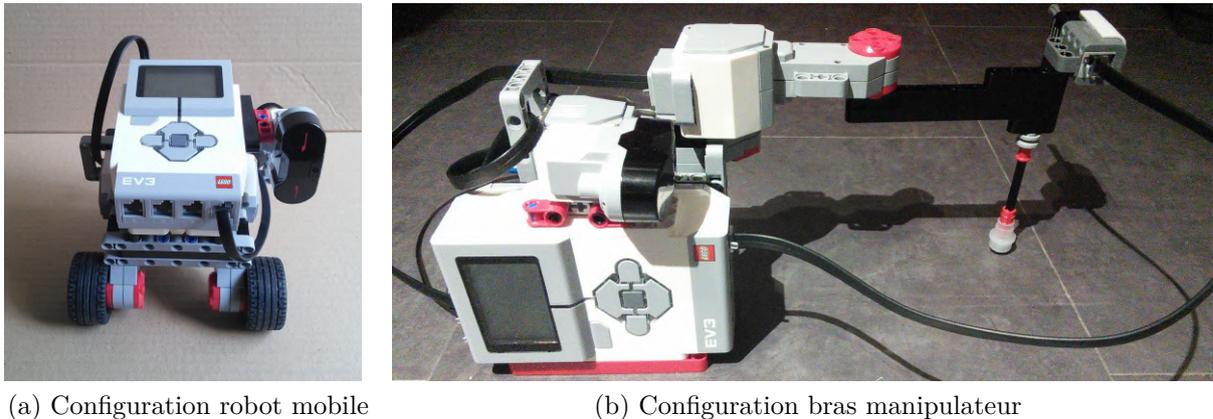


FIGURE 1.3 – Robot Lego Mindstorms EV3

Depuis 2013, je dispense en parallèle un module d'Automatique dans la majeure **Santé et Technologies** au niveau M1. Cette formation a pour objectif de présenter les applications de la formation d'ingénieur dans les métiers liés à la santé. Le public visé dispose d'un background très différent de l'OA, le cours se focalise donc sur les éléments théoriques suffisants (cinématique, commande mono-variable, temps discret) pour mettre en œuvre l'asservissement en position d'un bras manipulateur (analogue à un robot chirurgical). Cela est mis en œuvre directement pendant le module sur un robot Mindstorms EV3 reconditionné sous la forme d'un bras manipulateur (Figure 1.3b). Ce cours est moins riche théoriquement que celui de l'option d'approfondissement, les étudiants Santé qui le souhaitent peuvent donc suivre ce dernier en M2. La mutualisation des plateformes robotiques permet donc de disposer de plus de matériel pour chaque étudiant. Le nombre d'heures annuel pour ces interventions est variable d'une année à l'autre en fonction de la taille des promotions (dédoulement du TP). J'ai également encadré des projets étudiants M1 et M2 en robotique mobile et aérienne (conception de plateformes et implémentation d'algorithmes embarqués) dans cette même école entre 2009 et 2015. Nous avons ainsi accompagné jusqu'à la publication deux travaux expérimentaux de groupes d'étudiants : le développement d'un système low-cost de motion tracking [50] et la conception d'un drone quadrirotor et de ses algorithmes de stabilisation [49].

2018 - 2019 :	27 heures M2 en OA « Robotique », 12 heures M1 en majeure « Santé »
2017 - 2018 :	27 heures M2 en OA « Robotique », 12 heures M1 en majeure « Santé »
2016 - 2017 :	27 heures M2 en OA « Robotique », 24 heures M1 en majeure « Santé »
2015 - 2016 :	30 heures M2 en OA « Robotique », 12 heures M1 en majeure « Santé »
2014 - 2015 :	30 heures M2 en OA « Robotique », 24 heures M1 en majeure « Santé »
2013 - 2014 :	27 heures M2 en OA « Robotique », 36 heures M1 en majeure « Santé »
2012 - 2013 :	29 heures M2 en OA « Robotique », 24 heures M1 en majeure « Santé »
2011 - 2012 :	29 heures, M2, Automatique en OA « Robotique »
2010 - 2011 :	29 heures, M2, Automatique en OA « Robotique »
2009 - 2010 :	25 heures, M2, Automatique en OA « Robotique »

## **IUT Vélizy (Université Versailles Saint Quentin) – GEII**

Ces enseignements de programmation (Objet Java et C++, temps réel QNX) à des étudiants de 2ème année de DUT GEII ont été réalisés pendant le doctorat, cette collaboration s'est terminée en 2012.

2011 - 2012 : 16 heures L2 GEII, TP Programmation Orientée Objet  
8 heures L2 GEII, TD temps réel  
2010 - 2011 : 16 heures L2 GEII, TP Programmation Orientée Objet  
8 heures L2 GEII, TD temps réel  
2009 - 2010 : 16 heures L2 GEII, TP Programmation Orientée Objet  
8 heures L2 GEII, TD temps réel  
2008 - 2009 : 16 heures L2 GEII, TP Programmation Orientée Objet  
16 heures L2 GEII, TP temps réel QNX  
8 heures L2 GEII, TD temps réel

## **ESILV (Pôle De Vinci, La Défense)**

Ces enseignements d'algorithmie et informatique générale à des étudiants de première année de cycle préparatoire intégré ont été réalisés pendant le doctorat, cette collaboration s'est terminée en 2011.

2010 - 2011 : 30 heures L1, TP Informatique générale (Unix, algorithmique, réseau)  
2009 - 2010 : 35 heures L1, TP Informatique générale (Unix, algorithmique, réseau)

## Chapitre 2

# Diagnostic de défauts et pronostic à base de modèles dynamiques

---

**Résumé** – Ce chapitre présente les activités de recherche liées à la surveillance de l'état de santé des systèmes. Cela concerne le développement de méthodes à base de modèles dynamiques pour d'une part la détection et la localisation de défauts, et d'autre part la prédiction de l'évolution d'une dégradation. Les applications considérées sont principalement les satellites, les systèmes de moteur fusée et la propagation de fissure dans les matériaux et structures.

---

### 2.1 Health and Usage Monitoring System (HUMS)

Un défaut est une modification inattendue d'une propriété ou d'un paramètre caractéristique du système surveillé par rapport au fonctionnement acceptable ou habituel. Un défaut peut être annonciateur d'une défaillance, à savoir l'interruption permanente de la capacité du système à accomplir sa mission, compte tenu de ses conditions de fonctionnement. La détection de défauts consiste à mettre en évidence la présence de défauts dans le système et identifier leurs instants d'apparition. Cette tâche est suivie de la localisation de défauts (en anglais, isolation), qui a pour but de les classer en fonction de leur type et de leur emplacement dans le système. Enfin, l'identification (ou estimation) de défauts vise à caractériser leurs amplitudes et leurs évolutions temporelles. Le processus complet est classiquement désigné sous les acronymes FDI pour Fault Detection and Isolation ou FDD pour Fault Detection and Diagnosis (détection et diagnostic de défauts), ce dernier incluant l'identification [69].

La dénomination HMS (Health and Monitoring System) est également employée dans le domaine aérospatial. Ces procédures nécessitent la plupart du temps de générer des

résidus, c'est-à-dire des indicateurs de la présence de défauts calculés à partir de l'écart entre les mesures relevées sur le système et le comportement prédit par un modèle. Ces signaux sont censés être de faible amplitude lorsque le système fonctionne normalement, et s'écartent suffisamment de leur valeur initiale pour être détectable en présence de défauts. Une fois qu'un défaut a été détecté, il apparaît naturel de chercher à le compenser par une modification adéquate de la loi de commande du système considéré. C'est ce que cherche à réaliser la commande tolérante aux défauts (FTC : Fault Tolerant Control), également nommée reconfiguration. On trouvera dans [70] un récapitulatif des études portant sur la FTC active, où la reconfiguration utilise des informations provenant du diagnostic, tandis que la reconfiguration passive fait uniquement appel à la commande robuste.

Trois principaux types de défauts sont distingués, en fonction de l'élément du système qu'ils affectent. Un défaut de capteur est une variation anormale d'une mesure, telle qu'une erreur systématique entachant subitement les données issues d'un accéléromètre d'une centrale inertielle. Un défaut d'actionneur représente un dysfonctionnement d'un dispositif agissant sur la dynamique du système, par exemple le blocage d'une gouverne. Les défauts de processus sont quant à eux des changements dans les paramètres internes du système qui entraînent une modification de sa dynamique, comme une redéfinition inattendue des coefficients aérodynamiques. L'évolution temporelle d'un défaut est en général imprévisible, et peut ainsi être abrupte, progressive (graduelle) ou encore intermittente – ces deux derniers comportements étant les plus délicats à détecter.

Le pronostic est un processus qui consiste à prédire l'évolution de l'état futur d'un système et à estimer le temps qu'il reste avant de subir une dégradation critique. Ce temps de vie restant est appelé durée de vie résiduelle (RUL : Remaining Useful Lifetime) du système. Grâce à la fonction de pronostic, les dérives de comportement d'un système peuvent être détectées suffisamment tôt pour éviter toute défaillance de celui-ci. La maintenance vise à maintenir ou à rétablir un bien dans un état spécifié afin que celui-ci soit en mesure d'assurer un service déterminé. Celle-ci s'effectue généralement soit de manière systématique (maintenance préventive) soit juste après l'apparition d'une défaillance (maintenance corrective). A l'avenir, les informations issues du pronostic devraient permettre de garantir la sécurité d'utilisation du système, mais aussi de gérer de façon optimale les opérations de maintenance du système lorsque les résultats du pronostic en révéleront le besoin. Cette maintenance intelligente permettrait ainsi la disponibilité maximale du système et la minimisation des coûts qui sont élevés dans le cas des maintenances classiques, tout en garantissant un système fiable et sécurisé. L'ensemble de ces éléments est au cœur de la démarche HUMS (Health and Usage Monitoring System) [71].

La boucle HUMS qui résulterait d'une automatisation complète, incluant également la maintenance intelligente pour la gestion du cycle de vie du système est présentée en Figure 2.2. Alors que dans le schéma classique les différents modules sont découplés et renvoient tous leurs informations à l'opérateur (ce qui peut induire une large charge cognitive), la boucle intégrée lie les différents modules et échelles de temps. Les indica-

teurs de défauts issus du diagnostic sont une entrée à la fois pour le pronostic et pour la reconfiguration de la boucle de commande afin de contrer leur influence. Les durées résiduelles de bon fonctionnement estimées par le pronostic sont une entrée pour l'analyse de maintenance, qui conduit à une action corrective sur le système. On a donc complémentarité et coexistence entre deux échelles de temps : la commande et la supervision du système pendant sa mission (court terme), et la prévision de bon fonctionnement et la maintenance associée sur l'ensemble du cycle de vie du véhicule (long terme). La suite du rapport présente ces différents modules et les techniques existantes permettant de réaliser leurs fonctionnalités.

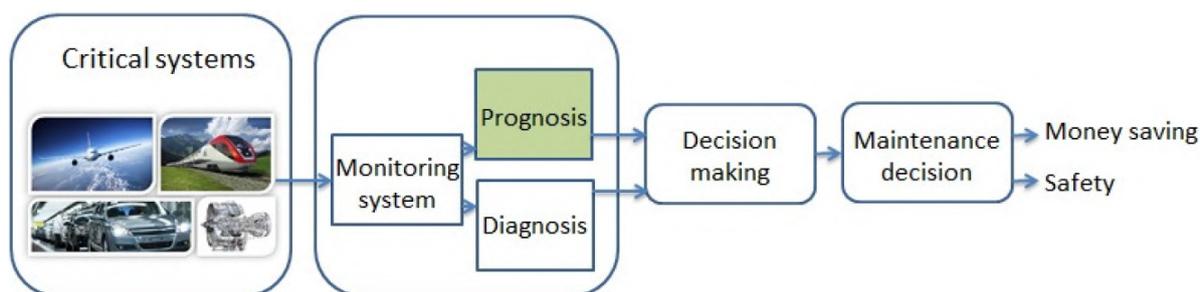


FIGURE 2.1 – Lien entre les modules de supervision dans un système HUMS intégré

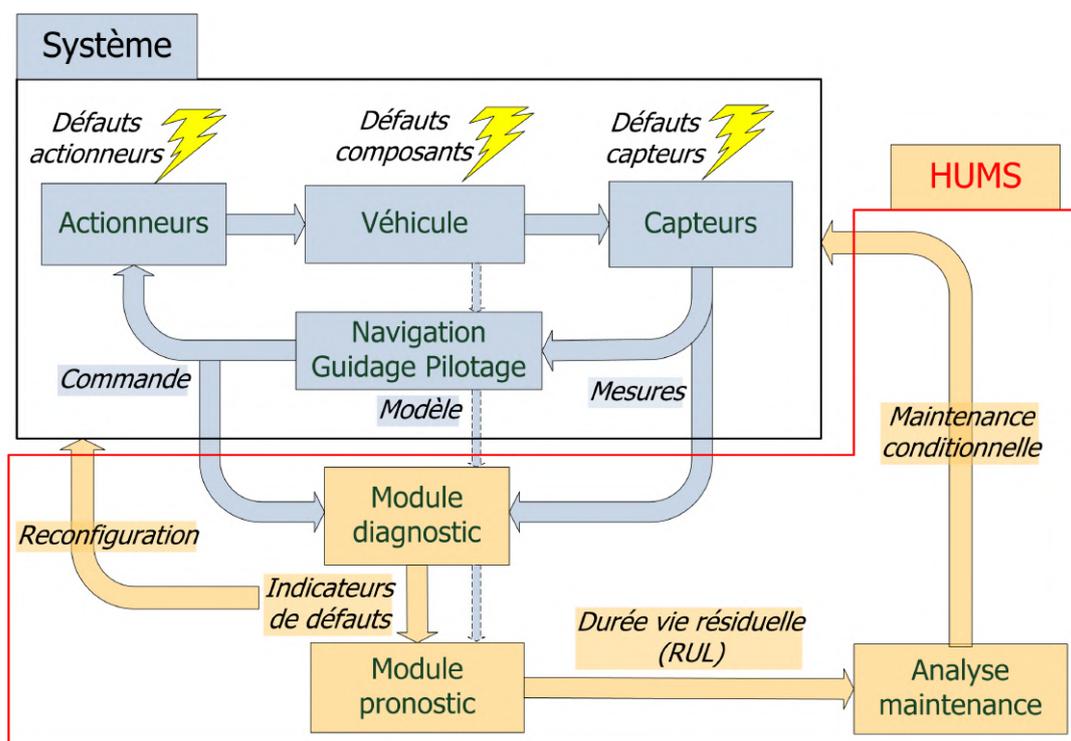


FIGURE 2.2 – Boucle complète HUMS

## 2.2 Diagnostic à base de modèles pour les systèmes aérospatiaux

### 2.2.1 Principes

L'objectif du module de diagnostic est de fournir l'état de santé courant du système, à partir des mesures des capteurs et d'une modélisation de celui-ci. Les indicateurs fournis en sortie renseignent sur l'identification de la cause probable de la (ou des) défaillance(s) à l'aide d'un raisonnement logique fondé sur un ensemble d'informations provenant d'une inspection, d'un contrôle ou d'un test.

#### *Redondance matérielle*

La stratégie de base d'une supervision robuste est l'utilisation d'équipements redondants. Au niveau le plus élémentaire, les composants peuvent être dupliqués afin de pouvoir comparer leurs mesures et faire face à une défaillance matérielle de l'un d'entre eux. A un niveau supérieur, les nœuds de communication et automates programmables chargés de fusionner et relayer l'information peuvent également être multipliés en cas de défaillance logicielle. Enfin, à un dernier niveau d'abstraction et pour des applications hautement critiques, il peut être envisageable de prévoir deux logiques algorithmiques différentes dans un même système multi-agents, dont les décisions peuvent être comparées pour parvenir à un consensus. Les deux premiers niveaux (redondance matérielle et logicielle) sont des composantes classiques dont la mise en œuvre est uniquement limitée par le coût des équipements unitaires et leur encombrement, tandis que le niveau supérieur présente un coût de conception et de développement plus important.

Les méthodes de diagnostic les plus simples à mettre en œuvre et historiquement adoptées font ainsi principalement appel à la comparaison de chaque variable mesurée avec un seuil (nommé *redline* dans le domaine spatial) et à la redondance matérielle des équipements [72], ce qui peut toutefois générer une forte augmentation des coûts et de la masse ou de l'encombrement des systèmes. Les logiques de détection et localisation des défauts associées sont : la vérification que les mesures capteurs ou les consignes actionneurs calculées sont dans la plage de valeurs physiques attendues, ou que le retour actionneur correspond bien à la consigne souhaitée ; les tests de continuité de câblage entre composants (circuits électriques ouverts, nœuds de communication inaccessible) ; la comparaison entre capteurs redondants (doublés, triplés, quadruplés, . . .) avec un vote majoritaire, moyen ou médian. Si les capteurs sont identiquement calibrés, la comparaison peut être absolue, tandis qu'elle sera approchée ou statistique si les capteurs sont dissemblables. Cette deuxième option peut toutefois prévenir les défaillances de mode commun qui pourraient affecter l'ensemble des capteurs redondants. On peut noter que deux capteurs redondants suffisent à signaler la présence d'un défaut lorsqu'une incohérence est visible, mais pas à localiser celui qui est en défaut : un troisième capteur

redondant est nécessaire à cet effet.

### *Redondance analytique*

La redondance dite analytique utilise un modèle d'évolution du système ou des liens entre les variables d'entrée/sortie mesurées ou calculées afin de détecter, localiser et identifier de manière plus précise les défaillances [73]. Le principe de base est de comparer le comportement attendu d'un équipement avec celui effectivement observé afin de générer des signaux (résidus) indicateurs de la présence des défauts et de leur localisation. Cela peut permettre de diminuer le nombre de capteurs redondants (par exemple limités à 2 pour garder une possibilité de reconfiguration) et d'être plus précis dans la localisation et l'identification des défauts. Il faut par contre disposer d'un modèle dynamique (de type équation différentielle issue de la physique) du processus régissant le fonctionnement de l'équipement, ce qui peut parfois être délicat s'il s'agit d'un composant « boîte-noire ». Ces méthodes commencent à être implantées sur des systèmes (ou sous-systèmes) industriels, notamment en aéronautique.

Le diagnostic de défauts s'effectue habituellement en combinant un générateur de résidus avec une stratégie d'analyse afin de fournir un ensemble de décisions booléennes sur la présence de défauts. L'étape de génération des résidus utilise un modèle du système, dans lequel sont injectées les entrées de commande envoyées aux actionneurs et les mesures des sorties provenant des capteurs, pour prédire son comportement attendu et le comparer à la réalité. L'objectif est de fournir un ensemble d'indicateurs quantitatifs de la présence de défauts, les résidus. Cette procédure est au cœur de la démarche du diagnostic à base de modèles, ce qui explique pourquoi la majorité des développements lui ont été consacrés.

La valeur moyenne des résidus doit être proche de zéro en fonctionnement normal, et s'en écarter lorsque qu'apparaissent les défauts auxquels ceux-ci ont été rendus sensibles. Il faut donc avoir recours à une méthode d'analyse des résidus qui traduise automatiquement l'évolution temporelle d'un résidu en une décision booléenne indiquant si le signal est considéré comme faible ou non et permettant également d'estimer un instant d'apparition du défaut. Les méthodes utilisées impliquent généralement le choix de seuils ou de tests statistiques d'hypothèses. Chaque résidu peut être sensible à un seul défaut, à tous les défauts, ou à un nombre intermédiaire. Ainsi, l'étape finale du processus est une logique de décision qui transforme les fonctions de décision obtenues précédemment en une estimée de la localisation des défauts.

Un article de survey avec une bibliographie conséquente sur les méthodes de diagnostic à base de modèles et leur application aux systèmes aérospatiaux a été publié à l'issue de mes travaux de thèse [18] et est régulièrement cité dans la communauté. Les approches modernes visent à remplacer les procédures habituelles de surveillance par seuillage indépendant pour chaque variable mesurée en liant les grandeurs entre elles via des modèles de comportement (issus de la physique ou empiriques). L'objectif est donc par ce biais de permettre aux sous-systèmes de détecter et localiser les défaillances sur leurs

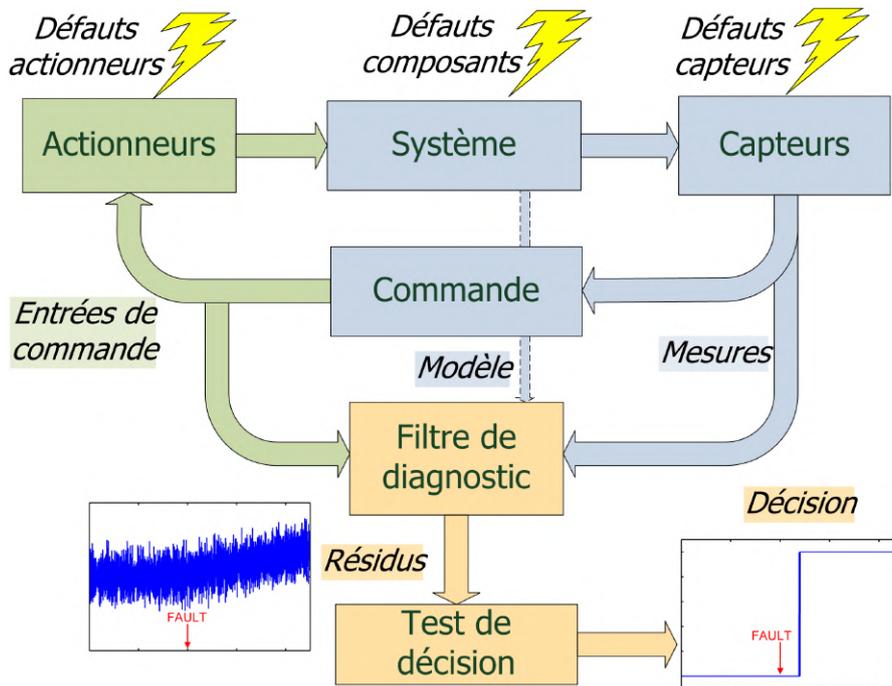


FIGURE 2.3 – Boucle de diagnostic de défauts à base de modèle

actionneurs et leurs capteurs, afin de renvoyer uniquement une information synthétique d'état de santé. Ceci est donc également lié à la mise en œuvre opérationnelle de capteurs et actionneurs intelligents faisant usage de ces algorithmes.

Un modèle dynamique du processus à surveiller est assez facile à établir pour la plupart des systèmes classiques, typiquement les régulations de température, de débit, de pression, de courant électrique qui impliquent un nombre réduit de variables et des structures bien connues. A partir de cette connaissance, le principe de base est de comparer le comportement attendu d'un système avec celui effectivement observé afin de générer les résidus. Les principaux types d'algorithmes sont les suivants [74, 75].

- Identification de paramètres : il s'agit d'estimer en temps réel les valeurs des paramètres (constants de temps par exemple) en minimisant l'écart entre la sortie du modèle et les variables mesurées. Cela sert d'une part à auto-calibrer les algorithmes en phase de déploiement, d'autre part à détecter les défauts en comparant les valeurs estimées à chaque instant avec celles de référence.
- Bancs d'observateurs ou de filtres de Kalman : en comparant la valeur prédite ou estimée par ces filtres avec la valeur effectivement mesurée, on obtient un résidu signalant la présence ou l'absence de défaillance. En combinant dans un banc un ensemble de modèles représentant un ensemble d'hypothèses de défaillances sur chaque capteur ou actionneur, on est capable de localiser le défaut sans ajouter de capteur dédié ou redondant. Un moyen de limiter la charge de calcul consiste à déclencher le banc d'identification uniquement lorsqu'un défaut a été détecté dans

- le système par un filtre unique de surveillance.
- Méthodes statistiques de détection de changement : à partir de tests d'hypothèses probabilistes (saut de moyenne ou de variance dans une série de données) dont le réglage est conditionné par le compromis souhaité entre les probabilités de fausse alarme et de non détection, les résidus obtenus par les méthodes précédentes peuvent être transformés en décisions booléennes (défaut présent ou absent) et traduits en état de santé du système en agrégeant l'ensemble des décisions unitaires.
  - Validation de mesures : lorsqu'il existe un lien temporel ou spatial direct entre variables mesurées, sans passer par un modèle dynamique, il est possible de vérifier leur cohérence statistique en recalculant les valeurs les plus probables compte-tenu de ce qui est observé. Une incohérence supérieure au bruit de mesure attendu indique la présence d'un défaut sur la variable concernée.

Le TRL de ces approches est de l'ordre de 4 à 5 : les résultats de simulation et sur maquettes de laboratoire sont très convaincants (voir notamment le très grand nombre d'articles publiés sur le benchmark Tennessee Eastman Process [76]), mais l'adoption généralisée par les industriels n'est pas encore effective. Une application notable est le diagnostic d'oscillations dans les commandes électriques des gouvernes de l'Airbus A380 [77]. Pour les autres domaines d'application, le cheminement de validation et de certification reste à entreprendre et suppose une volonté forte des concepteurs d'intégrer ces techniques d'estimation venant du domaine de l'automatique. Cette adoption pourra se concrétiser en lien avec le déploiement futur des capteurs et actionneurs intelligents, l'enjeu étant de pouvoir améliorer la précision et la réactivité de la détection de pannes sans ajouter de capteurs supplémentaires – ce qui facilitera également les actions de maintenance. Il apparaît par ailleurs que les niveaux de fiabilité requis par la certification, toujours plus élevés, ne pourront bientôt plus être atteints par les approches à base de redondance matérielle et de seuillage individuel par capteur, mais nécessiteront bien de prendre en compte la redondance dite analytique entre toutes les variables du processus supervisé [78].

### 2.2.2 Méthodes exploitant l'information de commande

Mes travaux de thèse ont conduit au développement de deux méthodes de diagnostic exploitant l'information de commande en boucle fermée et les caractéristiques des modèles aéronautiques. Le cas d'étude considéré était un missile intercepteur équipé d'une loi de guidage de poursuite (alignement de la vitesse missile sur la ligne de vue) ou de navigation proportionnelle (annulation de la vitesse de rotation de la ligne de vue) afin d'intercepter une cible non manœuvrante (Figure 2.4). Les actionneurs considérés sont quatre gouvernes de profondeur permettant d'infléchir l'orientation du véhicule, et un taux de propulsion agissant directement sur l'accélération dans l'axe principal de l'engin.

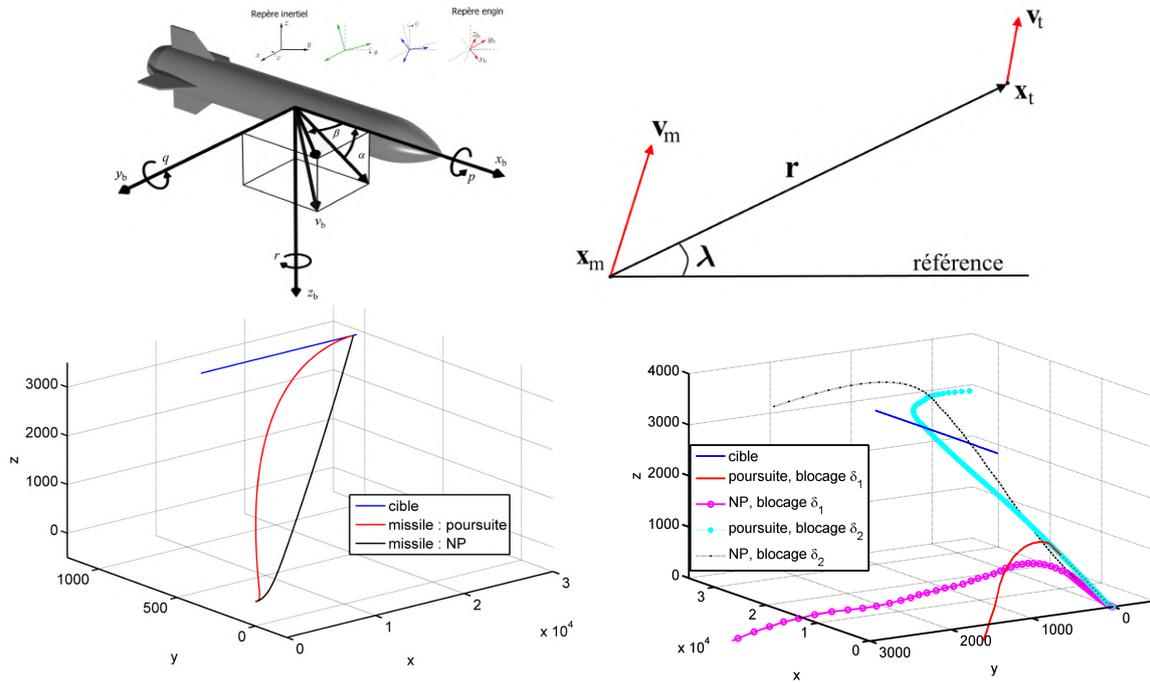


FIGURE 2.4 – Haut : Missile intercepteur et géométrie du problème d'interception  
Bas : Exemples de scénarios sains et avec défaillance d'actionneur

### Adéquation aux objectifs de commande

La première méthode utilise les objectifs de commande induits par les lois de guidage-pilotage pour générer des résidus indiquant la présence de défauts [19, 57, 58]. Ceci permet la détection des défauts sur les actionneurs et les capteurs, ainsi que leur localisation pour ces derniers. L'effet de la boucle de rétroaction sur le diagnostic a été analysée dans [79, 80]. Ceci est en lien avec la conception couplée des lois de commande et des filtres de diagnostic, examinée notamment dans [81, 82], afin de réaliser un compromis entre les performances de diagnostic et de commande. Ces objectifs étant opposés (dilemme commande–diagnostic), le signal de commande contient nécessairement de l'information concernant les défauts affectant un système bouclé [83, 84]. C'est ce constat qui est à la base de la méthode que nous proposons. Les approches de suivi des performances en boucle fermée (*closed-loop performance monitoring*), bien qu'elles ne soient pas directement liées au diagnostic de défauts, sont également proches du point de vue adopté ici. Leur objectif est de détecter des changements dans les performances de la commande, en vérifiant si le correcteur réalise correctement sa mission en comparant la moyenne et la variance observées du signal de rétroaction avec leurs valeurs attendues [84, 85].

Soit le système linéaire avec défauts additifs sur l'état

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{Ax} + \mathbf{Bu} + \mathbf{w}_f \\ \mathbf{y} = \mathbf{Cx} \end{cases} \quad (2.1)$$

où  $\mathbf{x}$  est le vecteur d'état,  $\mathbf{u}$  le vecteur de commande,  $\mathbf{w}_f$  le vecteur de défauts,  $\mathbf{y}$  le vecteur de mesures,  $\mathbf{A}$ ,  $\mathbf{B}$ ,  $\mathbf{C}$  des matrices de dimension appropriées. Un observateur de Luenberger classique de la forme

$$\begin{cases} \dot{\hat{\mathbf{x}}} = \mathbf{A}\hat{\mathbf{x}} + \mathbf{B}\mathbf{u} + \mathbf{L}(\mathbf{y} - \mathbf{C}\hat{\mathbf{x}}) \\ \hat{\mathbf{y}} = \mathbf{C}\hat{\mathbf{x}} \end{cases} \quad (2.2)$$

conduit à l'erreur d'estimation d'état

$$\dot{\mathbf{e}}_x = (\mathbf{A} - \mathbf{L}\mathbf{C})\mathbf{e}_x + \mathbf{w}_f \quad (2.3)$$

dont le premier membre tend asymptotiquement vers zéro si la matrice  $\mathbf{L}$  est choisie telle que  $(\mathbf{A} - \mathbf{L}\mathbf{C})$  soit stable, ce qui est toujours possible si la paire  $(\mathbf{C}, \mathbf{A})$  est observable. Une méthode usuelle de génération de résidu est donc d'utiliser directement  $\mathbf{e}_x$  en supposant que la convergence de l'observateur est rapide. Si on considère maintenant la régulation par retour d'état  $\mathbf{u} = -\mathbf{K}\mathbf{x}$ , on obtient

$$\dot{\mathbf{x}} = (\mathbf{A} - \mathbf{B}\mathbf{K})\mathbf{x} + \mathbf{w}_f \quad (2.4)$$

et les mêmes arguments que ceux invoqués pour (2.3) permettant de considérer la distance entre  $\mathbf{x}$  et sa référence désirée – ici  $\mathbf{0}$  – comme un résidu. En particulier, dans le domaine fréquentiel, (2.4) devient  $\bar{\mathbf{x}}(s) = (s\mathbf{1}_n - \mathbf{A} + \mathbf{B}\mathbf{K})^{-1}\bar{\mathbf{w}}_f(s)$ .

Cette méthode s'appuie uniquement sur les contraintes géométriques qui sont à la base des lois de guidage-pilotage et la vérification du respect des objectifs de commande. Elle n'utilise donc pas explicitement le modèle dynamique de l'engin, ce qui allège significativement la charge de calcul et augmente la robustesse aux imprécisions de modèle. En boucle fermée, un éventuel défaut critique affectant le système est propagé dans la boucle de commande, conduisant au non-respect des contraintes initiales. La détection et la localisation des défauts capteurs et actionneurs sont donc réalisables en vérifiant l'adéquation du système à ces contraintes. La sensibilité des défauts aux résidus ainsi générés s'étudie soit analytiquement à l'aide du modèle initial, soit numériquement selon la complexité du modèle.

Le cas test considéré est un missile intercepteur disposant d'un jeu de capteurs et actionneurs usuels et non redondants, ainsi qu'une boucle de commande de guidage-pilotage. Les lois de guidage visant à l'interception d'une cible (poursuite, navigation proportionnelle) imposent au missile des contraintes géométriques qui doivent être respectées. Celles-ci ont été traduites sous forme de résidus, et l'analyse de leur sensibilité aux défauts a permis de montrer que la détection et la localisation de défauts capteurs était réalisable, ainsi que la détection sans localisation des défauts sur les actionneurs (à cause du couplage lors de la réalisation des consignes de pilotage). Cette limitation de la méthode vient du fait que la sensibilité des résidus est liée à la structure du système. Deux exemples de résidus générés en présence de défauts sur capteur ou actionneur sont présentés en Figure 2.5.

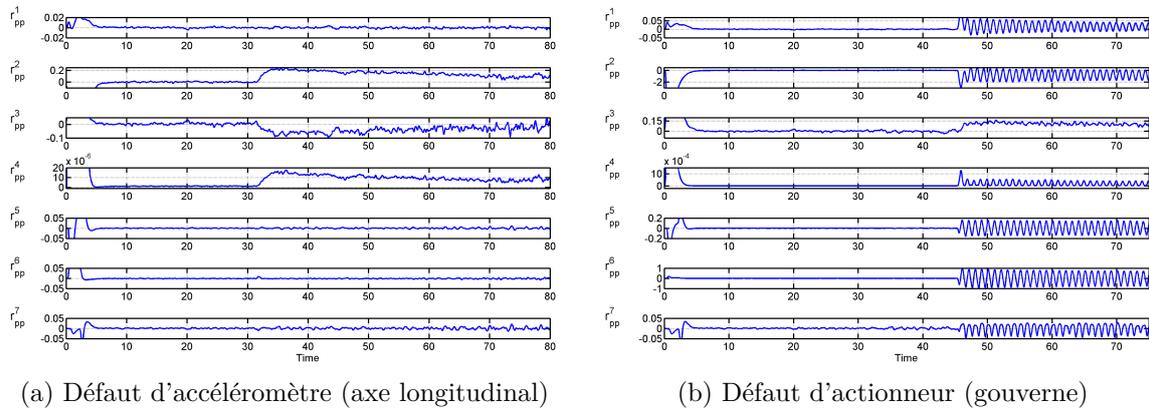


FIGURE 2.5 – Méthode à base de contraintes de guidage-pilotage : exemples de résidus

*Découplage et reconstruction de la commande appliquée*

Les méthodes de diagnostic à base de géométrie différentielle ont été parmi les premières à exploiter la structure des systèmes non linéaires affines en la commande [86], notamment à partir des concepts d'observabilité définis dans [87]. Elles cherchent à concevoir des filtres de diagnostic sensibles à un seul défaut et découplés des autres entrées [88, 89]. Une généralisation plus proche du concept initial de l'espace de parité a également été proposée dans [90] pour la même classe de systèmes. Les approches utilisant l'algèbre différentielle [91, 92] nécessitent quant à elles, via la théorie de l'élimination, la transformation de l'équation d'état non linéaire en un ensemble d'équations polynomiales en les entrées et sorties du système ainsi que leurs dérivées temporelles successives. Il est alors possible de construire des résidus à partir de ces équations. Une alternative intéressante est le diagnostic par inversion à gauche du système [93], qui permet d'obtenir un modèle dynamique fournissant en sortie les défauts, à partir des entrées et sorties du système originel et leurs dérivées temporelles successives [94, 95]. La plupart de ces techniques nécessitent le calcul des dérivées successives des variables d'entrée et de sortie, qui s'effectue en pratique à partir de mesures bruitées et perturbées. La différentiation numérique de ces signaux risque d'entraîner de sévères imprécisions lors de leur utilisation dans un filtre de diagnostic [96]. De manière alternative, nous avons proposé dans [55, 56] d'exploiter la mesure de dérivées des variables d'état pour estimer la valeur de la commande réalisée par les actionneurs, sans intégration du modèle non linéaire du système. Le diagnostic est alors effectué en comparant cette estimée avec la valeur désirée, ce qui permet la détection, la localisation et l'identification de défauts multiples sur les actionneurs.

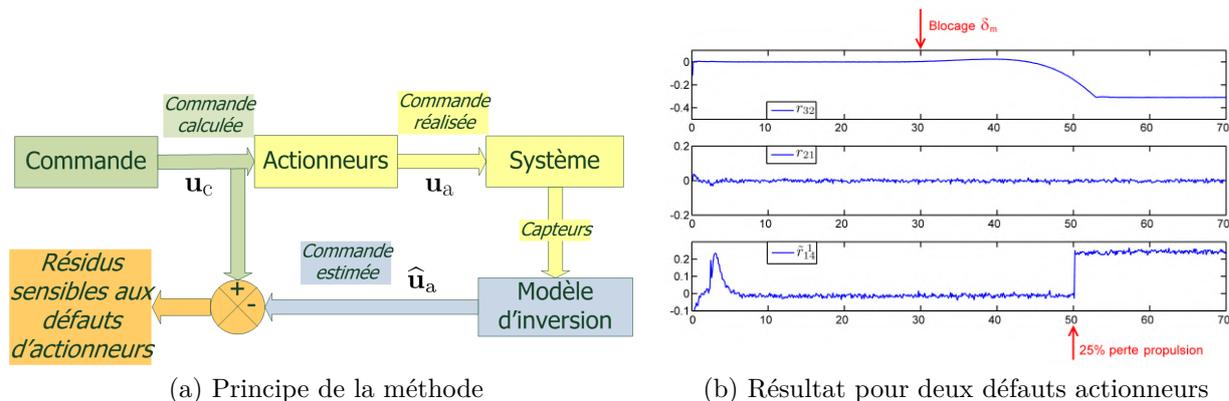


FIGURE 2.6 – Méthode de découplage avec reconstruction de la commande appliquée  
 Les systèmes non linéaires considérés sont affines en la commande, tels que

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}) + \mathbf{G}(\mathbf{x}) \cdot \mathbf{u} \\ \mathbf{y} = \mathbf{C} \cdot \begin{bmatrix} \mathbf{x} \\ \dot{\mathbf{x}} \end{bmatrix} \end{cases} \quad (2.5)$$

La forme particulière de l'équation de mesure indique que le vecteur de sortie  $\mathbf{y}$  ne dépend pas uniquement du vecteur  $\mathbf{x}$ , mais aussi de sa dérivée première par rapport au temps. C'est notamment le cas en aéronautique où le système de navigation inertielle fournit une estimée du vecteur d'état complet, ainsi que de l'accélération. Le principe de base de la plupart des méthodes de diagnostic est de comparer des estimées des sorties avec les valeurs mesurées correspondantes afin de générer des résidus indicateurs de la présence de défauts. Nous proposons au contraire, dans l'optique de la détection de défauts sur les actionneurs, de nous positionner du côté des entrées du système. L'ensemble des variables caractérisant les entrées de commande peut être partitionné en trois sous-ensembles (Figure 2.6) :

- $\mathbf{u}_c$  est le vecteur des entrées de commande calculées par le module de guidage-pilotage et envoyées aux actionneurs ;
- $\mathbf{u}_a$  est le vecteur des entrées de commande effectivement réalisées par les actionneurs (celles-ci sont inconnues, en l'absence de capteur sur les actionneurs) ;
- $\hat{\mathbf{u}}_a$  est une estimée de  $\mathbf{u}_a$ , à déterminer via un algorithme adapté.

En régime nominal, l'entrée appliquée  $\mathbf{u}_a$  est proche de l'entrée calculée  $\mathbf{u}_c$ , aux incertitudes propres aux actionneurs près (retards, imprécisions de positionnement...). Un défaut sur les actionneurs se matérialise comme une différence entre ces vecteurs, et peut donc être détecté voire identifié en examinant les résidus calculés comme la différence entre  $\mathbf{u}_c$  et l'estimée  $\hat{\mathbf{u}}_a$  de  $\mathbf{u}_a$ . Une procédure automatique de calcul de résidus à base de ce principe a été proposée et implémentée en Maple [1]. Une première étape consiste à déterminer, dans le modèle non linéaire (2.5), les équations d'état qui contiennent des entrées de commande et impliquent uniquement des variables d'état mesurées et leurs

dérivées. La  $i^{\text{ème}}$  équation d'état est

$$\dot{x}_i = f_i(\mathbf{x}) + \mathbf{g}_i^T(\mathbf{x}) \cdot \mathbf{u}, \quad (2.6)$$

où  $\mathbf{g}_i^T$  est la  $i^{\text{ème}}$  ligne de  $\mathbf{G}$ . En conservant uniquement les  $n_r$  équations remplissant cette condition et en notant  $m_r$  le nombre d'entrées de commande restantes, le système peut se mettre sous la forme  $\bar{\mathbf{f}}(\mathbf{y}) = \bar{\mathbf{G}}(\mathbf{y}) \cdot \mathbf{u}$  avec

$$\begin{bmatrix} \bar{f}_1(\mathbf{y}) \\ \vdots \\ \bar{f}_{n_r}(\mathbf{y}) \end{bmatrix} = \begin{bmatrix} \bar{\mathbf{g}}_1^T(\mathbf{y}) \\ \vdots \\ \bar{\mathbf{g}}_{n_r}^T(\mathbf{y}) \end{bmatrix} \mathbf{u} = \begin{bmatrix} \bar{g}_{11}(\mathbf{y}) & \cdots & \bar{g}_{1m_r}(\mathbf{y}) \\ \vdots & \ddots & \vdots \\ \bar{g}_{n_r1}(\mathbf{y}) & \cdots & \bar{g}_{n_r m_r}(\mathbf{y}) \end{bmatrix} \cdot \begin{bmatrix} u_1 \\ \vdots \\ u_{m_r} \end{bmatrix} \quad (2.7)$$

Chaque entrée de commande impliquée peut être exprimée en fonction des mesures  $\mathbf{y}$  et des autres entrées de commande présentes dans l'équation, à condition que l'élément de  $\bar{\mathbf{G}}$  lui correspondant ne soit pas nul. Ceci implique qu'il existe autant de manières d'exprimer chaque entrée de commande qu'il y a d'équations où elle apparaît. Notons  $\hat{u}_{aij}$  l'estimée de la  $j^{\text{ème}}$  entrée de commande à partir de la  $i^{\text{ème}}$  équation de (2.7). Ainsi, si  $\bar{g}_{ij}$  n'est pas nul, on obtient

$$\hat{u}_{aij}(\mathbf{u}) = \frac{1}{\bar{g}_{ij}} \left[ \bar{f}_i - \sum_{\substack{k=1 \\ k \neq j}}^{m_r} \bar{g}_{ik} u_k \right]. \quad (2.8)$$

En pratique, ces estimées se calculent en injectant dans (2.8) le vecteur des commandes calculées  $\mathbf{u}_c$  à la place du vecteur inconnu des commandes  $\mathbf{u}$ . Elles dépendent donc uniquement de variables mesurées, puisque les expressions des fonctions  $f()$  et  $g()$  sont connues et les commandes  $u_{ck}$  ( $k$  variant de 1 à  $m_r$ ) sont fournies par le module de guidage. Pour  $i$  variant de 1 à  $n_r$  et  $j$  de 1 à  $m_r$ , il est donc possible de générer des résidus  $r_{ij}$  en comparant chaque entrée de commande calculée  $u_{cj}$  avec chacune des estimées correspondantes  $\hat{u}_{aij}$ . Chaque résidu  $r_{ij}$  est défini comme

$$r_{ij} = u_{cj} - \hat{u}_{aij}(\mathbf{u}_c), \quad (2.9)$$

soit

$$r_{ij} = \frac{\bar{g}_{ij}}{\bar{g}_{ij}} u_{cj} - \frac{\bar{f}_i}{\bar{g}_{ij}} + \frac{1}{\bar{g}_{ij}} \sum_{\substack{k=1 \\ k \neq j}}^{m_r} \bar{g}_{ik} u_{ck}, \quad (2.10)$$

ce qui mène finalement à

$$r_{ij} = -\frac{\bar{f}_i}{\bar{g}_{ij}} + \frac{1}{\bar{g}_{ij}} \sum_{k=1}^{m_r} \bar{g}_{ik} u_{ck}. \quad (2.11)$$

La sensibilité du résidu aux défauts se détermine en remplaçant  $\bar{f}_i$  par son expression

comprenant les commandes réellement appliquées, soit

$$r_{ij} = -\frac{1}{\bar{g}_{ij}} \left( \sum_{k=1}^{m_r} \bar{g}_{ik} u_{ak} \right) + \frac{1}{\bar{g}_{ij}} \sum_{k=1}^{m_r} \bar{g}_{ik} u_{ck}, \quad (2.12)$$

ce qui donne finalement

$$r_{ij} = \frac{1}{\bar{g}_{ij}} \left( \sum_{k=1}^{m_r} \bar{g}_{ik} (u_{ck} - u_{ak}) \right). \quad (2.13)$$

L'identification du défaut est possible, en (2.13), pour  $k = j$ , puisque  $r_{ij}$  contient alors directement l'écart  $u_{cj} - u_{aj}$ . Des résidus supplémentaires peuvent être générés en considérant toutes les combinaisons possibles entre les estimées de type (2.8) et les résidus de type (2.11). On obtient ainsi une large collection de relations de redondance, offrant un choix de résidus différents pour la localisation et l'identification des défauts. Un exemple de résultat illustrant le découplage de la sensibilité des résidus à deux défauts d'actionneurs est présenté en Figure 2.6b. Une extension possible de ces travaux consisterait à considérer une fenêtre temporelle glissante pour le modèle (2.7) afin d'ajouter plus de robustesse au bruit et améliorer l'identification des défauts.

### 2.2.3 Diagnostic et commande tolérante aux défaillances – application à un modèle de satellite

Les méthodes à base de modèles les plus classiques utilisent comme résidus les composantes de l'innovation d'observateurs (ou de filtres de Kalman). Afin de localiser les défauts sur les actionneurs ou les capteurs, un banc d'observateurs (multi-modèles) est le plus souvent construit. Cela consiste à faire tourner en parallèle un ensemble de filtres excités par un sous-ensemble d'entrées ou de sorties, l'analyse de l'ensemble des innovations permettant alors de localiser l'actionneur ou le capteur défaillant. Nous avons développé avec Antoine Abauzit dans [4] une technique à base de bancs d'observateurs afin de détecter et localiser les défaillances affectant les propulseurs d'un satellite (modèle similaire à celui présenté par [97] ou encore à la mission Microscope), complété par la reconfiguration du système via la réallocation des commandes des propulseurs en pré-compensant le défaut estimé à l'aide d'un observateur supplémentaire. Nous nous sommes intéressés au diagnostic de défaillances affectant ses 12 propulseurs (répartis par groupe de 4). Afin de limiter la charge de calcul lorsque la mission se déroule nominalement, la méthode proposée présente une structure hiérarchique (Figure 2.7). Un observateur à modes glissants prenant en compte toutes les entrées et sorties sur la dynamique de rotation permet de détecter une anomalie dans le système sans la localiser. Cette détection s'effectue en appliquant un test CUSUM sur l'innovation de cet observateur. Lorsqu'une anomalie est détectée, un banc de 12 observateurs à entrée inconnue (UIO) est utilisé pour localiser l'actionneur défaillant. Un observateur à modes glissants (SMO) permet de reconstruire l'évolution temporelle du défaut (couple). Une fois qu'un

défaut a été détecté, il apparaît naturel de chercher à le compenser par une modification adéquate de la loi de commande, dite tolérante aux défauts. Le vecteur d'état du satellite est défini par  $x = [p, v, q, \omega]^T$ , contenant la position et vitesse inertielle, le quaternion permettant de passer du repère inertielle au repère engin et la vitesse angulaire. Le modèle dynamique d'état est donné par

$$\begin{cases} \dot{p} = v \\ \dot{v} = \frac{1}{m} R_{B \rightarrow I} B_F u \\ \dot{q} = \frac{1}{2} \Omega q \\ \dot{\omega} = I^{-1} B_T u - I^{-1} \omega \times I \omega \end{cases} \quad (2.14)$$

où  $I$  est la matrice d'inertie,  $\Omega$  la matrice usuelle de la dynamique d'un quaternion [98] et  $R_{B \rightarrow I}$  la matrice de passage du repère engin au repère inertielle. La matrice de sensibilité des forces des propulseurs  $B_F = [d_1, \dots, d_{12}]$  permet de calculer la force résultante appliquée au satellite telle que  $F = B_F u = \sum_{i=1}^{12} d_i u_i$ , où  $u_i$  est la norme de la poussée du  $i$ -ème propulseur. De même, on définit la matrice de sensibilité des moments  $B_T = [d_{T1}, \dots, d_{T12}]$  avec  $d_{Ti} = G A_i \times d_i$  où  $A_i$  est le point d'application de la  $i$ -ème poussée et  $G$  le centre de masse du satellite. Deux boucles distinctes de commande par retour d'état sont utilisées dans le cas nominal afin de contrôler les dynamiques de translation et rotation. Ces contrôleurs fournissent 3 accélérations et 3 vitesses angulaires, qui sont allouées aux 12 propulseurs via un algorithme classique d'optimisation itératif tel que défini dans [99]. Les capteurs disponibles sont supposés être un viseur d'étoiles et une centrale inertielle un bruit étant ajouté en simulation.

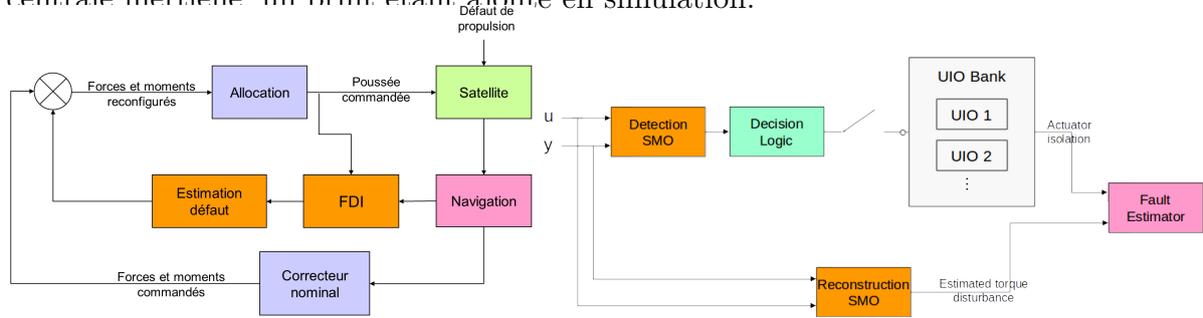


FIGURE 2.7 – Schéma FDIR multi-observateurs (UIO et SMO) pour un satellite

La méthode de diagnostic est appliquée uniquement sur la dynamique de rotation ( $\dot{\omega}$ ), d'une part pour limiter la complexité de l'algorithme, mais également car la matrice  $B_T$  de sensibilité des moments est de rang plus élevée que celles des forces  $B_F$  et permet donc une meilleure localisation des défauts. Un premier observateur à modes glissants, analogue à celui proposé dans [100] est utilisé pour la simple détection de présence d'un défaut. Celui-ci est de la forme

$$\dot{\hat{\omega}} = I^{-1} B_T u - I^{-1} \hat{\omega} \times I \hat{\omega} + B u - G e_y + v \quad (2.15)$$

où  $e_y$  est l'erreur entre la sortie mesurée et reconstruite,  $v$  une fonction de commutation

de cette erreur choisie telle que  $v = -M \arctan(e_y)$  avec le gain  $M > 0$ , et  $G$  la matrice de gain choisie telle que l'observateur soit stable. Il est alors possible de reconstruire un défaut par la technique dite *equivalent output injection* qui cherche à maintenir l'état estimé sur la surface de glissement. Une originalité de ce travail est de considérer ces deux SMO avec la même structure mais avec un réglage différent : la détection nécessite une confiance plus élevée dans le modèle (réglage lent), tandis que l'identification (reconstruction du défaut) doit rapidement réinjecter la mesure dans le signal (réglage rapide, voir Figure 2.9). En présence d'un défaut actionneur  $\Delta u$ , la dynamique de rotation devient

$$\dot{\omega} = I^{-1}B_T(u + \Delta u) - I^{-1}\omega \times I\omega \quad (2.16)$$

Si l'on remplace l'état estimé  $\hat{\omega}$  par sa mesure  $\omega_y$  (disponible ici en intégralité) dans le membre de droite de l'observateur 2.15, on peut réécrire la dynamique de l'erreur d'estimation comme

$$\dot{e}_y = Ge_y + v - I^{-1}B_T\Delta u + I^{-1}(\omega \times I\omega - \omega_y \times I\omega_y) \quad (2.17)$$

L'observateur à mode glissant est conçu de manière à assurer, après convergence vers la surface de glissement,  $e_y = 0$  et  $\dot{e}_y = 0$ . En supposant les erreurs de mesure négligeables, on obtient donc directement l'estimation du défaut

$$v = I^{-1}B_T\Delta u \quad (2.18)$$

Lorsqu'il n'y a pas de défaut présent, seul l'observateur de détection d'ordre 3 est actif, un test CUSUM usuel [101] est utilisé pour signifier un changement significatif dans le résidu  $e_y$ . Lorsqu'un défaut est détecté, un banc de 12 observateurs à entrée inconnue est activé afin de localiser la défaillance (de manière similaire à [102]). Cette étape de localisation est nécessaire car le SMO reconstruit la vitesse de rotation issue du défaut, mais cela ne permet pas de déterminer quel actionneur est en cause. Chaque UIO est excité par toutes les entrées de commande sauf une qui est découplée (le banc est dit « généralisé ») comme suit. La formulation classique d'un UIO d'ordre plein [103] est adoptée :

$$\begin{cases} \dot{z} = Fz + TBu + Ly \\ \hat{x} = z + Hy \end{cases} \quad (2.19)$$

Le découplage est direct dans le cas de la dynamique de rotation avec mesure complète de l'état, il suffit pour chaque UIO de choisir  $T = (I_3 - H)$  et  $H$  telle que l'influence du  $i$ -ème propulseur soit annulée :  $(I_3 - H)d_{Ti} = 0$ . En considérant la dynamique de rotation en boucle fermée, la matrice  $F$  est égale au gain du retour d'état  $-K$  (stable par conception). La matrice de gain de l'UIO est alors choisie comme  $L = KT$  pour assurer la convergence. Dans le cas test considéré, la géométrie symétrique du satellite impliquait que 2 paires d'actionneurs (respectivement  $\{1, 3\}$  et  $\{2, 4\}$ ) avaient des directions  $d_{Ti}$  parfaitement opposées, ce qui pouvait induire une ambiguïté pour la localisation du

défaut. Cependant leur composante en force  $d_i$  était identique (pour les 4), il a donc été possible de les distinguer en utilisant simplement le signe du défaut reconstruit  $\Delta u$ . Enfin, la reconfiguration a été effectuée comme dans [104] en pré-compensant le défaut estimé et en réallouant les commandes des propulseurs avec le même allocateur qu'initialement (voir résultats en Figure 2.9). Ainsi, la dynamique en boucle fermée reste identique à la dynamique nominale tant que la commandabilité est préservée, sans changer la structure de la loi de commande.

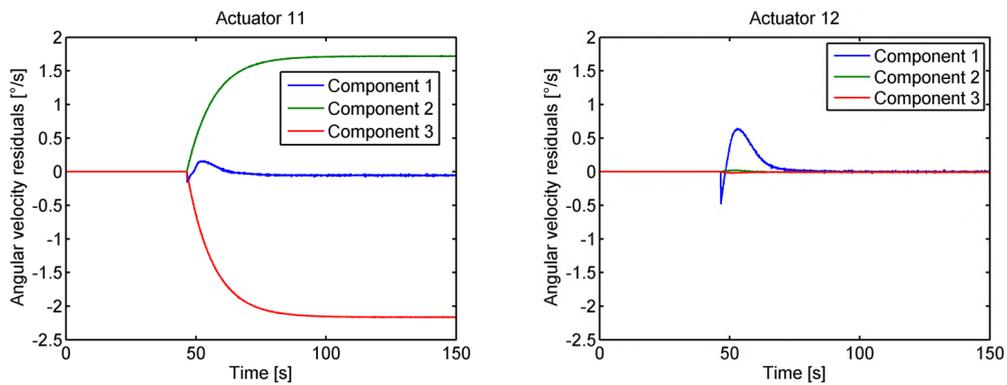
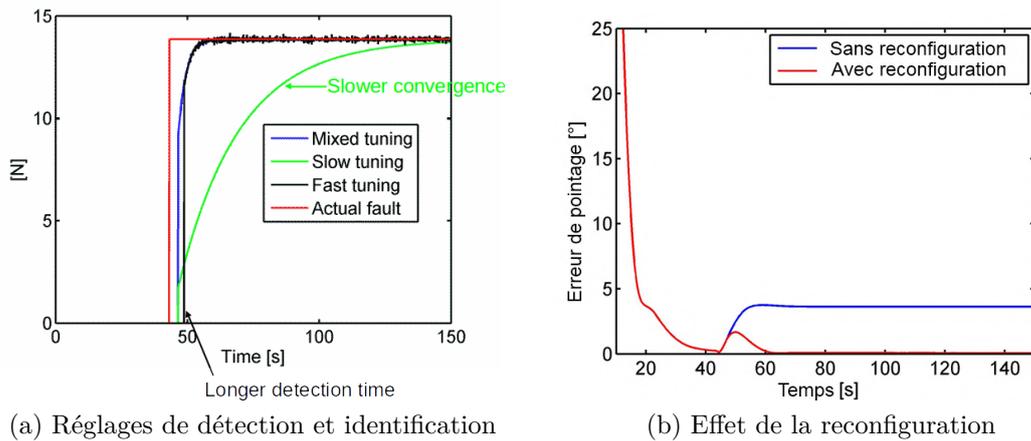


FIGURE 2.8 – FDIR satellite : résidus en présence d'un défaut sur l'actionneur 11



(a) Réglages de détection et identification

(b) Effet de la reconfiguration

FIGURE 2.9 – FDIR satellite : réglages observateurs et reconfiguration

### 2.2.4 Moteur fusée à ergols liquides

Depuis fin 2012, nous travaillons avec le CNES sur l'application de méthodes de diagnostic à base de modèles aux moteurs fusée à ergols liquides ou aux bancs de test de ces mêmes moteurs. Cela a été initié dans le cadre de la [thèse d'Alessandra Iannetti \[105\]](#), réalisée en parallèle de ses attributions en temps qu'ingénieur propulsion à la Direction des Lanceurs (DLA) au CNES (Paris) entre 2013 et 2016. Cette thèse a été co-dirigée avec Hélène Piet-Lahanier (ONERA DTIS) et Gérard Ordonneau (ONERA, spécialiste propulsion). Cette collaboration se poursuit actuellement avec la thèse de Camille Sarotte (démarrée en 2016 dans la continuité, co-financée par le CNES et l'ONERA). L'encadrement est assuré par la même équipe, ainsi que Marco Galeotta (CNES DLA) en tant qu'expert propulsion.

Le contexte général des travaux est le HMS (Health Monitoring System) des moteurs fusée à ergols liquides cryogéniques (classiquement oxygène/hydrogène ou oxygène/méthane). Ces ergols liquides brûlent dans une chambre de combustion à des niveaux de pression variant entre 30 bar et 200 bar, les gaz produits pouvant atteindre des températures de l'ordre de 3500 K, ceux-ci sont éjectés par une tuyère afin d'obtenir une vitesse de sortie de l'ordre de 4500 m/s [106]. A ce jour, ces moteurs (comme par exemple le Vulcain 2 équipant Ariane 5) sont réglés sur un point de fonctionnement unique et opérés en boucle ouverte (débits d'ergols constants à des niveaux prédéfinis). Les systèmes de surveillance moteurs sont basés sur la comparaison indépendante des mesures délivrées par les capteurs avec des seuils fixes prédéterminés (redlines). Ceux-ci sont associés aux paramètres critiques identifiés et permettent de déclencher un arrêt moteur en cas de dépassement. Cette approche est applicable pour un moteur en conditions opérationnelles, où tous les paramètres sont figés. En revanche, cela est plus contraignant pour les essais au banc qui cherchent à balayer une plus large gamme de conditions d'opération. Dans le contexte du développement de moteurs réutilisables, ce besoin de monitoring adaptatif est encore plus important, car il est prévu que ces moteurs puissent atteindre différents points de fonctionnement et il faudra également gérer la durée de vie et les activités de maintenance futures (boucle HUMS complète). L'objectif est donc d'étudier des systèmes de diagnostic afin d'évaluer leur apport pour fiabiliser le diagnostic de pannes et apporter une contribution à un système de réglage d'un moteur à ergols liquides en temps réel. Ces travaux sont toujours en cours, avec de nombreuses perspectives (estimateurs et commande non linéaire, mise en œuvre sur le banc).

Le système étudié est le banc d'essai de combustion cryogénique MASCOTTE (Figure 2.10), co-développé depuis 1994 par l'ONERA (DMPE : département multi-physique pour l'énergétique) et la direction des lanceurs du CNES [107–109]. Un essai au banc Mascotte permet de brûler les ergols dans la chambre en condition représentative d'un moteur fusée et d'analyser les phénomènes liés à la combustion et à la détente dans la tuyère. De nombreuses campagnes de recherche ont été menées depuis sa création, ce qui permet de disposer de jeux de données expérimentales, qui ont été exploités pour analyser la pertinence des modèles et des algorithmes développés ici.

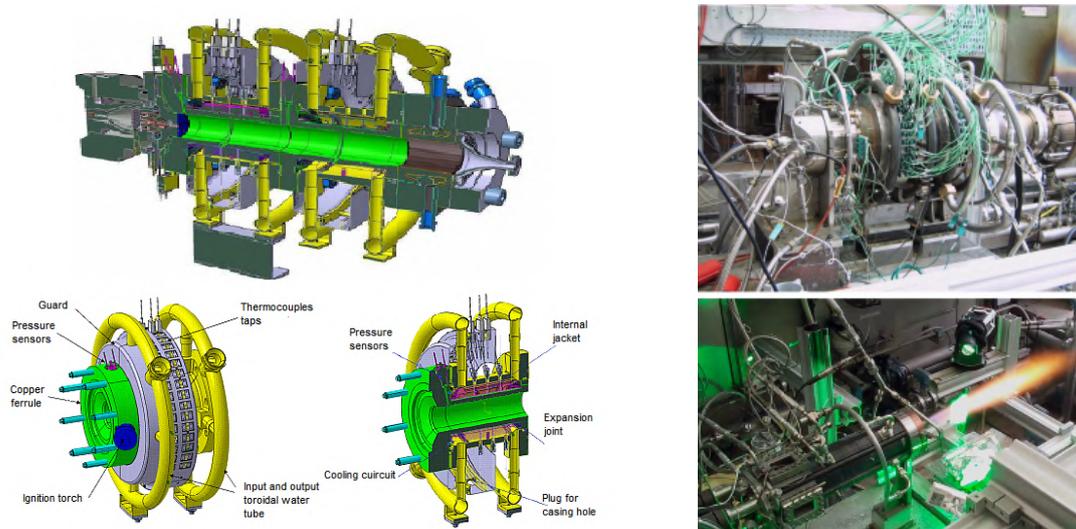


FIGURE 2.10 – Banc d'essai à ergols liquides MASCOTTE (ONERA/CNES)

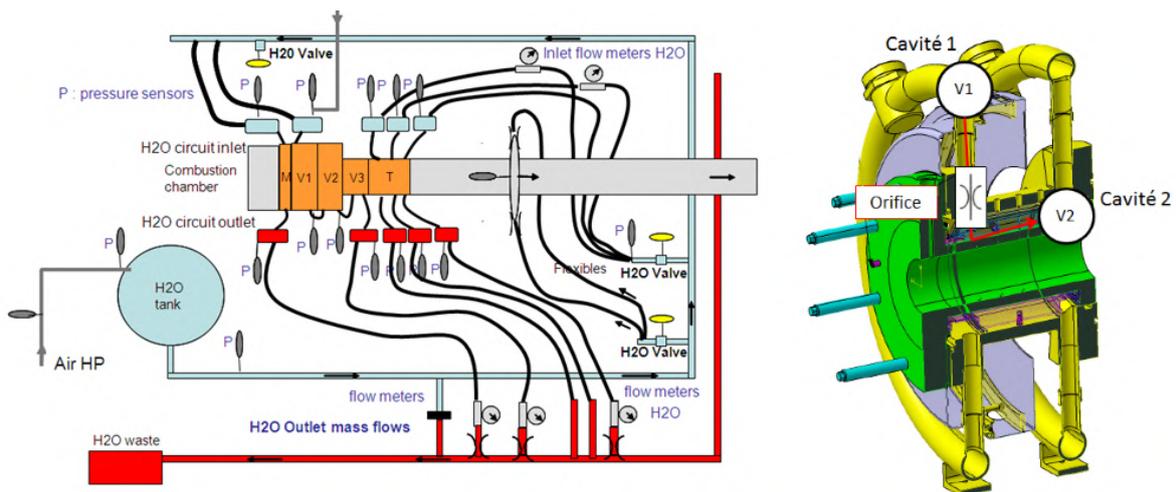


FIGURE 2.11 – Circuit de refroidissement : synoptique et modèle cavité-orifice-cavité

### Modèle dynamique

Le circuit de refroidissement de la chambre de combustion, sous-système critique du banc, a tout d'abord été choisi pour développer et valider les algorithmes de diagnostic (Figure 2.11). Une première partie des travaux a consisté à dériver un modèle dynamique d'état suffisamment représentatif, d'une part car les modèles utilisés par les spécialistes de l'énergétique ne sont pas sous cette forme et d'autre part car ceux-ci sont souvent très complexes (équations aux dérivées partielles, éléments finis) afin de prédire le comportement complet du système. Les contraintes dans ces développements ont été la nécessité

de conserver une certaine simplicité des modèles pour limiter la complexité de mise en œuvre et donc le temps requis pour identifier les paramètres et pour la simulation et de disposer néanmoins d'une représentation suffisamment précise pour permettre la détection de pannes.

Les travaux d'Alessandra Iannetti sont partis de l'hypothèse que chaque sous-partie du circuit d'eau peut être décomposée en un simple modèle thermodynamique « cavité – orifice – cavité ». On considère les grandeurs physiques suivantes pour chacune des deux cavités (1 et 2) :  $P_i$  la pression dans la cavité  $i$ ,  $q_i^e$  le débit d'entrée dans la cavité  $i$  et  $q_i^s$  le débit de sortie de cette même cavité. En considérant les équations de conservation de masse, quantité de mouvement et énergie (cadre Navier-Stokes classique), on obtient la relation suivante :

$$\frac{dP_i}{dt} = (q_i^e - q_i^s) \cdot \frac{c^2}{V_i} \quad (2.20)$$

où  $c$  représente la vitesse du son du fluide (ici, l'eau) et  $V_i$  le volume de la cavité  $i$ . Un premier modèle a alors été établi [14], en considérant que la longueur de l'orifice est négligeable par rapport au reste du circuit :

$$P_1 - P_2 = \frac{k_p}{\rho S^2} q^2 \Rightarrow q^2 = \frac{\rho S^2}{k_p} (P_1 - P_2) \quad (2.21)$$

où  $k_p$  est le coefficient de perte de charges,  $\rho$  la masse volumique,  $S$  la section de passage de l'orifice et  $q$  le débit dans l'orifice. En considérant  $q = q_2^e$ , puis  $q_2 = q_2^s$  et que  $P_1 > P_2$  (vrai en régime permanent), on obtient le modèle dynamique de la pression dans la cavité 2 (là où des mesures de pression et débit sont disponibles sur le banc) :

$$\frac{dP_2}{dt} = \frac{c^2}{V_2} \left[ \left( \frac{\rho S^2}{k_p} (P_1 - P_2) \right)^{0.5} - q_2 \right] \quad (2.22)$$

Le coefficient de perte de charge  $k_p$  peut être exprimé en fonction du débit de l'écoulement via la corrélation de Blasius [110], on obtient finalement

$$\dot{P}_2 = \theta_1 \left( -q_2 + \theta_2 \cdot q_2^{0.125} \cdot (P_1 - P_2)^{0.5} \right) \quad (2.23)$$

avec les paramètres suivants (où  $M$  est une constante dépendant des caractéristiques de l'écoulement) :

$$\theta_1 = \frac{c^2}{V_2}, \theta_2 = S \left( \frac{\rho}{M} \right)^2 \quad (2.24)$$

Un modèle similaire peut être dérivé pour la dynamique de la température. Ce modèle peut être utilisé localement à chaque emplacement d'une mesure de pression et de débit le long du circuit d'eau. Les paramètres  $\theta_1$  et  $\theta_2$  peuvent être déterminés à partir des caractéristiques géométriques du système. Le modèle (2.23) considère les variables me-

surées  $q_2$  et  $P_1$  comme des entrées, et  $P_2$  comme la variable d'état (mesurée) évoluant dynamiquement.

Le modèle (2.23) est valable autour du régime permanent, il est apparu sur les données d'essai que dans le transitoire la relation d'ordre sur les pressions n'est pas toujours valable. Un nouveau modèle a donc été développé au début de la thèse de Camille Sarotte [23] en ajoutant explicitement la dynamique du débit d'entrée  $q_2^e$  qui est désormais une variable d'état additionnelle telle que :

$$\begin{cases} \dot{q}_2^e = \theta_3 (q_2^e)^{\frac{7}{4}} - \theta_4 (P_1 - P_2) \\ \dot{P}_2 = -\theta_1 (q_2^s - q_2^e) \end{cases} \quad (2.25)$$

avec  $\theta_1$  identique à (2.24),  $\theta_4 = S^2/V_2$  et  $\theta_3$  dépendant des mêmes grandeurs physiques que  $\theta_1$ . Ce nouveau modèle a donc deux variables d'état mesurées,  $q_2^e$  et  $P_2$ , une entrée mesurée  $P_1$  et désormais une entrée inconnue  $q_2^s$ . Les deux modèles ont été évalués sur des données d'essai du banc MASCOTTE, en intégrant numériquement depuis la même condition initiale (pression, débit) et en injectant uniquement les entrées mesurées à chaque instant. Les résultats sont présentés en Figure (2.12), et montrent une bonne adéquation des deux modèles aux données expérimentales, avec une meilleure précision du deuxième.

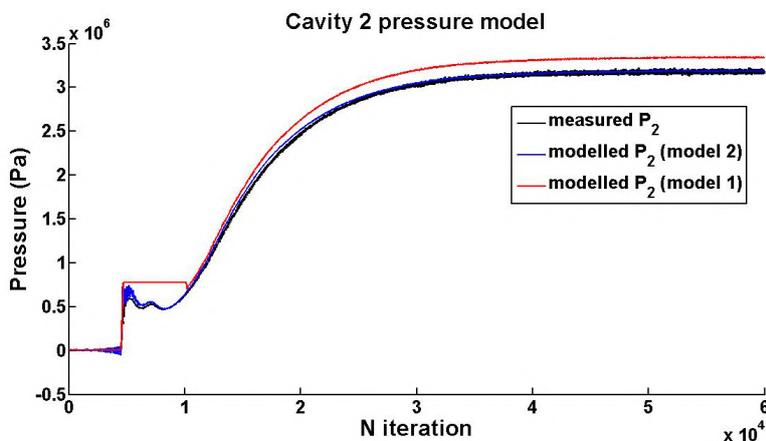


FIGURE 2.12 – Validation expérimentale des modèles d'évolution de la pression

La plupart des données d'essai disponibles sont sans défaut, car l'essai est généralement immédiatement arrêté en cas de suspicion de défaillance sur franchissement d'un seuil fixe. Cela permet de vérifier l'absence de fausse alarme avec les algorithmes de diagnostic à base de modèles. En revanche, la validation des capacités de détection de défauts s'est effectuée en simulation à partir de données générées par le simulateur ONERA/CNES Carins [111] où est représenté le fonctionnement nominal et hors nominal en phase stabilisée et transitoire du banc de combustion. Les défauts simulés sont des obstructions des vannes d'injection des ergols ou des lignes d'alimentation du circuit d'eau, avec

différents niveaux de criticité et de dynamique (apparition abrupte ou dérive).

### Moindres carrés récursifs

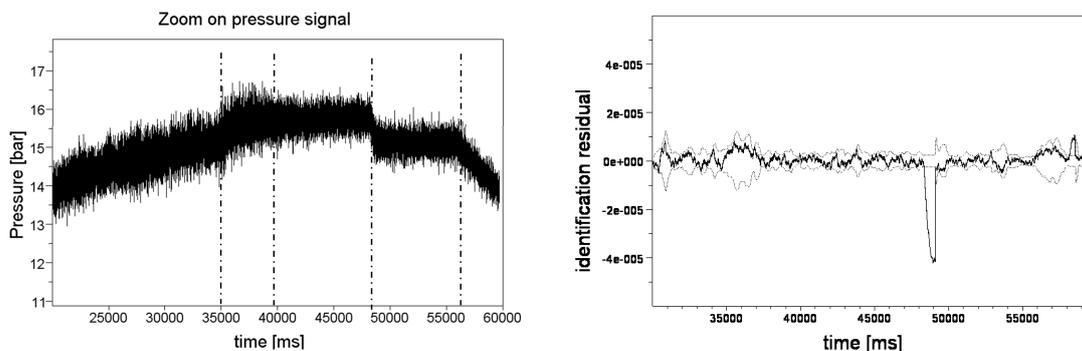


FIGURE 2.13 – Identification de paramètres pour détection d'un défaut de petite amplitude (données expérimentales, banc Mascotte)

Une première possibilité de monitoring à partir du premier modèle (2.23) est de considérer le régime permanent tel que  $\dot{P}_2 = 0$ , on obtient alors le modèle

$$q_2 = \theta_2 \cdot q_2^{0.125} (P_1 - P_2)^{0.5} \quad (2.26)$$

qui est linéaire par rapport au paramètre  $\theta_2$ . Nous avons donc estimé celui-ci à l'aide d'un algorithme des moindres carrés récursifs avec facteur d'oubli sur plusieurs phases d'essais en régime permanent. Il est apparu que le paramètre est bien constant et il est donc possible de détecter une rupture du régime permanent en monitorant son évolution au cours du temps (pour plus de détails, voir [14, 64]). L'identification paramétrique permet ainsi de ne surveiller qu'un seul paramètre indiquant la cohérence du modèle, et non pas chaque variable séparément (température, pression et débit). Un résidu  $r(t)$  est généré en comparant l'estimée du paramètre  $\hat{\theta}_2(t)$  avec une valeur de référence  $\theta_2^{\text{ref}}(t)$ , qui peut être calculée de différentes manières : fixée a priori ou estimée en ligne. Le résidu est ensuite analysé avec un test statistique bilatéral de type CUSUM (sommées cumulées, changement positif ou négatif) [101, 112] :

$$\begin{cases} S_{\min}(t) = \max(S_{\min}(t-1) - r(t) - \delta, 0) \\ S_{\max}(t) = \max(S_{\max}(t-1) + r(t) - \delta, 0) \end{cases} \quad (2.27)$$

Une alarme est déclenchée lorsque l'une des deux statistiques franchit un seuil choisi comme  $\lambda \cdot \delta$ , où  $\delta$  est une taille de variation acceptable du signal et  $\lambda$  le seuil. Dans la référence [33], deux méthodes (moyenne et écart maximal au résidu, sur une fenêtre glissante) ont été testées pour calculer en ligne la valeur de référence  $\theta_2^{\text{ref}}(t)$  et la taille du

défaut  $\delta$ . La performance de l'algorithme est alors uniquement gouvernée par la valeur de  $\lambda$ , ce qui le rend plus aisé à régler.

Un benchmark en simulation sous Carins a permis de quantifier les performances des différentes approches (par exemple, plus de 90% de bonne détection et moins de 10% de fausses alarmes pour des défauts de type fuite dans le circuit de refroidissement). Par ailleurs, sur les données de l'un des essais du banc en régime permanent, une légère fuite a pu être correctement détectée (Figure 2.13, celle-ci n'avait pas mis en danger l'essai et avait été constatée a posteriori sur le matériel).

### Estimation d'état

Afin d'étendre le domaine de validité de la surveillance par rapport à l'algorithme précédent, un filtre de Kalman étendu a été mis en œuvre sur le modèle dynamique en pression (2.23), l'état étant augmenté du paramètre  $\theta_2$  dont l'évolution dynamique est considérée comme un bruit blanc. Cela permet de prédire l'évolution de la pression en plus du paramètre, et de disposer ainsi de deux résidus [37, 63]. Le filtre peut également être utilisé dans les transitoires. Le filtre de Kalman donne également des résultats prometteurs permettant de reconstituer l'état d'un capteur (pression ou température) à partir des mesures collectées expérimentalement et les sorties fournies par le modèle simplifié. Cette approche permettrait donc de reconstituer la valeur attendue d'une mesure lorsqu'un capteur est en panne, de fiabiliser le diagnostic du système grâce au contrôle de cohérence avec le modèle et les autres mesures en entrée, de localiser une section du système ou un capteur en panne avec une approche type bancs de filtres.

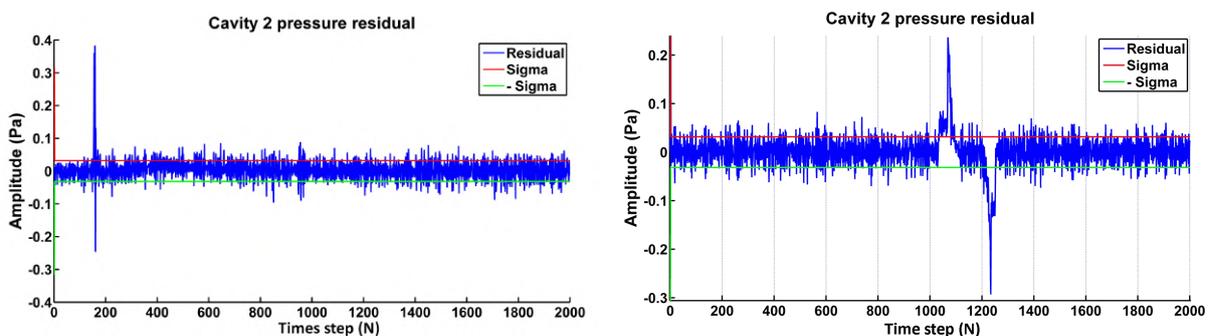


FIGURE 2.14 – Estimation d'état (EUIO) : résidu sur la pression en absence et présence de défaut (superposé en simulation sur données réelles)

Le deuxième modèle (2.25) a également été exploité pour réaliser l'estimation de l'état et générer ainsi des résidus. La validité du modèle est meilleure, cependant celui-ci présente une entrée inconnue (débit non mesuré). Un observateur étendu à entrée inconnue (EUIO) similaire à ceux développés dans [113] a donc été employé [23]. A partir d'un

modèle d'état discrétisé de la forme

$$\begin{cases} x_{k+1} = A_k x_k + B_k u_k + E d_k + w_k \\ y_k = C x_k + v_k \end{cases} \quad (2.28)$$

où  $x$  est le vecteur d'état,  $u$  le vecteur des entrées connues et  $d$  le vecteur des entrées inconnues,  $w$  et  $v$  des bruits blancs additifs. L'observateur est de la forme

$$\begin{aligned} z_k &= N_k z_{k-1} + K_k y_{k-1} + G u_{k-1} \\ \hat{x}_k &= z_k + H y_k \end{aligned} \quad (2.29)$$

avec

$$\begin{aligned} G &= T B \\ T A_{k-1} - N_k T - K_k C &= 0 \\ T E &= 0 \end{aligned} \quad (2.30)$$

où  $T = I - HC$ . Une condition nécessaire d'existence est que le rang de  $CE$  soit égal à celui de  $E$ , ce qui est assuré pour notre système en choisissant  $H = E((CE)^T(CE))^{-1}(CE)^T$ . La matrice  $N_k$  doit être choisie Hurwitz, par exemple telle que  $N_k = T A_{k-1} - K_k C$ . De manière similaire à un filtre de Kalman classique, le gain qui minimise la variance de l'état estimé est de la forme  $K_k = P_k C^T (C P_k C^T + R_k)^{-1}$  avec  $P_k = A_{k-1} P_{k-1} A_{k-1}^T + Q_{k-1}$ , où  $Q_k$  et  $R_k$  sont respectivement les matrices de covariance des bruits d'état  $w_k$  et de mesure  $v_k$ . De manière classique, le résidu utilisé est la différence entre la pression estimée et la pression mesurée. Celui-ci est analysé par un test CUSUM bilatéral adaptatif, la moyenne du résidu étant ici estimée à l'aide d'une généralisation d'une formule de moyenne glissante exponentiellement pondérée telle que définie dans [114]. Un exemple de résultat est présenté en Figure (2.14), l'absence de fausse alarme étant confirmée dans le cas sans défaut (données réelles) et la bonne détection dans un cas où le défaut a été superposé aux mêmes données en simulation. A noter que ce même estimateur de débit pourrait également être très utile pour les moteurs fusée en vol, qui ne sont généralement pas équipés de débitmètres. On disposerait ainsi d'un capteur logiciel utilisable à des fins de monitoring ou de régulation, qui n'est pas disponible sur les systèmes en service actuellement.

### Commande tolérante active

A partir de l'EUIO défini précédemment, il est utile de disposer d'une reconstruction de l'entrée inconnue  $d_k$  afin de la compenser dans l'objectif d'une commande tolérante aux défauts dite active [70]. Cela a été réalisé [23] en définissant un vecteur d'entrées auxiliaires et ses dérivées, dont l'estimation est réalisée par un observateur à modes glissants d'ordre supérieur tel que défini par [115, 116]. L'estimée  $\hat{d}_k$  peut ainsi être

injectée dans le modèle (2.28) pour obtenir une nouvelle formulation ne dépendant que de quantités connues. Dans ces travaux, on considère pour la commande la linéarisation du système autour du point d'équilibre de référence, celui-ci étant l'état à maintenir en cas d'apparition de défaut (régime nominal du moteur). Le nouveau système est de la forme

$$\begin{aligned} x_{c,k+1} &= A_c x_{c,k} + B_c u_k \\ y_k &= C x_{c,k} \end{aligned} \quad (2.31)$$

où  $A_c$  et  $B_c$  dépendent des matrices initiales du système mais également de celles de l'observateur à entrées inconnues (2.30) et de celles de l'estimateur de l'entrée inconnue. On considère un défaut additif d'actionneur tel que  $u_k = f_k + u_{c,k}$  où  $u_{c,k}$  est l'entrée de commande nominale (retour d'état, par exemple). Ce défaut additif est estimée par un deuxième EUIO similaire à (2.29) considérant la projection  $B_c$  pour l'entrée inconnue, et dont la matrice  $N_c$  est Hurwitz. La commande tolérante aux défauts considère alors la loi de commande suivante, similaire à celle développée par [104],

$$u_{c,k} = -B_c^+ B_c \hat{f}_k - W_c (\hat{x}_{c,k} - \bar{x}_k) \quad (2.32)$$

où  $B_c^+$  est la pseudo-inverse de  $B_c$  afin de compenser le défaut et  $W_c$  un gain stabilisant ( $A_c - B_c W_c$ ). Afin d'assurer simultanément la convergence de l'estimation du défaut par l'EUIO et la stabilité de la commande compensant le défaut, on définit le système augmenté suivant :

$$\zeta_{k+1} = \begin{bmatrix} A_c - B_c W_c & -B_c W_c \\ 0 & N_c \end{bmatrix} \zeta_k \quad (2.33)$$

où  $\zeta_k = [\eta_k^T \ e_{c,k}^T]^T$  avec  $\eta_k$  l'erreur entre l'état réel et l'état de référence et  $e_{c,k}$  l'erreur d'estimation de l'observateur. Le schéma d'ensemble de la méthode et un exemple de résultat de simulation sont présentés en Figure (2.15).

### Localisation de défaut dans des lignes parallèles

Les modèles décrits précédemment fonctionnent sur des sections du circuit de refroidissement considérées séparément. Or, il existe certaines lignes en parallèle qui ont un débit d'entrée commun et leur comportement dynamique est donc couplé. C'est pourquoi nous avons proposé dans [21] une approche de localisation de la ligne défaillante en cas de détection d'incohérence dans les modèles locaux de chacune des lignes. L'EUIO défini précédemment est utilisé dans chaque sous-système, et une approche de type espace de parité intégrant les contraintes de la mécanique des fluides (conservation du débit et de l'énergie) permet d'identifier la ou les lignes défaillantes en observant le signe des anomalies de débits reconstruites (Figure (2.16)).

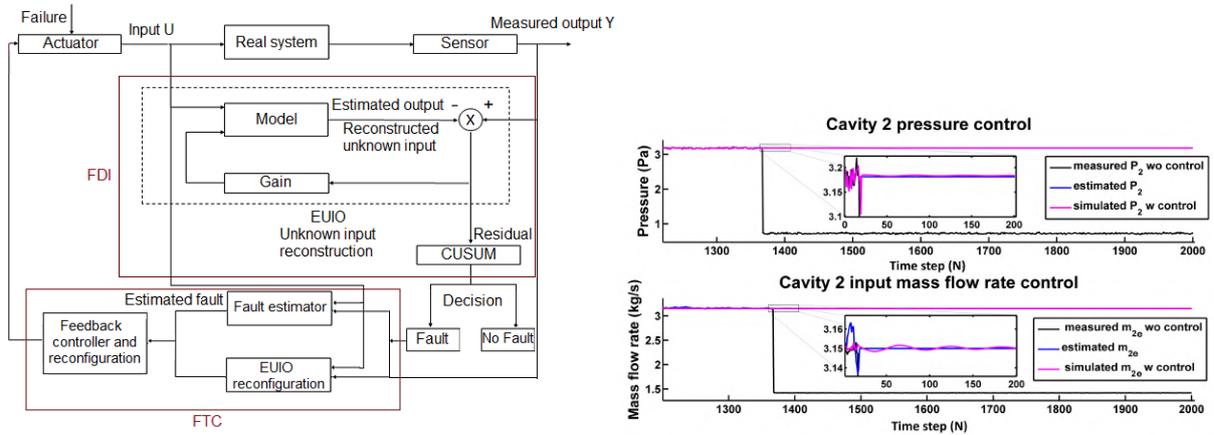


FIGURE 2.15 – Schéma complet FDI / FTC et exemple de résultat FTC (simulé)

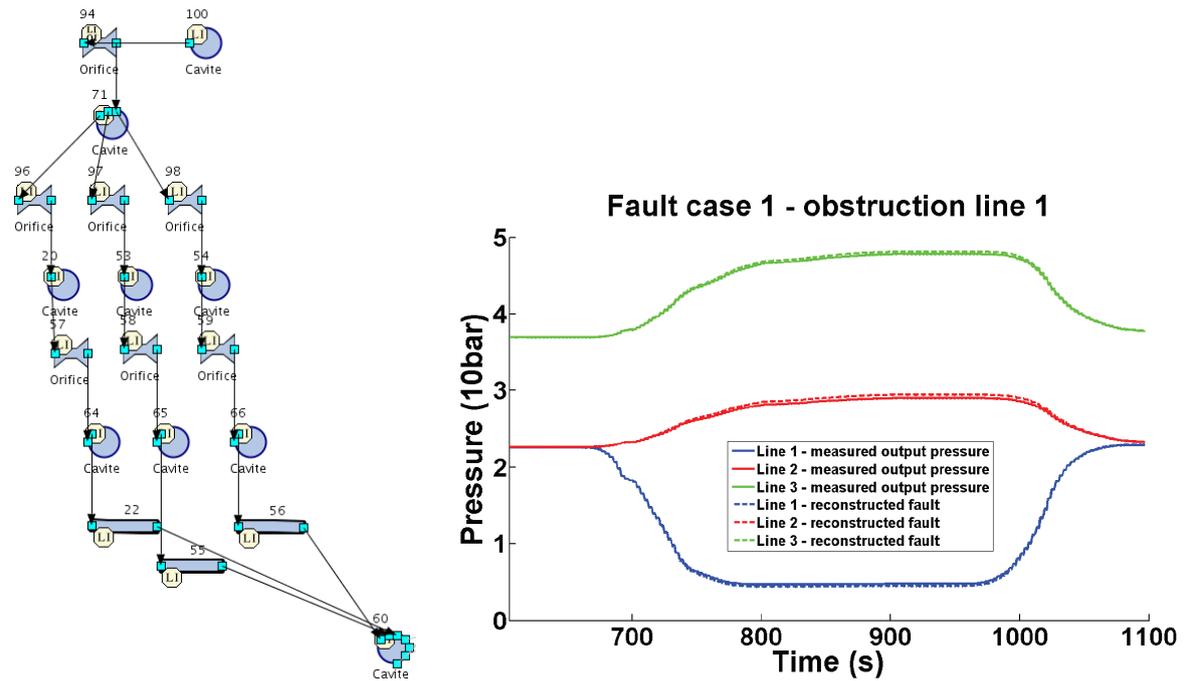


FIGURE 2.16 – Localisation de défaut dans des lignes parallèles du circuit de refroidissement : modèle et résidus par espace de parité (simulation Carins)

## 2.3 Pronostic à base de modèles pour les véhicules aéronautiques

Un autre type d'aide à l'opérateur est la possibilité de prédire l'évolution de l'état de santé d'un sous-système à partir des informations courantes, et ainsi prévenir une défaillance ou anticiper son aggravation si le défaut détecté ne remet pas en cause la fonction globale à l'instant considéré mais pourrait y contribuer. Ceci peut être nécessaire par exemple dans le cas d'une dérive ou d'une perturbation lente. Si un modèle précis du procédé est disponible, il peut être intéressant de faire une prédiction de son comportement afin de montrer à l'opérateur comment le problème se développera à l'avenir si aucune action n'est entreprise ou après certaines décisions d'action proposées.

Le pronostic permet ainsi d'estimer l'évolution de l'état futur d'un système et d'estimer le temps qu'il lui reste avant de subir une dégradation inacceptable. Pour conduire le pronostic d'un système, il faut estimer son état actuel puis le projeter dans le futur afin d'estimer à chaque instant sa RUL. Il existe trois approches principales pour réaliser ces tâches : les approches à base de connaissances (utilisation des informations acquises grâce aux experts et à l'historique des pannes enregistrées sur le système), les approches à base de données (relevé de différentes données sur le système pour extraire des caractéristiques permettant d'évaluer l'état de santé du système), les approches à base de modèles (comparaison entre le fonctionnement réel du système et son modèle mathématique de référence construit à partir des lois de la physique). Cette classification en trois approches, très analogue à celle du diagnostic, est la plus rencontrée dans la littérature [117–119]. Jusqu'ici, l'approche la plus utilisée est celle à base de données, tandis que peu de travaux ont pour le moment été consacrés aux méthodes à base de modèles.

Le calcul de la RUL repose sur une loi de vieillissement (ou loi d'usure, loi de dégradation) qui peut être obtenue à partir de données issues de bancs de test [120]. Une loi de vieillissement décrit l'évolution de l'état de santé (ou de dégradation) d'un système tout au long de sa vie. L'état de santé d'un système est défini à partir de propriétés spécifiques aux composants et des sollicitations du système (conditions opérationnelles). Celui-ci peut être affecté par des sollicitations anormales ou inattendues du système qui accélèrent ou ralentissent son vieillissement et modifient donc par conséquent sa RUL. Afin de déterminer de manière précise la RUL, il est nécessaire que la loi de vieillissement tienne compte des facteurs de stress qui influencent réellement le système tout au long de sa vie [121, 122]. Les facteurs de stress représentent toutes les sollicitations (normales et anormales) qui peuvent influencer l'état de santé du système, telles que les conditions opérationnelles (conditions environnementales comme l'humidité, la pression, la surtension, la température, les vibrations mécaniques, ...), ou encore les défauts pouvant survenir sur les composants et leurs conséquences sur les autres composants du système.

Les décisions de maintenance prévisionnelle reposent sur une analyse complète et effi-

cace de l'état de santé du système lors de son fonctionnement [123,124] par des fonctions de diagnostic et de pronostic. Les méthodes de diagnostic utilisent une connaissance sur le comportement du système alors que les méthodes de pronostic reposent plutôt sur une connaissance de l'évolution de l'état de santé ou de dégradation des composants.

Quelle que soit la technique employée, le pronostic s'effectue en deux temps : durant l'intervalle d'analyse  $I_a = [t_0; t_p]$  (Figure 2.17), l'observation des mesures d'entrée et de sortie du système est réalisée. Ensuite, en se basant sur ces observations, une prédiction de la RUL est effectuée dans l'intervalle de prédiction  $[t_p; t_{pf}]$  où  $t_p$  est le temps auquel on effectue la prédiction. En notant  $f$  la fonction représentant la dégradation et  $t_{pf}$  le temps auquel le système est défaillant c'est à dire où  $f(t_{pf}) = f_c$  le niveau critique de dégradation, on a finalement  $RUL = t_{pf} - t_p$ . On associe généralement une densité de probabilité à cette estimation. Le niveau de connaissance disponible est tout d'abord

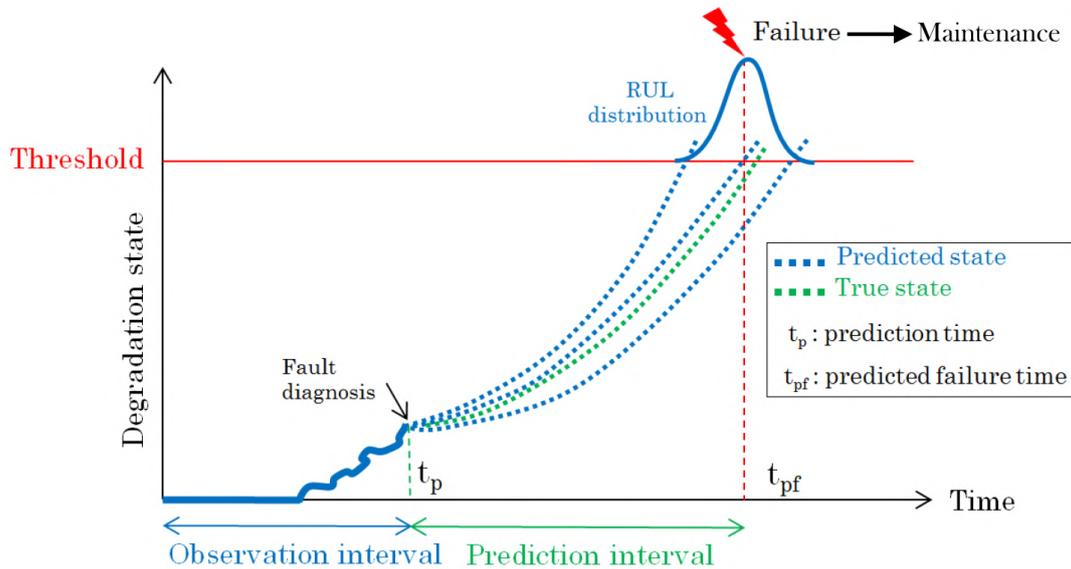


FIGURE 2.17 – Etapes du pronostic à base de modèle

caractérisé par la présence de capteurs sur le système. Selon la qualité et la quantité de capteurs, il est possible d'obtenir en ligne des informations sur son état (données enregistrées, mesures, messages, alarmes, ...). Le second type de connaissance dont on dispose est un modèle de pronostic qui décrit l'évolution de l'état de dégradation du système. Ce modèle de pronostic peut être très pauvre en l'absence de capteurs et reposer uniquement sur l'expérience. Mais il peut être également très riche dans le cas où des observations en ligne sont considérées et extrapolées par des raisonnements physiques sur les composants susceptibles de tomber en panne dans le futur. Le Tableau 2.1 présente les trois classes de méthodes de pronostic qui reposent sur différents niveaux de connaissance disponible et leurs caractéristiques.

L'approche dite « à base de modèles » repose sur une modélisation fine de la dynamique des processus supervisés couplée avec une modélisation de la dégradation qui peut

Tableau 2.1 – Comparatif des approches de pronostic

Approche de pronostic	Avantages	Inconvénients
Connaissances	Connaissances expertes disponibles dans de nombreux domaines	Nécessite un bon retour d'expérience. Difficile d'intégrer les variations de conditions opérationnelles
Données	Connaissance des mécanismes de dégradation directement incluse dans les données	Nécessite une multitude de données et donc stockage et temps de calcul plus importants
Modèles	Meilleures performances (précision). Flexibilité de l'approche due à l'intégration de connaissance de la structure des mécanismes de dégradation	Difficultés dans la modélisation du système et de la dégradation

être probabiliste ou ensembliste. Un modèle mathématique précis du système qui intègre l'évolution dynamique de la dégradation est nécessaire pour pouvoir utiliser l'approche à base de modèles. Qu'ils soient sous la forme d'équations différentielles ou encore d'équations aux différences, ces modèles intègrent non seulement la connaissance des conditions opérationnelles et les effets de leur variabilité sur le comportement du système, mais également l'évolution dynamique de la dégradation et son effet sur la dérive de comportement du système. Le pronostic étant réalisé à partir de l'analyse de la dégradation, il est nécessaire de connaître précisément son modèle. Selon l'application étudiée, différentes modélisations peuvent être employées : l'étude spécifique de la fatigue des matériaux, ou dans un cadre plus général l'utilisation de modèles dynamiques à temps continu ou discret.

Par exemple, l'analyse structurelle d'une dégradation telle que l'analyse de stress ou de déformation de structures consiste dans un premier temps à détecter et localiser les micro-fissures dans un matériau en fonction des sollicitations exercées sur celui-ci. Cette analyse se fait à l'échelle mésoscopique, et un critère d'accumulation de contraintes locales fournit les directions et une valeur seuil d'initiation de propagation de ces fissures. Ensuite, un modèle décrivant l'évolution des fissures selon le type de mécanisme de dégradation considéré est choisi. Le modèle est implémenté sous un logiciel de résolution par éléments finis afin de simuler l'évolution géométrique de la fissure, et une prédiction du temps à partir duquel la fissure atteindra une taille critique est effectuée. Afin d'avoir une explication détaillée, l'ouvrage [125] peut être consulté.

Les méthodes de pronostic par estimation d'état ou de paramètres sont utilisées pour prédire le comportement d'un paramètre révélateur de l'état de dégradation du système. Il s'agit de minimiser l'écart entre un modèle de référence de ce paramètre significatif et les mesures obtenues à partir des capteurs à un instant donné. Le modèle de pronostic

utilisé peut être lié à une connaissance physique du système ou simplement à une analyse mathématique du comportement. La prédiction de la valeur attendue des paramètres repose seulement sur les mesures à l’instant précédent et sur une équation dynamique. La méthode d’estimation permet d’obtenir un pronostic adaptatif. L’étape de propagation permettant de déterminer la distribution de probabilité de la RUL est typiquement un problème de propagation d’incertitudes, pour lequel on utilise principalement des méthodes probabilistes. Le filtre de Kalman (étendu en cas de présence de non-linéarités) peut ainsi être utilisé pour minimiser l’erreur entre le modèle de pronostic et les données observées pour prédire le comportement futur d’un paramètre du système [126]. Lorsque le modèle est fortement non-linéaire ou les incertitudes non-gaussiennes, le filtrage particulaire est de plus en plus utilisé avec des résultats prometteurs bien que son coût de calcul soit relativement élevé [127].

Jusqu’ici, l’approche la plus utilisée dans la littérature pour le pronostic est celle dite à base de données, tandis que peu de travaux ont été consacrés aux méthodes à base de modèles. C’est donc une voie de recherche prometteuse, qui a été explorée dans la thèse d’Elinirina Robinson (2015 – 2018 [128]), co-dirigée avec Tarek RAÏSSI (CNAM CEDRIC). Les méthodes développées ont été principalement appliquées sur des problématiques de propagation de fissure, en collaboration avec le département Matériaux et Structures (DMAS) de l’ONERA qui a notamment fourni des données d’essai de matériaux composites.

### 2.3.1 Modélisation probabiliste des incertitudes

Deux phases sont nécessaires pour réaliser le pronostic à base de modèles : tout d’abord une estimation conjointe de l’état et des paramètres incertains du système à partir des données collectées en temps réel, et ensuite une phase de prédiction de l’état futur de la dégradation. Cependant, ces deux étapes sont entachées d’incertitudes. Ainsi, le principal enjeu du pronostic est de tenir compte des incertitudes de modèle, de mesures et des futures conditions d’opération du système. Dans un premier temps, l’approche stochastique couramment employée dans la littérature a été étudiée.

Dans la référence [32], nous avons réalisé une évaluation des principales méthodes (filtre de Kalman étendu, filtrage particulaire) sur un cas test académique usuel, à savoir la loi de Paris-Erdogan décrivant la longueur d’une fissure selon le modèle suivant :

$$\frac{da}{dN} = C(\Delta K)^m = C \left( \Delta \sigma \sqrt{\pi a} \right)^m = \exp(\log(C)) \cdot \left( \Delta \sigma \sqrt{\pi a} \right)^m \quad (2.34)$$

où  $a$  est la longueur de fissure,  $N$  le nombre de cycles de sollicitation du matériau,  $\Delta \sigma$  le chargement appliqué (supposé connu), et  $m$  et  $C$  des paramètres caractéristiques du matériau (qui peuvent être initialement incertains). Le paramètre  $C$  étant très petit, une réécriture sous la forme  $\exp(\log(C))$  a été utilisée pour des raisons numériques. On considère qu’une défaillance critique survient lorsque la longueur de fissure excède un seuil prédéfini.

Deux approches classiques, un filtre de Kalman étendu (EKF) et un filtre particulaire SIR (ré-échantillonnage par importance), ont été testées sur le modèle (2.34) discrétisé par rapport au cycle et en considérant le vecteur d'état augmenté  $X_k = [a_k, \log(C_k), m_k]^T$  pour réaliser l'estimation conjointe état-paramètres avec un modèle bruit blanc sur les paramètres. Un exemple de résultat de simulation est présenté en Figure 2.18. Les étapes habituelles de prédiction et correction de ces filtres sont appliquées tant que des mesures sont disponibles (jusqu'au cycle  $N = 1200$  ici). Puis, il s'agit de propager le modèle dans le futur sans nouvelle mesure, afin de déterminer l'instant de franchissement du seuil. Dans le cas de l'EKF, la matrice de covariance est considérée constante à partir du dernier instant de mesure connue et le bruit d'état est généré à chaque pas lors de l'étape de correction à partir de celle-ci puis est injecté dans l'équation du modèle. L'évaluation de la densité de probabilité de la RUL est effectuée en répétant 100 fois cette opération. Dans le cas du filtre particulaire, la propagation s'effectue en considérant que le poids des particules est invariant à partir de l'instant de prédiction jusqu'à atteindre le seuil de dégradation [129]. Un ensemble de métriques a été utilisée dans l'ensemble des travaux de thèse pour quantifier la performance du pronostic et comparer les différentes méthodes. L'*exactitude* mesure la proximité de la RUL prédite par rapport à la vraie RUL (connue uniquement pour les cas simulés). La *précision* mesure la largeur de l'intervalle contenant les RUL prédites. L'*opportunité* mesure la position relative de la RUL prédite par rapport à la vraie RUL (« trop tôt » ou « trop tard »). L'exactitude et la précision sont comprises entre 0 et 1, où 1 reflète la meilleure performance. Plus l'opportunité est grande, plus on s'éloigne de la vraie distribution de la RUL, et un poids plus important est donné aux prédictions en retard afin de les pénaliser.

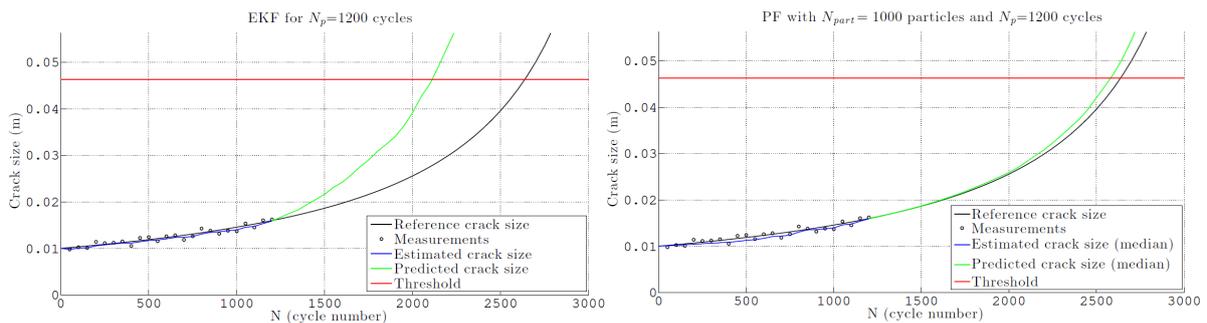


FIGURE 2.18 – Résultats de simulation pour filtre de Kalman étendu et filtre Particulaire sur le cas test Paris-Erdogan

Une fois ces outils méthodologiques en place, un cas test plus réaliste a été étudié : la propagation de fissure dans un matériau composite renforcé avec des fibres, le chargement étant inconnu et la structure soumise à des variations brusques de chargement (représentatives d'un choc par exemple). Des données réelles issues de tests de fatigue réalisés au département matériaux et structures de l'ONERA (DMAS) ont été utilisées [130]. La loi de Paris-Erdogan simple n'étant plus valable pour ce matériau, un nouveau modèle a été établi pour le pronostic à partir de la littérature dédiée aux matériaux [131]. La principale difficulté dans ce modèle concerne l'estimation d'un des paramètres de chargement ( $\Delta P$ ) qui se fait généralement par la méthode des éléments finis. Cependant ce n'est pas adapté au pronostic en ligne à cause des temps de calcul beaucoup trop importants. Il a été proposé de considérer ce paramètre comme uniforme, afin de simplifier le modèle et l'adapter au pronostic. Finalement, on obtient la loi de Paris modifiée suivante :

$$\frac{da}{dN} = \exp(\log(C)) \left( F \Delta \sigma_a \sqrt{\pi a} - 2F \sqrt{\frac{a}{\pi}} \Delta P \left( \frac{\pi}{2} - \arcsin \left( \frac{a_0}{a} \right) \right) - K_{th} \right)^m \quad (2.35)$$

Ce modèle contient deux types de paramètres. D'une part, les paramètres constants de modèle  $m$  et  $\log(C)$  peuvent être estimés comme précédemment avec un filtre particulière sur un jeu de données où le chargement est maintenu constant. D'autre part, les paramètres de chargement  $\Delta P$  et  $\Delta \sigma_a$  dépendent du chargement appliqué à la structure et peuvent donc varier au cours du temps en situation réelle. Des jeux de données supplémentaires présentant ces caractéristiques ont donc été utilisés, et l'état augmenté est alors dans ce cas  $[a, \Delta \sigma_a, \Delta P]$ . Une des particularités des matériaux composites est de stopper la propagation de la fissure lorsque le chargement ne varie plus (Figure 2.19, la RUL n'est alors plus définie), mais une nouvelle variation brutale du chargement peut entraîner la dégradation rapide de la structure : il faut donc être capable de la détecter.

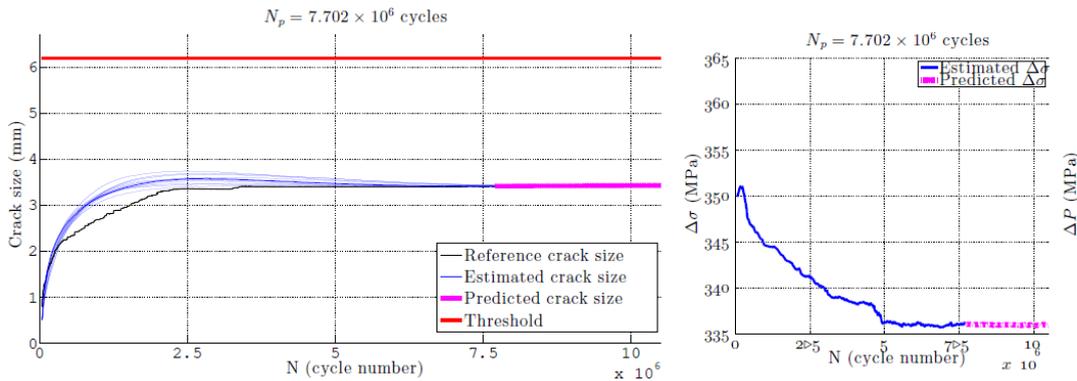


FIGURE 2.19 – Matériau composite sans variation de chargement : estimation par filtre particulière de la longueur de fissure et des paramètres de chargement

Or, le filtre particulière classique ne parvient pas à suivre la rupture du paramètre lors d'une telle variation (Figure 2.20a). Il a donc été proposé d'adjoindre au filtre un

algorithme de détection de changement (CUSUM bilatéral) sur la valeur estimée du paramètre  $\Delta\sigma_a$ , par rapport à sa moyenne glissante avec facteur d'oubli. Lorsqu'un changement est détecté, les valeurs des paramètres estimés sont réinitialisées pour que le filtre particulaire converge après la variation. Les valeurs de réinitialisation sont déterminées à partir de la connaissance de la valeur de chargement critique  $\Delta\sigma_{crit}$  au-delà de laquelle la longueur de la fissure risque d'augmenter plus rapidement. Ceci permet de retrouver une estimation et une prédiction de la RUL correctes (Figure 2.20b). Afin de tenir compte de l'incertitude sur cette valeur, il a été vérifié que l'estimation était correctement réalisée lorsque cette réinitialisation s'effectue aléatoirement dans un intervalle à  $\pm 10\%$ . Ces travaux ont fait l'objet de la communication [22] à la conférence Safeprocess 2018 pour laquelle la doctorante a reçu le prix « IFAC Young Author », et d'un article [6] dans un numéro spécial de la revue *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part A : Civil Engineering*.

Toujours dans un contexte probabiliste, une méthode de prédiction permettant d'estimer la RUL sans intégrer pas à pas le modèle a été proposée dans [27]. Il s'agit d'une transposition pour le pronostic de l'*inverse first-order reliability method* (FORM) utilisée habituellement en fiabilité [132]. On peut ainsi estimer directement un point de la fonction de répartition de la RUL (moyenne ou tout quantile désiré), qui s'exprime comme une contrainte par rapport au seuil sur la longueur de fissure déterminant l'instant de défaillance et à l'aide d'un modèle analytique ou boîte noire de l'évolution temporelle de la fissure en fonction du nombre de cycles (expression analytique disponible dans le cas de loi de Paris-Erdogan (2.34)). La précision de cette méthode est comparable à la technique Monte-Carlo habituelle, mais avec un coût de calcul moindre.

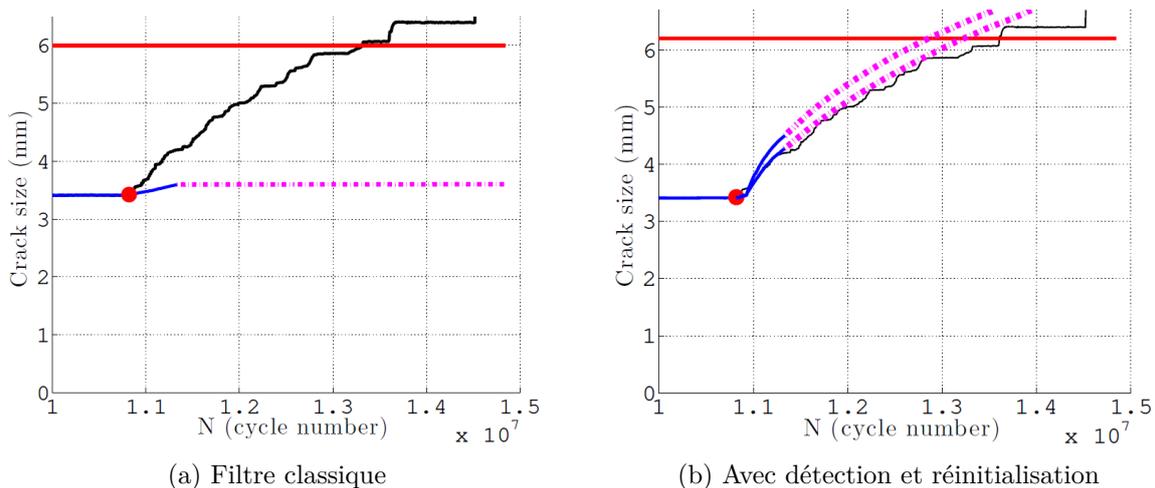


FIGURE 2.20 – Matériau composite avec variation brusque de chargement, estimation conjointe de la longueur de fissure et des paramètres de chargement

### 2.3.2 Modélisation par intervalle des incertitudes

Ces travaux de thèse ont également étudié la représentation des incertitudes comme des intervalles, afin d'obtenir un ensemble garanti de définition de la RUL plutôt qu'une densité de probabilité. Deux approches ont été proposées en fonction du contexte : la première repose sur une technique de satisfaction de contraintes afin d'estimer les paramètres du modèle et propager la dégradation lorsque celle-ci est mesurée ; la deuxième considère le cas où la dégradation n'est pas directement mesurée mais est liée à l'évolution d'un paramètre du modèle : dans ce cadre, un nouvel estimateur d'état ensembliste à entrée inconnue a été proposé [128].

Dans le premier cas, nous avons considéré le modèle (2.34), pour lequel les paramètres caractéristiques du matériaux  $m$  et  $\log(C)$  doivent être estimés, avant de pouvoir prédire l'évolution de la fissure. On considère l'évolution à temps discret de ce système :

$$\begin{cases} x_k = f(x_{k-1}, \theta, w_k) \\ y_k = h(x_k, v_k) \end{cases} \quad (2.36)$$

où les bruits sont supposés bornés tels que  $\|w_k\| \leq W$ ,  $\|v_k\| \leq V$ . Les mesures disponibles  $y_k^m$  sur l'intervalle  $k \in [k_0, k_p]$  sont utilisées pour estimer le domaine faisable des paramètres. Cette estimation est réalisée par satisfaction de contraintes, à savoir la recherche de l'ensemble contenant tous les paramètres respectant le modèle (2.34) discrétisé sur la séquence considérée :

$$\mathcal{C} : \begin{cases} \mathcal{C}_k : x_k = f(x_{k-1}, \theta, w_k), y_k = h(x_k, v_k), k \in [k_0, k_p] \\ w_k \in [-W, W], v_k \in [-V, V] \\ \theta \in [\underline{\theta}, \bar{\theta}] \end{cases} \quad (2.37)$$

Une solution a pu être trouvée avec l'algorithme d'inversion ensembliste SIVIA [133], plus particulièrement son implémentation vectorielle dans la toolbox Matlab VSIVIA [134]. Une fois l'ensemble faisable des paramètres obtenu, il s'agit de propager le modèle à partir du cycle  $k_p$  jusqu'au franchissement du seuil de dégradation, grâce à la fonction d'inclusion naturelle du modèle Paris-Erdogan et les bornes sur les bruits. On obtient finalement l'intervalle  $k_{RUL} = [k_f - k_p, \bar{k}_f - k_p]$ . Les résultats (Figure 2.21) ont été comparés avec les méthodes probabilistes, et il est apparu que la méthode par intervalles obtient des performances très proches de celles du filtre particulaire, avec une dispersion légèrement supérieure (due au caractère garanti de l'intervalle obtenu, tandis que la distribution de probabilité est tronquée) [32].

Dans le deuxième cas étudié, la dégradation (fissure) n'est pas directement mesurée mais peut être reliée par un modèle analytique à l'évolution d'un paramètre ou d'une entrée inconnue. Nous avons donc proposé une chaîne de traitement complète composée d'un observateur par intervalles à entrée inconnue permettant d'estimer l'état et l'évolution des paramètres d'intérêt, dont les estimées sont utilisées lors d'une phase d'inversion

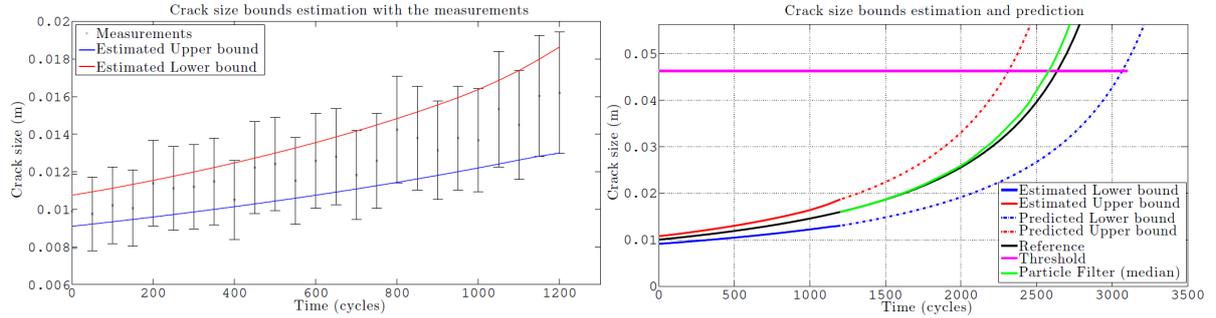


FIGURE 2.21 – Estimation de paramètres (à gauche) et propagation (à droite) par intervalles de la longueur de fissure (modèle Paris-Erdogan)

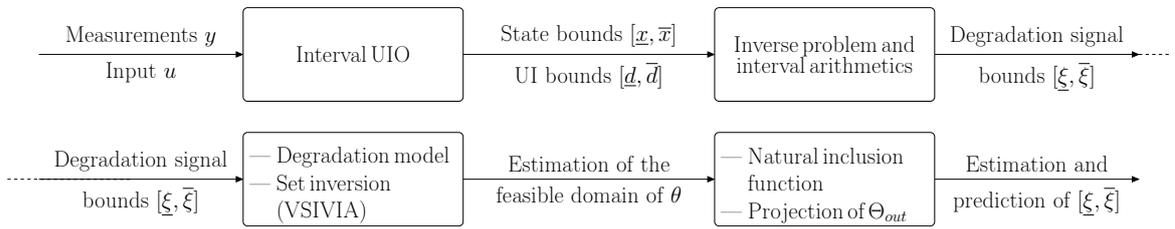


FIGURE 2.22 – Chaîne d'estimation ensembliste d'une dégradation non mesurée

ensembliste pour reconstruire le signal de dégradation (et ses bornes), avant de propager le modèle comme précédemment afin d'obtenir l'intervalle contenant la RUL. Un observateur à entrée inconnue pour les systèmes linéaires à temps discret a été proposé [28], en combinant les résultats sur les observateurs intervalles à temps continu [135] et les observateurs à entrée inconnue pour systèmes discrets [136]. Le type de modèle traité est de la forme suivante, où  $d$  est le vecteur des entrées inconnues,

$$\begin{cases} x_{k+1} = Ax_k + Bu_k + Fd_k + w_k \\ y_k = Cx_k + v_k \end{cases} \quad (2.38)$$

Les étapes de conception de l'observateur sont les suivantes :

1. Effectuer un changement de coordonnées (statique) pour obtenir deux sous-systèmes, l'un affecté par l'entrée inconnue et l'autre non.
2. Effectuer un nouveau changement de coordonnées pour le sous-système non affecté par l'entrée inconnue, afin de garantir la coopérativité de l'erreur d'observation (état toujours positif).
3. Estimer l'intervalle contenant l'état du sous-système non affecté par l'entrée inconnue, puis l'ensemble de l'état via les deux changements de coordonnées précédents.
4. Estimer l'intervalle contenant l'entrée inconnue.

Ces développements ont été appliqués sur le cas d'étude d'un système de suspension

composé de deux amortisseurs masse-ressort en série (Figure 2.23a), dont le déplacement vertical est mesuré. Une fissure du ressort peut être modélisée via la loi de Paris-Erdogan utilisée dans les travaux précédents, et une fonction polynomiale issue de la littérature [137] lie cette dégradation (normalisée telle que  $\xi \in [0, 1]$ ) avec l'évolution de la constante de raideur du ressort  $k_1$ . L'observateur est utilisé pour estimer en temps qu'entrée inconnue la variation de ce paramètre  $\delta k_1$ , puis cette estimée sous forme d'intervalle est traitée par inversion ensembliste pour reconstruire l'évolution de  $\xi$ . La fissure est alors finalement propagée comme dans le premier cas traité, par intégration de la fonction d'inclusion naturelle de la loi de Paris-Erdogan. Les résultats sont présentés en Figure 2.23. Cette procédure est répétée à chaque nouvelle mesure afin de préciser l'intervalle de franchissement du seuil de dégradation, i.e. la RUL.

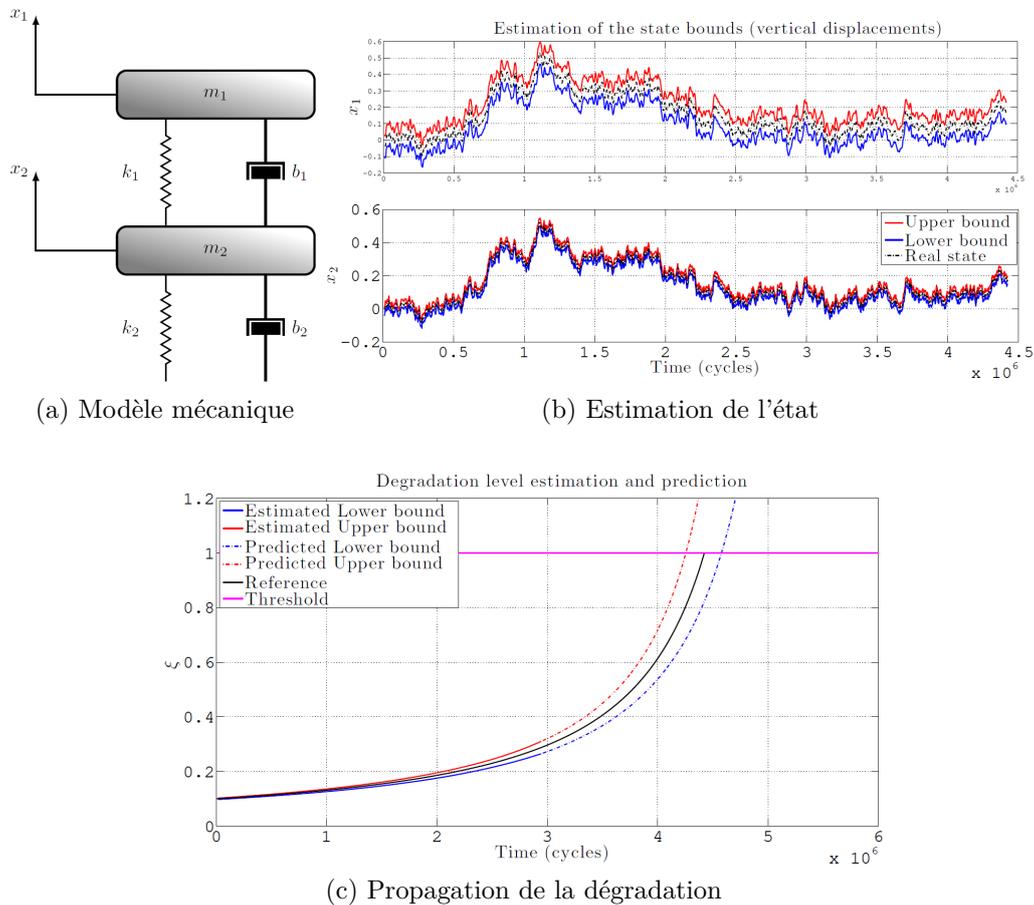


FIGURE 2.23 – Pronostic par intervalles d'une dégradation non mesurée dans un système d'amortisseur



# Chapitre 3

## Navigation autonome mono et multi-robots

---

**Résumé** – Ce chapitre présente le développement de méthodes de guidage pour les robots terrestres et aériens. Le sujet traité principalement est la navigation autonome en milieu intérieur encombré à base de vision embarquée, avec extension à la commande coopérative distribuée de flottes de véhicules. Nous menons une activité de robotique expérimentale permettant de valider ces approches en conditions réalistes, ce qui a donné lieu à de nombreuses démonstrations de capacités nouvelles de navigation et vol autonome dans le cadre de projets industriels et de recherche.

---

Le laboratoire expérimental **COPERNIC** (Commande et Perception pour la Navigation autonome et la Coopération), initié en 2014 au sein de l'ONERA DTIS par le projet interne éponyme, développe des solutions d'intelligence embarquée pour la robotique aérienne et terrestre. Il associe au sein du département les compétences en perception et vision par ordinateur à celles en commande et planification pour réaliser des démonstrations de robotique autonome et collaborative dans des contextes liés à des applications civiles ou défense (missions d'inspection ou de surveillance). Les thèmes de recherche comprennent la vision géométrique pour la localisation et la modélisation 3D, la commande mono-véhicule et multi-véhicules (c'est principalement ici que j'interviens) et la planification de mission. COPERNIC comprend une activité importante d'ingénierie matérielle (capteurs, solutions de calcul embarquées et plate-formes) pour être à même de produire des **preuves de concept de robotique expérimentale dans des contextes réalistes**, notamment dans le cadre de projets à financement industriel ou européen. Deux projets principaux ont conduit à des démonstrations d'envergure en conditions réelles avec un mini-drone embarquant une boucle complète de perception et commande pour la navigation autonome à base de stéréo-vision en milieu intérieur encombré : le partenariat Recherche-Industrie DROSOFLES avec la SNCF (Section 3.2.3) et le Challenge FP7

EuRoC (European Robotics Challenges, Section 3.2.4) avec RTE comme *end-user*.

Tous les robots du laboratoire (terrestres et aériens, cf Figure 3.1) sont équipés de bancs stéréo composés de deux caméras identiques et synchronisées à 20 Hz, séparées par une distance d’une vingtaine de centimètres soit une portée de 5 à 10 m. Les bancs sont calibrés via l’outil open-source *kalibr* [138, 139] afin de déterminer les paramètres intrinsèques des caméras ( focale, point à l’origine), les coefficients de distorsion, et les transformations entre les deux caméras du banc et avec la centrale inertielle embarquée. Les algorithmes développés sont implémentés sous le middleware open-source ROS [140], qui permet une interaction modulaire entre de nombreux *nœuds* indépendants (écrits en C++ ou Python) via un système de messages standardisés. Celui-ci tourne à bord des robots en lien avec leurs capteurs et actionneurs, et offre également la possibilité de tester au préalable ces mêmes briques algorithmiques avec le simulateur Gazebo [141, 142] intégrant un moteur physique ainsi que de nombreux modèles de robots et d’environnements (Figure 3.2). Nous disposons également d’une volière sur le site ONERA de Palaiseau (6m x 7m au sol et hauteur 3m) couverte par un système Optitrack de motion capture, ce qui permet de valider les algorithmes de localisation et de tester les lois de commande indépendamment lors des premiers stades de développement.

Le sujet d’étude principal est l’exploration autonome par des plateformes robotiques mobiles dans l’optique de missions de reconnaissance (recueil d’informations, Search-And-Rescue), d’inspection ou de surveillance de sites industriels. Le fonctionnement en autonomie de ces plateformes permet de s’affranchir des difficultés pouvant survenir dans le cas d’une télé-opération entièrement manuelle de l’engin, suite à des pertes de connexion ou une latence trop importante. L’utilisation de différents types de plateformes robotiques, terrestres ou aériennes, permet d’augmenter la capacité d’acquisition des informations dans l’environnement. Les robots terrestres ont l’avantage d’avoir une autonomie de fonctionnement et une charge utile plus importantes que celle des robots aériens. D’un autre côté, les drones présentent une plus grande mobilité par rapport aux robots terrestres, ils peuvent explorer des zones qui leur sont inaccessibles et peuvent ainsi obtenir des points de vue multiples. Pour que ces plateformes puissent naviguer de façon autonome et sûre, différentes tâches embarquées doivent être exécutées en temps réel. La capacité à percevoir l’environnement est primordiale, afin d’obtenir des informations nécessaires pour pouvoir calculer la localisation de l’engin, cartographier l’environnement ou détecter des obstacles. A partir de ces différentes informations, le robot peut ensuite calculer sa commande afin de réaliser la mission définie [143]. Les applications considérées se déroulant dans des environnements intérieurs et/ou très encombrés, où les signaux GPS ne sont pas disponibles, les travaux reposent sur l’utilisation de capteurs de stéréo-vision (légers et peu chers). De nombreux algorithmes de localisation et cartographie ont été proposés dans la littérature [144, 145], cependant l’intégration de ces systèmes dans une boucle embarquée de perception embarquée et commande exécutée entièrement à bord des robots demande un effort important d’adaptation des algorithmes et de nombreux tests expérimentaux. Une poignée seulement de démonstrateurs de drones et robots mobiles avec des capacités de navigation autonome à partir

de mesures vision ont été présentés récemment [146–148]. Nos travaux s’inscrivent dans cette perspective, avec le développement d’algorithmes de guidage couplés à la localisation et la cartographie basées vision pour véhicules unitaires (drone, robot mobile) et désormais pour les flottes multi-robots. Cette recherche appliquée est soutenue par un certain nombre de projets internes et externes à l’ONERA, en lien avec les *end-users* industriels ou étatiques.



FIGURE 3.1 – Plateformes robotiques du laboratoire Copernic (ONERA DTIS)

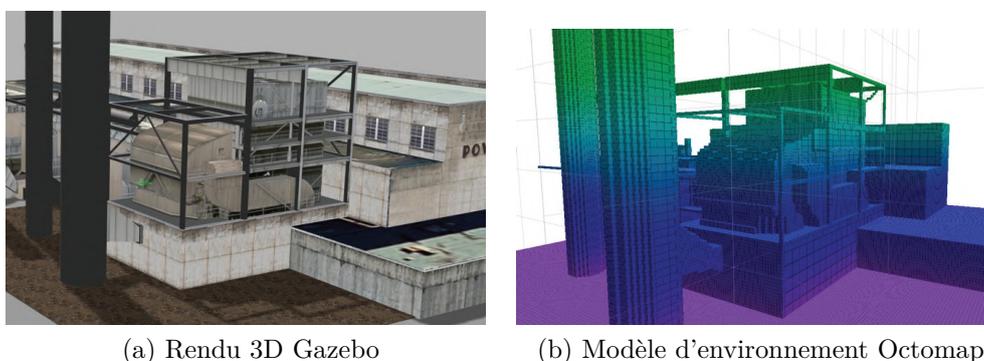


FIGURE 3.2 – Environnement de simulation ROS – Gazebo (cas d’étude EuRoC)

### 3.1 Algorithmes de localisation et cartographie à base de stéréo-vision

Cette partie décrit brièvement le principe de fonctionnement et les informations fournies par les algorithmes de localisation et cartographie à base de stéréo-vision [3, 25, 65, 149–152] développés par les collègues du laboratoire spécialisés en traitement d’image (Martial Sanfourche, Alexandre Eudes, Julien Moras, Anthelme Bernard-Brunel, Guy Le Besnerais, Aurélien Plyer). Une spécificité de la plupart des travaux décrits dans ce chapitre est justement l’interfaçage et la mise en œuvre expérimentale d’une boucle complète faisant interagir les algorithmes de perception et de commande afin de faire naviguer sans GPS un ou plusieurs robots (terrestres ou aériens) dans un milieu inconnu et potentiellement encombré.

#### *Localisation basée vision*

L’algorithme eVO [150, 151] développé à l’ONERA construit une carte composée d’amers 3D qui sont automatiquement générés à partir de points remarquables extraits et

suivis dans le temps à travers les images. En supposant que les amers 3D sont fixes, leur mouvement dans les images au cours du temps relève du mouvement 3D (translation et rotation) du banc stéréo et donc du véhicule qui le porte. La structure de l’algorithme est similaire à celle de PTAM [145] avec les deux processus suivants s’exécutant en parallèle.

1. Le processus de localisation réalise le suivi par l’algorithme KLT [153] des amers visuels 3D dans l’image acquise par la caméra gauche du banc stéréo. Ceci permet de calculer la position et l’attitude de la caméra gauche (choisie comme référence) par un algorithme d’appariement 2D-3D comprenant une étape d’initialisation robuste à base de RANSAC [154] puis la minimisation d’un critère de moindres carrés non linéaires [155]. Ces opérations sont exécutées pour chaque image et lorsque le nombre d’amers suivi passe sous un seuil, le module de cartographie permet de sélectionner et de localiser de nouveaux amers 3D. Les images utilisées pour générer ces nouveaux points 3D sont appelées *images-clefs*.
2. Le processus de cartographie est dédié à la gestion des points de repère 3D. Cette étape utilise les deux images du capteur stéréo, préalablement rectifiées afin de supprimer les distorsions. Des points caractéristiques de type Harris sont extraits dans l’image gauche. Leurs correspondants sont recherchés dans l’image droite et localisés en 3D dans le repère capteur par triangulation. Afin de limiter la charge de calcul, les amers sont supprimés de la carte dès qu’ils ne sont plus visibles [156].

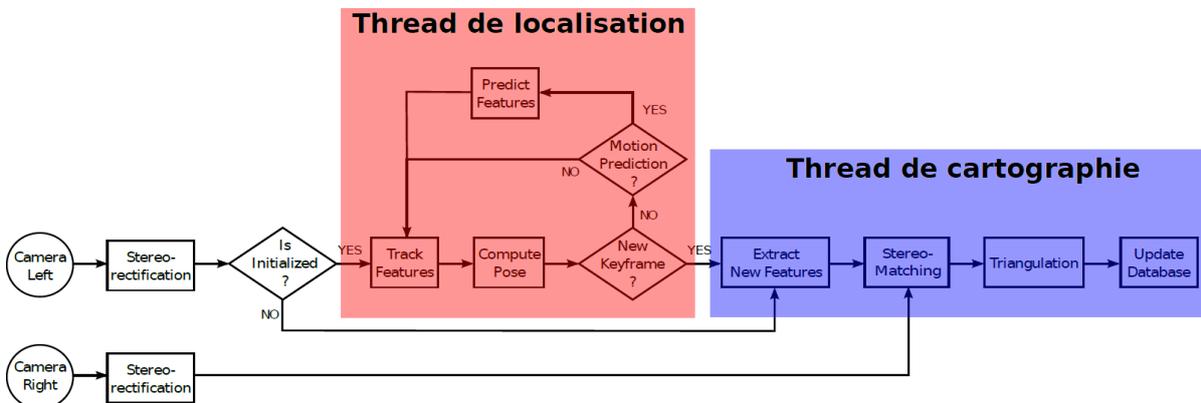


FIGURE 3.3 – Algorithme d’odométrie visuelle eVO

La Figure 3.3 résume les différentes étapes de l’algorithme. L’ensemble permet d’obtenir une estimée de pose à cadence vidéo (20 Hz dans les applications traitées), avec une performance de dérive en translation inférieure à 2% de la trajectoire parcourue et une erreur angulaire très faible (benchmark *Kitti* [157]).

### Estimation d’état

Afin d’obtenir une estimée de l’état du robot à plus haute cadence (100 Hz), l’odométrie visuelle est fusionnée avec les mesures issues d’une centrale inertielle par un filtre de Kalman. Dans le cas des drones Asctec, le contrôleur bas-niveau fournit une estimée

d'orientation fiable qui est conservée comme référence [158]. Un filtre linéaire basé sur un modèle double intégrateur (et biais constant) permet alors de combiner les mesures accélérométriques (prédiction à 100 Hz) et la position eVO (correction à 20 Hz) dans un repère de référence aligné sur la gravité. Un second filtre linéaire indépendant estime la hauteur et la vitesse verticale à partir d'un télémètre laser dirigé au nadir (pour les décollages et atterrissages automatiques ou pour la stabilisation d'urgence). Dans le cas d'un robot mobile, un filtre de Kalman étendu est appliqué avec comme entrées de prédiction la vitesse angulaire mesurée par la centrale inertielle et la mesure de vitesse linéaire issue de l'odométrie des roues. Pour tous les filtres, un test de diagnostic est effectué sur l'innovation en position afin de vérifier la cohérence de l'odométrie visuelle (dont la performance est conditionnée à la présence d'amers visuels significatifs dans la scène). En cas d'incohérence, la correction de position n'est pas appliquée et eVO est réinitialisé à la pose courante du filtre [39, 143].

#### *Modèle 3D de l'environnement*

Ce module agrège l'information 3D captée par le banc stéréo à chaque image-clef dans un modèle global cohérent basé sur une grille d'occupation probabiliste. L'opération se déroule en trois temps.

1. Une carte de disparité (décalage horizontal entre 2 pixels homologues des images rectifiées) est extraite par l'algorithme d'appariement dense ELAS (Efficient Large-scale Stereo Matching [159]) reposant sur une triangulation de Delaunay.
2. L'information de disparité est convertie en nuage de points 3D localisés dans le repère global à partir des informations de calibrage du banc stéréo et la pose de la caméra gauche estimée par eVO.
3. Les points 3D sont insérés dans une grille d'occupation probabiliste [160] implémentée à l'aide d'un Octree (bibliothèque open-source Octomap [161]). L'espace 3D est pavé en cellules cubiques (*voxels*), typiquement de 10 cm d'arête dans nos applications, contenant une probabilité d'occupation. Cette probabilité est mise à jour par une technique de lancer de rayon permettant de modéliser le processus de mesure 3D, vérifiant notamment que l'espace entre le capteur et un point 3D est libre d'obstacles et donc que la probabilité d'occupation des cellules traversées doit diminuer (estimation Bayésienne).

Le rafraîchissement du module Octomap est réalisé à 4 Hz en moyenne sur PC embarqué (exemple de carte en Figure 3.4). Pour la navigation autonome, tester tous les voxels autour de la position courante ou prédite d'un robot afin de déterminer les collisions [65] demande des ressources de calcul importantes. Une meilleure solution consiste à appliquer une *Euclidean Distance Transform* (EDT [162]) à l'Octomap. Cette transformation effectue une recherche locale à partir de chaque voxel de la carte afin de déterminer l'obstacle le plus proche (seuils prédéfinis de probabilité d'occupation et de distance maximale). On obtient ainsi un champ de distance et de direction à l'obstacle le plus

proche en toute position de l'espace, plus aisément exploitable par les algorithmes de guidage ou de planification de trajectoire. L'EDT peut être calculé à 2 Hz, avec une duplication en mémoire afin de prévenir l'accès concurrent entre le calcul à partir de l'Octomap et les requêtes de positions.

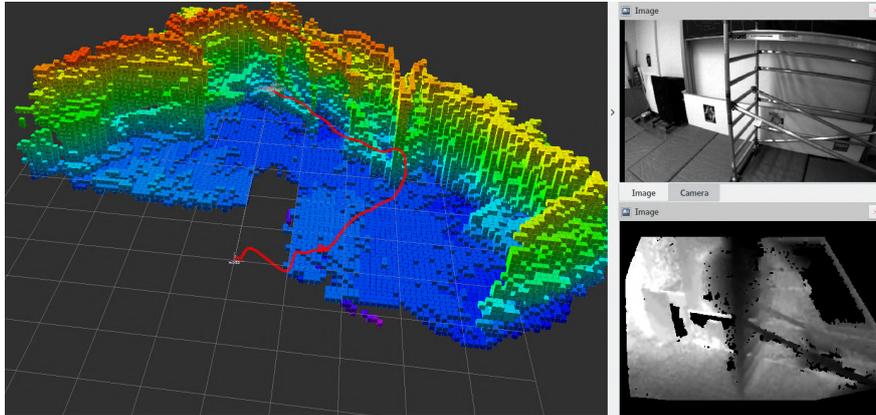


FIGURE 3.4 – Construction en ligne d'un modèle Octomap (à droite : image et disparité)

#### *Détection d'objet mobile à partir des mesures stéréo-vision*

Les objets mobiles ne sont pas cartographiés par le module Octomap, car celui-ci suppose une scène fixe et requiert ainsi plusieurs observations du même point d'intérêt avant de confirmer sa localisation comme occupée. La technique proposée est basée sur l'analyse du flot optique calculé uniquement sur les points de Harris extraits de la scène, dont la localisation 3D est connue via la stéréo (mécanisme présent dans eVO). Il est supposé que les objets mobiles se présentent comme des ensembles de points d'intérêt qui ne respectent pas les contraintes géométriques épipolaires entre deux images stéréo successives. L'étape de classification entre points statiques et dynamiques est réalisée grâce à deux tests. Le premier consiste à estimer la matrice fondamentale via un processus de type RANSAC qui identifie la transformation maximisant les associations temporelles de points d'intérêt entre deux images successives. Dans un second temps, les points d'intérêt validés par le premier test sont fournis à un calcul de pose robuste. La pose relative estimée est combinée à l'information de profondeur pour calculer un flot optique résiduel. Un seuillage de la norme de ce flot permet alors d'estimer les points d'intérêt sur ou à la frontière d'un objet mobile. Lors de l'étape d'agrégation, les points d'intérêt résultants sont rejetés ou regroupés en ensembles cohérents via une triangulation de Delaunay qui fournit des structures 3D en repère global, finalement englobées dans des cylindres représentant les objets mobiles candidats. Cette méthode parcimonieuse (points d'intérêts uniquement) s'exécute sur CPU embarqué à une cadence de 100 ms [3]. Une méthode dense nécessitant un GPU a également été développée à l'ONERA DTIS dans la thèse de Maxime Derome [149], celle-ci est également interfaçable en temps réel avec les algorithmes de guidage proposés dans ce chapitre [25].

## 3.2 Commande mono-véhicule

### 3.2.1 Exploration autonome d'une zone inconnue par un robot mobile

Nous avons présenté dans la référence [39] une première boucle embarquée de commande et estimation basée stéréo-vision pour permettre à un robot mobile de réaliser une mission d'exploration autonome. Celle-ci inclut un filtre de Kalman pour la fusion multi-capteurs et un algorithme de commande prédictive pour réaliser la mission et tenir compte en temps réel des contraintes de l'environnement (obstacles, champ de vue). Cette technique de commande est particulièrement employée dans nos travaux, car elle permet non seulement de tenir compte des évolutions de l'environnement (ce qui est indispensable lorsqu'il est initialement inconnu et encombré) et du comportement dynamique du système sur un horizon futur (que ce soit un robot mobile ou un drone). Les contributions apportées sont notamment la prise en compte d'objectifs multiples (suivi de trajectoire, exploration, évitement d'obstacle ou de collision) de manière générique, tout en respectant les contraintes de temps de calcul pour implémentation embarquée [13]. Une architecture embarquée a été définie et déclinée à bord de robots terrestres (Figure 3.5a) et de drones multi-rotors (Figure 3.16).

Le même modèle dynamique de type unicycle [163] a été considéré dans tous les travaux impliquant un robot mobile. Le vecteur d'état est  $\mathbf{x} = [x, y, \theta]^T$  avec  $(x, y)$  la position du robot et  $\theta$  son orientation, et le vecteur de commande est  $\mathbf{u} = [v, \omega]^T$  où  $v$  est la vitesse linéaire et  $\omega$  la vitesse angulaire du robot. Le modèle discrétisé avec un pas de temps  $t_e$  et le schéma d'Euler explicite s'écrit classiquement comme :

$$\begin{cases} x_k = x_{k-1} + t_e v_{k-1} \cos \theta_{k-1} \\ y_k = y_{k-1} + t_e v_{k-1} \sin \theta_{k-1} \\ \theta_k = \theta_{k-1} + t_e \omega_{k-1} \end{cases} \quad (3.1)$$

La commande prédictive est une méthode usuelle pour le guidage de véhicules autonomes dans des environnements complexes prenant en compte de nombreux objectifs et contraintes [164–166], appliquée avec succès pour la génération et le suivi de trajectoire [167–169] ou encore la réalisation de missions d'exploration [43, 170–172]. Dans la continuité de premiers travaux menés à l'ONERA DTIS sur ce sujet [173, 174], nous appliquons cette technique à la robotique mobile et aérienne avec validation expérimentale depuis 2014. Les principales caractéristiques de ces travaux sont l'interaction avec les algorithmes de perception décrits précédemment, ainsi que l'adéquation de l'algorithme de commande avec la charge de calcul disponible à bord des robots.

On considère l'état courant du robot  $\mathbf{x}_k$  à l'instant  $k$ , une séquence de commande  $\mathbf{U}_k$  est définie sur un horizon  $H_c$  ainsi que la séquence d'états résultants  $\mathbf{X}_k$  obtenus sur un

horizon de prédiction  $H_p$  à partir du modèle dynamique du robot.

$$\mathbf{U}_k = \{\mathbf{u}_k, \mathbf{u}_{k+1}, \dots, \mathbf{u}_{k+H_c-1}\}, \mathbf{u}_k \in \mathcal{U} \quad (3.2)$$

$$\mathbf{X}_k = \{\mathbf{x}_{k+1}, \mathbf{x}_{k+2}, \dots, \mathbf{x}_{k+H_p}\} \quad (3.3)$$

Dans le cas fréquent où  $H_c < H_p$ , les entrées de commande aux pas de temps supérieurs à  $H_c$  sont considérées constantes (dans le cas d'une vitesse linéaire par exemple) ou nulles (pour des accélérations ou vitesses angulaires). Une fonction de coût  $J(\mathbf{U}_k, \mathbf{X}_k)$  doit être définie afin de quantifier les objectifs et contraintes de la mission. Le problème d'optimisation suivant est alors résolu à chaque pas de temps afin de déterminer la séquence optimale de commande :

$$\begin{aligned} \mathbf{U}_k^* &= \arg \min_{\mathbf{U}_k \in \mathcal{U}^{H_c}} J(\mathbf{U}_k, \mathbf{X}_k) \\ \text{où } \mathbf{x}_i &\text{ suit un modèle dynamique du véhicule, par ex. (3.1)} \\ &\forall i \in [k+1; k+H_p] \end{aligned} \quad (3.4)$$

La première composante  $\mathbf{u}_k^*$  de la séquence trouvée est alors appliquée et la procédure est répétée à l'instant suivant, la fonction de coût  $J$  intégrant alors les nouvelles informations récupérées sur le robot et son environnement. Dans le cadre de premiers travaux (réalisés avec Hélène Roggeman, Martial Sanfourche et Aurélien Plyer), la fonction de coût suivante a été proposée pour le ralliement de points de passage ou l'exploration de zone inconnue [39] :

$$J = w_{\text{obs}} J_{\text{obs}} + w_u J_u + w_{\text{expl}} (b_e J_{\text{expl}} + \bar{b}_e J_{\text{wp}}) \quad (3.5)$$

avec  $J_{\text{obs}}$  le coût d'évitement d'obstacle (contrainte majeure prise en compte par pénalisation),  $J_u$  le coût de régulation des entrées de commande,  $J_{\text{expl}}$  un coût d'exploration et  $J_{\text{wp}}$  un coût de navigation vers un point de passage. Les coûts  $J_u$  et  $J_{\text{obs}}$  sont toujours actifs, tandis que le booléen  $b_e$  permet de choisir entre une mission d'exploration ou de ralliement de point de passage dont les objectifs ne sont pas compatibles. Les sous-fonctions de coût  $J_\bullet$  sont toutes définies de norme maximale égale à 1, afin de faciliter le réglage des pondérations  $w_\bullet$ . Le coût d'obstacle  $J_{\text{obs}}$  pénalise l'intersection entre chaque position prédite et les obstacles de l'environnement. Afin de faire le lien avec la grille d'occupation 3D obtenue à partir des capteurs visuels (Section 3.1), une *Euclidean Distance Transform* [162] est appliquée afin de retourner la distance  $d_o(\mathbf{x})$  à l'obstacle le plus proche. Une transformation lisse prenant ses valeurs entre 0 et 1 est ensuite appliquée (comme dans [174]) :

$$f_o(\mathbf{x}_k) = \frac{1 - \tanh(\alpha(d_o(\mathbf{x}_k) - \beta))}{2}, \alpha = \frac{6}{d_{\text{des}} - d_{\text{sec}}}, \beta = \frac{1}{2}(d_{\text{des}} + d_{\text{sec}}) \quad (3.6)$$

où  $d_{\text{des}}$  est une distance désirée aux obstacles au delà de laquelle ils sont ignorés, et  $d_{\text{sec}}$

une distance de sécurité en dessous de laquelle le robot ne doit jamais se trouver. Le coût d'obstacle sur l'horizon de prédiction est alors égal à  $J_{\text{obs}} = \frac{1}{H_p} \sum_{i=k+1}^{k+H_p} f_o(\mathbf{x}_i)$ . Le coût de commande  $J_u$  permet de réguler la vitesse angulaire autour d'une vitesse nominale  $v_0$  et pénaliser les vitesses angulaires de grande amplitude sur l'horizon de prédiction.

$$J_u = \frac{1}{2H_c} \sum_{i=k}^{H_c-1} \left( \frac{\omega_i^2}{\omega_{\text{max}}^2} + \frac{w_v (v_i - v_0)^2}{(\|v_0\| + \|v_{\text{max}}\|)^2} \right) \quad (3.7)$$

L'objectif du coût d'exploration est de maximiser les nouvelles zones vues par les caméras embarquées, tout en évitant la revisite des zones préalablement couvertes (nous avons également traité ce problème avec une flotte de robots dans [43], cf Section 3.3.1). Une copie de la carte de l'environnement est utilisée afin de prendre en compte les obstacles. La grille d'exploration 2D au temps  $k$  est notée  $\mathbf{G}(k)$ , celle-ci est discrétisée avec un pas arbitraire  $d_{\text{grid}}$  et contient  $l \times h$  cellules. Une case  $g_{i,j}(k)$  contient la valeur 1 si elle a été explorée, 0 sinon. Pour chaque trajectoire candidate correspondant à une séquence d'entrées  $\mathbf{U}_k$ , l'intersection entre les cellules de la grille et le champ de vue du capteur (d'aire  $\mathcal{A}_{\text{fov}}$ , ici de forme triangulaire) est calculée à l'aide d'un algorithme de détection de contour (Bresenham) suivi d'une opération morphologique de fermeture. La grille prédite est notée  $\mathbf{G}(k + H_p)$ . Le coût (à minimiser, donc négatif) est finalement

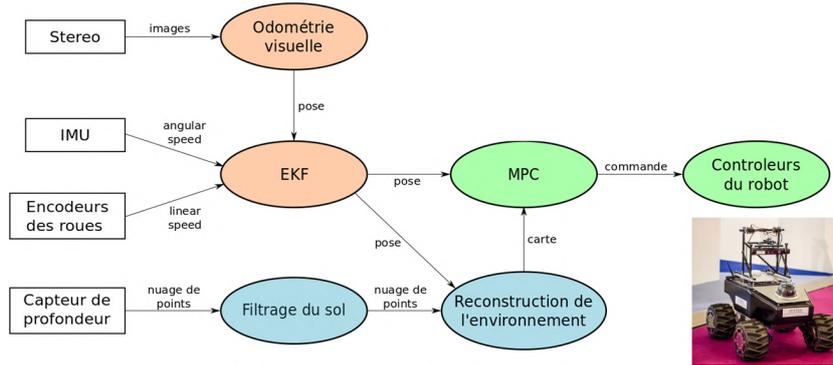
$$J_{\text{expl}} = \frac{d_{\text{grid}}^2}{H_p \mathcal{A}_{\text{fov}}} \sum_{i=1}^l \sum_{j=1}^h [g_{i,j}(k) - g_{i,j}(k + H_p)] \quad (3.8)$$

L'horizon de prédiction étant limité, cette technique d'exploration peut parfois conduire (dans des environnements très encombrés) à des minima locaux où le robot ne se déplace plus. Dans ce cas, un point de passage  $\mathbf{p}_w$  peut être déterminé sur la frontière de la zone explorée [175] et le coût suivant est utilisé en remplacement du coût d'exploration :

$$J_{\text{wp}} = \frac{1}{H_p v_{\text{max}} t_e} \sum_{i=k+1}^{k+H_p} \|\mathbf{p}_w - \mathbf{p}_i\|^2 \quad (3.9)$$

Afin de maintenir le coût de calcul de la commande dans le temps visé (entre 0.1 s et 0.25 s selon le robot et le langage de programmation utilisé), quelques simplifications sont appliquées. A l'image de [166], la même entrée est répétée sur l'ensemble de l'horizon de commande. Seule deux variables doivent donc être déterminées dans (3.4) :  $\forall i \in [k; k + H_c - 1]$ ,  $\mathbf{u}_i^* = [v^*, \omega^*]^T$ . Deux approches ont été testées pour la minimisation de la fonction de coût. La première consiste à discrétiser l'espace de commande en fonction du temps de calcul nécessaire pour une combinaison d'entrées [174]. La deuxième consiste à utiliser un optimiseur global : dans notre cas la méthode numérique DIRECT [176] – disponible notamment dans la toolbox *NLopt* – a permis d'obtenir un résultat à chaque pas de temps pour le problème considéré. La Figure 3.5 présente un exemple de résultat d'exploration autonome. Le post-doctorat de Duc Kien-Phung [30], co-encadré avec Bruno Hérisse

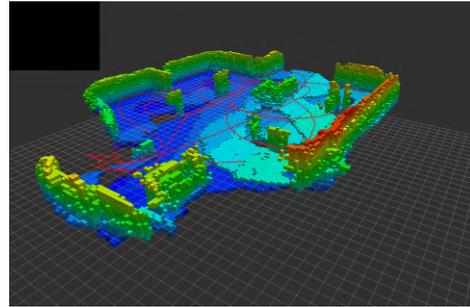
et Sylvain Bertrand (ONERA DTIS), a par ailleurs évalué l'apport du calcul parallèle sur GPU (Graphics Processing Unit) afin d'améliorer les performances de la commande prédictive d'un robot mobile lors de la phase d'optimisation (choix des commandes) sous contrainte de temps de calcul, avec validation expérimentale réussie sur le même robot que précédemment (ralliement de point de passage uniquement). Cela a permis de considérer des trajectoires plus versatiles (plusieurs valeurs d'entrées successives) en respectant la même contrainte de temps de calcul (Figure 3.6).



(a) Boucle embarquée sur robot mobile



(b) Environnement exploré



(c) Modèle 3D obtenu

FIGURE 3.5 – Expérimentation d'exploration autonome de zone par un robot mobile

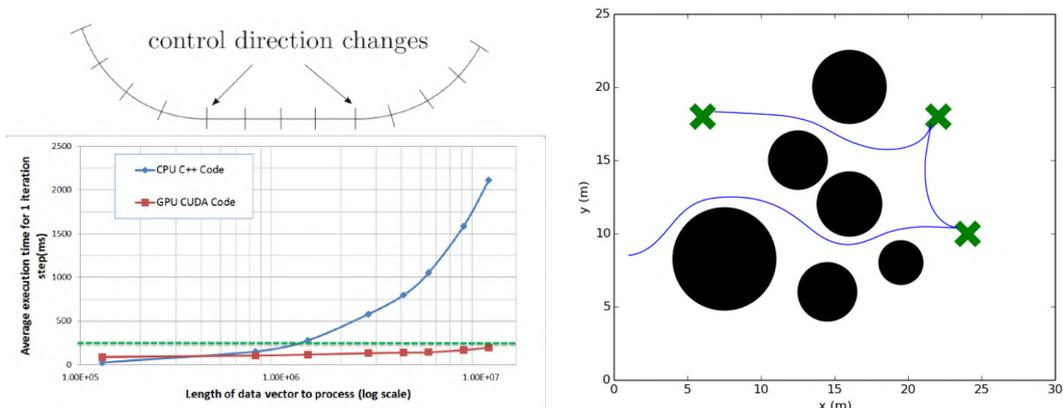


FIGURE 3.6 – Apport du calcul parallèle (GPU) pour la commande prédictive embarquée

### 3.2.2 Navigation autonome tenant compte de la qualité de la localisation basée vision

Dans le cadre de la thèse d'Hélène Roggeman [143], dirigée par Guy Le Besnerais (ONERA DTIS, spécialiste en perception et traitement d'image), nous avons étudié le couplage entre la commande et la perception pour la navigation autonome d'un robot équipé de stéréo-vision. Ceci a conduit au développement d'un critère de qualité de la localisation visuelle afin de maintenir l'intégrité de la localisation dans un environnement inconnu [26, 34]. Celui-ci a été intégré dans la méthode de commande prédictive pour réaliser des missions de ralliement de point de passage et d'exploration autonome telles que décrites dans la section précédente. La stratégie fondée sur ce couplage consiste à anticiper ce qui sera vu dans les images futures afin d'adapter la trajectoire réalisée par le robot dans le but de garantir la précision de la localisation visuelle tout au long du déplacement. L'environnement dans lequel le robot évolue peut présenter des zones peu texturées, où le calcul de la localisation visuelle peut être difficile. Un exemple est présenté en Figure 3.7 à partir de données recueillies lors d'une mission d'exploration (cf section précédente) : l'algorithme de fusion multi-capteurs est capable de rejeter une partie des inconsistences visuelles, mais lorsque la zone est mal texturée la localisation et la cartographie associée (fortement couplées, cf Section 3.1) peuvent devenir incohérentes et compromettre la poursuite de la mission. Les algorithmes développés ont été embarqués sur des robots terrestres et de nombreuses expériences ont été réalisées afin de valider ces algorithmes dans des situations réelles.

Des travaux précédents ont abordé le couplage entre génération de trajectoire et qualité visuelle. La génération de trajectoires maximisant la qualité de reconstruction de l'environnement a été étudiée avec des stratégies itératives de type « Next Best View » dans [177, 178], de planification RRT\* dans [179] et également de commande prédictive dans [180]. Les différents critères étudiés sont relatifs à la minimisation de l'incertitude de modélisation via la trace de la matrice de covariance des amers stockés par un SLAM monoculaire ou lidar, ou encore la densité locale du modèle 3D d'environnement. Les travaux de [181] se rapprochent des nôtres, avec la prise en compte de plusieurs critères de qualité de localisation sur les points extraits des images pour une pose candidate, afin de réaliser une mission de ralliement de point de passage avec un drone. Cette approche est basée sur un SLAM monoculaire, tandis que nous étudions les possibilités offertes par un capteur stéréo-vision, qui permet une prédiction plus directe dans l'espace 3D et la prise en compte de l'incertitude de localisation. Par ailleurs, notre contrôleur à base de commande prédictive permet de prendre en compte le modèle dynamique du robot et de mettre à jour la définition de la trajectoire à chaque pas en fonction des informations recueillies, contrairement aux approches de planification. Les caméras sont rigidement liées au robot dans ces travaux, on pourrait également considérer la possibilité d'orienter les capteurs afin d'optimiser la qualité de localisation comme dans [182] ; cela pose cependant un certain nombre de difficultés au niveau de la calibration des capteurs et l'incertitude additionnelle liée aux actionneurs permettant de les déplacer.

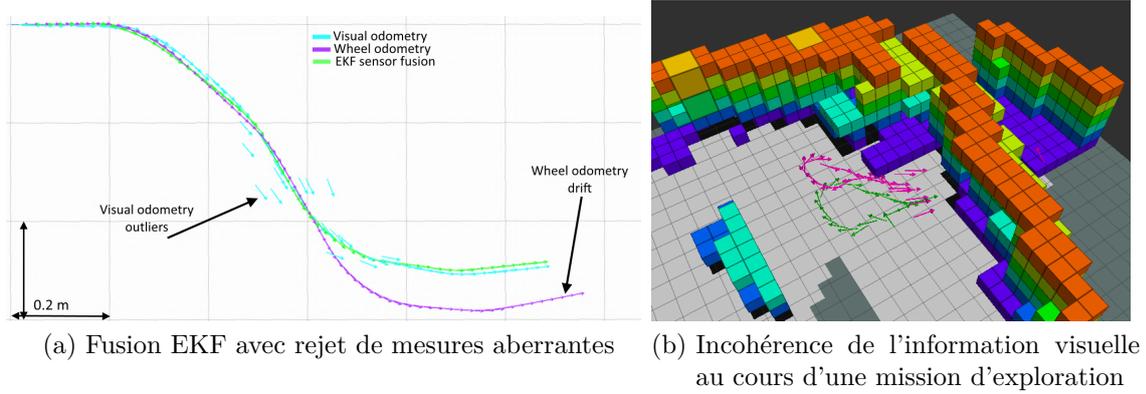


FIGURE 3.7 – Influence de la qualité de la localisation visuelle

Le critère de qualité visuelle dans la future scène est calculé à partir de l'ensemble  $\mathcal{Y}_n$  des points 3D extraits par l'odométrie visuelle à l'instant courant  $t_n$ . Dans notre cas, il s'agit d'eVO [150], mais cela s'applique à tous les algorithmes de localisation basé sur des amers [183, 184] de tous types [185–187]. On cherche à prédire le nombre de points qui seront visibles à une pose candidate (générée par commande prédictive) correspondant à un instant futur  $t_{n+H_{loc}}$  (Figure 3.8a). Chaque point 3D courant est projeté dans le plan de l'image correspondant à cette future pose en tenant compte de l'incertitude liée au processus de vision, ce qui permet finalement de calculer la probabilité de présence du point dans cette image. La position d'un point dans l'image courante (rectifiée) est notée  $\mathbf{p} = [u_l, v_l]^T$  et celle dans la future image  $\mathbf{p}'$ . La position triangulée  $\mathbf{y}$  dans le repère caméra courant s'exprime classiquement par

$$\mathbf{y} = \begin{pmatrix} x \\ y \\ z \end{pmatrix} = \Pi^{-1}(u_l, v_l, d) = \frac{-b}{d} \cdot \begin{pmatrix} u_l - u_0 \\ v_l - v_0 \\ \alpha \end{pmatrix} \quad (3.10)$$

où  $b$  est la ligne de base,  $d$  la disparité,  $\alpha$  la distance focale et  $u_0, v_0$  les coordonnées du centre optique. La position 3D dans le repère caméra futur est donnée par  $\mathbf{y}' = \mathbf{R} \cdot \mathbf{y} + \mathbf{t}$ , où la matrice de rotation  $\mathbf{R}$  et le vecteur translation  $\mathbf{t}$  se décomposent comme

$$\mathbf{R} = \mathbf{R}_z(\theta_z)\mathbf{R}_y(\theta_y)\mathbf{R}_x(\theta_x), \quad \mathbf{t} = (t_x, t_y, t_z)^T \quad (3.11)$$

avec  $\theta_x, \theta_y, \theta_z$  trois angles d'Euler. On note  $\boldsymbol{\theta} = (\theta_x, \theta_y, \theta_z, t_x, t_y, t_z)$  le vecteur des paramètres de déplacement et  $\boldsymbol{\eta} = (u, v, d)$  le vecteur de paramètres image lié au point. L'expression de  $\mathbf{p}'$  est alors

$$\mathbf{p}' = \Pi \left[ \mathbf{R}(\boldsymbol{\theta}) \cdot \Pi^{-1}(\boldsymbol{\eta}) + \mathbf{t}(\boldsymbol{\theta}) \right] \quad (3.12)$$

où  $\Pi$  est une fonction de projection et  $\Pi^{-1}$  la fonction de triangulation (3.10).

L'incertitude sur la position du point  $\mathbf{p}'$  a été modélisée en fonction d'hypothèses gaussiennes sur la localisation du déplacement du robot et de la triangulation du point 3D, finalement résumées à une matrice de covariance  $\Sigma_{\mathbf{p}'}$  de dimension 2 (voir [34] pour plus de détails). A partir de cette modélisation, il est possible de déterminer l'ellipse de confiance à 90% telle que

$$(\mathbf{x} - \mathbf{p}')^T \Sigma_{\mathbf{p}'}^{-1} (\mathbf{x} - \mathbf{p}') = s \quad (3.13)$$

avec  $s = 4.605$  (table  $\chi^2$  à 2 degrés de liberté). L'aire de l'ellipse est donnée par  $\mathcal{A}_{ell} = \pi s \sqrt{\lambda_1 \lambda_2}$  avec  $\lambda_{1,2}$  les valeurs propres de  $\Sigma_{\mathbf{p}'}$ . On calcule ensuite l'aire commune  $\mathcal{A}$  entre l'ellipse et l'image par double intégration numérique après avoir testé l'intersection de l'ellipse avec les 4 bords de l'image. Finalement, la probabilité du point d'appartenir à l'image est prise égale à

$$P_r = \frac{\mathcal{A}}{\mathcal{A}_{ell}} \quad (3.14)$$

A l'instant  $t_n$ , l'ensemble des points 3D,  $\mathcal{Y}_n = (\mathbf{y}_i)_{i \in [1, N_{\max}]}$ , est obtenu par l'algorithme d'odométrie visuelle et la future transformation  $(\mathbf{R}_{n+H_{loc}}, \mathbf{t}_{n+H_{loc}})$  est déterminée en fonction de l'état  $\mathbf{x}_{n+H_{loc}}$  du robot généré par exemple par intégration d'une commande candidate sur l'horizon  $H_{loc}$ . Cet horizon de prédiction est l'instant choisi par l'utilisateur pour évaluer la visibilité future (unique dans ces travaux du fait de la charge de calcul, mais on pourrait imaginer étendre la procédure à l'ensemble de l'horizon). L'ensemble des étapes depuis la triangulation (3.10) jusqu'au calcul de la probabilité (3.14) sont effectuées pour chacun de ces points 3D. Lorsque la probabilité  $P_r$  est supérieure à un seuil  $s_{proba}$  (choisi égal à 0.5), le nombre de points prédits  $N(\mathbf{x}_{n+H_{loc}}, \mathcal{Y}_n)$  est incrémenté. Ceci permet finalement de définir le coût de qualité de localisation normalisé :

$$J_{loc} = 1 - \frac{N(\mathbf{x}_{n+H_{loc}}, \mathcal{Y}_n)}{N_{\max}(t_n)} \quad (3.15)$$

Ce critère est intégré au coût global de l'algorithme de commande prédictive (3.4) comme

$$J = w_{loc} J_{loc} + w_{obs} J_{obs} + w_{expl} (b_e J_{expl} + \bar{b}_e J_{wp}) \quad (3.16)$$

Une illustration des trajectoires sélectionnées dans le cas d'un ralliement de point de passage et d'une mission d'exploration avec la prise en compte de la visibilité des points 3D est donnée en Figure 3.9. Les capacités de prédiction du critère ont tout d'abord été vérifiées sur un ensemble de données acquises avec un robot mobile télépiloté effectuant plusieurs boucles dans un environnement peu texturé, où des marqueurs ont été ajoutés au fur et à mesure. La Figure 3.8b montre une corrélation élevée entre le nombre de points futurs réellement vus (rejeu de la trajectoire) et le nombre anticipé par le critère, et une bonne prédiction des zones mal texturées (chute brusque à l'instant 200). Ces ex-

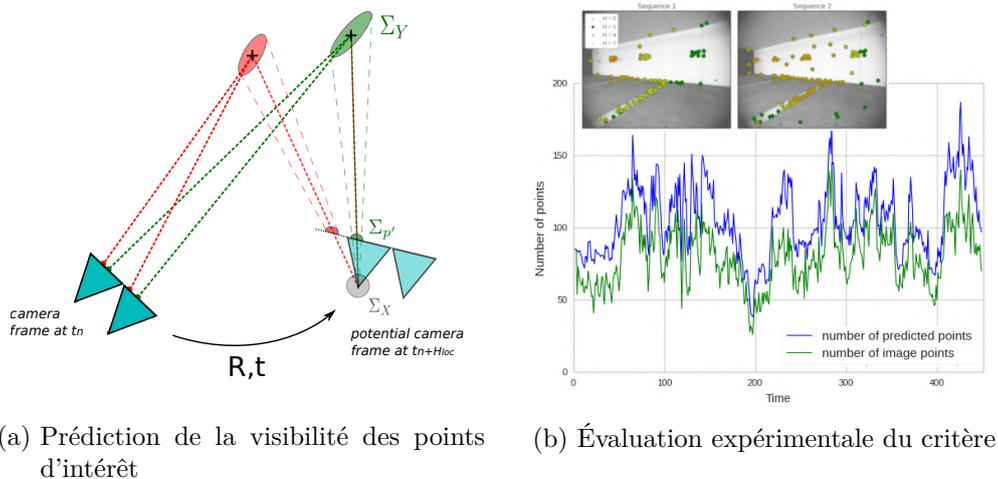


FIGURE 3.8 – Prédiction du nombre de points extraits pour l'odométrie visuelle

périmentations ont par ailleurs permis de déterminer une valeur convenable (compromis entre conservatisme local et prédiction) pour l'horizon de prédiction de la localisation  $H_{loc}$ , celui-ci étant pris dans la suite égal à 4 (soit 1 seconde pour un pas de temps de 0.25 s).

De nombreuses expérimentations ont ensuite été réalisées afin de valider le comportement de la boucle de commande prédictive intégrant le maintien de la qualité de localisation visuelle. Tout d'abord, seuls les coûts de ralliement de waypoint  $J_{wp}$  et de localisation  $J_{loc}$  ont été activés afin de déterminer empiriquement la pondération adéquate (le poids  $w_{expl}$  étant pris égal à  $1 - w_{loc}$ ). Un environnement expérimental a été mis en place avec une surface unie placée devant le point à rallier (résultats en Figure 3.10, plus de détails dans [34]) et le poids  $w_{loc}$  augmenté progressivement (10 répétitions pour chaque réglage). Pour une pondération  $w_{loc} < 0.4$ , le nombre de points 3D suivis est insuffisant pour assurer la localisation (robot « perdu »), l'optimum étant atteint pour un poids de 0.5 qui entraîne une légère déformation de trajectoire suffisante pour augmenter le nombre de points observés et arriver à l'objectif.

Une deuxième campagne d'expérimentations a ensuite été réalisée pour une mission d'exploration de zone inconnue et encombrée (Figure 3.11), l'ensemble des coûts (3.16) étant alors actifs. Le dispositif expérimental comprenait une zone de  $11 \times 11 \text{ m}^2$  couverte par un système de motion capture utilisé comme vérité terrain pour la localisation, et comprenant un large mur entièrement noir afin de mettre en défaut les traitements visuels. Il a ainsi été vérifié, avec plusieurs dizaines de répétitions de l'expérience démarrant de positions initiales aléatoires, que l'exploration ne pouvait être réalisée correctement sans utiliser le critère de qualité de localisation tandis que la mission était toujours menée à bien en utilisant celui-ci (résultats détaillés dans [26, 143]).

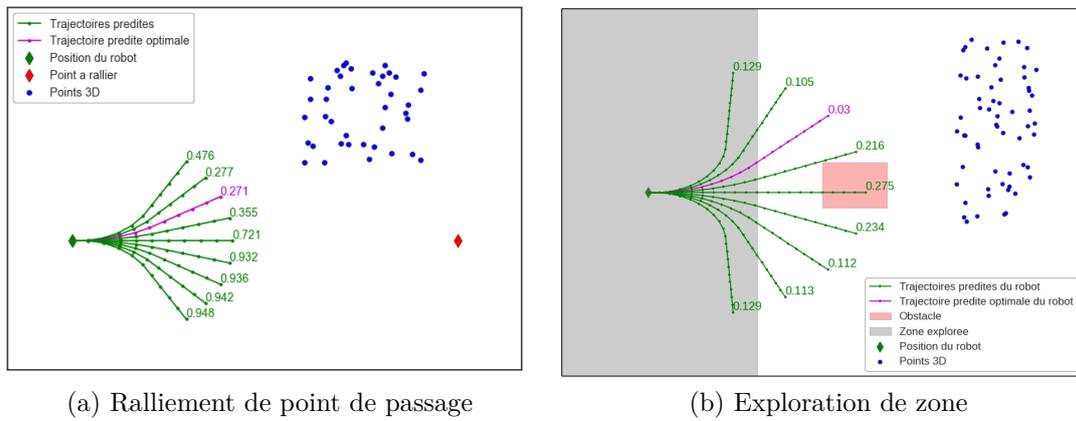


FIGURE 3.9 – Illustration des coûts de commande prédictive selon la mission

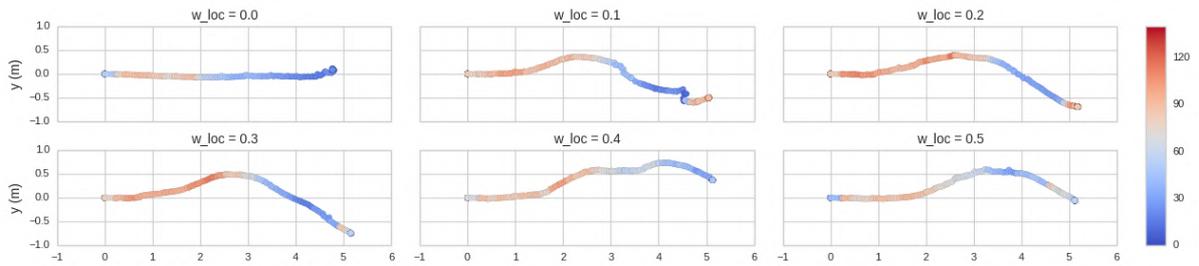


FIGURE 3.10 – Réglage expérimental des pondérations MPC entre qualité de localisation et ralliement de point de passage

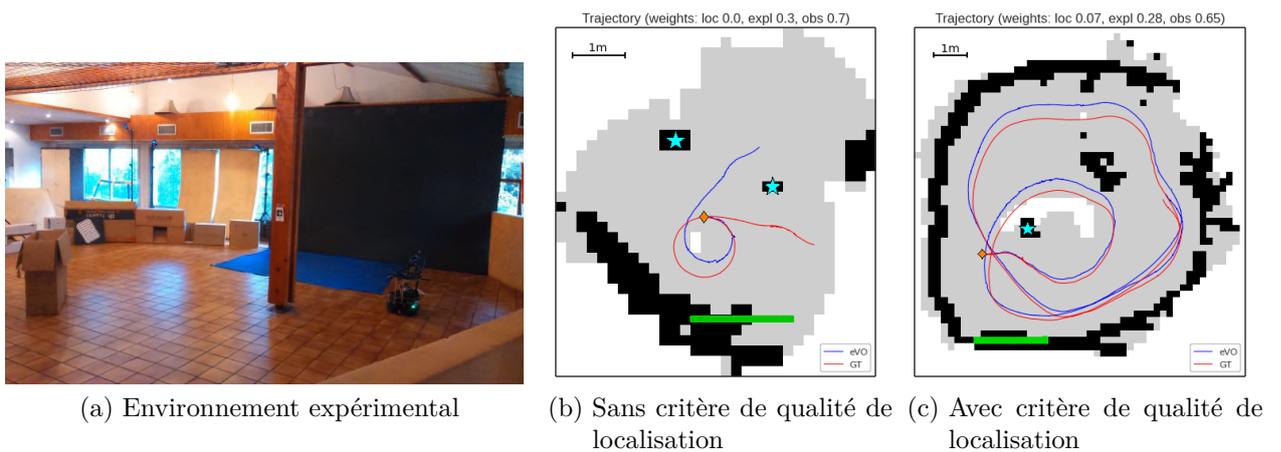


FIGURE 3.11 – Résultats d'exploration en fonction du critère de qualité de localisation

### 3.2.3 Partenariat Recherche Industrie ONERA-SNCF

Le Partenariat Recherche Industrie (PRI) DROSOFILES entre l'ONERA et SNCF Réseau (2015-2019) vise à développer de nouvelles briques technologiques pour les drones et les capteurs embarqués associés (Figure 3.12). En particulier, des missions d'inspection sûre en environnement intérieur ou à proximité de structures (gare, entrepôt, ponts) ont été étudiées. Dans ce contexte, la mise en œuvre des drones repose actuellement sur des pilotes experts et des autopilotes très peu robustes à la perte de réception GPS ou aux conditions de vent défavorables. Les travaux du projet visent à spécifier et à valider sur des cas d'usage typiques du monde ferroviaire de nouvelles avioniques permettant d'étendre le domaine d'emploi des drones, d'améliorer la sécurité des vols automatiques et de soulager la charge de travail du pilote/opérateur. Ces avioniques du futur seront notamment bâties autour de capteurs extéroceptifs, tels que des capteurs de vision (caméras, caméras de profondeur, lidar) qui permettent, après traitements, de recueillir des informations sur l'environnement du drone et sur son mouvement propre. Ces composants de perception fourniront avec un haut degré de fiabilité les informations nécessaires à des algorithmes de contrôle et de navigation chargés d'assurer la navigabilité de l'engin et de remplir des missions complexes comme l'inspection automatique ou le suivi de linéaire, tout en optimisant la prise de données de la charge utile mission. Le chantier « Indoor » adresse plus spécifiquement le problème de la navigation en environnement très encombré sans GPS ou infrastructure déployée préalablement au vol. Nous avons donc mis en œuvre et adapté des algorithmes de perception et guidage embarqués sur mini-drone, afin de permettre un suivi de trajectoire sécurisé avec cartographie temps-réel embarquée dans le cadre de missions d'inspection [3]. Les démonstrations<sup>1</sup> décrites ci-après ont été réalisées en tant que livrables du projet, sur site SCNF Réseau (entrepôt de stockage de matériel roulant, cf Figure 3.13).

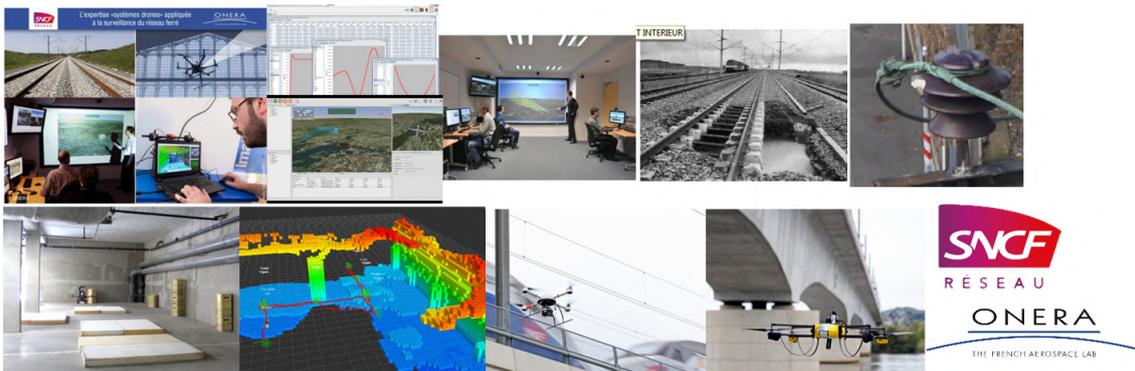


FIGURE 3.12 – Illustrations des applications traitées dans le Partenariat ONERA-SNCF

1. Liens vidéos dans la version électronique du document

**Indoor 1 - juin 2015** et **Indoor 2 - mai 2016** : La première étape a consisté à mettre en place les briques de base afin de réaliser de manière autonome le suivi d'une trajectoire et l'évitement d'obstacles statiques par un mini-drone en milieu intérieur encombré sans GPS (Figure 3.14). Cela a consisté en la définition de l'architecture embarquée de perception-commande présentée en Figure 3.16, comprenant le développement et l'adaptation d'une loi de guidage à base de commande prédictive et son interaction avec la localisation et la modélisation d'environnement à base de stéréo-vision (présentées en Section 3.1). **Ce démonstrateur a été présenté lors du congrès IFAC WC 2017 [29]** et a recueilli de nombreux commentaires positifs des chercheurs de la communauté.



FIGURE 3.13 – Site industriel SNCF de Sotteville-lès-Rouen

**Indoor 3 - décembre 2016** : Ces travaux ont étendu les algorithmes de perception et de guidage du mini-drone afin de détecter, localiser et éviter les objets mobiles pouvant interagir avec la trajectoire suivie [25] (Figure 3.18). Une fonctionnalité de positionnement relatif à un plan à inspecter, avec prise en compte de contraintes de distance et de champ de vue, a également été développée comme alternative à l'inspection par suivi de trajectoire prédéfinie [3].

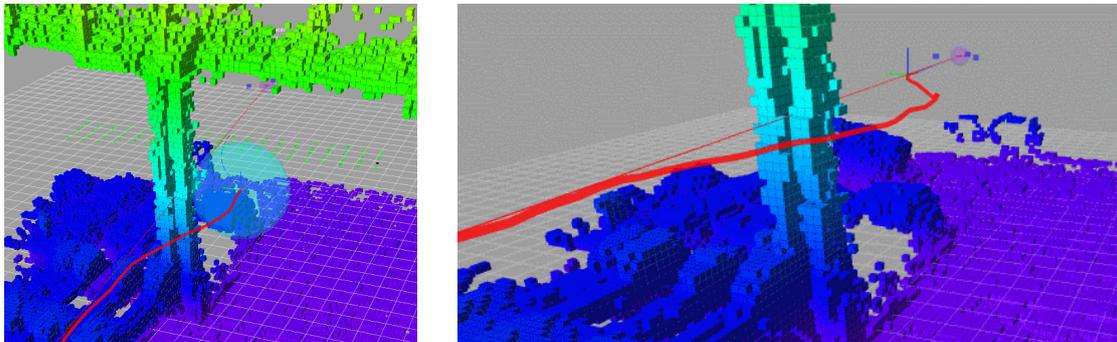


FIGURE 3.14 – Évitement d'obstacle statique par un drone en lien avec le modèle d'environnement Octomap (calculs effectués à bord du drone Asctec Pelican)

**Indoor 4 - février 2018** : Une fois la boucle embarquée complètement autonome développée, les utilisateurs SNCF ont exprimé le besoin de pouvoir contrôler le déroulement de l'inspection de manière intuitive et sécurisée. Nous avons donc axé les travaux suivants sur la téléopération assistée le long d'une trajectoire avec évitement d'obstacle (Figure 3.15), tout en conservant la même structure pour l'architecture de navigation autonome basée vision [20].

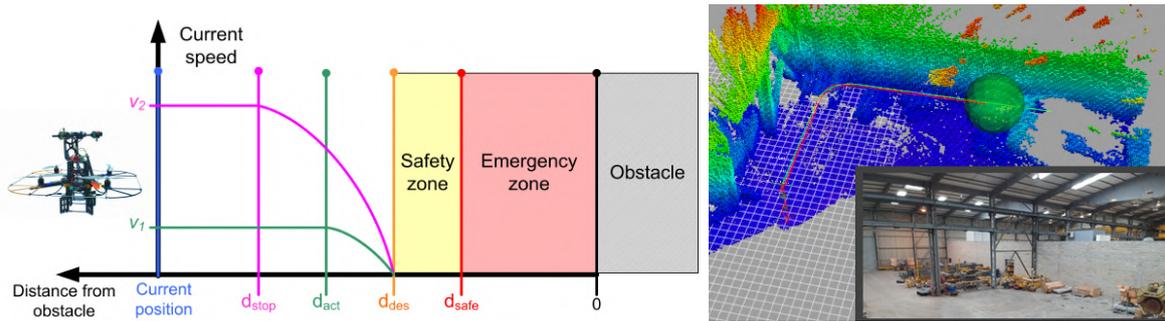


FIGURE 3.15 – Téléopération assistée le long d'une trajectoire

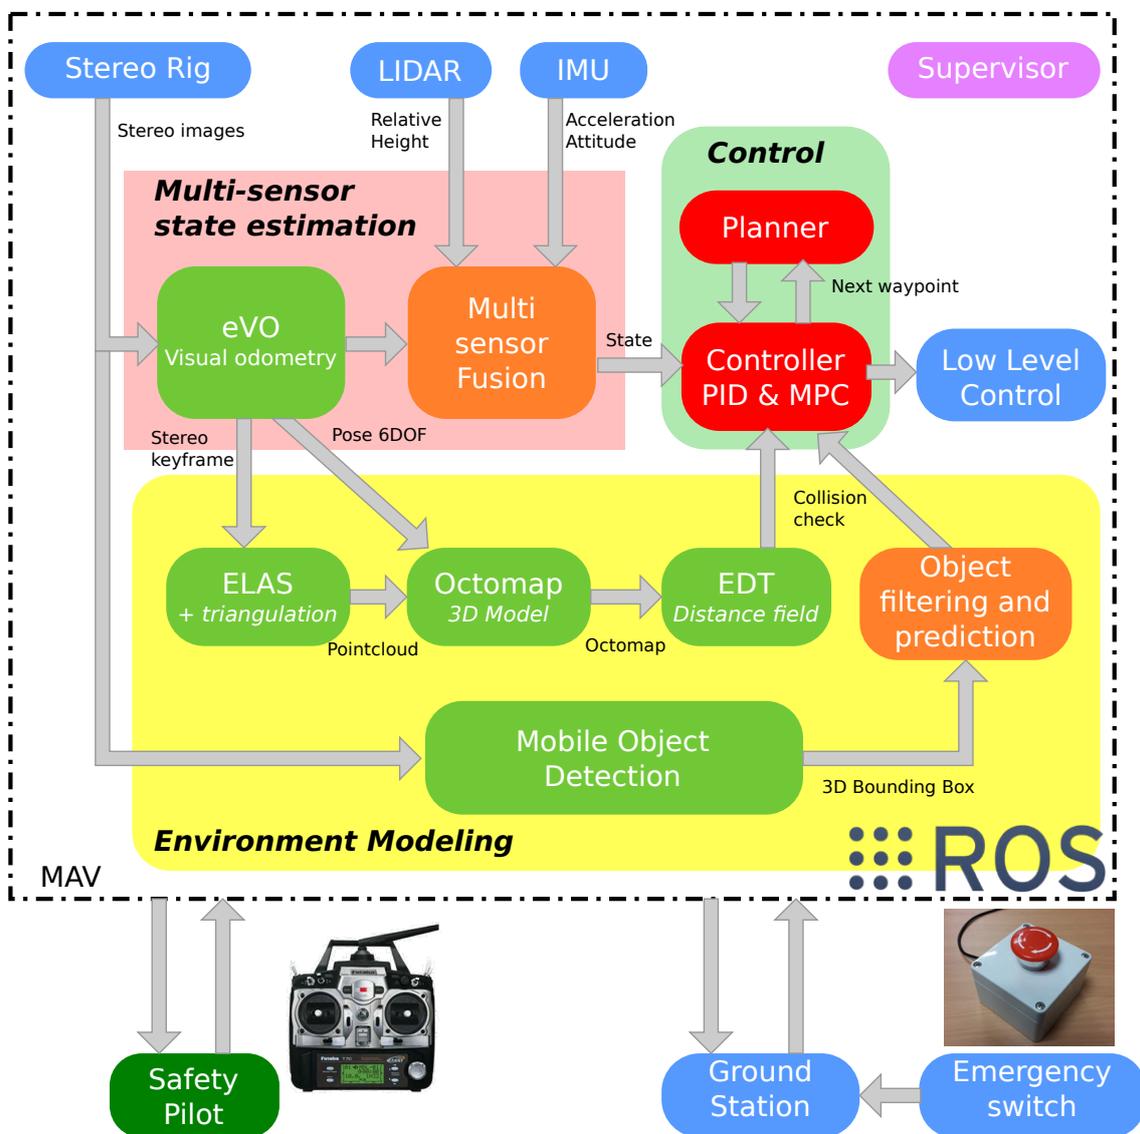


FIGURE 3.16 – Boucle embarquée sur drone (PRI DROSOFILES / FP7 EuRoC)

La Figure 3.16 décrit l'architecture ROS exécutée en temps réel sur le PC Linux embarqué du drone Asctec Pelican (à gauche sur la Figure 3.1). A partir des mesures de stéréo-vision (banc calibré, objectifs grand champ 120°), le module d'odométrie visuelle [150] décrit précédemment fournit à 20 Hz la position et l'attitude du drone dans le repère inertiel lié à la position initiale du drone. Le module de fusion visio-inertielle par filtre de Kalman fournit à 100 Hz la position, la vitesse et l'attitude de l'engin. Il retourne également indépendamment une hauteur sol filtrée en combinant un télémètre Lidar-Lite et l'IMU. La surveillance de l'innovation du filtre de Kalman permet de contrôler l'intégrité de la localisation basée vision. Une grille d'occupation de type Octomap [161] permet de stocker le modèle 3D de la scène à partir de mesures de profondeur extraites des données de stéréovision via l'algorithme ELAS [159]. Une carte de distance aux obstacles est générée par transformation EDT (Euclidean Distance Transform) à partir de l'Octomap [162]. La mise en cohérence des amers extraits des images stéréo avec une hypothèse de scène statique permet d'extraire les objets mobiles et de reconstruire leur mouvement [25]. Le module de guidage détermine à 20 Hz une accélération de consigne à partir de toutes ces informations. Celle-ci est transformée en une poussée et deux angles de roulis et tangage associés qui sont transmis (ainsi qu'une vitesse de rotation en lacet) à l'autopilote bas-niveau du drone Asctec [188]. Ce dernier assure la boucle rapide (100 Hz) de stabilisation angulaire et de commande des moteurs sur un calculateur ARM, selon le découplage classique guidage/pilotage valable ici pour les manœuvres peu agressives considérées [189]. Une brique de planification permet de générer une trajectoire de référence à partir d'informations fournies par un module de séquençage de la mission (vitesse nominale, points de passage, primitives : ligne droite, ellipse, arc de cercle). Un superviseur de mission gère alors les phases de la mission autonome du drone (décollage, attente utilisateur, phase principale, atterrissage). Une procédure d'arrêt d'urgence permet de mettre le drone en sécurité (stabilisation sur place) soit via l'actionnement du bouton d'arrêt d'urgence depuis la station sol soit de manière automatique en cas de défaillance détectée à bord. Le télé-pilote garde la possibilité de reprendre la main à tout moment indépendamment de ces fonctions de supervision.

#### *Suivi de trajectoire avec évitement d'obstacle statique*

La commande prédictive (MPC) a de nouveau été retenue pour réaliser le suivi de trajectoire par un mini-drone, afin d'anticiper le comportement futur du véhicule et tenir compte de l'évolution de la référence pour calculer la commande ce qui permet d'éviter des sollicitations en inadéquation avec la physique du système (le modèle dynamique du véhicule étant explicitement pris en compte). Pour la définition de la loi de guidage, la dynamique de translation du drone est décrite par le modèle suivant :

$$\begin{aligned}\dot{\xi} &= v \\ \dot{v} &= -\frac{\mathcal{T}}{m} Re_3 + ge_3\end{aligned}\tag{3.17}$$

où  $\xi \in \mathbb{R}^3$  et  $v \in \mathbb{R}^3$  sont respectivement la position et la vitesse du drone en repère inertiel  $\mathcal{I} = (O; e_1, e_2, e_3)$ ,  $\mathcal{T} \in \mathbb{R}^+$  étant le module des forces aérodynamiques (poussée des rotors),  $m$  la masse,  $g$  l'accélération de la pesanteur et  $R$  la matrice de rotation entre  $\mathcal{I}$  et le repère lié à l'engin  $\mathcal{B} = (G; e_1^b, e_2^b, e_3^b)$ . L'entrée de commande est définie classiquement comme  $u = -\frac{\mathcal{T}}{m} R e_3 + g e_3$  et on suppose que la boucle d'attitude du contrôleur bas-niveau assure une convergence rapide permettant de négliger cette dynamique au niveau du guidage. On obtient alors le système linéaire du second ordre à temps discret (période  $t_e$ ) tel que

$$x_{k+1} = Ax_k + Bu_k, \quad x_k = \begin{bmatrix} \xi_k \\ v_k \end{bmatrix}, \quad A = \begin{bmatrix} I_3 & t_e I_3 \\ 0_3 & I_3 \end{bmatrix}, \quad B = \begin{bmatrix} \frac{t_e^2}{2} I_3 \\ t_e I_3 \end{bmatrix} \quad (3.18)$$

La trajectoire de référence est définie comme une suite de positions  $\xi_k^r$  et vitesses  $v_k^r$ . La commande appliquée à l'instant  $k$  est décomposée comme la somme de deux termes :  $u_k = u_k^n + 1_k^{obs} u_k^a$ , où  $u_k^n$  est une commande nominale de suivi de trajectoire,  $1_k^{obs}$  est égal à 1 en cas de risque de collision sur la trajectoire prédite et 0 sinon,  $u_k^a$  est la commande qui permet de faire dévier le drone de la trajectoire de référence juste assez pour éviter la collision. Afin d'obtenir une solution analytique linéaire et sans offset pour le suivi de trajectoire, on définit l'incrément de commande  $\delta_k = u_k - u_{k-1}$  et l'état augmenté associé  $z_k = [x_k^T \quad u_{k-1}^T]^T$ . On définit les vecteurs d'incrément et de références suivants :

$$\begin{aligned} \Delta_k &= [\delta_k^T \quad \delta_{k+1}^T \quad \dots \quad \delta_{k+H_p-1}^T]^T \\ X_k^r &= [(x_k^r)^T \quad (x_{k+1}^r)^T \quad \dots \quad (x_{k+H_p}^r)^T]^T, \quad x_k^r = [(\xi_k^r)^T \quad (v_k^r)^T]^T \end{aligned} \quad (3.19)$$

où  $H_p$  représente l'horizon de prédiction (égal à 200 pas de temps dans les expérimentations, soit 10s de vol). La commande nominale  $u_k^n$  est obtenue en résolvant

$$\Delta_k^* = \arg \min_{\Delta_k} \sum_{i=0}^{H_p-1} \left\{ \|\bar{x}_{k+i} - x_{k+i}^r\|_Q^2 + \|\delta_{k+i}\|_R^2 \right\} + \|\bar{x}_{k+H_p} - x_{k+H_p}^r\|_Q^2 \quad (3.20)$$

$$\begin{aligned} \bar{x}_{k+i+1} &= A\bar{x}_{k+i} + Bu_{k+i} \\ u_{k+i} &= u_{k+i-1} + \delta_{k+i} \quad i = 0, \dots, (H_p - 1) \\ \bar{x}_k &= x_k \end{aligned}$$

La solution est obtenue sous la forme suivante, équivalente à un retour d'état :

$$\Delta_k^* = -(\mathcal{B}^T \mathcal{Q} \mathcal{B} + \mathcal{R})^{-1} (\mathcal{Q} \mathcal{B})^T [\mathcal{A} z_k - X_k^r] \quad (3.21)$$

où les matrices de prédiction  $\mathcal{A}$  et  $\mathcal{B}$  dépendent des matrices initiales  $A$  et  $B$ , et les matrices  $\mathcal{Q}$  et  $\mathcal{R}$  contiennent respectivement  $Q$  et  $R$  comme éléments diagonaux [190].

On déduit alors  $u_k^n = u_{k-1}^n + \delta_k^*$  à partir de la première composante de la solution à (3.21). Cette commande est calculée à chaque instant, ce qui donne une trajectoire nominale du drone prédite sur l'horizon de prédiction. La possibilité d'une collision entre chaque point de cette trajectoire et l'environnement est alors testée, et le cas échéant une composante supplémentaire est calculée en utilisant l'information de carte de distance afin de dévier la trajectoire du drone en respectant une distance minimale aux obstacles. L'Algorithme 3.1 résume la procédure complète.

---

**Algorithme 3.1** Guidage prédictif pour l'évitement d'obstacle
 

---

HORS- LIGNE	Définir les commandes d'évitement Définir les plans d'évitement
EN LIGNE (à chaque pas de temps)	Calculer la commande nominale $u_k^n$ et prédire la trajectoire du drone associée Tester les collisions sur la trajectoire prédite <b>If</b> (collision)   <b>For</b> chaque plan d'évitement             Calculer $u_k^a$         <b>If</b> solution trouvée               $u_k = u_k^n + 1_k^{obs} u_k^a$               <b>Exit loop</b>         <b>Else if</b> pas de solution mais il reste des plans à tester                   Passer au plan suivant         <b>Else if</b> pas de solution et tous les plans ont été testés                   Mode Emergency         <b>End If</b>   <b>End For</b> <b>Else</b> (pas de collision)   $u_k = u_k^n$ <b>End If</b> Appliquer $u_k$ comme entrée de commande du drone (après saturation)

---

La carte de distance calculée à partir du modèle d'environnement Octomap (cf Section (3.1)) est appelée pour chaque position  $\{\bar{\xi}_{k+i}^*\}_{i=0..N}$  de la trajectoire prédite en utilisant la commande nominale  $\Delta_k^*$ , ce qui fournit une distance  $d_{k+i}^{obs} = d_{obs}(\bar{\xi}_{k+i}^*)$  et un vecteur directeur unitaire  $n_{k+i}^{obs} = n_{obs}(\bar{\xi}_{k+i}^*)$  par rapport à l'obstacle le plus proche. Le risque de collision est avéré si au moins un point de la trajectoire prédite vérifie

$$(n_{k+i}^{obs})^T \cdot \text{diag} [d_x^{-2} \ d_y^{-2} \ d_z^{-2}] \cdot n_{k+i}^{obs} \leq (d_{k+i}^{obs})^{-2} \quad (3.22)$$

Les distances  $d_x, d_y, d_z$  permettent de définir l'ellipsoïde de sécurité du drone, et de prendre ainsi en compte la forme du drone de manière anisotrope. Dans le cas d'une collision, la commande d'évitement  $u_k^a$  doit être calculée. L'utilisation de la carte de distance ne permet plus d'obtenir une solution analytique, une technique de recherche systématique a donc été employée [166]. On définit pour un horizon de commande  $0 < H_c \leq H_p$  le vecteur  $U_k^a = [(u_k^a)^T \ (u_{k+1}^a)^T \ \dots \ (u_{k+H_c-1}^a)^T]^T$ , dont toutes les composantes sont

égales pour diminuer la combinatoire du problème [174]. On résout alors le problème suivant, dont la fonction de coût est similaire à (3.5),

$$\begin{aligned}
 U_k^{a*} &= \arg \min_{U_k^a} w_{\text{obs}} J_k^{\text{obs}} + w_{\text{nav}} J_k^{\text{nav}} \\
 u_{k+i} &\in \mathbb{U} \quad i = 0, \dots, H_p - 1 \\
 u_{k+i} &= \begin{cases} u_{k+i}^n + u_{k+i}^a & \text{si } i < H_c \\ u_{k+i}^n & \text{sinon} \end{cases}
 \end{aligned} \tag{3.23}$$

où  $\mathbb{U}$  définit l'ensemble faisable pour les entrées de commande combinées. Le coût de navigation  $J_k^{\text{nav}}$  comprend la composante de suivi de la trajectoire présente dans le problème

nominal (3.20) et le coût d'obstacle est  $J_k^{\text{obs}} = \frac{1}{H_p} \sum_{i=k+1}^{k+H_p} f_o(\xi_i)$  avec  $f_o$  telle que définie

précédemment par (3.6). Afin de réduire le temps de calcul, la recherche des commandes d'évitement s'effectue dans un plan. Pour prendre en compte le caractère potentiellement 3D de l'environnement, on définit un nombre arbitraire de plans d'évitement à tester successivement [191]. Hors ligne, on initialise l'ensemble discret d'incrément de commandes d'évitement à tester et les plans successifs par rapport à la trajectoire de référence (horizontal vers l'avant, vertical, horizontal vers l'arrière, etc) [29]. Pour un premier plan d'évitement préalablement défini, la fonction de coût est évaluée sur l'horizon de prédiction pour toutes les commandes d'évitement candidates et la commande correspondant au coût minimal est alors choisie comme commande d'évitement, à condition d'être faisable (pas de collision). Si aucune commande de l'ensemble discrétisé n'est faisable, la procédure est répétée pour le deuxième plan d'évitement et ainsi de suite. Si aucune commande n'est trouvée comme faisable à l'issue du balayage de tous les plans, le drone passe en mode d'urgence (stabilisation sur place) en attente d'une action de l'opérateur station sol ou du pilote de sécurité. Une illustration des résultats expérimentaux sur site SNCF est présentée en Figures 3.13 et 3.14.

### *Prise en compte d'un objet mobile dans l'algorithme d'évitement MPC*

Lorsqu'un objet mobile est détecté par le module de traitement d'image décrit en Section 3.1, la position 3D de son centre de gravité et ses dimensions (rayon et hauteur du cylindre) sont transmises au module de guidage afin de le prendre en compte pour générer une éventuelle trajectoire d'évitement. Un filtre de Kalman est utilisé pour filtrer le mouvement de l'objet et les variations des dimensions reconstruites par traitement d'image, mais également afin d'estimer sa vitesse afin de prédire son mouvement futur. Un modèle à vitesse constante [192] est utilisé à cet effet, le vecteur d'état étant constitué de la position et la vitesse, le rayon et la hauteur de l'objet :  $\mathcal{X}_k = [X_k^T, V_k^T, r_k, h_k]^T$ . Il est alors possible de prédire sur un horizon temporel les positions futures de l'objet en fonction de ces estimées. Lorsque la mesure est perdue (passage hors champ de l'objet mobile par exemple), la prédiction continue à être effectuée sur la base des informations

de position et vitesse précédentes. Comme la commande prédictive est appliquée sur l'horizon fini de  $H_p$  pas de temps, les positions futures de l'objet  $\tilde{X}_i$  sont prédites sur le même horizon à partir des positions et vitesses filtrées, soit à l'instant  $k$  :

$$\tilde{X}_k = \widehat{X}_k, \quad \forall i \in [k + 1; k + H_p], \quad \tilde{X}_{i+1} = \tilde{X}_i + t_e \cdot \widehat{V}_i \quad (3.24)$$

Dans le cas de multiples objets, un indice est associé à chacun et on définit l'ensemble contenant toutes les positions prédites des  $N_{\text{obs}}$  objets détectés à l'instant  $k$  comme  $\Xi_k = \{ \tilde{X}_k^{(j)}, j = 1, \dots, N_{\text{obs}} \}$ . Le test de collision (3.22) et la formulation de la commande prédictive (3.23) restent applicables, cependant la distance considérée tient maintenant compte à la fois des obstacles fixes et des objets mobiles. A chaque instant  $i \in [k, \dots, k + H_p]$  de l'horizon de prédiction, la fonction de collision  $d_{\text{obs}}(p_i, \Xi_i)$  retourne la distance (selon le test anisotrope (3.22)) à l'élément le plus proche de la position prédite du drone. On considère la distance au cylindre englobant chaque objet mobile, calculée à l'aide de la méthode géométrique décrite dans [193]. Le coût d'obstacle est inchangé, la fonction  $f_o$  définie par (3.6) prenant simplement en entrée cette nouvelle distance. La Figure 3.18 illustre le comportement de l'algorithme en présence d'un objet mobile.

#### *Téléopération sur trajectoire de consigne*

Les besoins en inspection nécessitent le suivi par un opérateur des informations observées en temps réel par la charge utile (par exemple, capteurs thermiques afin de détecter des fissures ou points chauds), avec parfois l'opportunité de revenir en arrière ou de changer l'orientation du drone. Nous avons donc proposé un mode de téléopération le long d'une trajectoire prédéfinie, sur la base des développements en navigation autonome présentés ci-dessus. Une trajectoire de référence  $\mathcal{T}$  est définie par l'utilisateur en préparation de mission, constituée d'une suite de  $n$  positions  $\xi^r$ , vitesses  $v^r$  et accélérations  $a^r$  compatibles avec une vitesse de référence  $v_{\text{ref}}$  (0.5 m/s dans nos tests) et un pas de temps constant  $t_e$  (0.05 s). Des pentes de vitesse respectant une accélération maximale peuvent être incluses en début et fin de trajectoire. On suppose que le drone se situe proche du point initial de la trajectoire (indice  $i = 0$ ) au lancement de la télé-opération. Ce point peut être rejoint manuellement ou de manière autonome par point de passage.

Le télé-opérateur fournit les informations suivantes à partir d'une radio-commande dédiée : la vitesse de consigne  $v_{\text{des}} \in [-v_{\text{max}}, v_{\text{max}}]$ , dont le signe indique la direction à suivre sur la trajectoire, la vitesse de rotation en lacet  $\omega_{\text{des}} \in [-\omega_{\text{max}}, \omega_{\text{max}}]$  afin de modifier l'angle de lacet de référence  $\psi_{\text{des}}$ , et le mode d'opération désiré pour l'orientation (*Absolu* : l'angle est défini en repère global; *Relatif* : l'angle est défini par rapport à la direction courante de la trajectoire de référence). Un filtrage du premier ordre est tout d'abord appliqué sur la vitesse de consigne  $v_{\text{des}}$  afin d'éviter des fluctuations indésirables dues à la sensibilité de l'opérateur humain. La vitesse résultante est notée  $v_f$ . La trajectoire de référence étant générée avec une vitesse de référence constante  $v_{\text{ref}}$ , une adaptation locale est nécessaire afin de tenir compte de la vitesse fournie par

l'opérateur. A cet effet, on définit l'opérateur multiplicatif suivant :  $\mu = v_f v_{\text{ref}}^{-1}$ . Sa dérivée par rapport au temps est notée  $\delta\mu$ , et le signe de  $\mu$  indique la direction suivie sur la trajectoire. On peut ainsi déterminer l'indice  $i$  correspondant au point suivant sur la trajectoire, ce qui fournit la position de référence à l'instant  $k$  courant  $\xi_k^r = \xi_i^r$ , la vitesse de référence  $v_k^r = \mu v_i^r$  et l'accélération  $a_k^r = \mu a_i^r + \delta\mu v_i^r$ . La commande est calculée comme précédemment sur la base d'un modèle dynamique du deuxième ordre (positions, vitesses), une pré-compensation de l'accélération de consigne est introduite pour le suivi de trajectoire, soit la commande d'accélération désirée suivante :  $u(k) = a^r(k) + K_d(v^r(k) - v_k) + K_p(\xi^r(k) - \xi_k)$  où  $\xi_k$  est la position et  $v_k$  la vitesse en repère inertiel fournies par la chaîne de perception basée vision. Si la vitesse  $v_f$  est en dessous d'un certain seuil (0.05 m/s), une action de stabilisation pure est effectuée (accélération et vitesse de consigne nulles).

Une fonction d'anticollision par filtrage des consignes du télé-pilote a été ajoutée afin d'agir sur les consignes de vitesse, en cas de détection de collision sur la trajectoire dans la direction d'évolution actuellement considérée. Trois distances sont paramétrées par l'utilisateur : une distance d'activation  $d_{\text{act}}$ , en dessous de laquelle l'obstacle est pris en compte, une distance de sécurité désirée  $d_{\text{des}}$ , au-delà de laquelle le drone doit toujours se situer, et une distance d'urgence  $d_{\text{safe}}$ , en dessous de laquelle une action de stabilisation d'urgence est enclenchée. Dans le cadre des scénarios étudiés, on a par exemple considéré  $d_{\text{safe}} = 1\text{m}$ ,  $d_{\text{des}} = 1.3\text{m}$ ,  $d_{\text{act}} = 1.5\text{m}$ . On détermine tout d'abord la position de l'obstacle le plus proche le long de la trajectoire. Pour ce faire, un balayage de la trajectoire est effectué dans les deux sens à partir du point de référence courant pour toutes les positions successives  $\xi_i$ . Le test de collision (3.22) s'effectue de la même manière que dans les travaux précédents par appel de la carte de distance (EDT) obtenue à partir du modèle Octomap de l'environnement afin d'obtenir la distance  $d_{\text{obs}}^{\text{uav}}(k)$  entre le drone et l'obstacle. Si aucune collision n'est présente dans la direction active le long de la trajectoire, la vitesse de référence  $v_f$  n'est pas modifiée. Dans le cas contraire, l'information de collision est prise en compte pour calculer une consigne de vitesse assurant l'évitement de collision, à partir également de la vitesse courante du drone  $v_c$  et d'une accélération de freinage maximale  $a_{\text{stop}}$ . On définit la distance de freinage désirée comme

$$d_{\text{stop}}(k) = \max\left(\frac{v_c^2(k)}{2a_{\text{stop}}}, d_{\text{act}} - d_{\text{des}}\right)$$

La vitesse de référence  $v_f$  est alors modifiée comme suit :

- Si  $d_{\text{obs}}^{\text{uav}}(k) > d_{\text{stop}}(k) + d_{\text{des}}$ , aucune modification de  $v_f$
- Si  $d_{\text{stop}}(k) + d_{\text{des}} > d_{\text{obs}}^{\text{uav}}(k) > d_{\text{des}}$ , il faut freiner :  $v_f = \text{sign}(\mu) \left( v_c(k) - \frac{v_c^2(k)t_e}{2d_{\text{stop}}(k)} \right)$
- Si  $d_{\text{obs}}^{\text{uav}}(k) < d_{\text{des}}$ , freinage d'urgence  $v_f = 0$

Deux cas sont illustrés en Figure 3.15 selon la vitesse courante du drone  $v_c$  :

- $v_1$  telle que  $d_{\text{stop}} = d_{\text{act}} - d_{\text{des}}$ , donc la décélération nécessaire est inférieure à  $a_{\text{stop}}$ .
- $v_2$  est bien supérieure et nécessite un freinage avant la distance d'activation pour

respecter la contrainte de décélération.

Cette procédure est indépendante de la direction de suivi de la trajectoire. Il convient de noter que si le télé-pilote modifie la direction alors que l'évitement de collision est actif, et que dans l'autre sens le premier obstacle est situé bien au-delà de  $d_{\text{stop}} + d_{\text{des}}$ , alors le filtrage de la vitesse n'est plus actif. Autrement dit, le télé-pilote a toujours la possibilité de s'éloigner de l'obstacle manuellement (comportement spécifié par les utilisateurs).

### 3.2.4 Projet Européen FP7 EuRoC

En parallèle du projet précédent, nous avons participé au **challenge FP7 EuRoC (European Robotics Challenge)** de 2014 à 2017. Dans ce cadre, j'ai agi en temps que *Team Leader* d'une équipe constituée du laboratoire ONERA DTIS Copernic, de l'ISIR-UPMC (coordination Pascal Morin) et du end-user RTE (gestionnaire du réseau électrique haute tension français). A l'issue d'une première phase en simulation sous ROS/Gazebo [65], nous avons été parmi les 5 équipes européennes sélectionnées (sur 21 engagées initialement) afin de proposer une solution pour le déploiement de petits drones dans des scénarios industriels concrets (inspection d'installations dangereuses ou difficiles d'accès, utilisation dans les usines du futur pour du transport). Nous avons alors développé de nouveaux algorithmes de perception et de commande prédictive pour répondre au cas d'usage RTE d'inspection autonome d'avaries dans un poste de transformation électrique haute tension. L'équipe supervisant les démonstrations était l'Autonomous Systems Lab de l'ETH Zürich, avec qui nous avons eu de nombreux échanges techniques. Nous n'avons finalement pas été retenus parmi les deux équipes retenus pour une dernière phase de démonstration sur le terrain (concurrence de très haut niveau, CVG de TUM et GRVC de l'Université de Séville y ont accédé). Ce fut cependant une expérience très positive en termes d'intégration et de mise en œuvre expérimentale de nouvelles capacités embarquées (tous les calculs étant effectués à bord du drone [25]). Outre une démonstration imposée des capacités de base en localisation basée vision et navigation autonome de drone, nous avons effectué et démontré expérimentalement les développements spécifiques suivants.

**Évitement d'obstacle mobile (démon dite "Freestyle")** – Les fonctions d'évitement d'objet mobile décrite dans la partie précédente ont été développées conjointement dans le cadre de ce projet et mises en œuvre en volière (à l'ETH Zürich) à bord d'un drone AscTec Firefly Neo dont la configuration logicielle et matérielle est similaire au Pelican utilisé dans le cadre SNCF. Le scénario consistait à suivre une trajectoire de référence tandis qu'un objet mobile (pendule sur poulie déplacé manuellement) coupait celle-ci perpendiculairement. La répétition de l'expérience à plusieurs reprises a permis de montrer que le drone restait toujours dans une zone sûre par rapport à l'obstacle mobile.

**Exploration en milieu intérieur encombré, conditions de luminosité dégradées (démon dite "Showcase")** – Le cas d'application fourni par RTE consistait en la navigation autonome d'un drone dans **un poste électrique** afin de localiser l'emplacement d'un défaut suite à la détection d'une anomalie à plus large échelle. Ce type de milieu est très en-

combré avec de nombreux objets fins et linéaires (câbles, barres) pour lesquels aucune carte 3D préalable n'est disponible, la navigation à base de GPS et magnétomètres y est impossible (perturbations électromagnétiques), les interventions doivent pouvoir se faire en luminosité réduite (jour/nuit), et l'autonomie complète du drone est souhaitée car la communication est difficile dans cet environnement. Les contraintes de la démonstration nécessitaient un environnement contrôlé de laboratoire afin de calculer des indicateurs de performance, cela a donc été effectué dans la volière de l'ONERA Palaiseau, où une maquette d'éléments de poste électrique validée par RTE a été construite (Figure 3.17). La mission abordée consistait à explorer de manière autonome l'ensemble du volume de la volière, sans information a priori, afin de reconstruire le modèle 3D de la zone (à partir des caméras du banc stéréo complétées de 2 capteurs de profondeur Intel RealSense), et de détecter et localiser un ensemble de marqueurs (émulés par des AprilTags [194], mais non utilisés pour la localisation) représentant des défauts. Dans un second temps, nous avons montré que cette exploration pouvait également être réalisée en conditions nocturnes, à l'aide de LEDs embarquées sur le drone (un développement similaire a été réalisée à la même période par [195]). Ces expérimentations ont été répétées deux fois chacune avec succès.

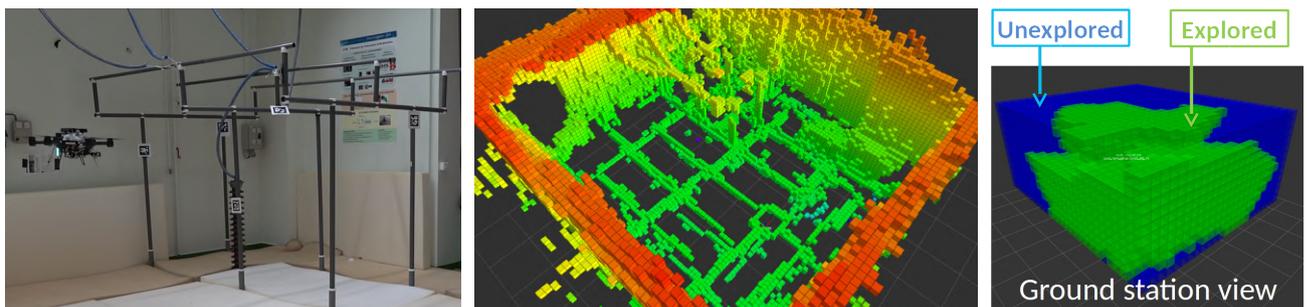


FIGURE 3.17 – Exploration autonome en environnement encombré (FP7 EuRoC)

L'algorithme d'exploration développé est à base de frontière [175], il consiste à calculer itérativement une *Next Best View* (NBV) en position et orientation afin de maximiser le nombre de nouveaux voxels vus par les capteurs embarqués. Celle-ci est sélectionnée sur la frontière entre la zone déjà explorée et la zone inconnue (hors obstacles), ces informations étant stockées dans une grille 3D de résolution équivalente au modèle Octomap (10 cm dans notre cas). Le choix de la vue est classiquement [196] un compromis entre la distance pour rejoindre une position (et une orientation candidate associée) sur la frontière et le gain réalisé à cet emplacement, celui-ci étant calculé géométriquement en fonction du champ de vue cumulé des capteurs et leur intersection avec les voxels de la grille. Dans notre cas, cela consistait à sélectionner la vue la plus proche permettant d'obtenir un nombre de voxels supérieur à un seuil arbitraire. Le chemin vers la NBV sélectionnée était alors planifié grâce à l'algorithme probabiliste LazyPRM\* [197] associé à un lissage via une B-spline (temps de calcul 1 s avec l'Open Motion Planning

Library [198]), en prenant en compte les collisions avec la carte Octomap de l'environnement comme en (3.22) et en contraignant la navigation dans les zones déjà explorées (afin de garantir la sûreté). Le suivi de trajectoire était alors réalisé avec l'algorithme MPC défini précédemment, puis une nouvelle NBV calculée lorsque la précédente était atteinte. Cette procédure est itérée jusqu'à couverture de 90% du volume défini initialement.

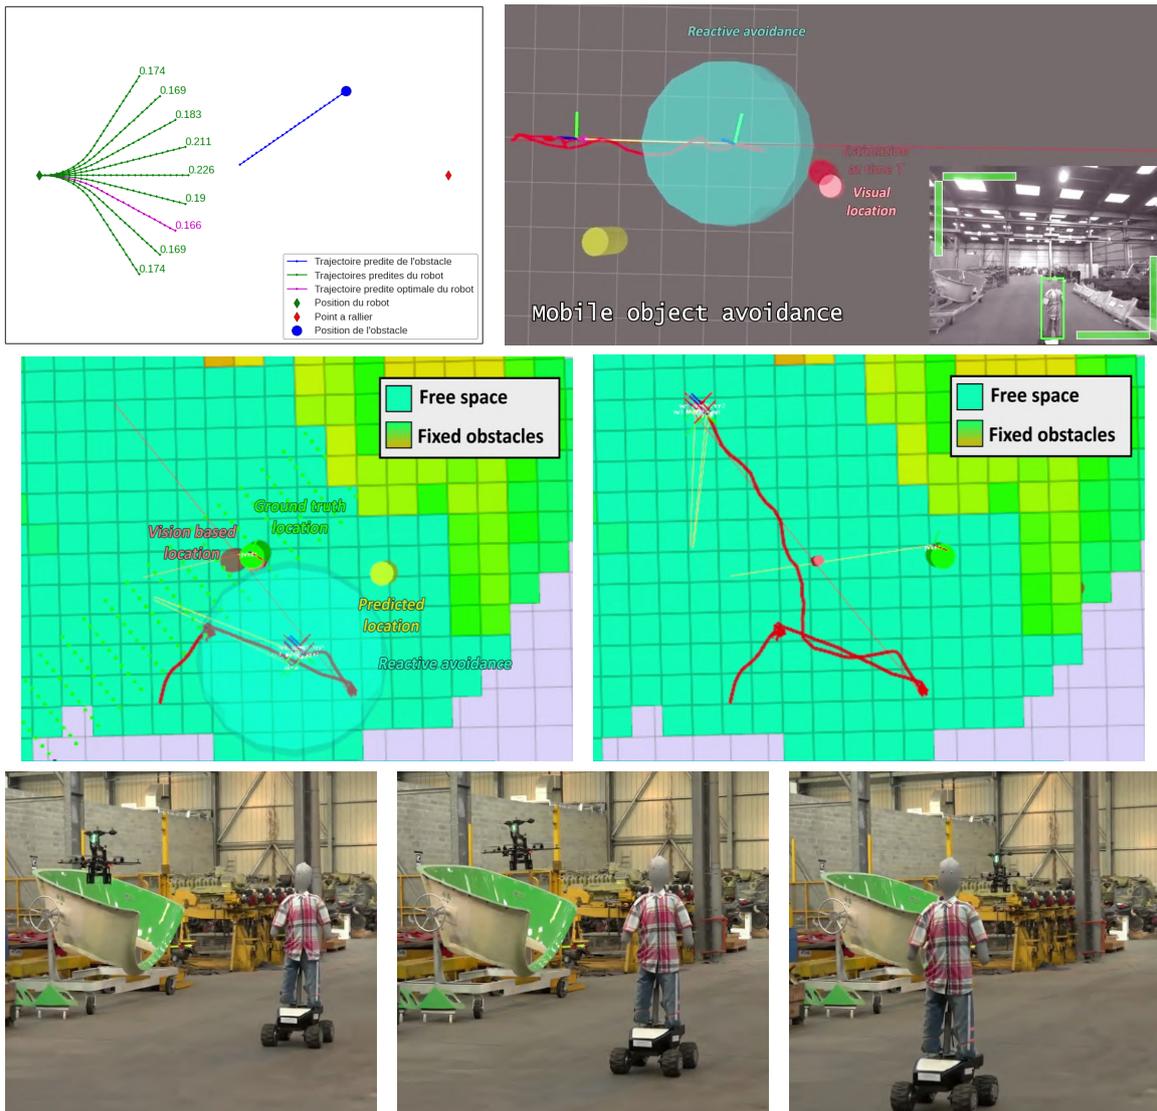


FIGURE 3.18 – MPC objet mobile : principe et résultats expérimentaux (FP7 EuRoC et PRI ONERA-SNCF DROSOFILES)

### 3.3 Commande multi-véhicules

L'ONERA DTIS travaille depuis plusieurs années sur le guidage de flottes de véhicules [174, 199], l'objectif étant de concevoir et valider des lois de commande assurant un comportement des véhicules permettant l'accomplissement d'une mission globale (exploration, déplacement en formation) et des contraintes de sécurité inhérentes à un déplacement coopératif (évitement de collisions entre véhicules et avec des obstacles). Les travaux réalisés ont porté sur le développement d'approches décentralisées, où chaque véhicule calcule lui-même sa propre loi de commande. Ceci a pour avantage de conférer plus de robustesse à la flotte, dans le cas par exemple d'une défaillance d'un ou plusieurs véhicules. La difficulté est cependant de définir des lois de commande compatibles avec la capacité de calcul à bord de chaque véhicule.

Depuis 2016, une convergence a été initiée entre ces travaux multi-véhicules et les travaux expérimentaux pour véhicule seul décrits dans la Section 3.2. Ceci fait l'objet notamment du projet interne GUIMAUVE (Guidance of Multiple Autonomous Vehicles) qui a démarré en 2017 pour une durée de 4 ans et dont je suis responsable. Ce projet s'intéresse au développement et à la mise en œuvre expérimentale de nouveaux algorithmes de guidage et de perception pour des flottes de véhicules autonomes amenées à évoluer en milieu incertain, avec pour principal moyen de localisation des caméras embarquées. Ces sujets posent de nombreuses problématiques scientifiques, pour la plupart encore ouvertes au niveau de l'état de l'art actuel sur les flottes de véhicules autonomes ou à un niveau de maturité insuffisant (coordination distribuée, mise en œuvre embarquée). Les applications envisagées sont le déploiement coopératif ou la coordination de véhicules autour d'un objectif fixe ou mobile et l'inspection de zones étendues inconnues et encombrées. Les développements sont guidés par la validation expérimentale de scénarios (localisation coopérative, déplacement en formation, exploration, localisation de source) à échelle significative avec des plateformes robotiques, afin de mettre en œuvre les nouvelles briques algorithmiques de perception et guidage et valider leur fonctionnement en embarqué. En parallèle s'est déroulé le projet Carnot « Cartographie Optimisée par Drones Autonomes » (CODA, 2016–2018), qui a permis de mettre en place l'architecture matérielle et logicielle d'une flotte de robots mobiles pour des applications de suivi de construction ou de numérisation 3D du patrimoine.

#### 3.3.1 Commande prédictive multifonctions pour flottes

La commande prédictive présentée en Section 3.2.1 a été étendue à ce cadre multi-véhicules, celle-ci pouvant être aisément décentralisée et la prédiction sur un horizon futur permettant de tenir compte des informations échangées avec les autres véhicules pour respecter les contraintes de sécurité. Une synthèse des possibilités offertes a été publiée dans [13], pour des missions de déplacement en flotte et d'exploration de zone. Les techniques présentées sont applicables à des flottes de  $N$  véhicules identiques, qui

peuvent être des robots mobiles modélisés par (3.1) ou bien des drones dont un modèle simplifié peut s'écrire comme suit :

$$\begin{cases} x_k = x_{k-1} + t_e v_{k-1} \cos \theta_{k-1} \\ y_k = y_{k-1} + t_e v_{k-1} \sin \theta_{k-1} \\ v_k = v_{k-1} + t_e a_{k-1}, \theta_k = \theta_{k-1} + t_e \omega_{k-1} \\ z_k = z_{k-1} + t_e v_{k-1}^z, v_k^z = v_{k-1}^z + t_e a_{k-1}^z \end{cases} \quad (3.25)$$

où les entrées de commande considérées sont les accélérations longitudinale  $a$  et verticale  $a^z$  et la vitesse angulaire en lacet  $\omega$ . Un modèle d'évolution 2D peut être obtenu en considérant nulles la vitesse et l'accélération sur l'axe vertical. La commande d'un véhicule est calculée à chaque instant par la minimisation d'un critère faisant intervenir une prédiction de son comportement ainsi que ceux des autres véhicules sur un horizon de temps fini. Des contraintes sur l'état et la commande des véhicules peuvent être directement prises en compte, lors de la formulation du problème d'optimisation à résoudre. En considérant les horizons de prédiction  $H_p$  et de commande  $H_c$ , on définit pour le véhicule  $i \in \{1, \dots, N\}$  les séquences d'état et de commande :

$$\begin{aligned} \mathbf{U}_i &= [\mathbf{u}_i(k)^T, \mathbf{u}_i(k+1)^T, \dots, \mathbf{u}_i(k+H_c-1)^T]^T \\ \mathbf{X}_i &= [\mathbf{x}_i(k+1)^T, \mathbf{x}_i(k+2)^T, \dots, \mathbf{x}_i(k+H_p)^T]^T \end{aligned}$$

et le problème d'optimisation à l'instant  $k$  afin de déterminer  $\mathbf{U}_i^*(k)$  :

$$\begin{aligned} \min J_i(\mathbf{U}_i, \mathbf{X}_i) \text{ pour } \mathbf{U}_i \in \mathcal{U}_i^{H_c} \\ \text{avec } \mathbf{x}_i(t) \text{ satisfaisant (3.25), } \forall t \in [k+1; k+H_p] \end{aligned}$$

La résolution numérique de ce problème a été réalisée par discrétisation de l'espace de commande, le coût de calcul unitaire étant plus important que dans le cas mono-véhicule et dans le but de garantir un temps de calcul constant à chaque itération. A chaque instant  $k$ , chaque véhicule partage avec les autres membres de la flotte sa position courante  $\mathbf{x}_i(k)$  ainsi que sa séquence de commande  $\mathbf{U}_i^*(k)$ . Le critère est similaire à celui défini en (3.5), avec des spécificités dues au caractère multi-véhicules :

$$J_i = w_{\text{safe}} J_{\text{safe}}^i + w_u J_u^i + w_{\text{expl}} (b_e^i J_{\text{expl}}^i + \bar{b}_e^i J_{\text{nav}}^i) \quad (3.26)$$

Le coût de sécurité  $J_{\text{safe}}^i = J_{\text{obs}}^i + J_{\text{veh}}^i$  se décompose en un coût  $J_{\text{obs}}^i$  prenant en compte les obstacles statiques (identique au cas mono-véhicule) et en un coût  $J_{\text{veh}}^i$  correspondant à l'application de la fonction obstacle aux distances entre chaque position prédite du véhicule  $i$  et chacun de ses voisins  $j \in \{1, \dots, N\} i \neq j$ , pour chaque pas de l'horizon de prédiction. Ce coût est analogue à celui défini pour l'évitement d'obstacle mobile, si ce n'est que les positions prédites sont inférées ici grâce aux informations partagées coopérativement dans la flotte. Le coût de navigation  $J_{\text{nav}}^i = J_{\text{wp}}^i + J_{\text{fleet}}^i$  se décompose en un

coût de ralliement de waypoint (3.9) inchangé et en un coût additionnel de regroupement en formation (lorsque la mission considère cette option) tel que

$$J_{\text{fleet}}^i = (NH_p)^{-1} \sum_{j=1, j \neq i}^N \sum_{t=k+1}^{k+H_p} f_{\text{fleet}}(\mathbf{x}_i(t), \mathbf{x}_j(t))$$

$$f_{\text{fleet}}(\mathbf{x}_i, \mathbf{x}_j) = \frac{1 + \tanh(\alpha(d_{ij}(\mathbf{x}_i, \mathbf{x}_j) - \beta))}{2} \quad (3.27)$$

où les paramètres  $\alpha$  et  $\beta$  sont définis comme pour le coût d'évitement d'obstacle (3.6). Ainsi, le coût de flotte et le coût d'obstacle définissent le comportement d'attraction-répulsion du véhicule vers une zone de stabilité comprise entre une distance minimale désirée aux obstacles et une distance maximale par rapport au reste de la flotte (Figure 3.19b). L'approche développée a été appliquée au guidage d'une flotte de drones quadrirotors (modèle de simulation plus complet que le modèle de conception de la loi de commande [174]) pour une mission de ralliement de points de passage en présence d'obstacles (Figure 3.19a). La méthode décentralisée développée a également été validée expérimentalement [40] sur des robots de type Lego Mindstorms, dont la capacité limitée de calcul permet de valider l'aspect embarquabilité (Figure 3.25b).

Dans le cas d'une mission d'exploration (coût de navigation désactivé via le booléen  $b_e^i$ ), le coût  $J_{\text{expl}}^i$  reste celui défini par (3.8) avec un partage d'information entre les robots concernant les zones explorées afin de minimiser naturellement les recouvrements [43]. Dans ces travaux, un autre coût de navigation a été ajouté pour guider les véhicules vers des points de sortie prédéfinis tout en gérant l'allocation des points entre véhicules de manière décentralisée. Une pondération dynamique est utilisée pour conférer plus d'importance à ce coût lorsque la mission touche à sa fin. La Figure (3.20) présente une illustration de cette approche, où la zone grisée est celle explorée en commun et la couleur d'un véhicule correspond au point de sortie envisagé.

Une approche alternative a été proposée dans [45] pour le vol en formation au sein d'une structure virtuelle ellipsoïdale capable de se déformer au cours du temps selon les besoins de la mission. Dans ce cas, deux niveaux de commande prédictive sont considérés. Un premier niveau (*flotte*) est utilisé afin de contrôler l'évolution de la structure virtuelle, selon les contraintes d'évitement d'obstacles et d'objectif à atteindre. Une pseudo-commande de déformation des axes et de rotation de la structure est calculée afin de pénaliser l'intersection de l'ellipse avec des obstacles tout en rapprochant le centre d'une destination. Cette opération peut être centralisée ou réalisée par chacun des véhicules à l'identique pour conserver un schéma décentralisé. Un second niveau (*véhicule*) est ensuite utilisé pour attirer les véhicules et les conserver au sein de cette structure virtuelle (distance de Mahalanobis à partir des paramètres de l'ellipse), tout en évitant les collisions inter-véhicules grâce au coût  $J_{\text{veh}}^i$  défini précédemment. Un exemple est présenté en Figure 3.21, où la structure virtuelle se déforme afin de permettre à la flotte de franchir un couloir.

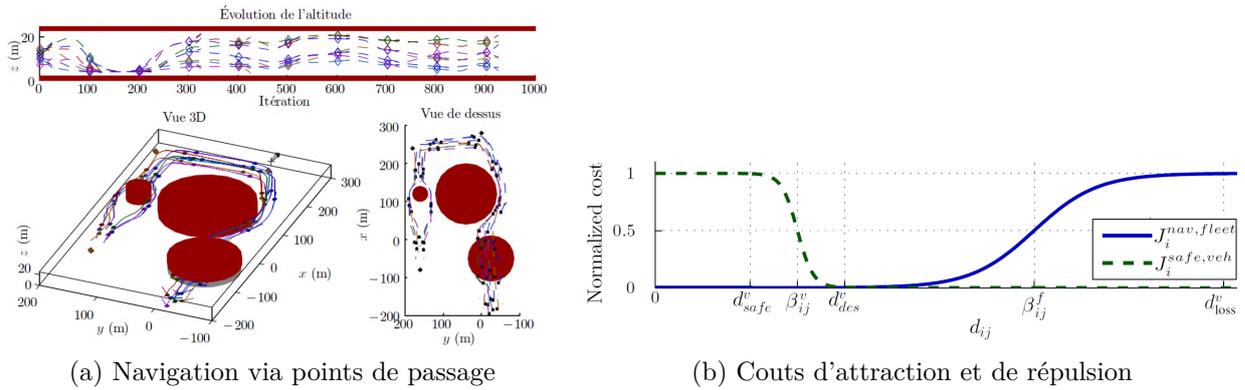


FIGURE 3.19 – Commande prédictive distribuée pour flotte de véhicules

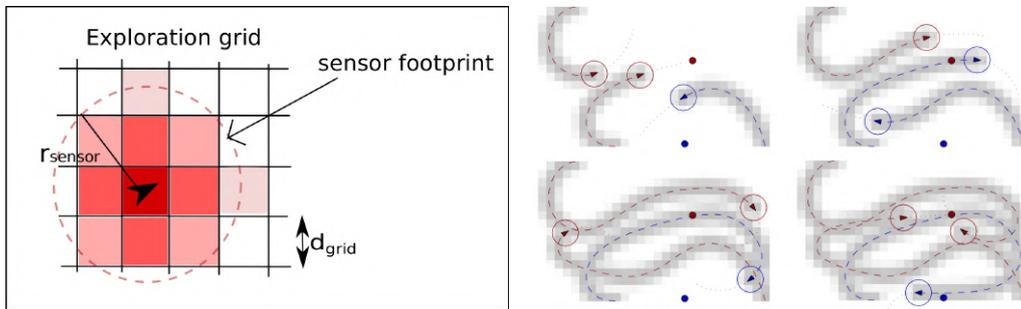
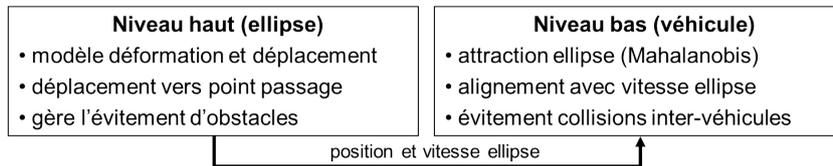
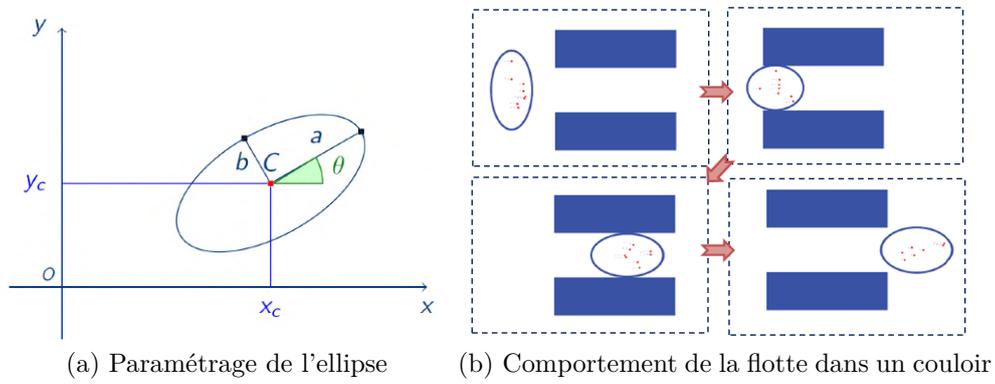


FIGURE 3.20 – Commande prédictive pour exploration coopérative de zone



(c) Schéma hiérarchique à 2 niveaux MPC

FIGURE 3.21 – Navigation d'une flotte contrainte dans une ellipse

### 3.3.2 Localisation de source par une flotte

Dans la thèse d'Arthur Kahn [200], co-dirigée par Hélène Piet-Lahanier (ONERA DTIS) et Michel Kieffer (L2S CentraleSupélec), une mission de localisation de source a été formalisée comme la recherche coopérative de la position du maximum d'un champ spatial initialement inconnu (schéma de principe en Figure 3.22). Une première approche développée s'appuie sur une stratégie de recherche locale qui cherche à estimer le gradient du champ inconnu dans le but de déplacer les agents selon cette direction. Une méthode coopérative de détection et d'identification de défauts de mesure utilisant un seuil adaptatif a également été proposée dans ce cadre [38]. La deuxième solution d'estimation s'appuie sur une stratégie de recherche globale du maximum. Le champ est modélisé par krigeage (voir Chapitre 4) et la recherche est effectuée en utilisant les propriétés statistiques de ce méta-modèle. Un nouveau critère d'échantillonnage a été développé pour permettre au système multi-agents de localiser la position du maximum global tout en limitant le nombre de mesures et en tenant compte des contraintes dynamiques des véhicules [36].

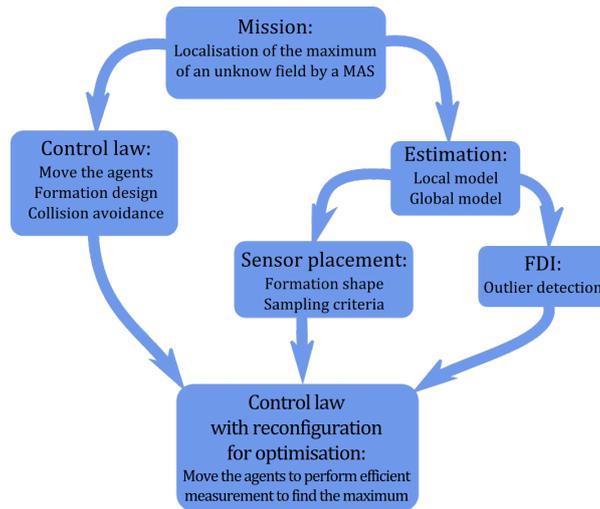


FIGURE 3.22 – Schéma de l'architecture algorithmique multi-véhicules définie dans la thèse d'Arthur Kahn

Les méthodes proposées visent à déterminer la position  $x_M$  du maximum d'un champ scalaire  $\phi$  dans la zone  $D \subset \mathbb{R}^n$ ,  $n = 2$  ou  $n = 3$ .

$$x_M = \arg \max_{x \in D} \phi(x) \quad (3.28)$$

Un groupe de  $N$  agents identiques est considéré, la position de l'agent  $i$  à l'instant  $t$  est notée  $x_i(t)$ . La dynamique des agents est régie par

$$M\ddot{x}_i + C(x_i, \dot{x}_i)\dot{x}_i = u_i, \quad (3.29)$$

où  $u_i(t)$  est la commande appliquée à l'agent  $i$  à l'instant  $t$ ,  $M$  la masse d'un agent et  $C(\cdot, \cdot)$  un coefficient de friction positif. Chaque agent est équipé d'un capteur lui permettant de mesurer la valeur du champ  $\phi$ , telle que :

$$y_i = \phi(x_i) + w_i(\eta_i), \quad (3.30)$$

où  $w_i$  modélise le bruit de mesure de l'agent  $i$ , et  $\eta_i$  indique l'état de santé du capteur : la variance du bruit est nominale pour  $\eta = 0$ , et défaillante (augmentation du niveau de bruit) pour  $\eta = 1$ . Le voisinage de l'agent  $i$  est défini par

$$\mathcal{N}_i(t) = \{j \mid \|x_i(t) - x_j(t)\| \leq R\} \quad (3.31)$$

avec  $R$  le rayon de communication entre deux agents. Les informations disponibles pour l'agent  $i$  à l'instant  $t_k$  sont

$$\mathcal{S}_i(t_k) = \bigcup_{\ell=0}^k \{[y_j(t_\ell), \mathbf{x}_j(t_\ell)] \mid j \in \mathcal{N}_i(t_\ell) \cap \mathcal{M}(t_\ell)\} \quad (3.32)$$

où  $\mathcal{M}(t_k)$  désigne l'ensemble des agents ayant effectué une mesure à l'instant  $t_k$ .

### Méthode locale

Cette approche est basée sur une estimation du gradient du champ inconnu suivi du déplacement des agents vers le maximum, de manière similaire aux approches décrites dans [201, 202]. Pour parvenir à ce résultat, une estimation coopérative du champ et de son gradient est effectuée par les agents à partir de leurs mesures. Les capteurs étant embarqués sur les agents mobiles, nous nous sommes donc aussi intéressés au positionnement optimal de la flotte. Une méthode de diagnostic a été proposée pour détecter quand un capteur de la flotte devient défaillant et fournit des données aberrantes. Un autre élément important consiste à développer la loi de guidage afin de déplacer les agents. Les objectifs de cette loi de guidage sont multiples, il lui faut placer les agents en respectant le résultat de l'analyse du placement optimal, il lui faut aussi déplacer l'ensemble de la flotte vers le maximum suivant le gradient local et enfin, il lui faut reconfigurer la flotte lorsqu'une erreur est détectée.

Tout d'abord, une estimation par moindres carrés est utilisée pour estimer la valeur locale du champ et de son gradient. Le champ peut être écrit sous la forme d'un développement de Taylor d'ordre deux à la position de référence  $x_0$  (centre de la flotte, par exemple)

$$\phi(x) = \phi(x_0) + (x - x_0)^T \nabla \phi(x_0) + \frac{1}{2} (x - x_0)^T \nabla^2 \phi(\chi) (x - x_0) \quad (3.33)$$

où  $\chi$  est un point du segment reliant  $x$  à  $x_0$ . Le vecteur des paramètres à estimer est  $\alpha = [\phi(x_0), \nabla \phi(x_0)^T]^T$  à partir des mesures de la flotte  $y_i$ ,  $i = 1, \dots, N$ .

Pour l'estimation, le champ est modélisé comme

$$\bar{\phi}(x) = \phi(x_0) + (x - x_0)^T \nabla \phi(x_0) \quad (3.34)$$

avec l'erreur de modélisation

$$e(x) = \phi(x) - \bar{\phi}(x) = \frac{1}{2}(x - x_0)^T \nabla^2 \phi(x) (x - x_0) \quad (3.35)$$

La mesure de tout agent  $j$  s'écrit alors

$$y_j = \begin{bmatrix} 1 & (x_j - x_0)^T \end{bmatrix} \alpha + e(x_j) + w_j \quad (3.36)$$

A un instant donné, le véhicule  $i$  récupère toutes les mesures des agents de son voisinage  $\mathcal{N}_i$  dans un vecteur  $\mathbf{y} = [y_1, \dots, y_N]^T$ , tel que

$$\mathbf{y}_i = \mathbf{R}\alpha + \mathbf{w} + \mathbf{e} \quad (3.37)$$

où la ligne  $j \in [1, N]$  de  $\mathbf{R}$  est égale à  $\begin{bmatrix} 1 & (x_j - x_0)^T \end{bmatrix}$ ,  $\mathbf{w}$  concatène les bruits de mesure de chaque capteur et  $\mathbf{e}$  les erreurs de modélisation (3.35).

Chaque agent  $i$  réalise une estimation au sens des moindres carrés pondérés

$$\hat{\alpha}_i = (\mathbf{R}^T \mathbf{W} \mathbf{R})^{-1} \mathbf{R}^T \mathbf{W} \mathbf{y}_i \quad (3.38)$$

avec la matrice

$$\mathbf{W} = \text{diag} \left[ \sigma_{\eta_1}^{-2} \exp \left( \frac{-\|x_1 - x_0\|_2^2}{k_w} \right), \dots, \sigma_{\eta_N}^{-2} \exp \left( \frac{-\|x_N - x_0\|_2^2}{k_w} \right) \right] \quad (3.39)$$

En plus de la variance du bruit de mesure, il a été choisi de pénaliser l'éloignement spatial entre agents car celui-ci fait croître de manière quadratique l'erreur de modélisation (3.35).

Nous avons alors recherché les configurations de la flotte qui minimisent la variance de l'estimation  $\hat{\Sigma}_\alpha = (\mathbf{R}^T \mathbf{W} \mathbf{R})^{-1}$ . Deux critères usuels [203], T-optimal (trace) et D-optimal (déterminant), ont été évalués sous contrainte de distance de sécurité minimale entre agents égale à  $R_{\text{safety}}$ . Il a été possible de déterminer analytiquement qu'une des solutions consiste à disposer les agents en cercle (si les contraintes d'inter-distance le permettent) autour de la position de référence  $x_0$ , le rayon dépendant du paramètre de pondération  $k_w$ . Si l'on considère la présence d'agents défaillants (variance du bruit de mesure plus élevée), il a pu être déterminé numériquement que les agents défaillants doivent être placés à une distance plus grande du centre afin de moins pénaliser l'estimation (Figure 3.23). L'erreur de modélisation (3.35) est quant à elle minimale lorsque la formation est à la distance la plus faible possible du centre  $x_0$ , compte tenu des contraintes.

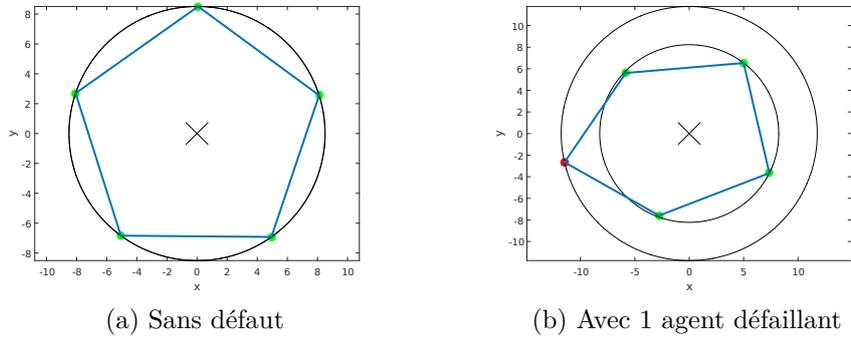


FIGURE 3.23 – Placement D-optimal de la flotte pour estimation à variance minimale

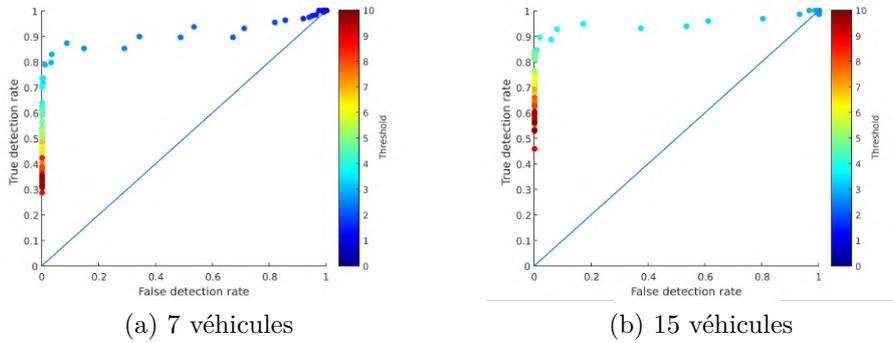


FIGURE 3.24 – Courbes ROC de détection en fonction du nombre d'agents dans la flotte

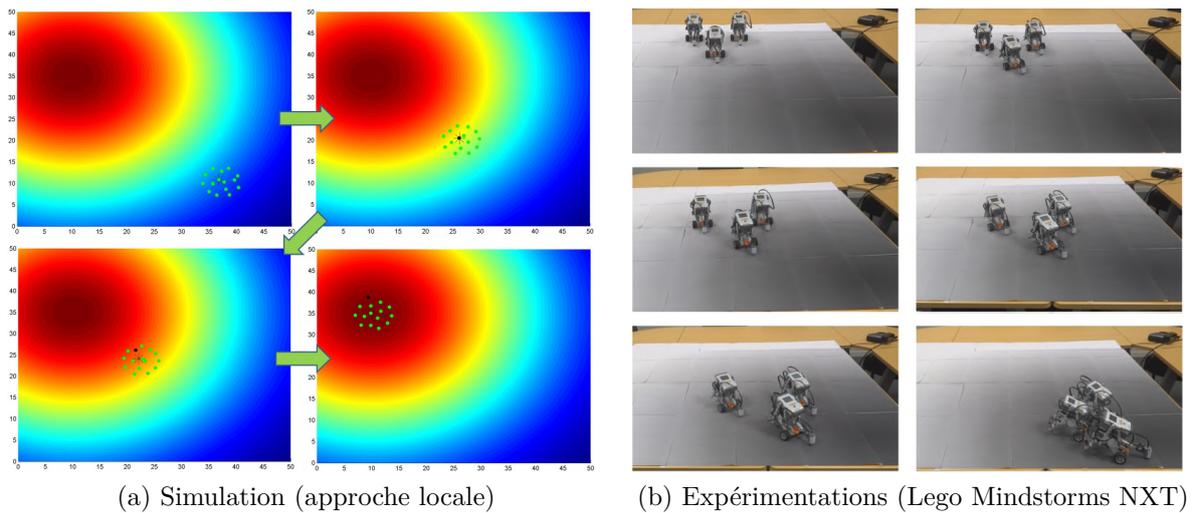


FIGURE 3.25 – Résultats de l'approche locale de recherche de maximum d'un champ

Il est possible de détecter les défauts de capteur en analysant les résidus  $r_{ij} = y_i - \hat{\phi}_{ij}$ , où  $\hat{\phi}_{ij}$  est l'estimée calculée à partir de (3.38) en excluant la  $j$ -ème mesure du processus. Un seuil adaptatif a été déterminé pour ce résidu, en fonction du niveau de bruit nominal et de la distance entre les véhicules  $i$  et  $j$ , dont dépend l'erreur de modélisation [38]. Les performances de bonne détection et de fausse alarme ont été quantifiées pour différentes configurations de défauts et de nombre d'agents dans la flotte (Figure (3.24)).

En ce qui concerne la commande de la flotte, celle-ci s'effectue en deux temps. Tout d'abord, la position de référence de la flotte est déplacée suivant la direction du gradient estimé, telle que

$$\dot{x}_0 = \nabla\phi \|\nabla\phi\|^{-1}v \quad (3.40)$$

avec  $v > 0$ . Si on note  $x_M$  la position réelle du maximum du champ, on peut montrer que cette commande permet de faire converger  $x_0$  vers  $x_M$  en considérant la fonction de Lyapunov  $V = \frac{1}{2}(x_M - x_0)^T(x_M - x_0)$ , sous l'hypothèse que le champ est concave ( $\nabla^2\phi < 0$  en tout point de l'espace) [40]. Dans un deuxième temps, on considère pour chaque agent la commande

$$\begin{aligned} u_i = & M\ddot{x}_0 + C(x_i, \dot{x}_i)\dot{x}_i - k_1(\dot{x}_i - \dot{x}_0) \\ & + 2k_2 \sum_{j=1}^N (x_i - x_j) \exp\left(-\frac{(x_i - x_j)^T(x_i - x_j)}{q}\right) \\ & - k_3^i(\eta_i)(x_i - x_0), \end{aligned} \quad (3.41)$$

dont la stabilité a été démontrée en considérant la fonction de Lyapunov

$$V = \frac{1}{2} \sum_{i=1}^N (V_1 + V_2 + V_3) \quad (3.42)$$

$$\left\{ \begin{array}{ll} V_1 = (\dot{x}_i - \dot{x}_0)^T M (\dot{x}_i - \dot{x}_0) & \text{suivi en vitesse} \\ V_2 = (x_i - x_0)^T k_3^i (x_i - x_0) & \text{suivi en position} \\ V_3 = k_2 \sum_{j=1}^N \exp\left(-\frac{1}{q} (x_i - x_j)^T (x_i - x_j)\right) & \text{évitement de collision} \end{array} \right. \quad (3.43)$$

Lorsque le capteur d'un agent est détecté comme défaillant, la loi de commande est adaptée en diminuant le gain  $k_3^i$  de l'agent correspondant, ce qui a pour effet de l'éloigner du centre de la formation, en accord avec l'étude de placement. Une illustration de la boucle complète est donnée en Figure 3.25a, où l'agent défaillant indiqué en noir est placé en périphérie de la flotte, qui parvient à rallier le maximum du champ.

### Méthode globale

L'approche précédente permet uniquement de rallier un maximum local du champ. Afin de traiter le cas multimodal, une approche globale a été développée. Celle-ci s'appuie

sur un modèle de krigeage du champ  $\phi(x)$  tel que

$$Y(x) = \mathbf{r}(x)^T \beta + Z(x)$$

où  $\mathbf{r}(x)$  est un vecteur arbitraire de régresseurs,  $\beta$  un vecteur de paramètres et  $Z(x)$  un processus gaussien de moyenne nulle et de matrice de covariance  $C(Z(x_1), Z(x_2))$ . Ce modèle de régression permet d'obtenir une moyenne estimée  $\hat{\phi}(x)$  et une variance  $\hat{\sigma}^2(x)$  en chaque point de l'espace. Ces éléments sont alors classiquement utilisés pour guider des algorithmes d'optimisation afin de sélectionner itérativement des prochains points d'échantillonnage d'une fonction coûteuse. Par exemple, afin de trouver le maximum

$$x_M = \arg \max_{x \in D} \phi(x),$$

l'algorithme décrit dans [204] choisit comme point d'échantillonnage  $x_+ = \arg \max \hat{\phi}(x) + b\hat{\sigma}(x)$ , car cet emplacement a une probabilité élevée de contenir le maximum de la fonction réelle ( $b$  étant une constante de réglage, égale à 2 par exemple). Par rapport à ce cadre, le problème de recherche du maximum via la flotte impose des contraintes dynamiques car les prochaines positions des agents ne peuvent pas être échantillonnées instantanément. Nous avons ainsi proposé dans [36] le critère décentralisé suivant :

$$J_i(x) = \|x_i - x\|^2 - \sum_{j \in \mathcal{N}_i} a \|x_j - x\|^2$$

où  $x_i$  est la position courante de l'agent  $i$ . Chaque agent détermine ainsi sa prochaine destination en résolvant le problème d'optimisation sous contrainte suivant :

$$x_i^d = \arg \min_{x \in D} J_i(x) \tag{3.44}$$

$$\text{s.t. } \hat{\phi}(x) + b\hat{\sigma}_i(x) > f_{\max}^i \tag{3.45}$$

où  $f_{\max}^i$  est la valeur maximale mesurée du champ à l'instant courant (parmi les mesures reçues par l'agent  $i$ ),  $a$  et  $b$  sont des constantes positives de pondération. En pratique, l'algorithme d'optimisation globale DIRECT (DIviding RECTangles [176]) a été utilisé pour déterminer les solutions. La position  $x_i^d$  ainsi définie est alors fournie à la loi de commande (3.41) afin de rallier ce point en évitant les collisions avec les autres agents. La contrainte (3.45) définit les zones à explorer comme étant les zones potentielles de présence du maximum, c'est à dire les zones dont la moyenne du modèle augmentée de l'incertitude est supérieure au maximum courant. Le principe du critère est illustré en Figure 3.26, où l'on peut voir la réduction rapide de l'espace de recherche au fur et à mesure des itérations. La Figure (3.27) présente un exemple du comportement obtenu en simulation avec une flotte de 5 véhicules. La fonction affichée est  $\hat{\phi}(x) + b\hat{\sigma}(x)$ , le code couleur allant du bleu foncé (min) au rouge foncé (max). Le maximum réel est situé en [15, 15]. Les points noirs indiquent la position courante de chaque agent, les points rouges

étant les positions échantillonnées précédemment. L'un des intérêts de la méthode est donc de permettre la recherche globale du maximum, sans nécessairement explorer toute la zone. Les résultats ont été comparés avec la méthode proposée par [205] qui considèrerait uniquement l'échantillonnage successif aux points d'incertitude maximale ( $\max \hat{\sigma}(x)$ ). La méthode proposée obtient un meilleur compromis entre une convergence rapide vers le maximum et le nombre de mesures nécessaire pour atteindre l'objectif (Figure 3.28).

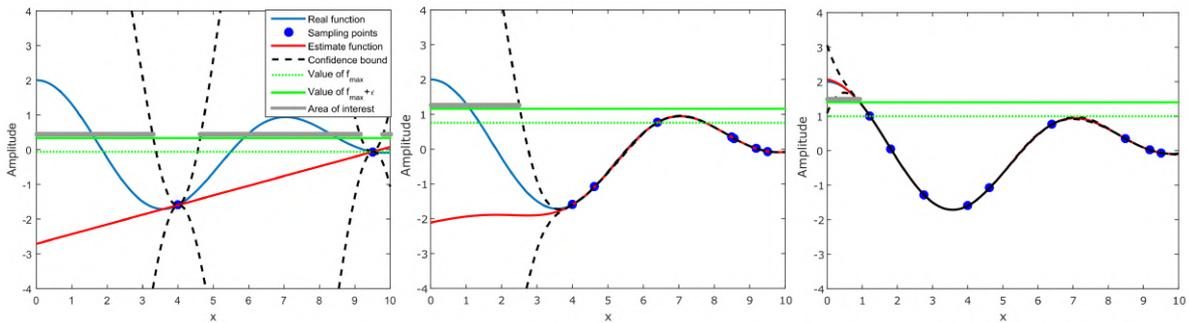


FIGURE 3.26 – Principe de fonctionnement du critère global

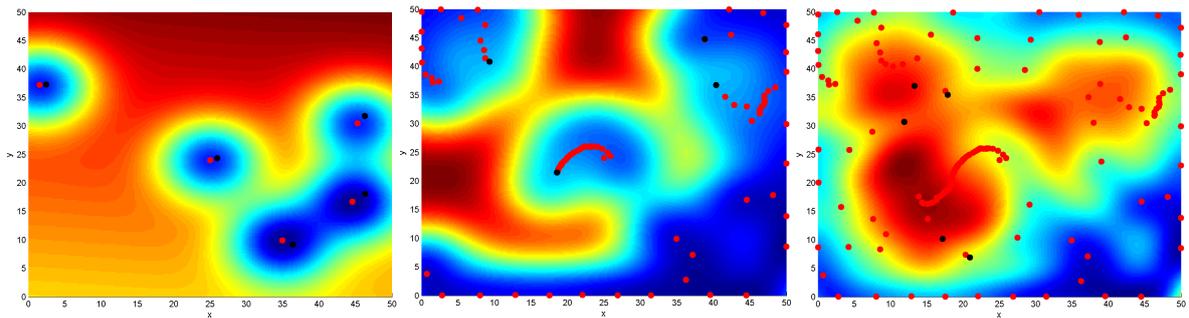


FIGURE 3.27 – Comportement de la flotte avec la recherche globale d'extrémum

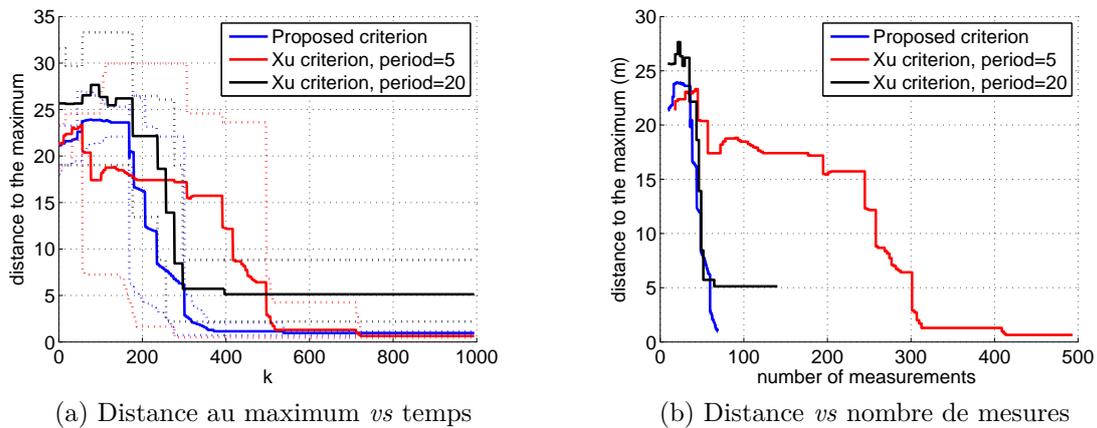


FIGURE 3.28 – Performances de la méthode globale à base de krigeage

### 3.3.3 Localisation collaborative basée vision en formation

Une approche de commande coopérative d'une flotte de drones multi-rotors incluant une méthode originale d'estimation distribuée à base de vision embarquée a été validée expérimentalement [35] dans le cadre du stage M2 de Nathan Piasco, co-encadré avec Martial Sanfourche (ONERA DTIS). La localisation basée vision peut être réalisée à partir de caméras monoculaires [145, 206] mais cela pose des difficultés pour l'estimation de l'échelle du mouvement. Une alternative est d'utiliser un banc de stéréo-vision comme dans les travaux décrits précédemment [150], mais cela nécessite la synchronisation et la calibration des deux caméras. Dans le cadre d'un déplacement en flotte, il est possible de tirer partie des complémentarités entre les capteurs embarqués sur les différents véhicules. Des travaux précédents ont étudié la possibilité de fusionner des cartes obtenues par SLAM monoculaire [207], et également la fusion d'une stéréo-vision « collaborative » combinant deux caméras de deux drones différents [208]. Dans la continuité de cette dernière référence, nous avons considéré une flotte de mini-drones identiques (Parrot AR Drones) où chacun est équipé d'une caméra monoculaire frontale, une centrale inertielle, une caméra au nadir et un capteur ultrason mesurant la hauteur sol. Un schéma de filtrage reposant sur un filtre de Kalman étendu a été développé afin d'estimer les positions et les orientations de tous les véhicules. Une commande distribuée de mise en formation afin de maximiser le recouvrement des champs de vue des véhicules vient compléter la boucle basée vision. Ces algorithmes ont été testés expérimentalement via une implémentation ROS centralisée et une liaison WiFi.

Le  $i$ -ème drone de la flotte dispose des mesures suivantes : sa vitesse angulaire  $\omega_i$ , sa vitesse linéaire  $v_i$  obtenue par fusion (propriétaire Parrot) entre le flot optique de la caméra nadir et l'IMU, la hauteur sol  $z_i$  et une image frontale de résolution 640x360. En considérant une paire de ces images issues de deux drones  $i$  et  $j$  ayant des champs de vue recouvrants, on peut estimer la rotation relative  $q_{ij}$  et le vecteur directeur  $d_{ij} = p_{ij} \|p_{ij}\|^{-1}$ . Ceci est réalisé en extrayant et appairant des points d'intérêt SIFT [209] puis en appliquant l'algorithme de Nister [210] associé à une procédure RANSAC, à partir de la librairie OpenGV [211]. Le filtre EKF est décrit pour une paire de drones, celui-ci se généralise aisément à  $N$  véhicules. Le vecteur d'état est composé des positions et orientations en repère inertiel,  $\mathbf{x} = [q_i, q_j, p_i, p_j]^T$ . Le vecteur d'entrées connues contient les vitesses angulaires et linéaires en repère engin,  $\mathbf{u} = [\omega_i, \omega_j, v_i, v_j]^T$ . Le vecteur de mesures contient la direction et l'orientation relative obtenue par la vision distribuée, et les mesures de hauteur,  $\mathbf{y} = [d_{ij}, q_{ij}, z_i, z_j]^T$ . On suppose le sol parfaitement plan, ainsi la hauteur sol coïncide avec la composante verticale de la position en repère inertiel. Le modèle dynamique et l'équation de mesure du système sont :

$$\dot{\mathbf{x}} = \begin{pmatrix} \frac{1}{2} (q_i \otimes (\omega_i + \eta_\omega^i)) \\ \frac{1}{2} (q_j \otimes (\omega_j + \eta_\omega^j)) \\ R(q_i) (v_i + \eta_v^i) \\ R(q_j) (v_j + \eta_v^j) \end{pmatrix}, \mathbf{y} = \begin{pmatrix} R^T(q_i) (p_i - p_j) \lambda_{ij} + \eta_p \\ q_i^* \otimes q_j + \eta_q \\ p_{i,z} + \eta_z^i \\ p_{j,z} + \eta_z^j \end{pmatrix}$$

où  $R$  désigne la matrice de rotation depuis le repère engin vers le repère inertiel, les vecteurs  $\eta_{(\cdot)}$  représentent des bruits blancs gaussiens indépendants. Le facteur d'échelle  $\lambda_{ij}$  est approximé par  $\|p_i - p_j\|^{-1}$  en utilisant les positions prédites, il n'est ainsi pas nécessaire de l'estimer en ligne contrairement à [208] qui ne considérait aucune mesure absolue de position ou vitesse. Les estimées obtenues ont été comparées avec celles fournies par le SLAM monoculaire PTAM (Figure 3.29a) : la stéréo-vision collaborative permet bien de corriger les dérives de la prédiction seule, et le résultat global est à la fois cohérent avec PTAM et plus lisse.

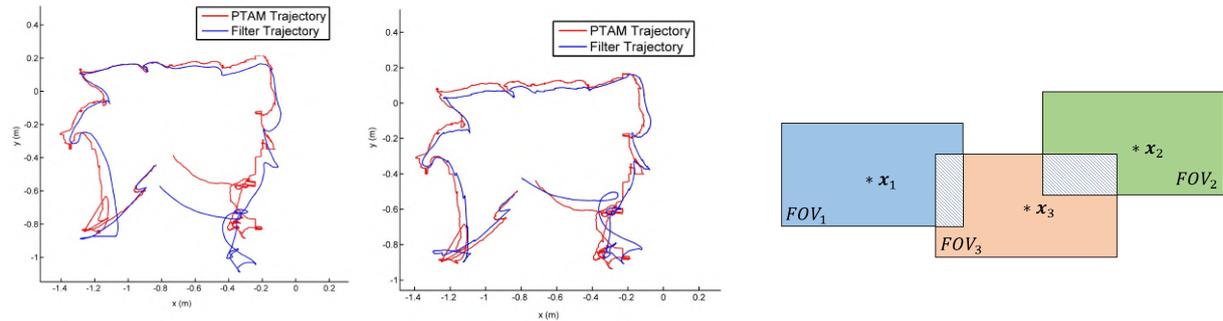
Le schéma d'estimation nécessitant que les drones aient des champs de vue communs (au moins 2 à 2), une commande de mise en formation a été définie pour maximiser cet effet. L'AR Drone disposant d'une boucle interne rapide, chaque drone dispose de quatre entrées de commande : trois vitesses linéaires et la vitesse angulaire en lacet. La loi de commande a été définie en trois parties indépendantes :

1. Aligner les drones à la même orientation, via un correcteur proportionnel sur l'axe de lacet.
2. Contraindre les drones sur un plan vertical de référence  $\mathcal{P}$ , via un correcteur proportionnel sur l'axe perpendiculaire au plan. Ce plan peut être mobile afin de déplacer la formation.
3. Maximiser l'aire de recouvrement tout en évitant les collisions.

Le dernier point nécessite de commander les vitesses suivant les axes  $y$  et  $z$  dans le plan  $\mathcal{P}$ . L'aire de recouvrement des champs de vue projetés avec une portée donnée est la zone grisée indiquée en Figure 3.29b. Cette aire pour la formation, notée  $\mathcal{A}_\Sigma$  est calculée comme le cumul des sous-aires de chaque paire de drones. La loi de commande est alors donnée par

$$\mathbf{v}_i = 2k_1 \sum_{j=1}^N (x_i - x_j) \frac{g_{ij}}{q} + k_2 \left( \frac{\partial \mathcal{A}_\Sigma}{\partial x_i} \right)^T$$

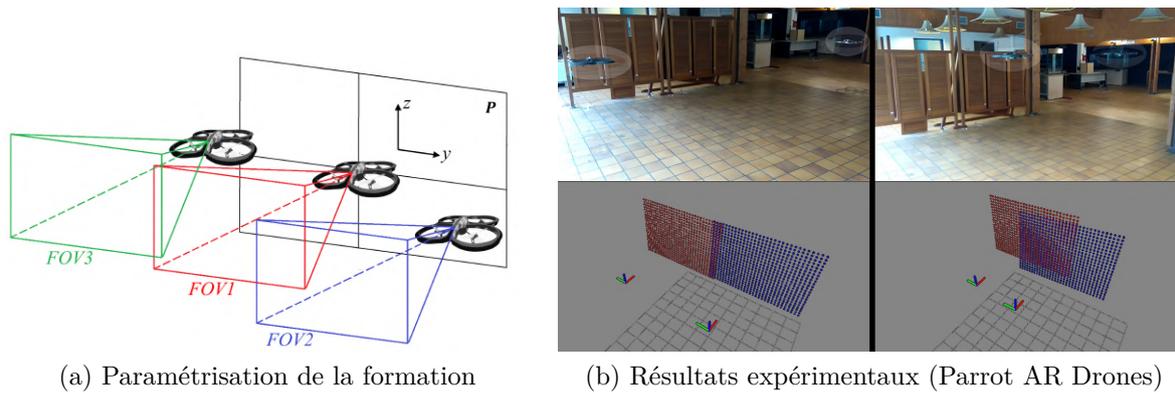
où  $\mathbf{v}_i$  regroupe les deux vitesses latérale et verticale du drone  $i$ ,  $x_i$  sa position sur le plan  $\mathcal{P}$ ,  $g_{ij} = \exp\left(-\frac{(x_i - x_j)^T (x_i - x_j)}{q}\right)$  est une fonction de répulsion,  $k_1$  et  $k_2$  deux gains de commande,  $N$  le nombre de drones dans la formation. La stabilité locale de cette commande peut être démontrée en considérant la fonction de Lyapunov  $V = \frac{1}{2} \sum_{i=1}^N k_1 \sum_{j=1}^N g_{ij} + k_2 (K - \mathcal{A}_\Sigma)$  avec  $K$  une constante positive telle que  $V$  soit positive. Un exemple de résultat expérimental combinant la localisation avec stéréo-vision distribuée et la loi de mise en formation est présenté en Figure 3.30.



(a) Comparaison du filtre avec le SLAM monoculaire PTAM (gauche : prédiction seule, droite : avec correction distribuée)

(b) Aires des champs de vue

FIGURE 3.29 – Localisation avec stéréo-vision collaborative



(a) Paramétrisation de la formation

(b) Résultats expérimentaux (Parrot AR Drones)

FIGURE 3.30 – Localisation distribuée basée vision et commande de flotte de drones

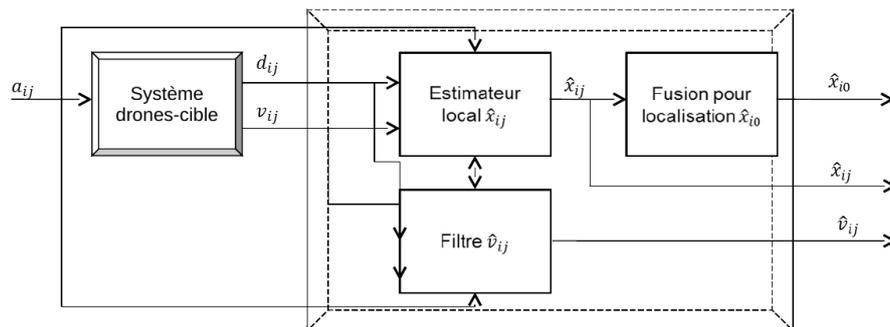


FIGURE 3.31 – Architecture distribuée d'estimation des états relatifs dans une formation

### 3.3.4 Estimation et guidage coopératif pour suivi de cible

L'estimation coopérative et le guidage d'une flotte de drones pour réaliser un suivi coopératif de cible à partir de mesures de distances et vitesses relatives ont été étudiés dans [7,31], lors du post-doctorat de Ioannis Sarras co-encadré avec Hélène Piet-Lahanier et Sylvain Bertrand (ONERA DTIS). Aucune mesure absolue n'est nécessaire (contrairement à [212–214]), et une dynamique de double intégrateur est considérée avec une cible dynamique alors que les travaux précédents de [215] considéraient uniquement une cible statique et une dynamique de simple intégrateur pour les agents. La cible à suivre est incluse dans le graphe de la flotte, qui comporte donc  $N + 1$  agents, représenté classiquement [216] par la matrice Laplacienne  $\mathcal{L}$  dont les éléments  $l_{ij}$ ,  $i, j \in \{0, \dots, N\}$  (la cible étant l'agent 0) sont définis comme

$$l_{ij} = \begin{cases} \sum_{j \in \mathcal{N}_i} w_{ij} & \text{si } i = j \\ -w_{ij} & \text{si } i \neq j \end{cases} \quad \text{avec } w_{ij} = \begin{cases} > 0 & \text{si } j \in \mathcal{N}_i \\ 0 & \text{si } i = j \text{ ou } j \notin \mathcal{N}_i \end{cases} \quad (3.46)$$

où  $\mathcal{N}_i$  représente l'ensemble des agents communiquant avec le  $i$ -ème véhicule (voisinage). Tous les agents (y compris la cible) sont modélisés comme un double intégrateur en 3D  $\dot{x}_i = v_i$ ,  $\dot{v}_i = u_i$ . L'accélération de la cible  $u_0$  est supposée connue (ou nulle en l'absence d'information) et chaque agent partage sa commande  $u_i$  avec ses voisins. La dynamique relative entre deux agents est telle que

$$\dot{x}_{ij} = v_{ij}, \quad \dot{v}_{ij} = u_{ij}, \quad \dot{d}_{ij} = \frac{v_{ij}^T x_{ij}}{d_{ij}} \quad (3.47)$$

et les mesures disponibles sont les distances et vitesses relatives :  $y_i = [d_{ij}^T, v_{ij}^T]^T$ . Le schéma distribué d'estimation des positions et vitesses relatives est présenté en Figure 3.31. L'observateur non-linéaire « local » suivant a tout d'abord été défini afin de reconstruire et filtrer les positions et vitesses relatives des agents, la cible pouvant être mobile :

$$\begin{cases} \hat{x}_{ij} = \xi_i + \frac{d_{ij}^2}{2} K_{ij} \hat{v}_{ij} \\ \hat{v}_{ij} = u_{ij} - K_{vi}(\hat{x}, \hat{v}, v, r) (\hat{v}_{ij} - v_{ij}) \\ \dot{\xi}_i = -\frac{K_{ij} d_{ij}^2}{2} (u_i - K_{vi}(\hat{x}, \hat{v}, v, r) (\hat{v}_{ij} - v_{ij})) - K_{ij} \hat{v}_{ij} \hat{v}_{ij}^T \hat{x}_{ij} + \hat{v}_{ij} \\ \dot{r} = -c_1 (r - 1) + c_2 K_{ij}^2 \|v_{ij}\|^2 \|\hat{v}_{ij} - v_{ij}\|^2 \end{cases} \quad (3.48)$$

où le gain  $K_{ij}$  est constant (et le seul nécessaire si la cible est statique), et le gain  $K_{vi}$  dépend de la valeur courante des vitesses et positions relatives, ainsi que d'une variable intermédiaire  $r$ . Il a été démontré que cet observateur est exponentiellement globalement stable au sens de Lyapunov, sous condition de persistance d'excitation des

vitesse relative  $v_{ij}$ , en s'appuyant sur les résultats théoriques précédemment établis dans [217,218]. Un deuxième étage de fusion est ensuite ajouté en définissant la position relative de chaque agent par rapport à la cible, nécessaire pour la commande en formation :  $\hat{x}_{i0}^j = \rho_j - \hat{x}_{ij}$  avec  $\rho_0 = 0$ . L'objectif est d'estimer cette dernière par consensus en ajoutant les deux états suivants à l'observateur (3.48) :

$$\begin{cases} \dot{\rho}_i = \hat{v}_{i0} + \lambda_0 \sum_{j \in \mathcal{N}_i} (\hat{x}_{i0}^j - \rho_i) \\ \hat{v}_{i0} = \hat{v}_{ij} + \sum_{k \in \mathcal{M}_j, l \in \mathcal{N}_0} \hat{v}_{kl} + \hat{v}_{l0} \end{cases} \quad (3.49)$$

où  $\mathcal{M}_j$  définit un chemin dans le graphe entre la cible et l'agent  $j$  considéré. La mesure de la vitesse propre de l'agent  $i$  est ici également nécessaire. Ce schéma permet de propager l'information sur la cible obtenue par un nombre réduit d'agents au reste de la flotte. La loi de commande distribuée suivante, identique pour chaque agent, permet de réaliser le tracking de la cible en formation :  $u_i = u_0 - k_v (v_i - \hat{v}_{i0}) - k_x \left( \sum_{j \in \mathcal{N}_i} l_{ij} \hat{x}_{ij} + \sum_{k \in \mathcal{N}_0} b_k \rho_k \right)$ . Elle est similaire à celle précédemment définie dans [219]. Un terme de répulsion inter-agents a également été ajouté tel que défini en (3.43) dans les travaux d'Arthur Kahn. Les résultats de simulation associés à l'ensemble de la boucle d'estimation et commande relative sont présentés en Figure (3.32).

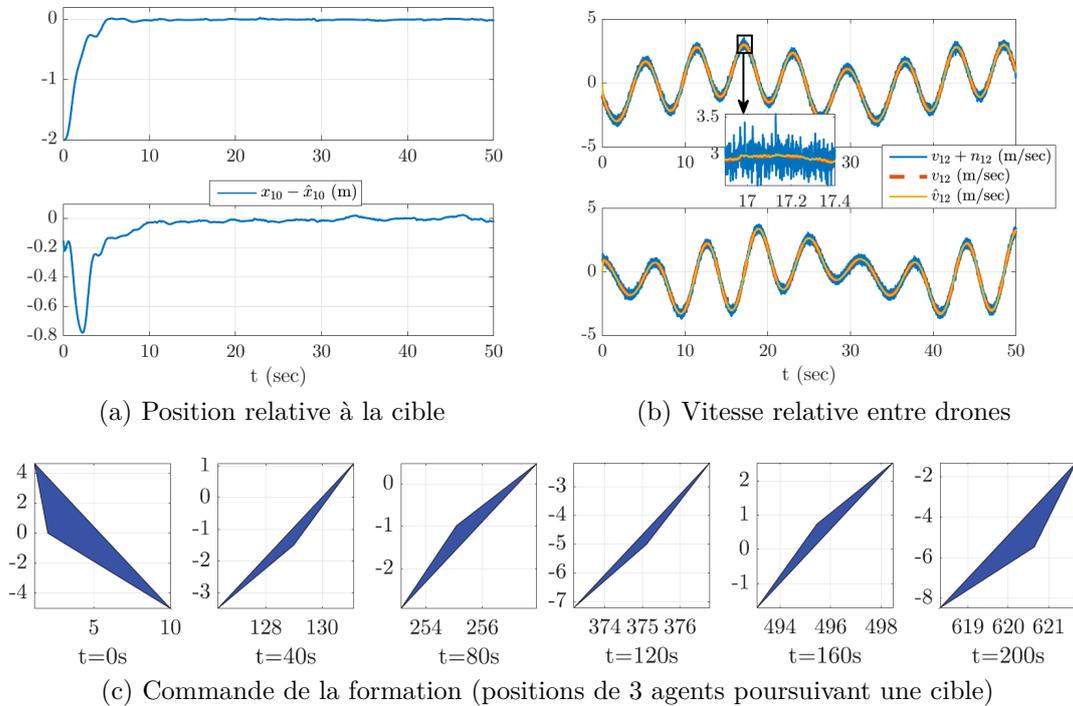


FIGURE 3.32 – Estimation et commande distribuée : résultats de simulation

### 3.3.5 Projet EDA EuroSWARM

Nous avons contribué au **projet pilote EuroSWARM financé par l'Agence Européenne de Défense (EDA) de novembre 2016 à février 2018**, portant sur la définition et l'évaluation en simulation d'algorithmes distribués d'estimation et de commande pour le déploiement d'une flotte hétérogène de capteurs (statiques et mobiles) à des fins de surveillance de zone (Figure (3.33a)). Le consortium était composé de l'Université de Cranfield, le FOI (équivalent suédois de l'ONERA), l'Université de Patras et donc l'ONERA DTIS. Nos contributions ont principalement porté sur le placement optimal de capteurs (hors scope de ce manuscrit), le diagnostic de défauts dans la flotte de capteurs et le guidage des agents mobiles reconfigurable en fonction du statut des capteurs fixes.

La plupart des techniques utilisées pour la détection et la localisation de défauts dans les réseaux de capteurs se basent sur des hypothèses statistiques et la comparaison des données entre nœuds voisins, ce qui peut être aisément décentralisé [220–222]. Dans le cadre de ces travaux, après une large revue de l'état de l'art, nous avons étudié les performances d'une méthode décentralisée permettant d'identifier les nœuds fournissant des mesures incohérentes, dans le cadre d'une application de détection d'intrusion [24]. Nous avons également étudié la complémentarité entre une flotte de capteurs mobiles et le réseau statique afin d'améliorer la détection de défauts et la couverture de la zone. Ces sujets sont encore ouverts dans la littérature de référence (quelques références associées sont [223–225]).

Les simulations réalisées ont considéré des capteurs omnidirectionnels (représentatifs de capteurs sismiques ou de magnétomètres), avec un simple modèle de détection binaire (à l'image de [226]) indiquant la présence ou non d'un intrus dans le champ du capteur. Le modèle d'intrusion considéré est une marche aléatoire. Un scénario d'intérêt correspond à un ensemble de fausses mesures d'intrusion, en absence ou en présence d'intrusion réelle. Cette distinction entre défaut de capteur et intrusion réelle est donc assez difficile à effectuer dans ce cadre [227], et il faut donc que le réseau soit assez recouvrant afin de pouvoir corrélérer les mesures entre voisins. Le placement des capteurs a été réalisé aléatoirement par Latin Hypercube Sampling (LHS [228]) et 1000 simulations de Monte-Carlo ont été réalisées pour chaque cas étudié (variation du pourcentage de capteurs défaillants entre 0 et 50%, notamment). La méthode testée est celle décrite dans [229], qui réalise itérativement et de manière décentralisée une catégorisation des nœuds du réseau avec consensus.

L'algorithme de détection de défaillances est le suivant :

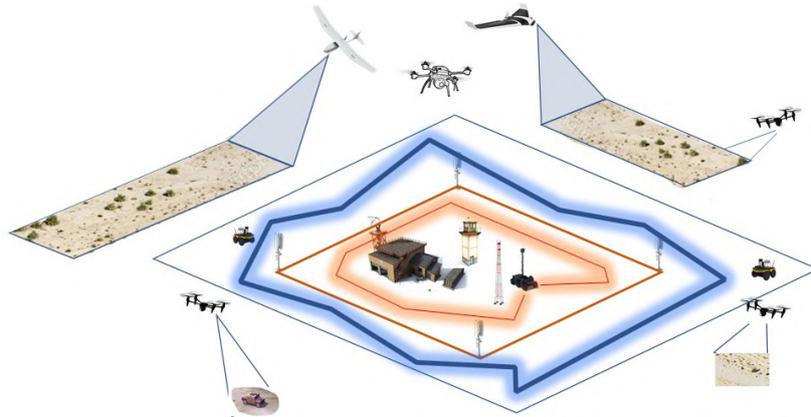
**Pour** chaque nœud  $i$ , afin de déterminer son statut  $F_i$  (0 : sain, 1 : défaillant, 2 : indéterminé) **faire**

1. **Créer** la table des voisins ( $NT$ ) et **initialiser**  $F_i \leftarrow 2$  (indéterminé)
2. **Récupérer** les mesures des voisins de  $i$  et **déterminer**  $k_i$  le nombre de voisins avec mesures cohérentes (identiques dans le cas binaire)
3. **Si**  $k_i > \theta_i$  **alors**  $F_i \leftarrow 0$

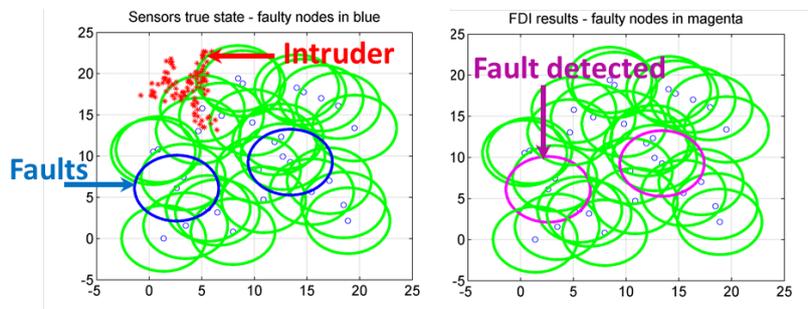
4. **Répéter**  $l$  fois pour les nœuds indéterminés :  
**Si** un des voisins en cohérence est déterminé comme sain, **alors**  $F_i \leftarrow 0$
5. Les nœuds restants sont considérés comme défaillants ( $F_i \leftarrow 1$ )
6. **Mettre à jour**  $NT$  (retirer les nœuds défaillants) et le seuil  $\theta_i$  pour l'instant suivant

Il est recommandé de choisir  $\theta_i = \max\left(\delta, \frac{d_i}{2}\right)$  avec  $d_i$  le nombre de voisins du nœud  $i$  et  $\delta$  le nombre minimal de voisins nécessaires pour prendre une décision (2, par exemple). Cette procédure s'applique également en considérant une fenêtre temporelle de mesures. Un exemple de bonne détection est présenté en Figure 3.33b. Un des résultats de l'étude a été de mettre en évidence la nécessité d'un degré moyen du graphe supérieur ou égal à 7 afin de pouvoir distinguer un défaut d'une intrusion réelle. Nous avons également mis en évidence que cette contrainte peut être significativement relâchée en considérant l'interaction entre ce réseau de capteurs et une flotte mobile couvrant le même espace dynamiquement et contribuant à l'algorithme précédent avec ses propres mesures (un degré 3 devient alors suffisant, cf Figure 3.33c).

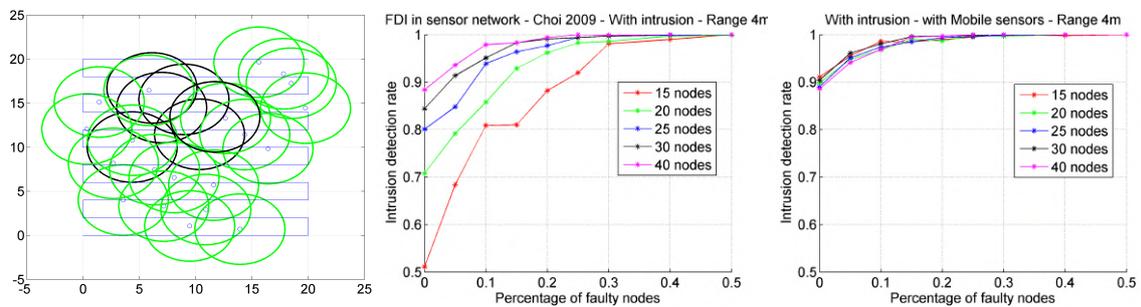
De manière complémentaire, nous avons proposé une loi de commande prédictive décentralisée (sur la base des travaux précédents [13, 43] décrits en Section 3.3.1 avec le modèle de capteur en Figure 3.20). Chaque véhicule dispose d'un point à rallier qui lui est propre, et sa commande est calculée à chaque instant afin de s'en rapprocher tout en évitant les collisions avec les autres véhicules (qui partagent leur trajectoire prédite sur l'horizon de prédiction) et en couvrant une zone au sol complémentaire d'une part de celle couverte par les agents mobiles mais également de celle des capteurs statiques afin de maximiser la zone couverte au cours du temps dans le cadre de cette mission de surveillance. Lorsque un ou plusieurs capteurs statiques se signale défaillant, une reconfiguration de la loi de guidage est réalisée en ligne afin de ne plus tenir compte de la zone couverte précédemment par les capteurs statiques et donc assurer tout de même une couverture globale. Des exemples de simulation dans le cas nominal et avec capteurs statiques défaillants (indiqués en rouge) sont présentés en Figure 3.33d.



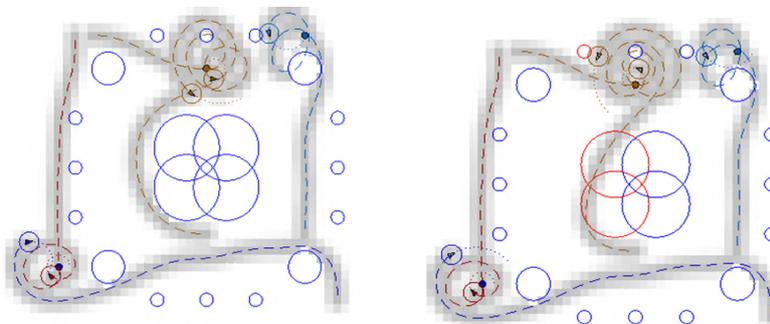
(a) Scénario de surveillance multi-robots



(b) FDI dans le réseau de capteurs statiques



(c) Amélioration FDI avec interaction réseau / flotte



(d) Guidage coopératif en lien avec le réseau de capteurs  
(nominal à gauche, avec reconfiguration à droite)

# Chapitre 4

## Méthodes d'optimisation et d'estimation à base de krigeage

---

**Résumé** – Ce chapitre présente le développement d'algorithmes d'optimisation et d'estimation pour des fonctions coûteuses uniquement évaluées en simulation et approximées par un méta-modèle de krigeage. Les méthodes d'optimisation globale étudiées ont considéré d'une part la robustesse au sens du minimax, et d'autre part la gestion de contraintes également coûteuses à évaluer. Cette modélisation stochastique a par ailleurs été exploitée pour définir des algorithmes efficaces d'estimation de probabilité d'évènements rares, et de filtrage pour la reconstruction des dérivées successives d'un signal.

---

Dans l'ensemble de ce chapitre, on considère une fonction scalaire  $f$  évaluée via une simulation numérique sur un ensemble compact  $\mathbb{X}_c$  de dimension  $d_c$ . Cette fonction n'est pas nécessairement différentiable, et n'est *a priori* connue que par les valeurs prises en un nombre fini de points échantillonnés. Un *méta-modèle*, modèle de substitution, ou encore surface de réponse, est une approximation de la fonction initiale qui peut être évaluée avec un faible coût de calcul. Parmi les nombreux méta-modèles existants (polynômes, splines, réseaux de neurones), le *krigeage* [230] permet de construire un modèle d'interpolation avec une indication sur la fiabilité de sa prédiction, ce qui peut être exploité pour construire des méthodes d'optimisation globale – y compris robustes et sous contraintes – de la fonction coûteuse initiale, ainsi que des techniques d'estimation. Le point de départ consiste à évaluer  $f(\cdot)$  en  $m_c$  valeurs préalablement choisies  $\mathbf{f}_{m_c} = [f(\mathbf{x}_{c,1}), \dots, f(\mathbf{x}_{c,m_c})]^T$ , on note par ailleurs  $\mathcal{X}_{m_c}^c = [\mathbf{x}_{c,1}, \dots, \mathbf{x}_{c,m_c}]$ . La fonction inconnue  $f(\cdot)$  est modélisée par un processus gaussien, qui peut être considéré comme la généralisation de distributions gaussiennes à un espace de fonctions de dimension infinie. Ainsi, de même qu'une distribution gaussienne est complètement définie par sa moyenne et sa matrice de covariance, un processus gaussien est caractérisé par ses *fonctions* de

moyenne et de covariance [231]. Dans ce qui suit, la fonction  $f$  est approchée par

$$F(\mathbf{x}_c) = \mathbf{p}^T(\mathbf{x}_c)\mathbf{b} + Z(\mathbf{x}_c) \quad (4.1)$$

Ce modèle est composé de deux parties, tout d'abord une fonction moyenne du processus

$$m_F(\mathbf{x}_c) = \mathbf{p}^T(\mathbf{x}_c)\mathbf{b} \quad (4.2)$$

où  $\mathbf{p}(\mathbf{x}_c)$  est un vecteur de régresseurs (des monômes en  $\mathbf{x}_c$ , par exemple) et  $\mathbf{b}$  est un vecteur de paramètres de régression à estimer sur les données. La deuxième composante  $Z(\mathbf{x}_c)$  est un processus gaussien de moyenne nulle et de fonction de covariance  $\text{cov}(\cdot, \cdot)$ . Cette fonction, généralement inconnue, est exprimée comme

$$\text{cov}(Z(\mathbf{x}_{c,i}), Z(\mathbf{x}_{c,j})) = \sigma_Z^2 \cdot k(\mathbf{x}_{c,i}, \mathbf{x}_{c,j}), \quad (4.3)$$

où  $\sigma_Z^2$  est la variance du processus et  $k(\cdot, \cdot)$  une fonction de corrélation paramétrée. Les paramètres de  $k(\cdot, \cdot)$  et la variance  $\sigma_Z^2$  peuvent être choisis *a priori* ou estimés à partir des données disponibles. Nous faisons le choix classique [232] de la fonction de corrélation exponentielle

$$k(\mathbf{x}_{c,i}, \mathbf{x}_{c,j}) = \exp\left(-\sum_{l=1}^{d_c} \left| \frac{\mathbf{x}_{c,i}(l) - \mathbf{x}_{c,j}(l)}{\theta_l} \right|^p\right), \quad (4.4)$$

où  $\mathbf{x}_{c,i}(l)$  représente la  $l$ -ème composante de  $\mathbf{x}_{c,i}$ . On peut remarquer que  $k(\mathbf{x}_{c,i}, \mathbf{x}_{c,j}) \rightarrow 1$  lorsque  $\|\mathbf{x}_{c,i} - \mathbf{x}_{c,j}\| \rightarrow 0$ , tandis que  $k(\mathbf{x}_{c,i}, \mathbf{x}_{c,j}) \rightarrow 0$  lorsque  $\|\mathbf{x}_{c,i} - \mathbf{x}_{c,j}\| \rightarrow \infty$ . Les paramètres  $\theta_l > 0$  quantifient la manière dont l'influence d'un point sur un autre diminue lorsque la distance qui les sépare augmente. Pour assurer la régularité de la fonction d'approximation, le paramètre  $p$  est généralement fixé à la valeur 2 par défaut (il peut également être estimé sur les données initiales). Le prédicteur (interpolateur) par krigeage de  $f(\mathbf{x}_c)$  est la prédiction linéaire non biaisée qui minimise la variance de l'erreur de prédiction<sup>1</sup>. La *moyenne du processus* en tout point  $\mathbf{x}_c \in \mathbb{X}_c$  est donnée par

$$\hat{f}(\mathbf{x}_c) = \mathbf{p}^T(\mathbf{x}_c)\hat{\mathbf{b}} + \mathbf{k}(\mathbf{x}_c)^T \mathbf{K}^{-1}(\mathbf{f}_{m_c} - \mathbf{P}\hat{\mathbf{b}}), \quad (4.5)$$

où  $\mathbf{K}$  est la matrice de dimension  $m_c \times m_c$  dont les composantes sont les corrélations du processus gaussien entre les points échantillonnés

$$\mathbf{K}_{i,j} = k(\mathbf{x}_{c,i}, \mathbf{x}_{c,j}), \quad (4.6)$$

$\mathbf{k}(\mathbf{x}_c)$  est le vecteur de dimension  $m_c$  des corrélations du processus gaussien entre les points préalablement échantillonnés et le point où la prédiction est calculée :

$$\mathbf{k}(\mathbf{x}_c) = [k(\mathbf{x}_{c,1}, \mathbf{x}_c), \dots, k(\mathbf{x}_{c,m_c}, \mathbf{x}_c)]^T, \quad (4.7)$$

---

1. *BLUP – best linear unbiased predictor*

$\mathbf{P}$  est la matrice de dimension  $m_c \times \dim \mathbf{b}$  dont les composantes sont les fonctions de régression évaluées aux points échantillonnés :

$$\mathbf{P} = [\mathbf{p}(\mathbf{x}_{c,1}), \dots, \mathbf{p}(\mathbf{x}_{c,m_c})]^\top, \quad (4.8)$$

et  $\hat{\mathbf{b}}$  est l'estimée au sens du maximum de vraisemblance du vecteur des coefficients de régression  $\mathbf{b}$  à partir des données disponibles  $\{\mathcal{X}_{m_c}^c; \mathbf{f}_{m_c}\}$ ,

$$\hat{\mathbf{b}} = (\mathbf{P}^\top \mathbf{K}^{-1} \mathbf{P})^{-1} \mathbf{P}^\top \mathbf{K}^{-1} \mathbf{f}_{m_c}. \quad (4.9)$$

L'estimée au sens du maximum de vraisemblance de la variance du processus  $\sigma_Z^2$  est

$$\hat{\sigma}_Z^2 = \frac{1}{m_c} (\mathbf{f}_{m_c} - \mathbf{P}\hat{\mathbf{b}})^\top \mathbf{K}^{-1} (\mathbf{f}_{m_c} - \mathbf{P}\hat{\mathbf{b}}). \quad (4.10)$$

Une estimée de la *variance de l'erreur de prédiction* peut être calculée comme

$$\hat{\sigma}^2(\mathbf{x}_c) = \sigma_Z^2 \left(1 - \mathbf{k}(\mathbf{x}_c)^\top \mathbf{K}^{-1} \mathbf{k}(\mathbf{x}_c)\right), \quad (4.11)$$

ce qui permet d'évaluer la précision de l'approximation par krigeage (4.5) en  $\mathbf{x}_c$ . Sa valeur est faible à proximité des points échantillonnés (nulle en leur emplacement exact) et plus importante loin de ceux-ci. Ceci est illustré en figure 4.1, où la fonction  $f(x_c) = \sin(x_c)/x_c$  est approchée par krigeage sur  $\mathbb{X}_c = [0; 10]$ . Les intervalles de confiance à 95% sont calculés à partir de l'équation (4.11).

## 4.1 Algorithmes d'optimisation

### 4.1.1 Optimisation robuste au sens du minimax

A partir de cette modélisation stochastique, une méthode bayésienne itérative connue sous le nom de *Efficient Global Optimization (EGO)* est très employée dans la littérature pour la recherche d'optimum global à partir d'un nombre restreint d'évaluations. A partir de cet existant, un nouvel algorithme combinant krigeage et relaxation a été proposé dans [9, 17, 46], afin de traiter l'optimisation robuste au sens du minimax de fonctions qui ne peuvent être évaluées que par des simulations numériques coûteuses. La formulation du problème suppose que les données d'entrée du code de simulation sont de deux types : les variables de conception qu'il s'agit de régler au mieux, et les variables environnementales contre l'effet desquelles il convient de se prémunir. Un certain nombre de travaux ont considéré l'optimisation robuste d'une simulation boîte noire à partir d'un méta-modèle de krigeage. Dans [233], des simulations de Monte-Carlo sont réalisées pour un ensemble de valeurs échantillonnées des variables de conception. Un modèle de krigeage est alors déterminé à partir de ces résultats, sur lequel l'optimisation est réalisée à l'aide d'algo-

rithmes classiques. L'approche proposée dans [234] étend le critère EI afin de prendre en compte la distribution de probabilité sur les variables environnementales. L'idée de base consiste à minimiser la moyenne pondérée de la performance pour un ensemble discret de variables environnementales. Néanmoins, un réglage optimal en moyenne peut donner de mauvaises performances pour des valeurs particulières des variables environnementales. Nous avons donc adopté le point de vue déterministe qui suppose que les variables environnementales appartiennent à un ensemble compact et la performance peut alors être évaluée en considérant le pire cas d'une mesure de robustesse. L'optimisation au sens du minimax est forcément conservatrice en moyenne, et le choix entre les deux paradigmes doit être fait en fonction des caractéristiques du problème considéré. Ces travaux ont été menés avec Hélène Piet-Lahanier (DTIS) et Eric Walter (L2S CentraleSupélec), dans la continuité de ma thèse. On rappelle tout d'abord l'algorithme EGO [235] qui permet de traiter le problème d'optimisation globale continue

$$\hat{\mathbf{x}}_c = \arg \min_{\mathbf{x}_c \in \mathbb{X}_c} f(\mathbf{x}_c). \quad (4.12)$$

L'idée principale est d'utiliser l'approximation par krigeage pour trouver itérativement de nouveaux points où la simulation coûteuse doit être évaluée, afin de se rapprocher d'un minimiseur global. Un nouveau point est choisi en maximisant un critère  $J(\cdot)$  mesurant l'intérêt d'échantillonner en  $\mathbf{x}_c$ , étant donné les résultats  $\mathbf{f}_{m_c}$  précédemment obtenus en  $\mathcal{X}_{m_c}^c$  ainsi que la prédiction (4.5) et la mesure de confiance associée (4.11),

$$\mathbf{x}_{c,m_c+1} = \arg \max_{\mathbf{x}_c \in \mathbb{X}_c} J(\mathbf{x}_c, \mathcal{X}_{m_c}^c, \mathbf{f}_{m_c}, \hat{f}(\mathbf{x}_c), \hat{\sigma}(\mathbf{x}_c)). \quad (4.13)$$

Ce problème (4.13) est en fait beaucoup plus facile à résoudre que (4.12), car il ne fait pas intervenir la simulation coûteuse. La meilleure estimée disponible de la valeur optimale du coût parmi les données échantillonnées est donnée par le minimum empirique

$$f_{\min}^{m_c} = \min_{i=1,\dots,m_c} \{f(\mathbf{x}_{c,i})\}, \quad (4.14)$$

qui permet de définir, pour tout  $\mathbf{x}_c \in \mathbb{X}_c$ , l'amélioration pour la recherche du minimum comme  $\max\{0, f_{\min}^{m_c} - \hat{f}(\mathbf{x}_c)\}$ . Un choix judicieux pour  $J(\cdot)$  est la maximisation de l'espérance de l'amélioration (*EI - Expected Improvement*), qui s'exprime comme

$$\text{EI}(\mathbf{x}_c, f_{\min}^{m_c}, \hat{f}, \hat{\sigma}) = \hat{\sigma}(\mathbf{x}_c) [u\Phi(u) + \phi(u)], \quad (4.15)$$

contracté en  $\text{EI}(\mathbf{x}_c)$  dans la suite, où  $\Phi$  est la fonction de répartition et  $\phi$  la densité de probabilité de la loi normale centrée réduite  $\mathcal{N}(0, 1)$ , et où

$$u = \frac{f_{\min}^{m_c} - \hat{f}(\mathbf{x}_c)}{\hat{\sigma}(\mathbf{x}_c)}. \quad (4.16)$$

Pour plus de développements, on pourra se référer à [236, 237], ainsi qu'à [238] pour des éléments concernant la convergence de la procédure. La maximisation de EI réalise un compromis entre la recherche locale (numérateur de  $u$ ) et l'exploration de zones inconnues (où  $\hat{\sigma}$  est grand), ce qui fait d'EI un critère approprié pour l'optimisation globale. L'algorithme 4.1 résume le déroulement de la procédure EGO. L'échantillonnage initial de l'étape 2 peut correspondre par exemple à un hypercube latin (*Latin Hypercube Sampling* – LHS) ou tout autre plan d'échantillonnage couvrant l'espace des entrées [239]. A l'étape 7, la maximisation de (4.15) par un algorithme auxiliaire est requise afin de trouver un nouveau point où échantillonner la fonction boîte noire. Son évaluation n'implique que le méta-modèle de krigeage. L'algorithme d'optimisation DIRECT [176] est utilisé dans nos travaux. La procédure est itérée jusqu'à atteindre le seuil de précision  $\varepsilon_{\text{EI}}^c$  sur l'EI ou à épuiser le budget d'évaluations autorisées  $n_{\text{EI}}^c$ . Le déroulement d'EGO sur trois itérations est illustré en figure 4.1 pour la minimisation de la fonction  $f(x_c) = \sin(x_c)/x_c$ , considérée ici comme une boîte noire.

---

**Algorithme 4.1** Efficient Global Optimization (EGO)
 

---

- 1: **Entrées** :  $\mathbb{X}_c, f(\cdot), \varepsilon_{\text{EI}}^c, n_{\text{EI}}^c$
  - 2: Choisir un échantillonnage initial  $\mathcal{X}_{c,m_c} = \{\mathbf{x}_{c,1}, \dots, \mathbf{x}_{c,m_c}\}$  dans  $\mathbb{X}_c$
  - 3: Calculer  $\mathbf{f}_{c,m_c} = [f(\mathbf{x}_{c,1}), \dots, f(\mathbf{x}_{c,m_c})]^T$
  - 4: **tant que**  $\max_{\mathbf{x}_c \in \mathbb{X}_c} \text{EI}(\mathbf{x}_c) > \varepsilon_{\text{EI}}^c$  **et**  $m_c < m_c + n_{\text{EI}}^c$  **faire**
  - 5: Identifier le modèle de krigeage à partir des données  $\{\mathcal{X}_{m_c}^c; \mathbf{f}_{c,m_c}\}$
  - 6: Déterminer  $f_{\min}^{m_c} = \min_{i=1,\dots,m_c} \{f(\mathbf{x}_{c,i})\}$
  - 7: Déterminer  $\mathbf{x}_{c,m_c+1} = \arg \max_{\mathbf{x}_c \in \mathbb{X}_c} \{\text{EI}(\mathbf{x}_c)\}$
  - 8: Calculer  $f(\mathbf{x}_{c,m_c+1})$ , l'incorporer à  $\mathbf{f}_{c,m_c}$
  - 9: Incorporer  $\mathbf{x}_{c,m_c+1}$  à  $\mathcal{X}_{m_c}^c$
  - 10:  $m_c \leftarrow m_c + 1$
  - 11: **fin tant que**
  - 12: **Sortie** :  $f_{\min} = \min_{i=1,\dots,m_c} \{f(\mathbf{x}_{c,i})\}$
- 

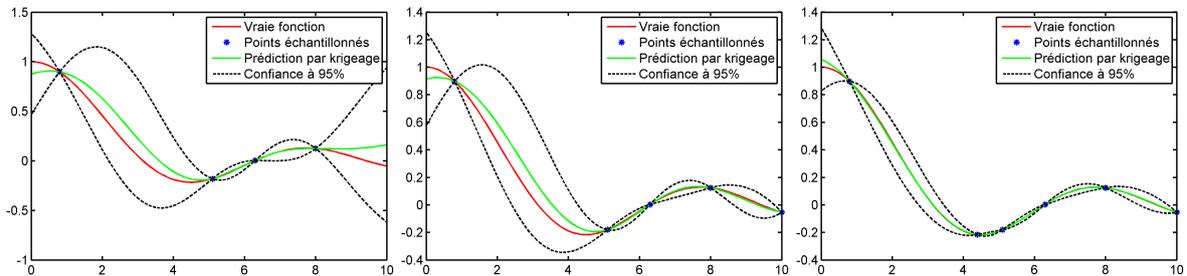


FIGURE 4.1 – Trois itérations d'EGO

**Algorithme 4.2** MiMaReK – **version 1** et **version 2**

Code couleur : commun aux deux versions ; **version 1** uniquement ; **version 2** uniquement.

**Etape 1**

Choisir  $\mathbf{x}_e^{(1)}$  dans  $\mathbb{X}_e$ . Initialiser  $\mathcal{R}_e = \{\mathbf{x}_e^{(1)}\}$ ,  $i \leftarrow 1$ .

**V1** : Choisir  $\mathcal{X}_0^c$  dans  $\mathbb{X}_c$  et  $\mathcal{X}_0^e$  in  $\mathbb{X}_e$ .

**V2** : Choisir un unique  $\mathcal{X}$  in  $\mathbb{X}_c \times \mathbb{X}_e$ .

**Tant que**  $e > \varepsilon_R$

**Etape 2**

**V1** :  $\mathbf{x}_c^{(i)} = \arg \min_{\mathbf{x}_c \in \mathbb{X}_c} \left\{ \max_{\mathbf{x}_e \in \mathcal{R}_e} f(\mathbf{x}_c, \mathbf{x}_e) \right\}$  avec EGO sur  $\mathcal{X}_0^c$   
et les valeurs précédentes de  $f$  pour  $\{\mathbf{x}_c \in \mathcal{X}_0^c, \mathbf{x}_e \in \mathcal{R}_e\}$

**V2** :  $\mathbf{x}_c^{(i)} = \arg \min_{\mathbf{x}_c \in \mathbb{X}_c} \left\{ \max_{\mathbf{x}_e \in \mathcal{R}_e} f(\mathbf{x}_c, \mathbf{x}_e) \right\}$  avec EGO et EI<sub>mm</sub> sur  $\mathcal{X}$

$e_{\text{prec}} = \max_{\mathbf{x}_e \in \mathcal{R}_e} J(\mathbf{x}_c^{(i)}, \mathbf{x}_e)$

**Etape 3** :  $\mathbf{x}_e^{(i+1)} = \arg \max_{\mathbf{x}_e \in \mathbb{X}_e} \left\{ f(\mathbf{x}_c^{(i)}, \mathbf{x}_e) \right\}$  avec EGO sur  $\mathcal{X}_0^e$  ou  $\mathcal{X}$ . L'ajouter à  $\mathcal{R}_e$ .

**Etape 4** : Compute  $e = f(\mathbf{x}_c^{(i)}, \mathbf{x}_e^{(i+1)}) - e_{\text{prec}}$ .  $i \leftarrow i + 1$

**Fin tant que**

---

Le vecteur des variables à optimiser étant toujours noté  $\mathbf{x}_c$ , on lui adjoint un vecteur de variables environnementales noté  $\mathbf{x}_e \in \mathbb{X}_e \subset \mathbb{R}^{d_e}$  tel que la fonction coût s'exprime maintenant comme  $f(\mathbf{x}_c, \mathbf{x}_e)$ . Il s'agit de résoudre le problème d'optimisation minimax pour trouver  $\hat{\mathbf{x}}_c$  et  $\hat{\mathbf{x}}_e$ , tels que

$$\{\hat{\mathbf{x}}_c, \hat{\mathbf{x}}_e\} = \arg \min_{\mathbf{x}_c \in \mathbb{X}_c} \max_{\mathbf{x}_e \in \mathbb{X}_e} f(\mathbf{x}_c, \mathbf{x}_e). \quad (4.17)$$

Ceci correspond à la recherche du vecteur  $\mathbf{x}_c$  donnant la meilleure performance, pour le cas le plus défavorable des variables perturbatrices  $\mathbf{x}_e$  sur  $\mathbb{X}_e$ . Bien que de nombreux travaux aient été consacrés à l'étude de la théorie de l'optimisation minimax, très peu d'algorithmes ont été proposés pour résoudre le problème (4.17), où  $f$  est continue sur les deux ensembles compacts  $\mathbb{X}_c$  et  $\mathbb{X}_e$  [240–242]. Les stratégies proposées dans ces références supposent l'existence d'une expression analytique de la fonction à optimiser, ainsi que la possibilité de calculer son gradient ou sous-gradient [243]. De ce fait, le problème qui nous occupe ne peut être résolu par ces algorithmes, étant donné que la valeur de la fonction n'est accessible que par simulation en certains points et que son gradient n'est pas calculable. Une première idée pourrait consister à trouver (avec EGO, par exemple) tout d'abord un minimiseur  $\hat{\mathbf{x}}_c$  de  $f$  sur  $\mathbb{X}_c$  pour une valeur fixée de  $\mathbf{x}_e \in \mathbb{X}_e$ , puis de maximiser  $f$  par rapport à  $\mathbf{x}_e$  sur  $\mathbb{X}_e$  pour cette valeur fixée  $\hat{\mathbf{x}}_c$ , et d'alterner ces étapes jusqu'à obtenir une solution stable. Toutefois la convergence de cet algorithme simpliste n'est pas garantie et il a tendance à osciller entre des valeurs non optimales de solutions candidates. Pour faire face à ces difficultés, Shimizu et Aiyoshi [244, 245] ont proposé de

transformer le problème initial (4.17) en introduisant le scalaire  $\tau$  tel que

$$\begin{cases} \min_{\mathbf{x}_c \in \mathbb{X}_c} \tau, \\ \text{sous la contrainte } f(\mathbf{x}_c, \mathbf{x}_e) \leq \tau, \forall \mathbf{x}_e \in \mathbb{X}_e \end{cases} \quad (4.18)$$

Ce nouveau problème d'optimisation est sujet à une infinité de contraintes et est donc toujours impossible à résoudre en l'état. Il est toutefois possible d'utiliser une procédure itérative pour obtenir une solution approchée, en relaxant le problème (4.18) avec le remplacement de la contrainte par  $f(\mathbf{x}_c, \mathbf{x}_e) \leq \tau, \forall \mathbf{x}_e \in \mathcal{R}_e$ , où  $\mathcal{R}_e$  est un ensemble *fini* contenant les valeurs de  $\mathbf{x}_e$  déjà explorées. Un seuil  $\varepsilon_R$  spécifie la précision désirée de la solution. Sous des hypothèses raisonnables, il a été prouvé que la boucle principale se termine en un nombre fini d'itérations [244]. Cet algorithme est générique et laisse libre le choix des procédures d'optimisation permettant de réaliser chacune des étapes de minimisation et maximisation dépendant d'un unique vecteur de variables (respectivement  $\mathbf{x}_c$  et  $\mathbf{x}_e$ ). Nous avons ainsi développé deux versions d'un algorithme (4.2) dénommé MiMaReK (*MiniMax optimization via Relaxation and Kriging*) combinant deux instances d'EGO au sein de cette procédure de relaxation. Dans la première version [17], deux échantillonnages initiaux  $\mathcal{X}_0^c$  sur  $\mathbb{X}_c$  et  $\mathcal{X}_0^e$  sur  $\mathbb{X}_e$  sont considérés. A l'étape 2, l'objectif est de trouver un minimiseur  $\mathbf{x}_c^{(i)}$  de la fonction  $\max_{\mathbf{x}_e \in \mathcal{R}_e} f(\mathbf{x}_c, \mathbf{x}_e)$ , où  $\mathcal{R}_e$  contient un nombre fini de valeurs préalablement explorées de  $\mathbf{x}_e$ . Ceci est réalisé en prenant, pour chaque point  $\mathbf{x}_c$  de l'échantillonnage  $\mathcal{X}_j^c$ , le minimum empirique de  $f(\mathbf{x}_c, \mathbf{x}_e)$  sur tous les éléments  $\mathbf{x}_e$  de  $\mathcal{R}_e$ . Ceci nécessite  $j \times i$  évaluations de  $f$  à chaque itération. Nous avons fait le choix de réutiliser le même échantillonnage  $\mathcal{X}_0^c$  à chaque itération de la relaxation afin de réduire le coût de calcul. Il faut également noter que la détermination du modèle de krigeage et la maximisation du critère EI associée ne dépendent ici que de  $\mathbf{x}_c$ , contrairement à  $f$  qui est fonction de  $\mathbf{x}_c$  et de  $\mathbf{x}_e$ . Ceci implique que les calculs nécessaires à l'établissement du méta-modèle sont effectués pour une dimension bien plus faible que si un échantillonnage avait été effectué sur  $\mathbb{X}_c \times \mathbb{X}_e$ . A l'étape 3, la fonction à maximiser est  $f(\mathbf{x}_c^{(i)}, \mathbf{x}_e)$  avec EGO où  $\mathbf{x}_c$  est fixé à  $\mathbf{x}_c^{(i)}$  qui est l'optimum obtenu à l'étape précédente. Le même échantillonnage initial  $\mathcal{X}_0^e$  sur  $\mathbb{X}_e$  est utilisé à chaque exécution de cette étape pour réduire la charge de calcul. Dans la deuxième version [9], un unique modèle de krigeage est évalué sur la base d'un ensemble  $\mathcal{X}$  de points échantillonnés itérativement sur l'ensemble couplé  $\mathbb{X}_c \times \mathbb{X}_e$ , afin d'exploiter l'intégralité de l'information recueillie au cours de la procédure. Ceci nécessite une modification de l'étape 2, où l'EI de la fonction  $\{\max_{\mathbf{x}_e \in \mathcal{R}_e} f(\mathbf{x}_c, \mathbf{x}_e)\}$  doit être calculé comme

$$\text{EI}_{\text{mm}}(\mathbf{x}_c) = \mathbb{E} \left[ \max_{i \in 1, \dots, m} \left( f_{\min} - f(\mathbf{x}_c, \mathbf{x}_e^{(i)}) \right)_+ \right] \quad (4.19)$$

où  $\mathcal{R}_e$  contient  $m$  éléments. Nous avons réalisé l'estimation de cette nouvelle fonction d'amélioration par Monte-Carlo, sa maximisation remplaçant celle de l'EI classique (4.15). L'étape 3 est peu modifiée, la maximisation de  $f(\mathbf{x}_c^{(i)}, \mathbf{x}_e)$  étant simple-

ment réalisée à partir de l'ensemble conjoint  $\mathcal{X}$ . La comparaison des deux versions permet d'établir que, pour des nombres équivalents d'échantillons initiaux  $n_c$  et  $n_e$  sur  $\mathbb{X}_c \times \mathbb{X}_e$ , la deuxième version nécessite moins d'évaluations de la fonction coûteuse si  $2(n_c + n_e) > N$ , où  $N$  est le nombre d'étapes de relaxation (boucle *tant que*). C'est très généralement le cas, le nombre initial d'échantillons étant usuellement choisi égal à 10 fois la dimension de l'espace. Les performances ont été évaluées numériquement sur un ensemble de fonctions tests également utilisées dans [246, 247], où des algorithmes évolutionnaires nécessitant  $10^5$  évaluations ont été proposés. Notre algorithme permet d'obtenir de bonnes performances avec bien moins d'appels à la fonction, et la deuxième version réduit d'environ 30% le nombre moyens d'évaluations par rapport à la première.

Tableau 4.1 – Comparaison entre les deux versions de MiMaReK (50 runs)

Evaluations	$f_1$	$f_2$	$f_3$	$f_4$	$f_5$	$f_6$
MiMaReK 1	<b>52</b> ± 1	<b>270</b> ± 68	<b>281</b> ± 72	<b>279</b> ± 89	<b>94</b> ± 4	<b>223</b> ± 89
MiMaReK 2	<b>33</b> ± 0	<b>150</b> ± 40	<b>224</b> ± 32	<b>225</b> ± 38	<b>55</b> ± 1	<b>143</b> ± 83

dim  $\mathbb{X}_c \times \mathbb{X}_e = 2$  pour  $f_1$  à  $f_4$  et dim  $\mathbb{X}_c \times \mathbb{X}_e = 4$  pour  $f_5, f_6$

### 4.1.2 Optimisation sous contraintes

On revient ici à la définition initiale du problème d'optimisation (4.12) sans considération de robustesse mais en y ajoutant un ensemble de  $m$  contraintes  $\mathbf{g}$ , celles-ci pouvant également être évaluées via une simulation numérique coûteuse (pas nécessairement la même que  $f$ ).

$$\begin{aligned} \hat{\mathbf{x}}_c &= \arg \min_{\mathbf{x}_c \in \mathbb{X}_c} f(\mathbf{x}_c), \\ s.t. \quad \mathbf{g}(\mathbf{x}_c) &\leq 0. \end{aligned} \tag{4.20}$$

Comme présenté précédemment, les méthodes à base de krigeage sont efficaces pour optimiser une fonction objectif boîte noire évaluée uniquement via une simulation coûteuse, à partir de critères reposant sur la prédiction et l'incertitude du méta-modèle. Dans le cadre du stage M2 de Cédric Durantin (co-encadré avec Mathieu Balesdent, ONERA DTIS), nous avons étudié l'extension de ces techniques pour traiter le problème sous contraintes (4.20). L'approche la plus usuelle consiste à construire des surfaces de réponse pour chaque contrainte et à utiliser cette information lors de l'optimisation du critère auxiliaire de recherche du prochain point à échantillonner. Trois techniques principales ont été définies dans la littérature. La première [248] consiste à sélectionner le prochain point via la maximisation de l'EI tel que défini en (4.15), multiplié par la probabilité de faisabilité des contraintes soit

$$\max_{\mathbf{x}_c \in \mathbb{X}_c} \text{EI}(\mathbf{x}_c) \times \text{PF}(\mathbf{x}_c) \text{ avec } \text{PF}(\mathbf{x}_c) = \prod_{i=1}^m \Phi \left( \frac{0 - \hat{g}_i(\mathbf{x}_c)}{\hat{\sigma}_{g_i}(\mathbf{x}_c)} \right) \tag{4.21}$$

où  $\hat{g}_i$  et  $\hat{\sigma}_{g_i}^2$  sont les fonctions moyenne et variance du modèle de krigeage de la  $i$ -ème contrainte. Une deuxième approche proposée dans [236] consiste à maximiser l'EI sous contrainte des fonctions moyennes tel que  $\max_{\mathbf{x}_c \in \mathbb{X}_c} EI(\mathbf{x}_c)$ , *s.t.*  $\hat{g}_i(\mathbf{x}) \leq 0$ ,  $i = 1, \dots, m$ .

Enfin, une troisième technique consiste à maximiser l'EI sous contrainte d'*Expected Violation* des contraintes [249], tel que  $\max_{\mathbf{x}_c \in \mathbb{X}_c} EI(\mathbf{x}_c)$ , *s.t.*  $EV_i(\mathbf{x}_c) \geq \varepsilon$ ,  $i = 1, \dots, m$  avec

$$EV_i(\mathbf{x}_c) = (0 - \hat{g}_i(\mathbf{x}_c)) \Phi \left( \frac{0 - \hat{g}_i(\mathbf{x}_c)}{\hat{\sigma}_{g_i}(\mathbf{x}_c)} \right) + \hat{\sigma}_{g_i}(\mathbf{x}_c) \phi \left( \frac{0 - \hat{g}_i(\mathbf{x}_c)}{\hat{\sigma}_{g_i}(\mathbf{x}_c)} \right) \quad (4.22)$$

Ces différentes méthodes ont été comparées sur un benchmark de fonctions analytiques usuelles [10], et la plus performante globalement apparait être l'utilisation de la probabilité de faisabilité (4.21), la méthode utilisant les contraintes krigées obtenant cependant de meilleurs résultats sur une partie des fonctions. Nous avons par la suite étudié l'application d'une optimisation bi-objectif entre le critère d'amélioration du coût et la faisabilité des contraintes, tel que proposé dans [250]. L'idée est de maximiser simultanément l'EI et la probabilité de faisabilité  $\max_{\mathbf{x}_c \in \mathbb{X}_c} \{EI(\mathbf{x}_c), PF(\mathbf{x}_c)\}$ , puis de choisir sur le front de Pareto obtenu (solutions non dominées) le meilleur point via le critère (4.21). Un exemple de résultat sur l'une des fonctions du benchmark analytique est présenté en Figure 4.2. Nous avons alors proposé une extension tri-objectif avec comme objectif supplémentaire la maximisation de l'incertitude sur les contraintes  $\sum_{i=1}^m \hat{\sigma}_{g_i}(\mathbf{x}_c)$ , afin d'améliorer la connaissance de celles-ci. On observe une amélioration de la précision sans dégradation de convergence ou coût d'évaluation (extrait de résultat en Figure 4.3). Un problème simplifié de conception d'un lanceur bi-étage à propulsion solide (4 variables de conception, 3 contraintes) a été traité avec succès par les méthodes multi-objectif proposées.

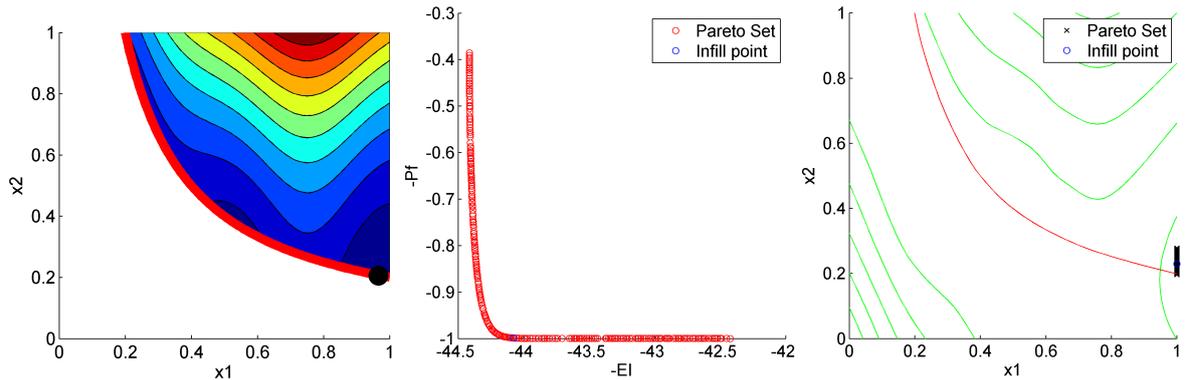


FIGURE 4.2 – Exemple de front de Pareto obtenu pour la méthode bi-objectif pour l'optimisation sous contraintes (fonction test *Branin1* à gauche)

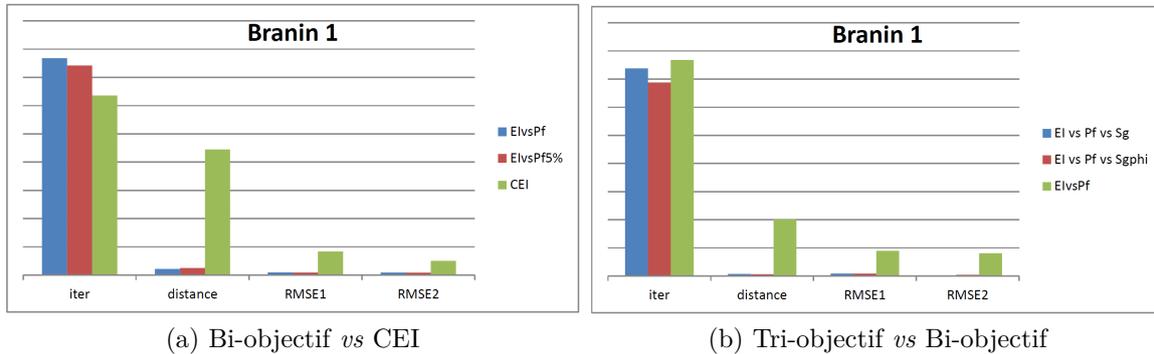


FIGURE 4.3 – Extrait de comparaison de performances entre les différentes approches d'optimisation sous contraintes (mono, bi- et tri-objectif)

## 4.2 Estimation à base de krigeage

### 4.2.1 Applications en réglage automatique et conception

La première application cible des méthodes d'optimisation décrites dans la partie précédente est le réglage automatique des paramètres internes (ou hyper-paramètres) d'algorithmes d'estimation ou de commande. Ceci permet une comparaison plus objective entre les méthodes en évaluant la meilleure performance de chacune sur les mêmes cas de tests, et cela fournit à l'utilisateur des plages de paramètres les plus à même de donner des résultats satisfaisants. Le réglage est donc vu comme un problème d'optimisation globale, la fonction à optimiser étant calculée via une simulation numérique potentiellement coûteuse. Le critère de performance est par exemple en diagnostic un compromis entre le taux de fausse alarme et le taux de non détection. La démarche proposée ici a consisté à substituer à la simulation numérique un modèle de krigeage admettant comme entrées les hyper-paramètres et fournissant en sortie le critère de performance, puis d'utiliser les algorithmes d'optimisation développés pour obtenir une solution en peu d'évaluations. Ceci a été appliqué à la comparaison d'algorithmes de détection de changement dans un signal [54], au réglage minimax par rapport aux incertitudes d'observateurs de diagnostic (cf Chapitre 2) pour des applications aéronautiques [5, 51, 52] ou un modèle de satellite [47]. Dans le cas du satellite, on cherche les réglages d'observateurs et de tests de décision les plus robustes par rapport aux variations de taille de défaut, bruit de mesure et incertitudes de modèles (Figure 4.4a). La simulation étant particulièrement lourde et les espaces de recherches continus, un résultat a pu être obtenu en quelques centaines d'appels, avec comme critère de performance le compromis entre fausses alarmes et non détections sur une trajectoire de référence. L'approche à base de krigeage a également été exploitée pour fournir un ensemble d'hyper-paramètres optimaux pour deux méthodes d'estimation de probabilité d'évènements rares, réputées délicates à appréhender pour les non-spécialistes [12, 15] qui disposent ainsi de lignes directrices de réglage sur un

ensemble représentatif de problèmes tests. Par ailleurs, l'algorithme proposé dans [53] comprend un raffinement itératif du méta-modèle par échantillonnage à l'emplacement de variance maximale, intégré dans un système d'apprentissage par renforcement pour le calcul d'une future pose optimale afin de reconnaître un objet en un minimum d'observations. Dans [48], une solution optimale à un problème de commande prédictive pour le guidage d'un robot mobile a été obtenu en temps réel grâce à EGO.

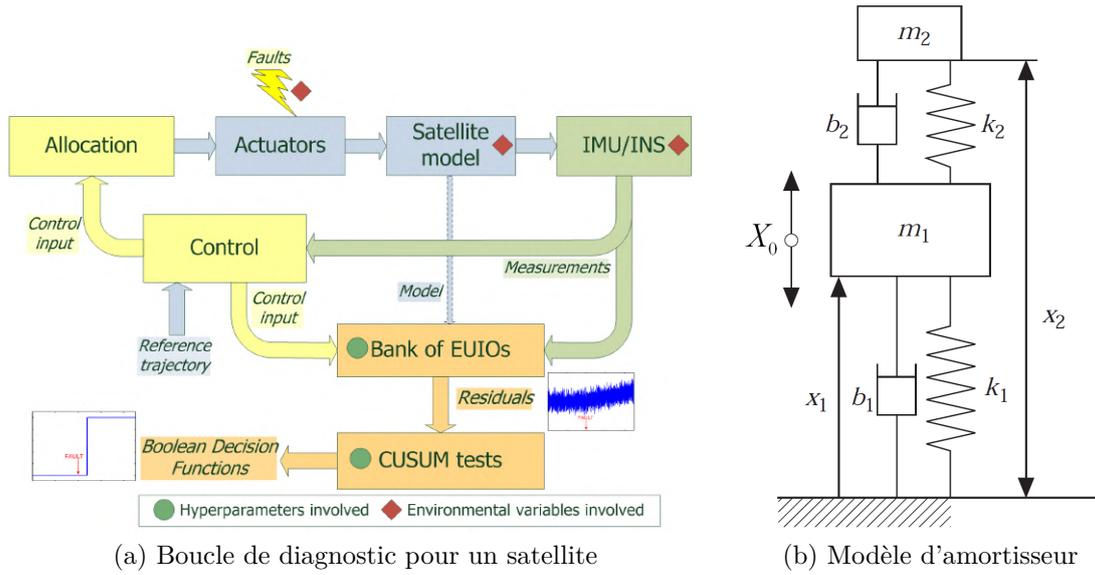


FIGURE 4.4 – Application au réglage robuste d'algorithmes et à la conception

L'algorithme MiMaReK a par ailleurs été appliqué à un cas usuel de conception mécanique robuste aux incertitudes pour un amortisseur [9, 66]. L'objectif est de minimiser le déplacement maximal de la masse  $m_1$ , tel que  $J = (k_1 X_1) X_0^{-1}$ , où  $X_0$  est une oscillation d'amplitude connue mais de fréquence inconnue  $\omega$ . Le problème se formule comme

$$\{\hat{\zeta}_2, \hat{T}, \hat{\beta}\} = \arg \min_{\zeta_2, T} \max_{\beta} J, \zeta_i = \frac{b_i}{2\sqrt{k_i m_i}}, \omega_i = \sqrt{\frac{k_i}{m_i}}, T = \frac{\omega_2}{\omega_1}, \beta = \frac{\omega}{\omega_1} \quad (4.23)$$

mais aucune solution analytique ne peut être déterminée. Il s'agit d'un cas test fréquemment étudié dans la littérature [251], les solutions numériques fournies nécessitant au minimum  $10^4$  évaluations avec un algorithme génétique pour obtenir un résultat suffisamment précis. Moins de 1000 évaluations ont été nécessaires à MiMaReK pour atteindre un résultat équivalent, ce qui confirme l'intérêt de la méthode pour ce type de problème de conception.

### 4.2.2 Estimation de probabilité d'évènement rare

En collaboration avec Mathieu Balesdent et Jérôme Morio [252], également chercheurs au DTIS, une méthode d'estimation de probabilité d'évènement rare s'appuyant sur un métamodèle de krigeage a été proposée dans [16]. La mise à jour du méta-modèle est spécifiquement étudiée pour rendre applicable les techniques d'échantillonnage préférentiel (*Importance Sampling*) à des codes de calcul coûteux. Le problème à résoudre consiste à estimer la probabilité  $P[f(\mathbf{x}) > S]$  où  $f : \mathbb{R}^d \rightarrow \mathbb{R}$  est une fonction entrée-sortie coûteuse,  $S$  un seuil d'intérêt et où le vecteur aléatoire  $\mathbf{x}$  suit une loi de probabilité de densité  $h_0$ .

Les méthodes d'estimation et d'intégration les plus couramment utilisées pour estimer des probabilités ou des quantiles, en particulier les simulations Monte-Carlo, n'aboutissent pas à des résultats suffisamment précis pour ces évènements rares (situés en queue de distribution). L'échantillonnage préférentiel est alors une technique couramment employée [253]. Cela consiste à utiliser une loi de tirage auxiliaire  $h$  des échantillons  $\mathbf{x}_i$  permettant de générer des évènements rares plus efficacement et estimer la probabilité comme

$$\hat{P}_{\text{IS}} = \frac{1}{N} \sum_{i=1}^N \mathbf{1}_{f(\mathbf{x}_i) > S} \frac{h_0(\mathbf{x}_i)}{h(\mathbf{x}_i)} \quad (4.24)$$

Il n'est possible de définir une loi auxiliaire optimale de tirage des échantillons que par le biais de la connaissance *a priori* de la probabilité à estimer. Cette loi peut néanmoins être approchée itérativement en optimisant les paramètres d'une famille donnée de lois. Une version non paramétrique et adaptative de l'échantillonnage préférentiel (méthode NAIS) basée sur l'optimisation itérative d'un estimateur à noyaux de densité  $h_k$  (gaussien par exemple) a également été proposée dans [254]. Cette version de l'algorithme permet d'estimer précisément la probabilité souhaitée mais au prix d'au moins  $10^4$  à  $10^6$  évaluations de la fonction  $f$ , ce qui n'est pas applicable dans le cas de simulations coûteuses – d'où la proposition d'introduire un modèle de krigeage. La stratégie retenue consiste à améliorer itérativement la connaissance de la fonction  $f$  autour de la zone de franchissement du seuil  $S$ . Soit  $\mathcal{Z} = [\mathbf{z}_1, \dots, \mathbf{z}_p]$  les vecteurs d'entrées échantillonnées et  $\mathbb{X}^k$  la population générée via la distribution auxiliaire  $h_k$  à l'étape  $k$ , on définit l'ensemble des points incertains comme

$$\tilde{\mathbb{X}}^k = \left\{ \mathbf{x}_i \in \mathbb{X}^k \mid \mathbb{E}(\hat{f}(\mathbf{x}_i, \mathcal{Z})) - k\hat{\sigma}(\mathbf{x}_i, \mathcal{Z}) < q_k < \mathbb{E}(\hat{f}(\mathbf{x}_i, \mathcal{Z})) + k\hat{\sigma}(\mathbf{x}_i, \mathcal{Z}) \right\} \quad (4.25)$$

où  $\hat{f}$  et  $\hat{\sigma}$  sont issues du modèle de krigeage à partir du design courant  $\mathcal{Z}$ ,  $k$  correspond à un niveau de confiance arbitraire (1.96 pour 95% par exemple), et  $q_k$  est la valeur du seuil courant (égal à  $S$  lorsque l'algorithme NAIS a convergé). Cet ensemble représente donc les échantillons potentiellement mal classés du fait de l'incertitude de l'approximation

par krigeage (Figure 4.5a). On choisit alors un prochain échantillon comme suit :

$$\mathbf{z}^* = \arg \max_{\mathbf{z} \in \mathbb{R}^d} \left\{ \sum_{i=1}^{\text{Card}(\tilde{\mathcal{X}}^k)} [\hat{\sigma}(\tilde{\mathbf{x}}_i, \mathcal{Z}) - \hat{\sigma}(\tilde{\mathbf{x}}_i, \mathcal{Z}, \mathbf{z})] \right\} \quad (4.26)$$

où  $\hat{\sigma}(\tilde{\mathbf{x}}_i, \mathcal{Z})$  est la fonction écart-type associé au modèle de krigeage courant et  $\hat{\sigma}(\tilde{\mathbf{x}}_i, \mathcal{Z}, \mathbf{z})$  l'écart-type attendu en ajoutant l'échantillon  $\mathbf{z}$  [231]. Cette procédure est donc appliquée récursivement jusqu'à ce que  $\tilde{\mathcal{X}}^k$  devienne l'ensemble vide. Un intervalle de confiance à 95% peut par ailleurs être obtenu pour la probabilité estimée.

Cette technique a été appliquée sur des cas-tests analytiques classiques, ainsi que sur l'analyse de la dispersion de la retombée du premier étage d'un lanceur au delà d'un seuil critique de distance (précédemment défini dans [252, 254]). Cela a permis de mettre en évidence la précision de la méthode, comparable à celle des techniques d'échantillonnage préférentiel sans méta-modèle, et la réduction du nombre d'évaluations jusqu'à un facteur 10 par rapport à celles-ci.

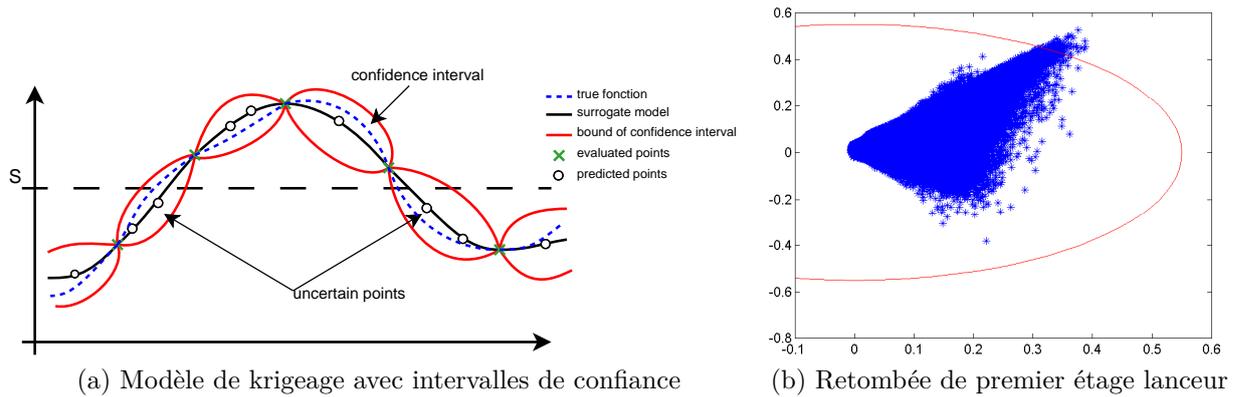


FIGURE 4.5 – Estimation de probabilité d'évènements rares assistée par krigeage

### 4.2.3 Estimateur de dérivées

Nous avons proposé, avec Hélène Piet-Lahanier (ONERA DTIS) et Eric Walter (L2S CentraleSupélec), une approche de filtrage pour l'estimation des dérivées successives d'un signal bruité à partir d'un modèle de krigeage [42], avec application à l'estimation d'une manœuvre cible par un missile intercepteur. Le résultat principal est une formulation comme un filtre FIR à coefficients constants, facilement implémentable. Les propriétés statistiques du krigeage permettent par ailleurs de définir des intervalles de confiance pour les dérivées successives.

On considère un signal temporel  $f(t)$  sur  $n$  instants  $\mathcal{T}_n = \{t_1, \dots, t_n\}$ , tel que  $\mathbf{f}_n = [f(t_1), \dots, f(t_n)]^T$ . Un modèle de krigeage tel que défini en début de chapitre est associé

à ces données, en considérant nul le modèle moyen (4.2), soit le prédicteur

$$\widehat{f}(t) = \boldsymbol{\lambda}^T(t) \mathbf{f}_n, \text{ avec } (\mathbf{K} + \sigma_N^2 \mathbf{I}_n) \boldsymbol{\lambda}(t) = \mathbf{k}(t) \quad (4.27)$$

où  $\sigma_N^2$  est la variance du bruit additif supposé gaussien de moyenne nulle qui s'applique sur le signal  $f$  [231], on note dans la suite  $\mathbf{K}_\sigma = \mathbf{K} + \sigma_N^2 \mathbf{I}_n$ .

Une estimée de la  $l$ -ème dérivée de  $f$  est alors

$$\begin{aligned} \widehat{f}^{(l)}(t) &= \boldsymbol{\lambda}_l^T(t) \mathbf{f}_n, \text{ avec } \mathbf{K}_\sigma \boldsymbol{\lambda}_l(t) = \mathbf{k}^{(l)}(t) \\ \mathbf{k}^{(l)}(t) &= [k^{(l)}(t - t_1), \dots, k^{(l)}(t - t_n)]^T \end{aligned} \quad (4.28)$$

sous hypothèse que la fonction de corrélation (4.4) est différentiable  $l$  fois (ce qui est le cas pour la corrélation exponentielle quadratique choisie, infiniment différentiable). D'après [255], l'intervalle de confiance associé pour la dérivée  $l$ -ème peut être calculé comme

$$\widehat{\sigma}_l^2(t) = \widehat{\sigma}_Z^2 \left( (-1)^l k^{(2l)}(0) - \boldsymbol{\lambda}_l^T(t) \mathbf{k}^{(l)}(t) \right). \quad (4.29)$$

On considère l'implémentation de ce filtre sur une fenêtre glissante de  $n$  points, on considère par ailleurs un pas d'échantillonnage constant  $t_s$ , ce qui permet de noter

$$\begin{aligned} \mathbf{t}_k &= [t_k - (n-1)t_s, \dots, t_k - t_s, t_k]^T \\ \mathbf{f}_k &= [f(t_k - (n-1)t_s), \dots, f(t_k - t_s), f(t_k)]^T \end{aligned} \quad (4.30)$$

L'estimée de la  $l$ -ème dérivée à l'instant  $t_k$  est alors donnée par

$$\widehat{f}^{(l)}(t_k) = \mathbf{h}_l^T \mathbf{f}_k, \text{ avec } \mathbf{K}_\sigma \mathbf{h}_l = \mathbf{r}_l \quad (4.31)$$

où  $\mathbf{k}_l$  et  $\mathbf{K}$  ne dépendent plus de l'instant  $t_k$  et s'écrivent comme

$$\begin{aligned} \mathbf{k}_l &= [k^{(l)}((n-1)t_s), \dots, k^{(l)}(t_s), k^{(l)}(0)]^T \\ \mathbf{K}_{|ij} &= k((i-j)t_s) \end{aligned} \quad (4.32)$$

On obtient ainsi un filtre à réponse impulsionnelle finie à appliquer sur une fenêtre glissante, permettant d'obtenir les dérivées successives du signal. De même, la variance associée est donnée par

$$\widehat{\sigma}_l^2(t_k) = \frac{1}{n} \left( \mathbf{f}_k^T \mathbf{K}_\sigma^{-1} \mathbf{f}_k \right) \left( (-1)^l k^{(2l)}(0) - \mathbf{h}_l^T \mathbf{k}_l \right) \quad (4.33)$$

Les paramètres de réglage sont la largeur de la fenêtre glissante  $n$ , le pas de temps, la variance du bruit, et  $\theta$  le facteur d'échelle de la fonction de corrélation – analogue à une bande passante. La méthode a été testée sur des fonctions analytiques usuelles et s'est montrée très performante : pas de délai d'estimation contrairement à l'approximation

polynomiale [256], vraie dérivée correctement encadrée dans l'intervalle de confiance.

Ce filtre a ensuite été appliqué à l'estimation de manœuvres d'une cible dans un contexte de duel terminal. Une modélisation simplifiée considère un missile intercepteur dont l'accélération  $a_m$  est instantanément réalisée face à une cible considérée non manœuvrante dans le cas nominal [257] (accélération  $a_t$  nulle, inconnue sinon). En considérant un engagement planaire et le système linéarisé (hypothèse d'angle faible de la ligne de vue  $\lambda$  entre les deux engins, cf Figure 2.4), on peut approcher la distance de passage finale par la position verticale relative  $y$  dont la dynamique est  $\ddot{y} = a_t - a_m$ . Une mesure bruitée  $y_{mes}$  peut être supposée accessible via un auto-directeur embarqué et la connaissance de la distance relative donnée par un moyen de mesure externe. La loi de navigation proportionnelle  $a_m = N v_c \dot{\lambda}$  (avec  $N$  un gain constant et  $v_c$  la vitesse de rapprochement) permet de maintenir la direction de la ligne de vue constante ce qui garantit l'interception en l'absence de manœuvre cible [258]. La loi dite augmentée  $a_m = N \left( v_c \dot{\lambda} + \frac{a_t}{2} \right)$  permet de compenser une manœuvre cible, mais nécessite l'estimation en ligne de son accélération  $a_t$ . Ceci est généralement réalisé via un filtre de Kalman faisant une hypothèse sur la manœuvre réalisée (évasive ou hélice) [259]. En remarquant que  $a_t = \ddot{y} + a_m$ , l'accélération de la cible est directement disponible si la dérivée seconde de la mesure bruitée  $y_{mes}$  peut être estimée en ligne sans retard. Nous avons donc appliqué la méthode à base de krigeage proposée aux cas de manœuvres évatives et hélicoïdales. Un exemple de résultat d'estimation est donné en Figure 4.6 avec les intervalles de confiance associés et en comparaison à la grandeur physique simulée. La performance de la méthode est comparable à celles de filtres de Kalman, mais sans nécessiter d'hypothèse sur le type de manœuvre. Il a été montré que la loi de navigation proportionnelle augmentée pouvait utiliser l'estimée fournie pour anticiper le mouvement de la cible et réaliser l'interception (Figure 4.6c).

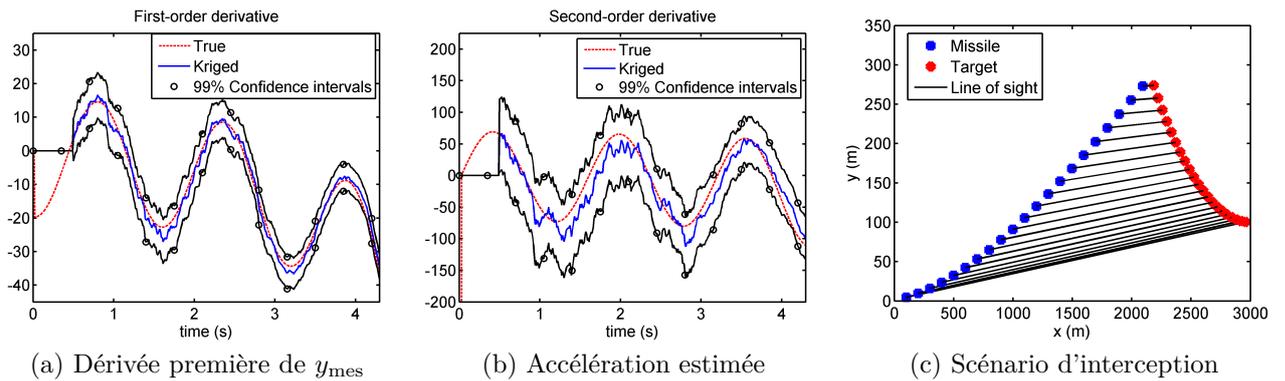


FIGURE 4.6 – Estimation de dérivées par krigeage dans le cas d'une manœuvre cible hélicoïdale à des fins d'interception

# Conclusions et Perspectives

## Diagnostic et pronostic à base de modèles dynamiques

### Contributions

Les développements réalisés en diagnostic à base de modèles ont principalement consisté à étudier l'applicabilité de techniques usuelles (observateurs à entrée inconnue, à modes glissants, tests statistiques) pour des systèmes aérospatiaux. Un partenariat a notamment été initié avec le CNES autour de la supervision des moteurs fusée à ergols liquides (thèse d'Alessandra Iannetti [105] soutenue en 2016, suivie de la thèse de Camille Sarotte [21,23] soutenue fin 2019). Ces travaux se caractérisent par un effort de modélisation important afin d'obtenir un modèle dynamique exploitable à des fins d'estimation en ligne, à partir de la connaissance des phénomènes physiques. Nous nous sommes ainsi appuyés sur le département multi-physique pour l'énergétique (DMPE) de l'ONERA, qui exploite le banc de test MASCOTTE [109] dont les données d'essai de campagnes de tirs passées ont servi de référence pour valider les résultats des thèses et montrer ainsi l'applicabilité des techniques à base de modèle. D'autres études en simulation ont porté sur la détection et l'estimation de défauts d'actionneurs à partir de modèles de dynamique du vol de systèmes aérospatiaux sur-actionnés (satellite notamment).

Le sujet émergent du pronostic à base de modèles dynamiques a été abordé via une première thèse soutenue en 2018 (Elinirina Robinson [128], co-encadrement CNAM). Les travaux ont porté sur le développement de méthodes de filtrage et de propagation d'incertitudes : des filtres particuliers associés à des tests statistiques ont été utilisés dans le cas d'hypothèses probabilistes, tandis qu'un nouvel observateur intervalle (sous hypothèses ensemblistes) a été développé pour les modèles linéaires à temps discret avec prise en compte d'entrées inconnues. Ces techniques ont été appliquées à la surveillance des structures métalliques ou composites, ce qui a nécessité à nouveau un travail de modélisation dynamique et validation sur données expérimentales, en collaboration avec le département Matériaux et Structure (DMAS) de l'ONERA.

---

## Perspectives

Le partenariat avec le CNES devrait prendre encore plus d'ampleur à l'avenir, en lien avec le développement de lanceurs réutilisables en Europe [260]. Ces systèmes nécessitent en effet une surveillance et un suivi du cycle de vie des sous-systèmes plus importants que précédemment, avec une intégration dans le cadre HUMS de méthodes de diagnostic et de commande pour les moteurs (à ergols liquides) ou l'avionique et des approches de surveillance et prédiction de l'état des structures (celles-ci étant instrumentées avec de multiples capteurs en réseau). Dans ce contexte, les sujets d'étude s'étendent également à la commande en boucle fermée des moteurs fusée (thèse de Sergio Perez Roca [60] démarrée en 2017 pour le compte du CNES et d'ArianeGroup, avec co-encadrement IRSEEM) au niveau du transitoire de démarrage et de la modulation de poussée induite par la phase de retour, avec de nombreuses incertitudes paramétriques. Au sein du banc de test expérimental MASCOTTE exploité à l'ONERA, sur lequel les techniques d'estimation ont été récemment testées, on pourra par ailleurs considérer la réalisation d'un prototype de régulation tolérante dans le cas de défauts de gravité mineure ne nécessitant pas à l'arrêt impératif du système.

Le pronostic à base de modèles est un sujet prometteur qui devrait ouvrir de nouvelles possibilités applicatives dans le domaine aérospatial, notamment en ce qui concerne la surveillance des éléments de motorisation et des matériaux. Sur la base des premiers travaux menés, de nouvelles méthodes d'estimation et de propagation d'incertitude reposant sur les concepts d'estimation ensembliste (intervalle, zonotope) pourront être développées pour les systèmes non linéaires à temps discret, avec la nécessité de découpler voire reconstruire une entrée inconnue lorsque les conditions de sollicitation du système sont mal connues. Un deuxième objectif pourra être d'établir une démarche de commande tolérante à la dégradation, celle-ci étant estimée et propagée via le module de pronostic. Il s'agirait notamment de garantir la réussite d'une mission donnée en tenant compte de la durée de vie résiduelle des composants et de l'impact rétroactif des sollicitations de la commande sur ces éléments (notamment dans le cadre de la navigation de véhicules aérospatiaux autonomes tels que les lanceurs ou les drones).

Enfin, de nouveaux types de systèmes étudiés à l'ONERA (robots terrestres et aériens, dirigeables) pourront bénéficier de ces approches à base de modèles et nécessiter des développements théoriques et applicatifs en fonction de leurs spécificités. La mise en œuvre d'une boucle HUMS (intégrant diagnostic, pronostic et maintenance) et son influence sur le cycle de vie des systèmes aérospatiaux sera également un sujet d'étude attendu.

## **Navigation autonome mono et multi-robots**

### **Contributions**

Ces travaux ont porté principalement sur la navigation autonome en milieu intérieur encombré à base de vision embarquée, avec extension à la commande de flottes de véhicules. Une activité de robotique expérimentale permet de valider ces approches, ce qui a donné lieu à de nombreuses démonstrations de capacités nouvelles de navigation autonome de robots terrestres et aériens dans le cadre de projets industriels (partenariat avec SNCF Réseau 2015-2019) et de recherche (Projet interne COPERNIC 2014-2017, FP7 EuRoC 2014-2017, EDA EuroSWARM 2017-2018).

Les premiers travaux ont porté sur l'utilisation d'un algorithme de commande prédictive pour l'exploration autonome d'une zone inconnue par un robot mobile, en interaction avec la localisation et la modélisation de l'environnement réalisées à partir de la stéréo-vision embarquée. Ceci a conduit aux travaux de la thèse d'Hélène Rogge-man [143] soutenue en 2017 sur la prédiction de la qualité de la localisation basée vision embarquée et sa prise en compte dans le guidage du robot pour de telles missions. De nombreux sujets portant sur le vol autonome de drones multi-rotors ont par ailleurs été traités et ont fait l'objet de démonstrations en conditions réelles (« hors du laboratoire ») avec l'ensemble de la boucle perception-action exécutée à bord en temps réel : le suivi de trajectoire en milieu intérieur avec détection et évitement d'obstacles statiques et mobiles, la télé-opération assistée à des fins d'inspection, l'exploration autonome d'un volume encombré par un mini-drone.

De nouvelles méthodes distribuées de guidage de flottes de robots ont été développées dans le cadre de travaux à plus bas TRL. Cela a notamment consisté en la mise en œuvre de schémas de commande prédictive distribuée pour le déplacement en flotte ou l'exploration collaborative de zone, ce qui a montré la possibilité d'étendre les travaux réalisés en mono-robot et l'adaptabilité de la technique à des objectifs variés. La thèse d'Arthur Kahn [200] soutenue en 2015 (collaboration L2S CentraleSupélec) a abordé la problématique de la localisation globale d'une source par une flotte de robots, ce qui combine à la fois un problème d'optimisation et une problématique de commande distribuée. Nous avons également proposé et validé expérimentalement un algorithme de localisation collaborative combinant les images de la même scène acquise par deux drones distincts et une loi de commande associée pour le maintien en formation. Enfin, un schéma distribué d'estimation et de guidage pour le suivi d'une cible mobile a été proposé lors du post-doctorat de Ioannis Sarras (2016-2017).

### **Perspectives**

Les travaux en commande de robots et drones sont en plein essor, que ce soit pour un unique véhicule autonome d'inspection en environnement complexe ou pour une flotte de véhicules afin de réaliser une mission d'exploration ou de suivi de cible(s) plus efficacement. Au cours des dernières années, nous avons participé activement à de nombreux projets et réalisé des démonstrations des capacités offertes par les algorithmes de com-

---

mande et d'estimation développés. Ceci va se poursuivre dans le contexte multi-véhicules, principalement en confrontant les algorithmes testés jusqu'ici en simulation à l'application réelle tout en tenant compte des contraintes de vision embarquée pour la localisation et la cartographie. L'objectif est de parvenir en quelques années à une démonstration de capacité complète d'une flotte d'exploration pour la cartographie d'un environnement inconnu et encombré, à des fins de reconnaissance, surveillance ou détection de changements. Ces travaux sont notamment soutenus par le projet interne GUIMAUVE (2017-2020) dont je suis responsable, associé à des projets industriels et étatiques sur la même thématique.

Les approches étudiées jusqu'à présent reposaient pour la plupart sur la commande prédictive avec un horizon fini et la discrétisation de l'espace de commande, les travaux futurs considéreront une approche plus globale intégrant une couche supérieure de planification de trajectoires qui tient compte des objectifs de la mission et des contraintes liées à la flotte et l'environnement. Ceci a été amorcé pour le cas de l'exploration autonome d'un volume par un mini-drone dans le projet FP7 EuRoC. Une thèse a ainsi débuté fin 2018 (Guillaume Hardouin, en collaboration avec le MIS Amiens) sur le développement de « scanners robotisés » pour la numérisation automatique du patrimoine, soit la coordination de robots mobiles et drones équipés de capteurs lidar et vision afin de reconstruire intégralement une surface. Une deuxième thèse a également été lancée en 2018 (Esteban Restrepo-Ochoa, avec le L2S CentraleSupélec) avec pour objectif la définition de lois de commande distribuées pour la coordination multi-objectifs de systèmes multi-drones dans des environnements dynamiques, notamment via la définition de fonctions de Lyapunov barrières.

La coordination de larges essaims (au moins une centaine) de robots autonomes reste un problème difficile d'un point de vue théorique et pratique, les démonstrations actuelles reposant sur une planification a priori des trajectoires (chorégraphie) avec gestion centralisée. Un passage à l'échelle des techniques distribuées de localisation, cartographie et guidage de robots est donc attendu pour les missions de déplacement groupé, exploration ou suivi d'objet avec comme difficulté supplémentaire la possible hétérogénéité des agents (capteurs complémentaires, robots terrestres et aériens, tailles et dynamiques différentes).

Depuis quelques années, on observe une importante évolution des outils d'interprétation de données via le développement de techniques issues de l'IA et plus spécifiquement de l'apprentissage par ordinateur. Des moyens de description symbolique de données, notamment image, ont fait leur apparition et sont capables de donner des résultats en temps réel et dans certaines configurations embarquées. Nous pourrions donc considérer l'intégration de ces nouvelles capacités au sein des fonctions robotiques pour la navigation autonome. Les algorithmes embarqués de guidage pourront notamment être enrichis selon deux axes principaux : d'une part l'interaction avec une modélisation sémantique des objets statiques et dynamiques présents dans l'environnement, et d'autre part une gestion plus efficace des informations échangées au cours de la mission (réduction voire absence de communication).

## **Méthodes d'optimisation et d'estimation à base de krigeage**

### **Contributions**

Plusieurs types de méthodes numériques ont été dérivées de l'approximation par krigeage d'une fonction évaluée par simulation numérique coûteuse, qui fournit un méta-modèle léger à évaluer et une mesure de confiance associée. De nouveaux algorithmes d'optimisation ont ainsi été proposés : d'une part afin de réaliser une conception robuste au sens du minimax en intégrant deux procédures d'optimisation à base de krigeage dans un schéma de relaxation itérative, d'autre part afin de prendre en compte un ensemble de contraintes également coûteuses en guidant les nouvelles évaluations de la fonction par des techniques multi-objectif combinant le méta-modèle de la fonction coût et l'incertitude sur les contraintes. Les principales applications de ces méthodes sont le réglage automatique d'algorithmes d'estimation (diagnostic, commande, calcul de probabilité) et la conception de systèmes.

Nous avons par ailleurs proposé de nouvelles techniques d'estimation. L'évaluation de la probabilité d'évènements rares par échantillonnage préférentiel devient ainsi faisable lorsque la fonction d'intérêt est évaluée par une simulation coûteuse en réduisant itérativement l'incertitude sur le méta-modèle de manière ciblée. Par ailleurs, l'estimation des dérivées successives d'un signal bruité a pu être réalisée en définissant un filtre à coefficients constants à appliquer sur une fenêtre glissante. Dans les deux cas, le modèle de krigeage permet de fournir un intervalle de confiance sur le résultat obtenu avec un très faible coût de calcul.

### **Perspectives**

Cet axe de travail autour de l'optimisation et l'estimation à base de krigeage est en ralentissement, le diagnostic et les activités en commande avec validation expérimentale ayant connu une forte expansion lors des cinq dernières années. Cependant, l'expérience acquise en modélisation stochastique et manipulation de méta-modèle peut ponctuellement fournir des pistes de solutions à des problèmes d'estimation ou d'optimisation qui pourraient se poser dans les deux premières thématiques. Cela a notamment été le cas de la thèse d'Arthur Kahn dont les travaux ont associé robotique multi-véhicules, diagnostic et krigeage afin de réaliser la localisation de l'extremum global d'un champ scalaire.

Les techniques développées restent régulièrement appliquées au sein de l'ONERA pour réaliser le réglage d'algorithmes, estimer des probabilités d'évènements rares ou calculer des indices de sensibilité. Parmi les sujets encore ouverts au niveau de l'optimisation robuste à base de krigeage, la prise en compte de contraintes évaluées via des simulations numériques coûteuses et présentant des couplages entre les variables de conception et les variables environnementales pourra nécessiter de nouveaux développements.

# Bibliographie

- [1] J. Marzat. *Diagnostic des systèmes aéronautiques et réglage automatique pour la comparaison de méthodes*. PhD thesis, University Paris-Sud XI, France, 2011.
- [2] J. Marzat. Estimation temps réel du flot optique. Master's thesis, INPL Nancy, France, 2008.
- [3] A. Eudes, J. Marzat, M. Sanfourche, J. Moras, and S. Bertrand. Autonomous and safe inspection of an industrial warehouse by a multi-rotor MAV. In *Field and Service Robotics*, pages 221–235. Springer, Cham, 2018.
- [4] A. Abauzit and J. Marzat. A multiple-observer scheme for fault detection, isolation and recovery of satellite thrusters. In *Advances in Aerospace Guidance, Navigation and Control*, pages 199–214. Springer, Berlin, Heidelberg, 2013.
- [5] J. Marzat, H. Piet-Lahanier, F. Damongeot, and E. Walter. Tuning and comparing fault diagnosis methods for aeronautical systems via Kriging-based optimization. In *Progress in Flight Dynamics, Guidance, Navigation, Control, Fault Detection and Avionics*, volume 6, pages 363–374. Torus Press, 2013.
- [6] E. I. Robinson, J. Marzat, and Raïssi T. Filtering and uncertainty propagation methods for model-based prognosis of fatigue crack growth in fiber reinforced titanium matrix composites. *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part A : Civil Engineering*, 2018.
- [7] I. Sarras, J. Marzat, S. Bertrand, and H. Piet-Lahanier. Collaborative multiple micro air vehicles' localization and target tracking in gps-denied environment from range-velocity measurements. *International Journal of Micro Air Vehicles*, 10(2) :225–239, 2018.
- [8] J. Marzat. A missile guidance law tolerant to unestimated evasive maneuvers. *Aircraft Engineering and Aerospace Technology*, 89(2) :314–319, 2017.
- [9] J. Marzat, E. Walter, and H. Piet-Lahanier. A new expected improvement algorithm for continuous minimax optimization. *Journal of Global Optimization*, 64(4) :785–802, 2016.
- [10] C. Durantin, J. Marzat, and M. Balesdent. Analysis of multi-objective kriging-based methods for constrained global optimization. *Computational Optimization and Applications*, 63(3) :903–926, 2016.
- [11] P. Bidaud, L. Burlion, H. De Plinval, T. Loquen, J. Marzat, and C. Pralet. Dealing with complexity through advanced control techniques. *AerospaceLab Journal*, 12 :1–18, 2016.
- [12] M. Balesdent, J. Morio, and J. Marzat. Recommendations for the tuning of rare event probability estimators. *Reliability Engineering and System Safety*, 133 :68–78, 2015.
- [13] S. Bertrand, J. Marzat, H. Piet-Lahanier, A. Kahn, and Y. Rochefort. MPC strategies for cooperative guidance of autonomous vehicles. *AerospaceLab Journal*, (8) :1–18, 2014.
- [14] A. Iannetti, J. Marzat, H. Piet-Lahanier, G. Ordonneau, and L. Vingert. Development of model-based fault diagnosis algorithms for MASCOTTE cryogenic test bench. *Journal of Physics : Conference Series*, 570(7), 2014.
- [15] J. Morio, D. Jacquemart, M. Balesdent, and J. Marzat. Optimisation of interacting particle system for rare event estimation. *Computational Statistics and Data Analysis*, 66 :117–128, 2013.
- [16] M. Balesdent, J. Morio, and J. Marzat. Kriging-based adaptive importance sampling algorithms for rare event estimation. *Structural Safety*, 44 :1–10, 2013.
- [17] J. Marzat, H. Piet-Lahanier, and E. Walter. Worst-case global optimization of black-box functions through Kriging and relaxation. *Journal of Global Optimization*, 55 :707–727, 2013.
- [18] J. Marzat, H. Piet-Lahanier, F. Damongeot, and E. Walter. Model-based fault diagnosis for aerospace systems : a survey. *Proceedings of the IMechE, Part G : Journal of Aerospace Engineering*, 226(10) :1329–1360, 2012.
- [19] J. Marzat, H. Piet-Lahanier, F. Damongeot, and E. Walter. Control-based fault detection and isolation for autonomous aircraft. *Proceedings of the IMechE, Part G : Journal of Aerospace Engineering*, 226(5) :510–531, 2012.
- [20] J. Marzat, A. Eudes, A. Bernard-Brunel, M. Sanfourche, and S. Bertrand. Collision-free MAV tele-operation along a reference trajectory in indoor cluttered environment. In *IROS Workshop Vision-based Drones : What's Next ?*, Madrid, Spain, October 5, 2018.

- [21] C. Sarotte, J. Marzat, H. Piet-Lahanier, M. Galeotta, and G. Ordonneau. Fault detection and isolation with fluid mechanics constraints for cryogenic combustion bench cooling circuit. In *Proceedings of the Annual Conference of the Prognostics and Health Management Society, Philadelphia, PA, USA, 24-27 September, 2018*.
- [22] E. I. Robinson, J. Marzat, and T. Raïssi. Model-based prognosis of fatigue crack growth under variable amplitude loading. In *Proceedings of the 10th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes, Warsaw, Poland, 2018*.
- [23] C. Sarotte, J. Marzat, H. Piet-Lahanier, A. Iannetti, M. Galeotta, and G. Ordonneau. Actuator fault tolerant system for cryogenic combustion bench cooling circuit. In *Proceedings of the 10th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes, Warsaw, Poland, 2018*.
- [24] J. Marzat, H. Piet-Lahanier, and S. Bertrand. Cooperative fault detection and isolation in a surveillance sensor network : a case study. In *Proceedings of the 10th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes, Warsaw, Poland, 2018*.
- [25] H. Roggeman, J. Marzat, M. Derome, M. Sanfourche, A. Eudes, and G. Le Besnerais. Detection, estimation and avoidance of mobile objects using stereo-vision and model predictive control. In *Proceedings of the 1st International Workshop on Vision for UAVs at ICCV, Venice, Italy, 2017*.
- [26] H. Roggeman, J. Marzat, A. Bernard-Brunel, and G. Le Besnerais. Autonomous exploration with prediction of the quality of vision-based localization. In *Proceedings of the 20th IFAC World Congress, Toulouse, France, pages 10763–10768, 2017*.
- [27] E. I. Robinson, J. Marzat, and T. Raïssi. Model-based prognosis using an explicit degradation model and inverse FORM for uncertainty propagation. In *Proceedings of the 20th IFAC World Congress, Toulouse, France, pages 14807–14812, 2017*.
- [28] E. I. Robinson, J. Marzat, and Raïssi T. Interval observer design for unknown input estimation of linear time-invariant discrete-time systems. In *Proceedings of the 20th IFAC World Congress, Toulouse, France, pages 4082–4087, 2017*.
- [29] J. Marzat, S. Bertrand, A. Eudes, M. Sanfourche, and J. Moras. Reactive MPC for autonomous MAV navigation in indoor cluttered environments : Flight experiments. In *Proceedings of the 20th IFAC World Congress, Toulouse, France, pages 16566–16572, 2017*.
- [30] D.-K. Phung, B. Herisse, J. Marzat, and S. Bertrand. Model predictive control for autonomous navigation using embedded graphics processing unit. In *Proceedings of the 20th IFAC World Congress, Toulouse, France, pages 12389–12394, 2017*.
- [31] I. Sarras, J. Marzat, S. Bertrand, and H. Piet-Lahanier. Collaborative multi-vehicle localization with respect to static/dynamic target from range and velocity measurements. In *Proceedings of the International Conference on Unmanned Aircraft Systems, Miami FL, USA, pages 850–859, 2017*.
- [32] E. I. Robinson, J. Marzat, and Raïssi T. Model-based prognosis algorithms with uncertainty propagation : application to a fatigue crack growth. In *Proceedings of the 3rd International Conference on Control and Fault-Tolerant Systems, Barcelona, Spain, pages 458–465, 2016*.
- [33] A. Iannetti, J. Marzat, H. Piet-Lahanier, and G. Ordonneau. Automatic tuning strategies for model-based diagnosis methods applied to a rocket engine demonstrator. In *Proceedings of the 3rd European Conference of the Prognostics and Health Management Society, Bilbao, Spain, pages 1–8, 2016*.
- [34] H. Roggeman, J. Marzat, A. Bernard-Brunel, and G. Le Besnerais. Prediction of the scene quality for stereo vision-based autonomous navigation. In *Proceedings of the 9th IFAC Symposium on Intelligent Autonomous Vehicles, Leipzig, Germany, pages 94–99, 2016*.
- [35] N. Piasco, J. Marzat, and M. Sanfourche. Collaborative localization and formation flying using distributed stereo-vision. In *Proceedings of the IEEE International Conference on Robotics and Automation, Stockholm, Sweden, pages 1202–1207, 2016*.
- [36] A. Kahn, J. Marzat, H. Piet-Lahanier, and M. Kieffer. Global extremum seeking by Kriging with a multi-agent system. In *Proceedings of the 17th IFAC Symposium on System Identification, Beijing, China, pages 526–531, 2015*.
- [37] A. Iannetti, J. Marzat, H. Piet-Lahanier, G. Ordonneau, and L. Vingert. Fault diagnosis benchmark for a rocket engine demonstrator. In *Proceedings of the 9th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes, Paris, France, pages 895–900, 2015*.
- [38] A. Kahn, J. Marzat, H. Piet-Lahanier, and M. Kieffer. Cooperative estimation and fleet reconfiguration for multi-agent systems. In *Proceedings of the 3rd IFAC Workshop on Multivehicle Systems, Genova, Italy, pages 11–16, 2015*.
- [39] H. Roggeman, J. Marzat, M. Sanfourche, and A. Plyer. Embedded vision-based localization and model predictive control for autonomous exploration. In *IROS Workshop on Visual Control of Mobile Robots (ViCoMoR), Chicago IL, USA, pages 13–20, 2014*.

- [40] J. Marzat, H. Piet-Lahanier, and A. Kahn. Cooperative guidance of LEGO mindstorms NXT mobile robots. In *11th International Conference on Informatics in Control, Automation and Robotics, Vienna, Austria*, volume 2, pages 605–610, 2014.
- [41] F. Briggs, Y. Huang, R. Raich, K. Eftaxias, Z. Lei, W. Cukierski, S. F. Hadley, A. Hadley, M. Betts, X. Z. Fern, J. Irvine, L. Neal, A. Thomas, G. Fodor, G. Tsoumakas, H. W. Ng, N. T. Nguyen Thi, H. Huttunen, P. Ruusuvoori, T. Manninen, A. Diment, T. Virtanen, J. Marzat, J. Defretin, D. Callender, C. Hurlburt, K. Larrey, and M. Milakov. The 9th annual MLSP competition : New methods for acoustic classification of multiple simultaneous bird species in a noisy environment. In *Proceedings of the IEEE International Workshop on Machine Learning for Signal Processing, Southampton, UK*, 2013.
- [42] J. Marzat, H. Piet-Lahanier, and E. Walter. Kriging-based estimation of time derivatives via FIR filtering. In *Proceedings of the IEEE International Workshop on Machine Learning for Signal Processing, Southampton, UK*, 2013.
- [43] T. Gorecki, H. Piet-Lahanier, J. Marzat, and M. Balesdent. Cooperative guidance of UAVs for area exploration with final target allocation. pages 260–265, 2013.
- [44] H. Piet-Lahanier, A. Kahn, and J. Marzat. Cooperative guidance laws for maneuvering target interception. In *Proceedings of the 19th IFAC Symposium on Automatic Control in Aerospace, Würzburg, Germany*, pages 301–306, 2013.
- [45] A. Kahn, J. Marzat, and H. Piet-Lahanier. Formation flying control via elliptical virtual structure. In *Proceedings of the IEEE International Conference on Networking, Sensing and Control, Paris-Evry, France*, pages 158–163, 2013.
- [46] J. Marzat, E. Walter, and H. Piet-Lahanier. A new strategy for worst-case design from costly numerical simulations. In *Proceedings of the American Control Conference, Washington DC, USA*, pages 3997–4002, 2013.
- [47] J. Marzat, E. Walter, F. Damongeot, and H. Piet-Lahanier. Robust automatic tuning of diagnosis methods via an efficient use of costly simulations. In *Proceedings of the 16th IFAC Symposium on System Identification, Brussels, Belgium*, pages 398–403, 2012.
- [48] J. Marzat and H. Piet-Lahanier. Design of nonlinear MPC by Kriging-based optimization. In *Proceedings of the 16th IFAC Symposium on System Identification, Brussels, Belgium*, pages 1490–1495, 2012.
- [49] J. B. Devaud, S. Najko, P. Le Nahédic, C. Maussire, E. Zante, and J. Marzat. Full design of a low-cost quadrotor UAV by student team. In *Proceedings of the IEEE International Conference on System Engineering and Technology, Bandung, Indonesia*, 2012.
- [50] S. Bertrand, J. Marzat, M. Carton, C. Chaix, P. Varela, R. Waroux, G. De Ferron, and R. Laurel. A low-cost system for indoor motion tracking of unmanned aerial vehicles. In *Proceedings of the Seventh IEEE International Conference on Intelligent Sensors, Sensor Networks and Information Processing, Adelaide, Australia*, pages 574–579, 2011.
- [51] J. Marzat, E. Walter, H. Piet-Lahanier, and F. Damongeot. Réglage automatique et comparaison de méthodes de diagnostic par krigeage. In *Actes des Quatrièmes Journées Doctorales du GDR MACS, Marseille, France*, 2011.
- [52] J. Marzat, E. Walter, and H. Piet-Lahanier. Min-max hyperparameter tuning with application to fault detection. In *Proceedings of the 18th IFAC World Congress, Milan, Italy*, pages 12904–12909, 2011.
- [53] J. Defretin, J. Marzat, and H. Piet-Lahanier. Learning viewpoint planning in active recognition on a small sampling budget : a Kriging approach. In *Proceedings of the 9th IEEE International Conference on Machine Learning and Applications, ICMLA 2010, Washington DC, USA*, pages 169–174, 2010.
- [54] J. Marzat, E. Walter, H. Piet-Lahanier, and F. Damongeot. Automatic tuning via Kriging-based optimization of methods for fault detection and isolation. In *Proceedings of the IEEE Conference on Control and Fault-Tolerant Systems, SysTol'10, Nice, France*, pages 505–510, 2010.
- [55] J. Marzat, H. Piet-Lahanier, F. Damongeot, and E. Walter. Fault diagnosis for nonlinear aircraft based on control-induced redundancy. In *Proceedings of the IEEE Conference on Control and Fault-Tolerant Systems, SysTol'10, Nice, France*, pages 119–124, 2010.
- [56] J. Marzat, H. Piet-Lahanier, F. Damongeot, and E. Walter. Nonlinear FDI based on state derivatives, as provided by inertial measurement units. In *Proceedings of the 8th IFAC Symposium on Nonlinear Control Systems, Bologna, Italy*, pages 951–956, 2010.
- [57] J. Marzat, H. Piet-Lahanier, and E. Walter. Détection et isolation de défauts par analyse des contraintes géométriques de guidage-pilotage. In *Actes de la Sixième Conférence Internationale Francophone d'Automatique, CIFA 2010, Nancy, France*, 2010.
- [58] J. Marzat, H. Piet-Lahanier, F. Damongeot, and E. Walter. A new model-free method performing closed-loop fault diagnosis for an aeronautical system. In *Proceedings of the 7th Workshop on Advanced Control and Diagnosis, ACD'2009, Zielona Gora, Poland*, pages 1–6, 2009.
- [59] J. Marzat, Y. Dumortier, and A. Ducrot. Real-time dense and accurate parallel optical flow using CUDA. In *Proceedings of the 17th International Conference in Central European Computer Graphics, Visualization and Computer Vision, Plzen, Czech Republic*, pages 105–111, 2009.

- [60] S. Perez Roca, J. Marzat, H. Piet-Lahanier, N. Langlois, M. Galeotta, F. Farago, and S. Le Gonidec. Derivation and analysis of a dynamic model for transient control of liquid-propellant rocket engines. In *Proceedings of the 9th International Conference on Mechanical and Aerospace Engineering, Budapest, Hungary, July 10-13, 2018*.
- [61] A. Iannetti, J. Marzat, H. Piet-Lahanier, C. Sarotte, and Ordonneau G. Promising HMS approaches for liquid rocket engines. In *7th European Conference for Aerospace Sciences (EUCASS), Milan, Italy, 2017*.
- [62] N. Merlinge, J. Marzat, and L. Reboul. Optimal guidance and observer design for target tracking using bearing only measurements. In *16th ONERA-DLR Aerospace Symposium, Oberpfaffenhofen, Germany, 2016*.
- [63] A. Iannetti, S. Palerm, J. Marzat, H. Piet-Lahanier, and G. Ordonneau. A new HMS for the MASCOTTE cryogenic test bench. In *Space Propulsion, Roma, Italy, 2016*.
- [64] A. Iannetti, S. Palerm, J. Marzat, H. Piet-Lahanier, and G. Ordonneau. HMS developments for the rocket engine demonstrator Mascotte. In *Proceedings of the 51st AIAA/SAE/ASEE Joint Propulsion Conference, Orlando FL, USA, 2015*.
- [65] J. Marzat, J. Moras, A. Plyer, A. Eudes, and P. Morin. Vision-based localization, mapping and control for autonomous MAV : EuRoC challenge results. In *15th ONERA-DLR Aerospace Symposium (ODAS), Toulouse, France, 2015*.
- [66] H. Piet-Lahanier, J. Marzat, and E. Walter. Robust minimax design from costly simulations. In *11th International Conference on Structural Safety and Reliability, New York, USA, 2013*.
- [67] H. Piet-Lahanier, Y. Rochefort, S. Bertrand, and J. Marzat. Application of cooperative guidance methods to missile or UAV flocks. In *Deep Strike, Barcelona, Spain, 2012*.
- [68] J. Marzat, H. Piet-Lahanier, F. Damongeot, and E. Walter. Autonomous fault diagnosis : state of the art and aeronautical benchmark. In *3rd European Conference for Aero-Space Sciences, Versailles, France, 2009*.
- [69] R. Isermann and P. Balle. Trends in the application of model-based fault detection and diagnosis of technical processes. *Control Engineering Practice*, 5(5) :709–719, 1997.
- [70] Y. Zhang and J. Jiang. Bibliographical review on reconfigurable fault-tolerant control systems. *Annual Reviews in Control*, 32(2) :229–252, 2008.
- [71] J. E. Land. HUMS - the benefits - past, present and future. In *Proceedings of the IEEE Aerospace Conference, Big Sky, MT, USA, volume 6, pages 3083–3094, 2001*.
- [72] D. M. Johnson. A review of fault management techniques used in safety-critical avionic systems. *Progress in Aerospace Sciences*, 32(5) :415–431, 1996.
- [73] I. Hwang, S. Kim, Y. Kim, and C.E. Seah. A survey of fault detection, isolation, and reconfiguration methods. *IEEE Transactions on Control Systems Technology*, 18(3) :636–653, 2010.
- [74] C. Edwards, T. Lombaerts, and H. Smaili. *Fault Tolerant Flight Control : A Benchmark Challenge*, volume 399 of *Lecture Notes in Control and Information Sciences*. Springer-Verlag, Berlin Heidelberg, 2010.
- [75] R. J. Patton and J. Chen. Review of parity space approaches to fault diagnosis for aerospace systems. *Journal of Guidance Control Dynamics*, 17 :278–285, 1994.
- [76] S. Yin, S. X. Ding, A. Haghani, H. Hao, and P. Zhang. A comparison study of basic data-driven fault diagnosis and process monitoring methods on the benchmark tennessee eastman process. *Journal of Process Control*, 22(9) :1567–1581, 2012.
- [77] P. Goupil. Oscillatory failure case detection in the A380 electrical flight control system by analytical redundancy. *Control Engineering Practice*, 18(9) :1110–1119, 2010.
- [78] P. Goupil. AIRBUS state of the art and practices on FDI and FTC in flight control system. *Control Engineering Practice*, 19(6) :524–539, 2011.
- [79] H. H. Niemann and J. Stoustrup. Robust fault detection in open loop vs. closed loop. In *Proceedings of the 36th IEEE Conference on Decision and Control, San Diego*, volume 5, pages 4496–4497, 1997.
- [80] H. Baïkeche, B. Marx, D. Maquin, and J. Ragot. On parametric and nonparametric fault detection in linear closed-loop systems. In *Proceedings of the 4th Workshop on Advanced Control and Diagnosis, Nancy, 2006*.
- [81] C. A. Jacobson and C. N. Nett. An integrated approach to controls and diagnostics using the four-parameter controller. *IEEE Control Systems Magazine*, 11(6) :22–29, 1991.
- [82] D. Henry. Fault diagnosis of microscope satellite thrusters using  $\mathcal{H}_\infty/\mathcal{H}_-$  filters. *Journal of Guidance, Control, and Dynamics*, 31(3) :699–711, 2008.
- [83] H. Baïkeche. *Diagnostic des systèmes linéaires en boucle fermée*. Thèse de doctorat de l’Institut National Polytechnique de Lorraine, 2007.
- [84] T. J. Harris, C. T. Seppala, and L. D. Desborough. A review of performance monitoring and assessment techniques for univariate and multivariate control systems. *Journal of Process Control*, 9(1) :1–17, 1999.
- [85] A. Ingimundarson and T. Hägglund. Closed-loop performance monitoring using loop tuning. *Journal of Process Control*, 15(2) :127–133, 2005.

- [86] C. De Persis and A. Isidori. A geometric approach to nonlinear fault detection and isolation. *IEEE Transactions on Automatic Control*, 46(6) :853–865, 2001.
- [87] A. Isidori. *Nonlinear Control Systems : An Introduction*. Springer-Verlag, Berlin-Heidelberg, 1995.
- [88] N. Meskin, T. Jiang, E. Sobhani, K. Khorasani, and C. A. Rabbath. Nonlinear geometric approach to fault detection and isolation in an aircraft nonlinear longitudinal model. In *Proceedings of the American Control Conference, New York City, USA*, pages 5771–5776, 2007.
- [89] M. Benini, M. Bonfe, P. Castaldi, W. Geri, and S. Simani. Fault diagnosis strategies for a simulated nonlinear aircraft model. In *Proceedings of the 17th IFAC World Congress, Seoul, Korea*, pages 7300–7307, 2008.
- [90] M. L. Leuschen, I. D. Walker, and J. R. Cavallaro. Fault residual generation via nonlinear analytical redundancy. *IEEE Transactions on Control Systems Technology*, 13(3) :452–458, 2005.
- [91] R. Martinez-Guerra and S. Diop. Diagnosis of nonlinear systems using an unknown-input observer : an algebraic and differential approach. *IEE Proceedings-Control Theory and Applications*, 151(1) :130–135, 2004.
- [92] D. Berdjag, C. Christophe, V. Cocquempot, and B. Jiang. Nonlinear model decomposition for robust fault detection and isolation using algebraic tools. *International Journal of Innovative Computing, Information & Control*, 2(6) :1337–1354, 2006.
- [93] R. Hirschorn. Invertibility of multivariable nonlinear control systems. *IEEE Transactions on Automatic Control*, 24(6) :855–865, 1979.
- [94] A. Edelmayer, J. Bokor, Z. Szabo, and F. Szigeti. Input reconstruction by means of system inversion : a geometric approach to fault detection and isolation in nonlinear systems. *International Journal of Applied Mathematics and Computer Science*, 14(2) :189–200, 2004.
- [95] A. Edelmayer, J. Bokor, and Z. Szabó. Inversion-based residual generation for robust detection and isolation of faults by means of estimation of the inverse dynamics in linear dynamical systems. *International Journal of Control*, 82(8) :1526–1538, 2009.
- [96] A. G. Ramm and A. B. Smirnova. On stable numerical differentiation. *Mathematics of Computation*, 70(235) :1131–1153, 2001.
- [97] W. R. Williamson, J. L. Speyer, V. T. Dang, and J. Sharp. Fault detection for deep space satellites. *Journal of Guidance, Control and Dynamics*, 32(5) :1570–1584, 2009.
- [98] M. J. Sidi. *Spacecraft Dynamics and Control : A Practical Engineering Approach*. Cambridge University Press, 1997.
- [99] B. Wie. *Space vehicle dynamics and control*. American Institute of Aeronautics and Astronautics, 2008.
- [100] C. Edwards, S. K. Spurgeon, and R. J. Patton. Sliding mode observers for fault detection and isolation. *Automatica*, 36(4) :541–553, 2000.
- [101] M. Basseville and I. V. Nikiforov. *Detection of Abrupt Changes : Theory and Application*. Prentice Hall Englewood Cliffs, NJ, 1993.
- [102] R. J. Patton, F. J. Uppal, S. Simani, and B. Polle. Robust fdi applied to thruster faults of a satellite system. *Control Engineering Practice*, 18(9) :1093–1109, 2010.
- [103] M. Darouach, M. Zasadzinski, and S. J. Xu. Full-order observers for linear systems with unknown inputs. *IEEE Transactions on Automatic Control*, 39(3) :606–609, 1994.
- [104] D. Theilliol, C. Join, and Y. Zhang. Actuator fault tolerant control design based on a reconfigurable reference input. *International Journal of Applied Mathematics and Computer Science*, 18(4) :553–560, 2008.
- [105] A. Iannetti. *Méthodes de diagnostic pour les moteurs de fusée à ergols liquides*. PhD thesis, University Paris-Saclay, France, 2016.
- [106] G. P. Sutton and O. Biblarz. *Rocket propulsion elements*. John Wiley & Sons, 2016.
- [107] L. Vingert, M. Habiballah, and J. C. Traineau. MASCOTTE : A test bench for cryogenic combustion research. In *47th International Astronautical Congress, Beijing, China*, 1996.
- [108] M. Habiballah, M. Orain, F. Grisch, L. Vingert, and P. Gicquel. Experimental studies of high-pressure cryogenic flames on the MASCOTTE facility. *Combustion Science and Technology*, 178(1–3) :101–128, 2006.
- [109] J. Pichillou, P. Grenard, L. Vingert, G. Leplat, and P. Reulet. Experimental analysis of heat transfer in cryogenic combustion chambers on Mascotte test bench. In *7th European Conference for Aeronautics and Space Sciences, Milan, Italy*, 2017.
- [110] I. E. Idel’Cik. Memento des pertes de charge. *Eyrolles, Paris*, 1969.
- [111] E. Cliquet, A. Iannetti, and J. Masse. Carmen, liquid propulsion systems simulation platform. *Progress in Propulsion Physics*, 2 :695–706, 2011.
- [112] F. Gustafsson. *Adaptive Filtering and Change Detection*. Wiley London, 2001.
- [113] M. Witczak. *Modelling and Estimation Strategies for Fault Diagnosis of Non-Linear Systems : From Analytical to Soft Computing Approaches*. Springer-Verlag, Berlin Heidelberg, 2007.

- [114] W. Jiang, L. Shu, and D. W. Apley. Adaptive CUSUM procedures with EWMA-based shift estimators. *IIE Transactions*, 40(10) :992–1003, 2008.
- [115] K. Kalsi, J. Lian, S. Hui, and S. H. Žak. Sliding-mode observers for systems with unknown inputs : A high-gain approach. *Automatica*, 46(2) :347–353, 2010.
- [116] F. Zhu. State estimation and unknown input reconstruction via both reduced-order and high-order sliding mode observers. *Journal of Process Control*, 22(1) :296–302, 2012.
- [117] D. Gucik-Derigny. *Contribution au pronostic des systèmes à base de modèles : théorie et application*. PhD thesis, Université Paul Cézanne Aix-Marseille III, 2011.
- [118] L. Hao, Y. Jinsong, Z. Ping, and L. Xingshan. A review on fault prognostics in integrated health management. In *9th IEEE International Conference on Electronic Measurement & Instruments, Beijing, China*, pages 4–267–4–270, 2009.
- [119] J. Luo, K. R. Pattipati, L. Qiao, and S. Chigusa. Model-based prognostic techniques applied to a suspension system. *IEEE Transactions on Systems, Man, and Cybernetics - Part A : Systems and Humans*, 38(5) :1156–1168, 2008.
- [120] K. Keller. Health management technology integration. In *18th International Workshop on Principles of Diagnosis, Nashville, TN, USA*, 2007.
- [121] L. V. Kirkland, T. Pombo, K. Nelson, and F. Berghout. Avionics health management : Searching for the prognostics grail. In *IEEE Aerospace Conference, Big Sky, MT, USA*, volume 5, pages 3448–3454, 2004.
- [122] C. Wilkinson, D. Humphrey, B. Vermeire, and J. Houston. Prognostic and health management for avionics. In *IEEE Aerospace Conference, Big Sky, MT, USA*, volume 5, pages 3435–3447, 2004.
- [123] C. S. Byington, P. W. Kalgren, B. K. Dunkin, and B. P. Donovan. Advanced diagnostic/prognostic reasoning and evidence transformation techniques for improved avionics maintenance. In *IEEE Aerospace Conference, Big Sky, MT, USA*, volume 5, pages 3424–3434, 2004.
- [124] F. Camci, G. S. Valentine, and K. Navarra. Methodologies for integration of phm systems with maintenance data. In *IEEE Aerospace Conference, Big Sky, MT, USA*, pages 1–9, 2007.
- [125] J. Lemaitre and R. Desmorat. *Engineering damage mechanics : ductile, creep, fatigue and brittle failures*. Springer Science & Business Media, 2005.
- [126] B. Saha, K. Goebel, and J. Christophersen. Comparison of prognostic algorithms for estimating remaining useful life of batteries. *Transactions of the Institute of Measurement and Control*, 31(3-4) :293–308, 2009.
- [127] D. An, J.-H. Choi, and N. H. Kim. Prognostics 101 : A tutorial for particle filter-based prognostics algorithm using matlab. *Reliability Engineering & System Safety*, 115 :161–169, 2013.
- [128] E. Robinson. *Méthodes de filtrage et de propagation d'incertitudes pour le pronostic à base de modèles*. PhD thesis, CNAM Paris, France, 2018.
- [129] M. E. Orchard and G. J. Vachtsevanos. A particle-filtering approach for on-line fault diagnosis and failure prognosis. *Transactions of the Institute of Measurement and Control*, 31(3-4) :221–246, 2009.
- [130] J. F. Maire, P. Levasseur, and P. Paulmier. Multi-scale model of crack propagation in unidirectional metallic matrix composites. In *ECF13, San Sebastian, Spain*, 2000.
- [131] W. S. Johnson, J. M. Larsen, J. M. Larsen, and B. N. Cox. *Life prediction methodology for titanium matrix composites*. ASTM International, 1996.
- [132] S. Sankararaman, M. J. Daigle, and K. Goebel. Uncertainty quantification in remaining useful life prediction using first-order reliability methods. *IEEE Transactions on Reliability*, 63(2) :603–619, 2014.
- [133] L. Jaulin, M. Kieffer, O. Didrit, and E. Walter. *Applied Interval Analysis*. Springer, London, 2001.
- [134] P. Herrero, P. Georgiou, C. Toumazou, B. Delaunay, and L. Jaulin. An efficient implementation of the SIVIA algorithm in a high-level numerical programming language. *Reliable Computing*, 16(1) :239–251, 2012.
- [135] D. Gucik-Derigny, T. Raïssi, and A. Zolghadri. A note on interval observer design for unknown input estimation. *International Journal of Control*, 89(1) :25–37, 2016.
- [136] D. Maquin, B. Gaddouna, and J. Ragot. Estimation of unknown inputs in linear systems. In *American Control Conference, Baltimore, MI, USA*, volume 1, pages 1195–1197, 1994.
- [137] K. Sobczyk and J. Trebicki. Stochastic dynamics with fatigue-induced stiffness degradation. *Probabilistic Engineering Mechanics*, 15(1) :91–99, 2000.
- [138] P. Furgale, J. Rehder, and R. Siegwart. Unified temporal and spatial calibration for multi-sensor systems. In *IEEE/RSJ International Conference on Intelligent Robots and Systems, Tokyo, Japan*, pages 1280–1286, Nov 2013.
- [139] J. Rehder, J. Nikolic, T. Schneider, T. Hinzmam, and R. Siegwart. Extending kalibr : Calibrating the extrinsics of multiple IMUs and of individual axes. In *IEEE International Conference on Robotics and Automation, Stockholm, Sweden*, pages 4304–4311, 2016.
- [140] M. Quigley, K. Conley, B. Gerkey, J. Faust, T. Foote, J. Leibs, R. Wheeler, and A. Y. Ng. ROS : an open-source robot operating system. In *ICRA workshop on open source software*, volume 3, page 5. Kobe, Japan, 2009.

- [141] N. Koenig and A. Howard. Design and use paradigms for Gazebo, an open-source multi-robot simulator. In *IEEE/RSJ International Conference on Intelligent Robots and Systems, Sendai, Japan*, volume 3, pages 2149–2154, 2004.
- [142] F. Furrer, M. Burri, M. Achtelik, and R. Siegwart. RotorS — A modular Gazebo MAV simulator framework. In *Robot Operating System (ROS)*, pages 595–625. Springer, 2016.
- [143] H. Roggeman. *Amélioration de performance de la navigation basée vision pour la robotique autonome : une approche par couplage vision/commande*. PhD thesis, University Paris-Saclay, France, 2017.
- [144] D. Scaramuzza and F. Fraundorfer. Visual odometry : Part I - the first 30 years and fundamentals. *IEEE Robotics and Automation Magazine*, 18(4) :80–92, 2011.
- [145] G. Klein and D. Murray. Parallel tracking and mapping for small AR workspaces. In *Proceedings of the 6th IEEE and ACM International Symposium on Mixed and Augmented Reality, Nara, Japan*, pages 225–234, 2007.
- [146] L. Heng, D. Honegger, G. H. Lee, L. Meier, P. Tanskanen, F. Fraundorfer, and M. Pollefeys. Autonomous visual mapping and exploration with a micro aerial vehicle. *Journal of Field Robotics*, 31(4) :654–675, 2014.
- [147] M. Burri, H. Oleynikova, M. W. Achtelik, and R. Siegwart. Real-time visual-inertial mapping, re-localization and planning onboard MAVs in unknown environments. In *IEEE/RSJ International Conference on Intelligent Robots and Systems, Hamburg, Germany*, pages 1872–1878, 2015.
- [148] M. Faessler, F. Fontana, C. Forster, E. Mueggler, M. Pizzoli, and D. Scaramuzza. Autonomous, vision-based flight and live dense 3D mapping with a quadrotor micro aerial vehicle. *Journal of Field Robotics*, 33(4) :431–450, 2016.
- [149] M. Derome, A. Plyer, M. Sanfourche, and G. Le Besnerais. Moving object detection in real-time using stereo from a mobile platform. *Unmanned Systems*, 3(4) :253–266, 2015.
- [150] M. Sanfourche, V. Vittori, and G. Le Besnerais. eVO : A realtime embedded stereo odometry for MAV applications. In *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Tokyo, Japan*, pages 2107–2114, 2013.
- [151] M. Sanfourche, A. Plyer, A. Bernard-Brunel, and G. Le Besnerais. 3DSCAN : Online ego-localization and environment mapping for micro aerial vehicles. *AerospaceLab Journal*, 8 :1–17, 2014.
- [152] A. Plyer, G. Le Besnerais, and F. Champagnat. Real-time Lucas-Kanade optical flow estimation for real-world applications. *Journal of Real Time Image Processing*, 2014.
- [153] J. Shi and C. Tomasi. Good features to track. In *1994 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA*, pages 593 – 600, 1994.
- [154] M. A. Fischler and R. C. Bolles. Random sample consensus : A paradigm for model fitting with applications to image analysis and automated cartography. *Communications of the ACM*, 24(6) :381–395, 1981.
- [155] M.I. A. Lourakis and A.A. Argyros. SBA : A Software Package for Generic Sparse Bundle Adjustment. *ACM Transactions on Mathematical Software*, 36(1) :1–30, 2009.
- [156] E. Mouragnon, M. Lhuillier, M. Dhome, F. Dekeyser, and P. Sayd. Real time localization and 3d reconstruction. In *IEEE Conference on Computer Vision and Pattern Recognition (CVPR), New York, NY, USA*, volume 1, pages 363–370, 2006.
- [157] A. Geiger, P. Lenz, and R. Urtasun. Are we ready for autonomous driving? The KITTI vision benchmark suite. In *IEEE Conference on Computer Vision and Pattern Recognition, Providence, RI, USA*, pages 3354–3361, 2012.
- [158] S. Lynen, M. W. Achtelik, S. Weiss, M. Chli, and R. Siegwart. A robust and modular multi-sensor fusion approach applied to MAV navigation. In *IEEE/RSJ International Conference on Intelligent Robots and Systems, Tokyo, Japan*, pages 3923–3929, 2013.
- [159] A. Geiger, M. Roser, and R. Urtasun. Efficient large-scale stereo matching. In *Proceedings of the 10th Asian Conference on Computer Vision (ACCV), Queenstown, New Zealand*, pages 25–38, 2010.
- [160] A. Elfes. Using occupancy grids for mobile robot perception and navigation. *Computer*, 22(6) :46–57, 1989.
- [161] A. Hornung, K. M. Wurm, M. Bennewitz, C. Stachniss, and W. Burgard. OctoMap : An efficient probabilistic 3d mapping framework based on octrees. *Autonomous Robots*, 34(3) :189–206, 2013.
- [162] B. Lau, C. Sprunk, and W. Burgard. Efficient grid-based spatial representations for robot navigation in dynamic environments. *Robotics and Autonomous Systems*, 61(10) :1116–1130, 2013.
- [163] S. M. LaValle. *Planning algorithms*. Cambridge University Press, 2006.
- [164] L. Singh and J. Fuller. Trajectory generation for a UAV in urban terrain, using nonlinear MPC. In *Proceedings of the American Control Conference, Arlington, VA, USA*, volume 3, pages 2301–2308, 2001.
- [165] A. Jadbabaie, Jie Yu, and J. Hauser. Unconstrained receding-horizon control of nonlinear systems. *IEEE Transactions on Automatic Control*, 46(5) :776–783, 2001.
- [166] E. W. Frew. Receding horizon control using random search for UAV navigation with passive, non-cooperative sensing. In *Proceedings of the AIAA Guidance, Navigation and Control Conference, San Francisco, CA, USA*, 2005.

- [167] D. Mellinger, N. Michael, and V. Kumar. Trajectory generation and control for precise aggressive maneuvers with quadrotors. *The International Journal of Robotics Research*, 5 :664–674, 2012.
- [168] M. Hofer, M. Muehlebach, and R. D’Andrea. Application of an approximate model predictive control scheme on an unmanned aerial vehicle. In *IEEE International Conference on Robotics and Automation, Stockholm, Sweden*, pages 2952–2957, 2016.
- [169] M. Neunert, C. de Crousaz, F. Furrer, M. Kamel, F. Farshidian, R. Siegwart, and J. Buchli. Fast nonlinear model predictive control for unified trajectory optimization and tracking. In *IEEE International Conference on Robotics and Automation, Stockholm, Sweden*, pages 1398–1404, 2016.
- [170] C. Leung, S. Huang, and G. Dissanayake. Active SLAM using model predictive control and attractor based exploration. In *IEEE/RSJ International Conference on Intelligent Robots and Systems, Beijing, China*, pages 5026–5031, 2006.
- [171] T. M. Howard, C. J. Green, and A. Kelly. Receding horizon model-predictive control for mobile robot navigation of intricate paths. In *Field and Service Robotics*, pages 69–78, 2010.
- [172] L. Bascetta, D. Cucci, G. Magnani, M. Matteucci, D. Osmankovic, and A. Tahirovic. Towards the implementation of a MPC-based planner on an autonomous all-terrain vehicle. In *IROS Workshop on Robot Motion Planning : Online, Reactive, and in Real-time, Vilamoura, Portugal*, 2012.
- [173] S. Bertrand, T. Hamel, and H. Piet-Lahanier. Performance improvement of an adaptive controller using model predictive control : Application to an UAV model. *IFAC Proceedings Volumes*, 39(16) :770–775, 2006.
- [174] Y. Rochefort, H. Piet-Lahanier, S. Bertrand, D. Beauvois, and D. Dumur. Model predictive control of cooperative vehicles using systematic search approach. *Control Engineering Practice*, 32 :204–217, 2014.
- [175] B. Yamauchi. A frontier-based approach for autonomous exploration. In *IEEE International Symposium on Computational Intelligence in Robotics and Automation, CIRA’97*, pages 146–151, 1997.
- [176] D. R. Jones, C. D. Perttunen, and B. E. Stuckman. Lipschitzian optimization without the Lipschitz constant. *Journal of Optimization Theory and Applications*, 79(1) :157–181, 1993.
- [177] E. Dunn, J. Van Den Berg, and J.-M. Frahm. Developing visual sensing strategies through next best view planning. In *IEEE/RSJ International Conference on Robots and Systems, St Louis, MO, USA*, pages 4001–4008, 2009.
- [178] S. Haner and A. Heyden. Optimal view path planning for visual slam. In *Scandinavian Conference on Image Analysis, Espoo, Finland*, pages 370–380, 2011.
- [179] S. A. Sadat, K. Chutskoff, D. Jungic, J. Wawerla, and R. Vaughan. Feature-rich path planning for robust navigation of MAVs with mono-SLAM. In *IEEE International Conference on Robotics and Automation, Hong Kong, China*, pages 3870–3875, 2014.
- [180] C. Forster, M. Pizzoli, and D. Scaramuzza. Appearance-based active, monocular, dense reconstruction for micro aerial vehicle. In *Robotics : Science and Systems, Berkeley, CA, USA*, 2014.
- [181] C. Mostegel, A. Wendel, and H. Bischof. Active monocular localization : Towards autonomous monocular exploration for multirotor MAVs. In *IEEE International Conference on Robotics and Automation, Hong Kong, China*, pages 3848–3855, 2014.
- [182] A. J. Davison and D. W. Murray. Mobile robot localisation using active vision. In *European Conference on Computer Vision, Freiburg, Germany*, pages 809–825, 1998.
- [183] A. Howard. Real-time stereo visual odometry for autonomous ground vehicles. In *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 3946–3952, 2008.
- [184] A. Mallet, S. Lacroix, and L. Gallo. Position estimation in outdoor environments using pixel tracking and stereo-vision. In *IEEE ICRA*, 2000.
- [185] C. Harris and M. Stephens. A combined corner and edge detector. In *In Proc. of Fourth Alvey Vision Conference*, pages 147–151, 1988.
- [186] D. G. Lowe. Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, 60(2) :91–110, 2004.
- [187] E. Rosten and T. Drummond. Machine learning for high-speed corner detection. In *European Conference on Computer Vision*, volume 1, pages 430–443, May 2006.
- [188] D. Scaramuzza, M. C. Achtelik, L. Doitsidis, F. Fraundorfer, E. Kosmatopoulos, A. Martinelli, M. W. Achtelik, M. Chli, S. Chatzichristofis, L. Kneip, et al. Vision-controlled micro flying robots : from system design to autonomous navigation and mapping in GPS-denied environments. *IEEE Robotics & Automation Magazine*, 21(3) :26–40, 2014.
- [189] M.-D. Hua, T. Hamel, P. Morin, and C. Samson. Introduction to feedback control of underactuated VTOL vehicles : A review of basic control design ideas and principles. *IEEE Control Systems Magazine*, 33(1) :76–88, 2013.
- [190] S. Bertrand. *Commande de drone miniature à voilure tournante*. PhD thesis, Université Nice Sophia Antipolis, 2007.
- [191] F. Belkhouche and B. Bendjilali. Reactive path planning for 3-D autonomous vehicles. *IEEE Transactions on Control Systems Technology*, 20(1) :249–256, 2012.

- 
- [192] C. Fulgenzi, A. Spalanzani, and C. Laugier. Dynamic obstacle avoidance in uncertain environment combining pvos and occupancy grid. In *Proceedings of the IEEE International Conference on Robotics and Automation*, pages 1610–1616, 2007.
- [193] A. Barbier and E. Galin. Fast distance computation between a point and cylinders, cones, line-swept spheres and cone-spheres. *Journal of Graphics tools*, 9(2) :11–19, 2004.
- [194] E. Olson. AprilTag : A robust and flexible visual fiducial system. In *International Conference on Robotics and Automation, Shanghai, China*, pages 3400–3407, 2011.
- [195] T. Özaslan, G. Loianno, J. Keller, Camillo J. Taylor, V. Kumar, J. M. Wozencraft, and T. Hood. Autonomous navigation and mapping for inspection of penstocks and tunnels with MAVs. *IEEE Robotics and Automation Letters*, 2(3) :1740–1747, 2017.
- [196] H. H. González-Banos and J.-C. Latombe. Navigation strategies for exploring indoor environments. *The International Journal of Robotics Research*, 21(10-11) :829–848, 2002.
- [197] K. Hauser. Lazy collision checking in asymptotically-optimal motion planning. In *IEEE International Conference on Robotics and Automation, Seattle, WA, USA*, pages 2951–2957, 2015.
- [198] I. A. Şucan, M. Moll, and L. E. Kavraki. The Open Motion Planning Library. *IEEE Robotics & Automation Magazine*, 19(4) :72–82, 2012. <http://ompl.kavrakilab.org>.
- [199] Y. Rochefort, H. Piet-Lahanier, S. Bertrand, D. Beauvois, and D. Dumur. Guidance of flocks of vehicles using virtual signposts. *IFAC Proceedings Volumes*, 44(1) :5999–6004, 2011.
- [200] A. Kahn. *Reconfigurable cooperative control for extremum seeking*. PhD thesis, University Paris-Saclay, France, 2015.
- [201] P. Ogren, E. Fiorelli, and N. E. Leonard. Cooperative control of mobile sensor networks : Adaptive gradient climbing in a distributed environment. *IEEE Transactions on Automatic Control*, 49(8) :1292–1302, 2004.
- [202] F. Zhang and N. E. Leonard. Cooperative Filters and Control for Cooperative Exploration. *IEEE Transactions on Automatic Control*, 55(3) :650–663, 2010.
- [203] E. Walter and L. Pronzato. *Identification of Parametric Models from Experimental Data*. Springer-Verlag, Berlin-Heidelberg, 1997.
- [204] D. D. Cox and S. John. A statistical method for global optimization. In *IEEE International Conference on Systems, Man, and Cybernetics, Chicago, IL, USA*, pages 1241–1246, 1992.
- [205] Y. Xu, J. Choi, and S. Oh. Mobile sensor network navigation using gaussian processes with truncated observations. *IEEE Transactions on Robotics*, 27(6) :1118–1131, 2011.
- [206] J. Engel, J. Sturm, and D. Cremers. Scale-aware navigation of a low-cost quadcopter with a monocular camera. *Robotics and Autonomous Systems*, 62(11) :1646–1656, 2014.
- [207] C. Forster, S. Lynen, L. Kneip, and D. Scaramuzza. Collaborative monocular SLAM with multiple micro aerial vehicles. In *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems, Tokyo, Japan*, pages 3962–3970, 2013.
- [208] M. W. Achtelik, S. Weiss, M. Chli, F. Dellaert, and R. Siegwart. Collaborative stereo. In *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems, San Francisco, CA, USA*, pages 2242–2248, 2011.
- [209] D. G Lowe. Object recognition from local scale-invariant features. In *Proceedings of the seventh IEEE International Conference on Computer Vision, Kerkyra, Greece*, volume 2, pages 1150–1157, 1999.
- [210] D. Nistér. An efficient solution to the five-point relative pose problem. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 26(6) :756–770, 2004.
- [211] L. Kneip and P. Furgale. OpenGV : A unified and generalized approach to real-time calibrated geometric vision. In *Proceedings of the IEEE International Conference on Robotics and Automation, Hong Kong, China*, pages 1–8, 2014.
- [212] D. Fox, W. Burgard, H. Kruppa, and S. Thrun. A probabilistic approach to collaborative multi-robot localization. *Autonomous robots*, 8(3) :325–344, 2000.
- [213] A. Bahr, J. J. Leonard, and M. F. Fallon. Cooperative localization for autonomous underwater vehicles. *The International Journal of Robotics Research*, 28(6) :714–728, 2009.
- [214] M. Deghat, I. Shames, B. D. O. Anderson, and C. Yu. Localization and circumnavigation of a slowly moving target using bearing measurements. *IEEE Transactions on Automatic Control*, 59(8) :2182–2188, 2014.
- [215] G. Chai, C. Lin, Z. Lin, and M. Fu. Single landmark based collaborative multi-agent localization with time-varying range measurements and information sharing. *Systems & Control Letters*, 87 :56–63, 2016.
- [216] W. Ren and R. W. Beard. *Distributed consensus in multi-vehicle cooperative control*. Springer, 2008.
- [217] A. Loría and E. Panteley. 2 cascaded nonlinear time-varying systems : Analysis and design. In *Advanced topics in control systems theory*, pages 23–64. 2005.

- [218] A. Loria and E. Panteley. Uniform exponential stability of linear time-varying systems : revisited. *Systems & Control Letters*, 47(1) :13–24, 2002.
- [219] Y. Hong, G. Chen, and L. Bushnell. Distributed observers design for leader-following control of multi-agent networks. *Automatica*, 44(3) :846–850, 2008.
- [220] K. Ni, N. Ramanathan, M. N. H. Chehade, L. Balzano, S. Nair, Sadaf Zahedi, Eddie Kohler, Greg Pottie, Mark Hansen, and Mani Srivastava. Sensor network data fault types. *ACM Transactions on Sensor Networks*, 5(3), 2009.
- [221] T. Muhammed and R. A. Shaikh. An analysis of fault detection strategies in wireless sensor networks. *Journal of Network and Computer Applications*, 78 :267–287, 2017.
- [222] A. Mahapatro and P. M. Khilar. Fault diagnosis in wireless sensor networks : A survey. *IEEE Communications Surveys & Tutorials*, 15(4) :2000–2026, 2013.
- [223] S. Datta, C. Klinowski, M. Rudafshani, and S. Khaleque. Distributed localization in static and mobile sensor networks. In *Proceedings of the IEEE International Conference on Wireless and Mobile Computing, Networking and Communications*, pages 69–76, 2006.
- [224] N. Mohamed, J. Al-Jaroodi, I. Jawhar, and A. Eid. Using mobile sensors to enhance coverage in linear wireless sensor networks. In *Proceedings of the 12th IEEE International Symposium on Network Computing and Applications*, pages 1–6, 2013.
- [225] D. Wang, J. Liu, and Q. Zhang. Probabilistic field coverage using a hybrid network of static and mobile sensors. In *Proceedings of the Fifteenth IEEE International Workshop on Quality of Service*, pages 56–64, 2007.
- [226] A. Arora, P. Dutta, S. Bapat, V. Kulathumani, H. Zhang, V. Naik, V. Mittal, H. Cao, M. Demirbas, and M. Gouda. A line in the sand : a wireless sensor network for target detection, classification, and tracking. *Computer Networks*, 46(5) :605–634, 2004.
- [227] Y. Zhang, N. Meratnia, and P. Havinga. Outlier detection techniques for wireless sensor networks : A survey. *IEEE Communications Surveys & Tutorials*, 12(2) :159–170, 2010.
- [228] M. D. McKay, R. J. Beckman, and W. J. Conover. A comparison of three methods for selecting values of input variables in the analysis of output from a computer code. *Technometrics*, 21(2) :239–245, 1979.
- [229] J.-Y. Choi, S.-J. Yim, Y. J. Huh, and Y.-H. Choi. A distributed adaptive scheme for detecting faults in wireless sensor networks. *WSEAS Transactions on Communications*, 8(2) :269–278, 2009.
- [230] G. Matheron. Principles of geostatistics. *Economic Geology*, 58(8) :1246, 1963.
- [231] C. E. Rasmussen and C. K. I. Williams. *Gaussian Processes for Machine Learning*. Springer-Verlag, New York, 2006.
- [232] D. R. Jones. A taxonomy of global optimization methods based on response surfaces. *Journal of Global Optimization*, 21(4) :345–383, 2001.
- [233] G. Dellino, J. P. C. Kleijnen, and C. Meloni. Robust optimization in simulation : Taguchi and response surface methodology. *International Journal of Production Economics*, 125(1) :52–59, 2010.
- [234] J. S. Lehman., T. J. Santner, and W. I. Notz. Designing computer experiments to determine robust control variables. *Statistica Sinica*, 14(2) :571–590, 2004.
- [235] D. R. Jones, M. J. Schonlau, and W. J. Welch. Efficient global optimization of expensive black-box functions. *Journal of Global Optimization*, 13(4) :455–492, 1998.
- [236] M. J. Sasena. *Flexibility and Efficiency Enhancements for Constrained Global Design Optimization with Kriging Approximations*. PhD Thesis, University of Michigan, USA, 2002.
- [237] J. Villemonteix, E. Vazquez, and E. Walter. An informational approach to the global optimization of expensive-to-evaluate functions. *Journal of Global Optimization*, 44(4) :509–534, 2009.
- [238] E. Vazquez and J. Bect. Convergence properties of the expected improvement algorithm with fixed mean and covariance functions. *Journal of Statistical Planning and Inference*, 140(11) :3088–3095, 2010.
- [239] D. J. C. MacKay. *Information Theory, Inference, and Learning Algorithms*. Cambridge Univ Press, Cambridge, 2003.
- [240] B. Rustem and M. Howe. *Algorithms for Worst-Case Design and Applications to Risk Management*. Princeton University Press, 2002.
- [241] D. Du and P. M. Pardalos. *Minimax and Applications*. Kluwer Academic Publishers, Norwell, 1995.
- [242] P. Pappas and B. Rustem. An algorithm for the global optimization of a class of continuous minimax problems. *Journal of Optimization Theory and Applications*, 141(2) :461–473, 2009.
- [243] F. H. Clarke. *Optimization and Nonsmooth Analysis*. Wiley, New York, 1983.
- [244] K. Shimizu and E. Aiyoshi. Necessary conditions for min-max problems and algorithms by a relaxation procedure. *IEEE Transactions on Automatic Control*, 25(1) :62–66, 1980.
- [245] K. Shimizu, Y. Ishizuka, and J. F. Bard. *Nondifferentiable and Two-level Mathematical Programming*. Kluwer Academic Publishers, Norwell, 1997.

- 
- [246] A. M. Cramer, S. D. Sudhoff, and E. L. Zivi. Evolutionary algorithms for minimax problems in robust design. *IEEE Transactions on Evolutionary Computation*, 13(2) :444–453, 2009.
- [247] R. I. Lung and D. Dumitrescu. A new evolutionary approach to minimax problems. In *Proceedings of the 2011 IEEE Congress on Evolutionary Computation, New Orleans, USA*, pages 1902–1905, 2011.
- [248] M. Schonlau. *Computer Experiments and Global Optimization*. PhD Thesis, University of Waterloo, Canada, 1997.
- [249] C. Audet, J.E. Dennis, D.W. Moore, A. Booker, and P.D. Frank. A surrogate-model-based method for constrained optimization. *Proceedings of the 8th AIAA/NASA/USAF/ISSMO Symposium on Multidisciplinary Analysis and Optimization*, 2000.
- [250] Keane A. J. Parr J. M., Forrester A. I. J. and Holden C. M. E. Enhancing infill sampling criteria for surrogate-based constrained optimization. *Journal of Computational Methods in Sciences and Engineering*, 12(1, 2) :25–45, 2012.
- [251] B. Brown and T. Singh. Minimax design of vibration absorbers for linear damped systems. *Journal of Sound and Vibration*, 330(11) :2437–2448, 2011.
- [252] J. Morio. *Contributions à la simulation des événements rares dans les systèmes complexes*. Habilitation à diriger des recherches, Université Rennes 1, 2013.
- [253] J. Morio and M. Balesdent. *Estimation of rare event probabilities in complex aerospace and other systems : a practical approach*. Woodhead Publishing, Elsevier, 2015.
- [254] J. Morio. Non-parametric adaptive importance sampling for the probability estimation of a launcher impact position. *Reliability Engineering & System Safety*, 96(1) :178–183, 2011.
- [255] E. Vazquez and E. Walter. Estimating derivatives and integrals with kriging. In *Proceedings of the 44th IEEE Conference on Decision and Control, Seville, Spain*, pages 8156–8161, 2005.
- [256] A. Savitzky and M.J.E. Golay. Smoothing and differentiation of data by simplified least squares procedures. *Analytical chemistry*, 36(8) :1627–1639, 1964.
- [257] P. Zarchan. *Tactical and Strategic Missile Guidance*. AIAA Progress in Astronautics and Aeronautics, Washington DC, 1990.
- [258] N. A. Shneydor. *Missile Guidance and Pursuit : Kinematics, Dynamics & Control*. Horwood Publishing Limited, Chichester, 1998.
- [259] R.A. Singer and K.W. Behnke. Real-time tracking filter evaluation and selection for tactical applications. *IEEE Transactions on Aerospace and Electronic Systems*, 7(1) :100–110, 1971.
- [260] P. Baiocco and C. Bonnal. Technology demonstration for reusable launchers. *Acta Astronautica*, 120 :43–58, 2016.