



HAL
open science

Surveillance et estimation de l'état de véhicules automobiles : un champ d'applications pour l'optimisation multi-objectif

Joan Davins-Valldaura

► **To cite this version:**

Joan Davins-Valldaura. Surveillance et estimation de l'état de véhicules automobiles : un champ d'applications pour l'optimisation multi-objectif. Automatique / Robotique. Ecole Centrale de Nantes (ECN), 2016. Français. NNT: . tel-01618471

HAL Id: tel-01618471

<https://hal.science/tel-01618471v1>

Submitted on 18 Oct 2017

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.

Thèse de Doctorat

Joan
DAVINS-VALLDAURA

Mémoire présenté en vue de l'obtention du
grade de Docteur de l'École centrale de Nantes
Label européen
sous le label de l'Université de Nantes Angers Le Mans

École doctorale : Sciences et Technologies de l'Information, et mathématiques

Discipline : Automatique

Unité de recherche : Institut de Recherche en Communications et Cybernétique de Nantes

Soutenance prévue le 4 juillet 2016

Surveillance et estimation de l'état de véhicules automobiles : un champ d'applications pour l'optimisation multi-objectif

JURY

Rapporteurs : **M. Mohamed DJEMAI**, Professeur des universités, Université de Valenciennes, LAMIH, Valenciennes
M. Patrick SIARRY, Professeur des universités, Université Paris-Est Créteil, LiSSI, Créteil

Examineurs : **M. Luc DUGARD**, Directeur de Recherche CNRS, INP Grenoble, GIPSA-lab, Saint Martin d'Hères
M. François FAUVEL, Docteur Ingénieur, Renault, Technocentre, Guyancourt
M. Saïd MOUSSAOUI, Maître de conférences, HDR, École Centrale de Nantes, IRCCyN, Nantes
M. Guillermo PITA GIL, Docteur Ingénieur, Renault, Technocentre, Guyancourt
M. Franck PLESTAN, Professeur des universités, École Centrale de Nantes, IRCCyN, Nantes

* * *

Directeur de thèse : **M. Franck PLESTAN**, Professeur des universités, École Centrale de Nantes, IRCCyN, Nantes
Co-directeur de thèse : **M. Saïd MOUSSAOUI**, Maître de conférences, HDR, École Centrale de Nantes, IRCCyN, Nantes

*C'est le temps que tu as perdu pour ta rose
qui fait ta rose si importante.*

Antoine de Saint-Exupéry

Remerciements

Je tiens à exprimer ma gratitude, ma reconnaissance et mes profonds remerciements à mon directeur de thèse Franck Plestan et à mon co-encadrant Saïd Moussaoui pour leurs conseils, leurs support et leur aide tout au long de la thèse. Je tiens aussi à souligner leurs énormes contributions à la relecture de ce manuscrit.

Quiero agradecer a Guillermo Pita Gil, mi tutor a Renault durante mi tesis y mi proyecto de final de carrera, por su confianza, sus consejos y sus enseñanzas técnicas y científicas. También darle las gracias por su lado más humano y para compartir conmigo innumerables buenos momentos.

J'aimerais remercier messieurs Patrick Siarry et Mohamed Djemaï qui m'ont fait l'honneur d'accepter d'être rapporteurs de ce travail, monsieur Luc Dugard d'avoir accepté de présider le jury de thèse et monsieur François Fauvel d'avoir accepté de participer à la soutenance de ma thèse.

Je remercie l'ensemble des équipes ADTSI et Commande de l'Institut de Recherche en Communications et Cybernétique de Nantes pour m'avoir accueilli dans leurs équipes et m'avoir aussi permis de développer mon approche scientifique dans ces deux domaines.

Je remercie tous les membres de l'équipe de développement lois de commandes et du service des ADAS de Renault, pour leur accueil chaleureux et la qualité des échanges techniques.

Je n'oublie pas d'associer à ces remerciements tous mes camarades thésards, nouveaux docteurs et stagiaires qui ont fait de ces trois années à l'IRCCyn et Renault un moment agréable, convivial et personnellement enrichissant.

Finalment, agrair a la meva família i amics pel seu valuós suport durant aquests anys, en el que la distancia no ha sigut un impediment per estar al meu costat en tot moment.

Table des matières

Résumé et mots-clés (Abstract and keywords)	ix
Abréviations	xi
Notations	xiii
1 Introduction générale	1
1.1 Motivation de la thèse	2
1.1.1 Système de surveillance de la pression des pneumatiques	2
1.1.2 Système de conduite automatique en embouteillage	3
1.2 Contributions principales	5
1.2.1 Articles dans des revues internationales	5
1.2.2 Articles dans des revues internationales en soumission	5
1.2.3 Brevets déposés	5
1.2.4 Communications dans des conférences avec actes et comité de lecture	5
1.2.5 Communications dans des colloques ou des journées scientifiques sans actes	6
1.2.6 Documents techniques	6
1.3 Autres contributions	6
1.4 Organisation du manuscrit	7
I Optimisation globale de fonctions coûteuses et boîtes noires	9
2 État de l’art	11
2.1 Notions fondamentales	12
2.2 Optimisation globale mono-objectif	15
2.2.1 Algorithmes déterministes	16
2.2.2 Algorithmes stochastiques directs	16
2.2.3 Algorithmes stochastiques indirects	17
2.2.4 Modèles de substitution	18
2.2.5 Fonctions de covariance	24
2.2.6 Estimation de paramètres de covariance	26
2.2.7 Plan d’expérience	27
2.2.8 Critère d’échantillonnage	29
2.3 Optimisation globale multi-objectif	33
2.3.1 Quelques définitions	34
2.3.2 <i>Nondominated Sorting Genetic Algorithm 2</i>	35
2.3.3 <i>Pareto Efficient Global Optimization</i>	36
2.3.4 <i>Multi-Objective Particle Swarm Optimization</i>	37
2.3.5 <i>Pareto Envelope-based Selection Algorithm 2</i>	37
2.3.6 <i>Strength Pareto Evolutionary Algorithm 2</i>	38
2.3.7 Récapitulatif	38
2.4 Conclusion	39

3	Double <i>krigeage</i> pour l'optimisation multi-objectif	43
3.1	Nouvelle méthode d'optimisation multi-objectif	44
3.2	Comparaison des algorithmes KEEP et ParEGO	46
3.3	Analyse comparative des performances	47
3.3.1	Conditions d'optimisation	49
3.4	Conclusion	52
4	Système de surveillance de la pression des pneumatiques	57
4.1	Introduction	58
4.2	Système de détection du SSPP indirect	59
4.2.1	Système de Détection de Crevaisson (SDC)	59
4.2.2	Système de Détection de Diffusion (SDD)	61
4.2.3	Algorithme de décision	62
4.3	Base de données de tests	64
4.3.1	Niveaux de sous-gonflages	64
4.3.2	Types de routes	65
4.3.3	Charge du véhicule	65
4.3.4	Type de pneumatiques	65
4.4	Plan de validation	65
4.4.1	Critères de performance	66
4.5	Mise au point du SSPP indirect	68
4.5.1	Mise au point du SDC	69
4.5.2	Mise au point du SDD	71
4.5.3	Étape intermédiaire	73
4.5.4	Mise au point de l'algorithme de décision	74
4.6	Conclusion	77
II	Observateurs pour les systèmes d'aide à la conduite	79
5	Introduction aux observateurs	81
5.1	Notations et notions mathématiques	81
5.2	Observateurs pour systèmes linéaires	82
5.2.1	Observateur de Luenberger	83
5.2.2	Observateur de Kalman	83
5.2.3	Observateur dans une boucle de commande	84
5.3	Observation des systèmes non linéaires	85
5.3.1	Forme canonique d'observabilité et synthèse d'observateurs	86
5.3.2	Observateurs à grand gain	89
5.3.3	Observateurs par mode glissant	90
5.4	Conclusion	92
6	Estimation d'état dans le cadre du <i>Traffic Jam Pilot</i> (TJP)	93
6.1	Systèmes de contrôle et observateurs pour l'automobile	94
6.2	Dynamique latérale du véhicule	96
6.2.1	Classification des modèles du mouvement latéral du véhicule	98
6.2.2	Modèle bicyclette	98
6.2.3	Modèle bicyclette avec un véhicule cible	99
6.2.4	Radar et caméra	100
6.2.5	Colonne de direction	100
6.2.6	Modèle complet du véhicule	101
6.3	Contrôle latéral TJP	103
6.4	Observateur linéaire	105

6.4.1	Analyse de l'observabilité	105
6.4.2	Filtre de Kalman	105
6.5	Observateurs non linéaires	109
6.5.1	Observabilité et condition d'observabilité	110
6.5.2	Forme canonique d'observabilité	111
6.5.3	Observateur à grand gain	112
6.5.4	Observateur par mode glissant	113
6.6	Optimisation du réglage des observateurs non linéaires	114
6.6.1	Critères de performance	114
6.6.2	Optimisation des gains de l'observateur	115
6.6.3	Résultats de l'optimisation des observateurs	116
6.7	Installation expérimentale	117
6.8	Résultats par simulation	118
6.9	Résultats sur des données réelles	123
6.10	Conclusion	125
Conclusion générale et perspectives		129
Annexes		135
A Autres systèmes d'aide à la conduite		137
A.1	Système de stationnement automatique	137
A.2	Système de <i>parking valet</i> autonome	138
A.3	Système de freinage d'urgence	138
A.4	Système de surveillance de la distraction du conducteur	139
B Réglage de la boucle du contrôle latéral du <i>Traffic Jam Pilot</i>		141
B.1	Introduction	141
B.2	Outil d'optimisation	142
B.3	Outil de mise au point	144
Références bibliographiques		158

Résumé

Cette thèse est dédiée à l'optimisation globale multi-objectif de fonctions coûteuses, avec des applications de mise au point de systèmes de surveillance et d'aide à la conduite automobile. Après avoir présenté un état de l'art du domaine, un nouvel algorithme basé sur une stratégie de double *krigeage* est proposé afin de réduire le nombre d'évaluations de la fonction objectif. La première application de l'algorithme concerne l'optimisation des paramètres de mise en œuvre d'un système de surveillance de la pression des pneumatiques sans capteur de pression. En plus du nombre important de paramètres à optimiser, cette mise au point est soumise à des contraintes de test sur une très grande base de données de roulage, dans différents scénarios et à un temps de calcul limité. La seconde application concerne un système de conduite automatique dans une situation d'embouteillage. Le travail est focalisé sur l'utilisation d'observateurs pour le contrôle latéral. La solution actuellement utilisée par Renault/Nissan est fondée sur un filtre de Kalman. Afin de réduire le nombre de paramètres de réglage, des solutions basées sur des approches non linéaires (grand gain et mode glissant) ont été proposées. Les gains de ces observateurs ont été réglés en utilisant le nouvel algorithme d'optimisation et en tenant compte d'essais sur route dont les mesures ont généré une grande base de données.

Mots-clés

Optimisation multi-objectif, Fonctions coûteuses, Modèles de substitution, Observateurs non linéaires, Applications automobiles.

Abstract

This thesis deals with multi-objective optimization for expensive evaluation functions and its application for the tuning of vehicle monitoring and driver assistance systems in the context of automotive engineering. After the presentation of a state of the art on multi-objective optimization methods, a new algorithm based on a double kriging strategy is proposed in order to reduce the number of objective function evaluations. The first application of the optimization algorithm concerns the tuning of an indirect tire-pressure monitoring system (without sensor). In addition to the tuning of high number of parameters, the optimization is constrained by the use of a large database, containing measurements obtained in real driving situations, and has to provide an optimal tuning in a limited processing time. The second application falls within lateral control of an autonomous driving system in a traffic jam situation. The current solution used by Renault/Nissan is based on a Kalman filter. In order to reduce the number of tuning parameters, solutions based on nonlinear approaches (high gain and sliding mode) are proposed. The tuning of the gains appearing in all these observers has been performed by using the proposed optimization algorithm, and by taking into account real driving data with measurements contained in a large database.

Keywords

Multi-objective optimization, Expensive evaluation functions, Surrogate models, Nonlinear observers, Automotive applications.

Abréviations

ADAS	Système d'aide à la conduite (<i>Advanced Driver Assistance System</i>)
AdD	Algorithme de Décision
AEBS	Système avancé de freinage d'urgence (<i>Advanced Emergency Braking System</i>)
BdD	Base de données
CdU	Cas d'Usage
CoG	Centre de Gravité
EERC	Estimation de l'Erreur Relative de la Courbure
EERDL	Estimation de l'Erreur Relative de la Distance Latérale
EGO	<i>Efficient Global Optimization</i>
EI	<i>Expected Improvement</i>
EPS	<i>Electric Power Steering system</i>
FA	Fausse alerte
GA	Algorithme d'optimisation génétique
gBdD	grande Base de Données
HCL	Hypercube Latin
HI	<i>Hypervolume indicator</i>
LCA	<i>Line Centering Assist</i>
KEEP	<i>Kriging for Expensive Evaluations Pareto</i>
MOE	Algorithmes multi-objectif évolutionnaires
MOPSO	<i>Multi-Objective Particle Swarm Optimization</i>
ND	Non détection
NSGA2	<i>Non-dominated Sorting Genetic Algorithm 2</i>
ParEGO	<i>Pareto Efficient Global Optimization</i>
PdE	Plan d'Expérience
PdV	Plages de Vitesse
PEI	<i>Pareto Expected Improvement</i>
PESA2	<i>Pareto Envelope-based Selection Algorithm 2</i>
PF	<i>Pareto Front</i> ou front de Pareto
PS	<i>Pareto Set</i> ou ensemble de Pareto
PSO	Algorithme d'optimisation par essaims de particules
SDC	Système de Détection de Crevaisson
SDD	Système de Détection de Diffusion
SPEA2	<i>Strength Pareto Evolutionary Algorithm 2</i>
SSPP	Système de Surveillance de la Pression Pneumatique
TJP	Conduite automatique en embouteillage <i>Traffic Jam Pilot</i>
VdR	Vitesse de Référence

Notations

Partie 1

f	Fonction mono-objectif à optimiser
\mathbf{x}	Configuration de paramètres
\mathcal{X}	L'espace de recherche ou l'espace de paramètres
\mathcal{F}	L'espace de performances
m	Le nombre de paramètres à optimiser
n	Le nombre d'objectifs à optimiser
\mathbf{f}^\bullet	Solution optimale globale
\mathbf{f}°	Solution optimale locale
\mathbf{f}^*	Solution optimale proposée par l'algorithme d'optimisation
\mathbf{x}^\bullet	Configuration de paramètres optimale globale
\mathbf{x}°	Configuration de paramètres optimale locale
\mathbf{x}^*	Configuration de paramètres optimale proposée par l'algorithme d'optimisation
j	Nombre d'évaluations de la fonction objectif réalisées
j_0	Nombre d'évaluations initiales
J	Nombre d'évaluations maximal
$\mathbf{X}^{(j)}$	Vecteur avec toutes les configurations de paramètres évaluées jusqu'à j
$\mathbf{F}^{(j)}$	Vecteur avec toutes les performances obtenues jusqu'à l'évaluation j
F	Variable gaussienne équivalente de la fonction objectif
\hat{F}	Modèle de substitution (<i>krigeage</i>) de F
\hat{f}	Moyenne du prédicteur par <i>krigeage</i>
$\hat{\sigma}^2$	Variance de l'erreur du prédicteur par <i>krigeage</i>
λ	Le vecteur de coefficients des solutions du <i>krigeage</i>
γ	Le vecteur de multiplicateurs de Lagrange
$k(\cdot, \cdot)$	La fonction de covariance
$\mathbf{k}(\mathbf{x})$	Le vecteur de covariance entre une configuration et les évaluations réalisées
\mathbf{K}	La matrice de covariance
\mathbb{E}	Espérance mathématique
$h(\cdot, \cdot)$	La distance entre deux configurations de paramètres
PI_{HI}	La valeur d'amélioration de performance ou <i>performance improvement</i>
R_{eff}	Le rayon effectif
Ω	La vitesse angulaire de la roue
v_x	La vitesse longitudinale
FA_{PV}	Le taux de fausse alerte en utilisant tous les CdU pondérés
ND_{PV}	Le taux de non détection en utilisant tous les CdU pondérés

Partie 2

x	Variable d'état
y	Variable de sortie
u	Variable d'entrée ou commande
\mathcal{X}	L'espace opérationnel du système
\mathcal{U}	L'espace opérationnel de la commande
n	Le nombre de variables d'état
m	Le nombre de variables de sortie
p	Le nombre de variables d'entrée
O	Matrice d'observabilité
\hat{x}	Estimation de la variable d'état
$\dot{\hat{x}}$	Dynamique de la variable d'état
$\dot{\hat{x}}$	Dynamique de l'estimation de la variable d'état
$w(t)$	Bruit du système ou d'évolution
$v(t)$	Bruit de mesure
$f(x, t)$	Dynamique qui ne dépend que de l'état et de paramètres variant dans le temps
$\chi(u, y)$	Dynamique qui ne dépend que des sorties et entrée
$\Delta f(x, t)$	Dynamique inconnue du système
ζ	Variable d'état dans la forme canonique
Γ	Vecteur de transformation de coordonnées ($\zeta = \Gamma(x)$)
k	Indice d'observabilité
κ	Terme correcteur de l'observateur
C_f	Coefficient de frottement visqueux - pneumatiques avant
C_r	Coefficient de frottement visqueux - pneumatiques arrière
M	Masse du véhicule
I_z	Moment d'inertie en lacet
l_f	Distance longitudinale du CoG à l'essieu avant
l_r	Distance longitudinale du CoG à l'essieu arrière
w_p	Pulsation de filtrage de la courbure
w_m	Pulsation propre de la colonne de direction
ξ	Facteur d'amortissement de la colonne de direction
w_f^n	Forces latérales de perturbation - roues avant
w_r^n	Forces latérales de perturbation - roues arrières
k_{eps}	Facteur d'amortissement de la colonne de direction
R^w	<i>World frame</i>
R^v	<i>Vehicle frame</i>
v	Vitesse du véhicule
v_x	Vitesse longitudinale du véhicule
v_y	Vitesse latérale du véhicule
θ_f	L'angle de la vitesse aux roues avant
θ_r	L'angle de la vitesse aux roues arrière
ψ	L'angle de lacet du véhicule
$\dot{\psi}$	La vitesse angulaire en lacet
ψ_i	L'angle idéal de lacet défini par la trajectoire du véhicule
ψ_r	Différence entre l'angle de lacet du véhicule ψ et l'angle idéal de lacet
y_t	La distance latérale du véhicule par rapport à la trajectoire du véhicule cible
y_c	La distance latérale par rapport au véhicule cible mesurée par la caméra
ρ	La courbure de la trajectoire
x_m	La distance longitudinale entre les deux véhicules
α_{in}	L'angle de braquage du volant
α	L'angle de braquage des roues
$ e_\rho $	L'erreur absolue d'estimation de la courbure
$ e_{y_t} $	L'erreur absolue d'estimation de la distance latérale

Introduction générale

Sommaire

1.1	Motivation de la thèse	2
1.1.1	Système de surveillance de la pression des pneumatiques	2
1.1.2	Système de conduite automatique en embouteillage	3
1.2	Contributions principales	5
1.2.1	Articles dans des revues internationales	5
1.2.2	Articles dans des revues internationales en soumission	5
1.2.3	Brevets déposés	5
1.2.4	Communications dans des conférences avec actes et comité de lecture	5
1.2.5	Communications dans des colloques ou des journées scientifiques sans actes	6
1.2.6	Documents techniques	6
1.3	Autres contributions	6
1.4	Organisation du manuscrit	7

Au cours des dernières années, les constructeurs automobiles ont investi dans la recherche et le développement technologique de sorte à améliorer la consommation énergétique, le confort et la sécurité des véhicules. Concernant la sécurité, les *systèmes d'aide à la conduite* (ou *Advanced Driver Assistance Systems* (ADAS)) et les *systèmes de surveillance* font partie des thématiques de développement prioritaires. Les premiers systèmes ont pour objectif de réaliser ou d'aider à la réalisation de certaines manœuvres de manière automatique afin de faciliter la conduite du véhicule. Les seconds ont pour but d'alerter et de prévenir le conducteur en cas de situations à risques.

Les véhicules équipés de ces systèmes utilisent un nombre important de capteurs qui fournissent les mesures liées à l'état du véhicule et de son environnement. De nombreux calculateurs sont de plus en plus embarqués afin d'exécuter les différentes tâches. Un exemple est la nouvelle *Renault Espace V* (voir Figure 1.1), qui est équipée de plusieurs ADAS et de systèmes de surveillance comme le régulateur de vitesse adaptatif, la manœuvre de parking partiellement automatisée, la reconnaissance de signalisation. Afin de fusionner toutes ces mesures, les ADAS et les systèmes de surveillance et de détection font appel à des lois de commande complexes qui sont définies en utilisant un nombre important de variables d'état. Néanmoins, certaines de ces variables ne sont pas mesurées et l'utilisation d'observateurs ou d'estimateurs devient nécessaire. De plus, ces systèmes doivent faire face à des perturbations et des mesures

SYSTÈMES D'ASSISTANCE AU CONDUCTEUR

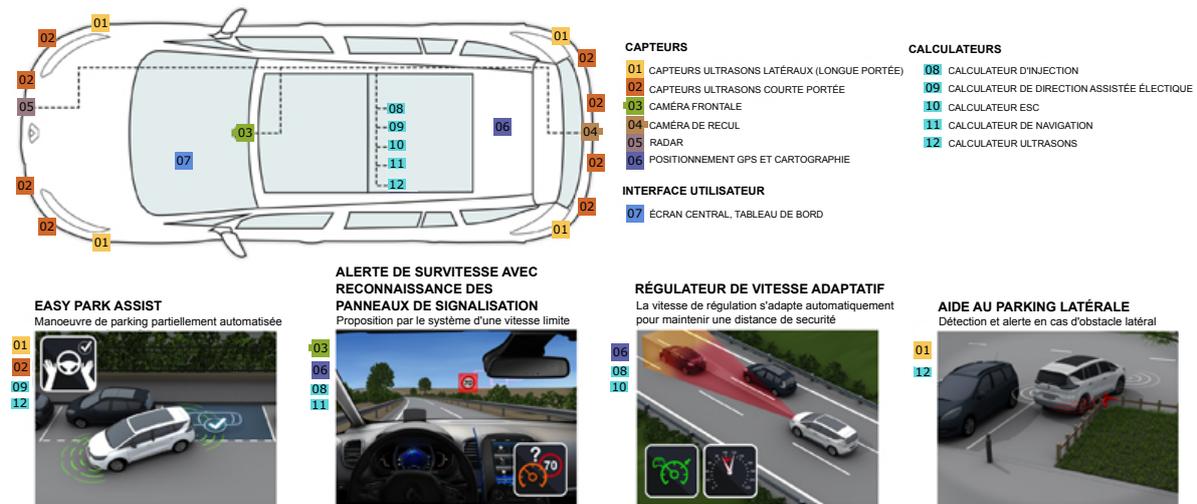


FIGURE 1.1: Systèmes d'aide à la conduite de la nouvelle *Renault Espace V* en détaillant les capteurs et calculateurs utilisés. (source de l'image : [Web, 1])

bruitées, ce qui a un impact direct sur leur robustesse.

Du point de vue de la conception de ce type de systèmes, les lois de commande et les estimateurs des grandeurs non mesurées doivent être réglés selon plusieurs critères : un bon fonctionnement du système, une erreur d'estimation faible, une robustesse face aux bruits de mesures et aux perturbations. Cependant, la complexité des lois de commande et des observateurs engendre un grand nombre de paramètres à mettre au point, ce qui transforme le réglage du système en un problème d'optimisation complexe. De plus, afin de garantir une mise au point assurant un bon fonctionnement dans diverses situations, ce réglage doit être testé sur un nombre important de scénarios de conduite, en utilisant une grande base de données avec des enregistrements réels.

1.1 Motivation de la thèse

La motivation principale de cette thèse est de présenter une solution de réglage optimal des paramètres de mise en oeuvre de systèmes de surveillance de l'état du véhicule et d'aide à la conduite. En effet, le recours à une approche manuelle pour le réglage de ces paramètres est une tâche fastidieuse et chronophage en raison de la taille des bases de données utilisées, du nombre important de critères à optimiser et du nombre élevé de paramètres à régler. **Sur le plan méthodologique, les objectifs de la thèse se reformulent en la proposition d'algorithmes d'optimisation multi-objectif répondant aux exigences de la mise au point automatique des systèmes.** Sur le plan appliqué, les travaux de cette thèse sont focalisés sur deux systèmes : un système de *surveillance de la pression des pneumatiques* et un système de *conduite automatique en embouteillage*. D'autres ADAS et systèmes de détection en développement chez Renault sont présentés dans l'Annexe A afin de montrer que les travaux de la thèse ont une portée au delà de ces deux applications. De plus, ceci montre que les contraintes et les difficultés traitées dans cette thèse sont aussi présentes pour d'autres systèmes.

1.1.1 Système de surveillance de la pression des pneumatiques (SSPP)

L'objectif de ce système est d'alerter le conducteur en cas de perte de pression des pneumatiques, ce qui permet de réduire les émissions de CO₂ causées par un sous-gonflage, d'allonger la durée de vie des pneumatiques et d'augmenter la sécurité des passagers, en réduisant le risque d'éclatement des roues.



FIGURE 1.2: Prototypes de véhicules autonomes : (en haut à gauche) la Google Car, (en haut à droite) la Volkswagen Passat appelée *Junior*, (en bas à gauche) la nouvelle Volvo XC90 *IntelliSafe* et (en bas à droite) la BMW i3. (source de l'image : [Web, 2], [Web, 3], [Web, 4] et [Web, 5])

Les solutions SSPP actuelles sont basées sur l'utilisation de capteurs de pression installés sur chaque valve des roues du véhicule en mesurant en temps réel les valeurs de pression et de température [Schimetta et al., 2000]. L'inconvénient de ces solutions est que les pneumatiques doivent être adaptés à l'installation de tels capteurs, que ces capteurs de pression nécessitent une maintenance régulière pour minimiser le risque de défaut et la perte de détection, et que les capteurs de pression engendrent des coûts de fabrication et d'entretien significatifs. Une nouvelle solution sans capteur de pression (SSPP indirect), en phase de développement chez Renault, propose de mettre en place un système de détection d'un sous-gonflage à partir de l'analyse de signaux présents sur le bus CAN (angle volant, vitesses angulaires, régime moteur et accélérations) [El-Tannoury, 2012]. En revanche, cette nouvelle solution est plus complexe que les solutions actuelles et sa mise au point est plus difficile.

Le SSPP indirect est constitué d'algorithmes de détection de sous-gonflage qui font appel à un nombre important de paramètres de réglage. Afin d'optimiser tous ces paramètres et valider le réglage final obtenu, une grande base de données de plus de 1 380 000 km de roulage a été conçue. Par conséquent, le temps de simulation du système sur toute cette base de données fait que la mise au point manuelle des algorithmes de détection du SSPP est une tâche complexe, fastidieuse et chronophage.

Le premier objectif de cette thèse est de concevoir une stratégie de mise au point automatique du système SSPP indirect en prenant en compte la complexité des algorithmes, le nombre important de paramètres à régler, le caractère multi-objectif du critère à optimiser et la très grande taille de la base de données.

1.1.2 Système de conduite automatique en embouteillage

La conception de ce système correspond à une des premières phases du projet *véhicule autonome*, qui est une des priorités actuelles des constructeurs automobiles. Les différentes évolutions du véhicule autonome sont classées en fonction du niveau d'autonomie défini par le standard NHTSA (USA) :

- N0 - Aucune automatisation
- N1 - Automatisation de certaines fonctions, comme par exemple les systèmes ABS¹ et ESP². À ce niveau, les systèmes sont considérés comme des fonctions d'assistance et le conducteur a toujours le contrôle du véhicule.
- N2 - Automatisation de fonctions combinées, comme par exemple le limiteur/régulateur de vitesse. Dans ce cas, les systèmes prennent en charge le contrôle du véhicule dans quelques situations spécifiques.
- N3 - Conduite autonome limitée. Dans ce contexte, les systèmes sont très autonomes ; néanmoins, ils peuvent nécessiter l'interaction du conducteur dans une situation atypique (perte de mesures, crevaison, route en travaux) en le prévenant avec une marge de temps suffisante.
- N4 - Conduite autonome complète.

Une classification alternative est faite par rapport à l'attention du conducteur :

- *Eyes on* : le conducteur doit superviser de manière permanente la conduite autonome et prendre la main s'il le considère nécessaire, ce qui correspond à une autonomie N1 et N2.
- *Eyes off* : le conducteur n'a pas besoin de superviser la conduite autonome ; cependant, le système peut requérir son intervention dans certaines situations. Il s'agit d'une autonomie N3.
- *Mind off* : le conducteur peut s'écarter de la tâche de conduite car celle-ci est gérée complètement par le véhicule, ce qui correspond à une autonomie N4.

Les *prototypes* de véhicules autonomes qui sont dans une phase plus avancée sont la Volkswagen Passat Junior, la Volvo XC90 IntelliSafe, la Tesla Model S AutoPilot et la BMW i3 AutoPilot (voir Figure 1.2). Ces prototypes ont réussi un niveau N3 d'autonomie avec une attention du conducteur proche du niveau *eyes off* ; néanmoins, les cas d'usages et les situations de fonctionnement sont très limitées et la robustesse du système vis-à-vis des défauts des capteurs et la dégradation des mesures n'est pas encore suffisante. Actuellement, un des véhicules autonomes de référence est la *Google Car*, capable de s'adapter à plusieurs situations et un des seuls à être considéré comme un vrai *eyes off*. Néanmoins, ces prototypes utilisent une technologie onéreuse, ce qui les rend non commercialisables à ce jour.

Concernant les véhicules autonomes du niveau N2 et *eyes on*, on remarque que certains sont déjà sur le marché. Il s'agit de véhicules équipés d'un système qui a pour objectif de contrôler le véhicule dans des *situations d'embouteillage* à basse vitesse et en autoroute à haute vitesse, le système étant appelé *Traffic Jam Assist* ou *Traffic Jam Pilot* (TJP). Ce système sera étudié dans le Chapitre 6 de cette thèse. En fait, ce système peut être vu comme une combinaison du système ACC³ qui garantit une distance inter-véhiculaire donnée (contrôle longitudinal), et du système LCA⁴ qui garantit un bon alignement du véhicule (contrôle latéral). Dans ce contexte, Volvo fait office de référence avec la *Volvo v40* présentée dès 2012, et actuellement avec *Volvo XC90*. D'autres véhicules à mentionner sont la Volkswagen Passat, la BMW i3, l'Audi Q7, les Mercedes Classe C, E et S, l'Aura RLX et l'Infiniti Q50.

Le second objectif de cette thèse est de proposer des méthodes d'observation d'état optimisées pour le contrôle latéral du TJP plus performantes que la méthode d'estimation d'état actuellement envisagée par Renault/Nissan. En effet, les solutions classiques demandent de concevoir un estimateur pour plusieurs plages de vitesse afin de linéariser la dynamique du véhicule et de proposer un ensemble d'observateurs linéaires (de type Kalman). La solution proposée ne considère qu'un seul observateur non linéaire, ce qui facilite fortement la tâche de mise au point du système.

¹Antiblockiersystem ou système anti-blocage des roues

²Electronic Stability Program ou stabilisateur de trajectoire

³Adaptive Cruise Control ou système de régulateur automatique de vitesse.

⁴Line Centering Assist ou système de centrage automatique du véhicule à la voie.

1.2 Contributions principales

Cette thèse a été effectuée entre mars 2013 et mars 2016 dans le cadre d'une convention CIFRE entre l'Institut de Recherche en Communications et Cybernétique de Nantes (IRCCyN) à l'École Centrale de Nantes (ECN), et Renault S.A.S au sein du Technocentre à Guyancourt dans le service DEA-SA (Systèmes ADAS).

Les travaux réalisés dans la thèse ont permis de réaliser une étude comparative d'algorithmes d'optimisation multi-objectif pour la mise au point automatique. Ensuite, a été proposée une méthode d'optimisation capable de répondre aux exigences de la mise au point automatique en termes de temps de calcul limité. Enfin, cette méthode a été utilisée à des fins d'optimisation de deux systèmes : le SSPP et le contrôle latéral du TJP.

Ces résultats novateurs ont donné lieu à des publications de différents types :

1.2.1 Articles dans des revues internationales

1. Joan DAVINS-VALLDAURA, Saïd MOUSSAOUI, Guillermo PITA-GIL et Franck PLESTAN. *Parego extensions for multi-objective optimization of expensive evaluation functions*. Journal of Global Optimization, 18 pages, Springer, 2016. (**Version accessible en ligne. En attente de mise sous-pressé**)

1.2.2 Articles dans des revues internationales en soumission

1. Joan DAVINS-VALLDAURA, Franck PLESTAN, Saïd MOUSSAOUI et PITA-GIL, Guillermo. *State and road curvature estimation for autonomous vehicles - nonlinear observers, optimal tuning and experimental evaluation*. IEEE Transactions on Intelligent Transportation Systems. (**Soumise en décembre 2015**)

1.2.3 Brevets déposés

1. Joan DAVINS-VALLDAURA, Franck PLESTAN, Saïd MOUSSAOUI, Iris BALLESTEROS et Jean-Philippe VIGNAUD. *Procédé de contrôle latéral de la trajectoire d'un véhicule à plages de vitesses variables*. N.Brevet Renault : PJ-15-0686. Dossier de dépôt du brevet envoyé à l'INPI. Avril 2016.

1.2.4 Communications dans des conférences avec actes et comité de lecture

1. Joan DAVINS-VALLDAURA, Saïd MOUSSAOUI, Guillermo PITA-GIL et Franck PLESTAN. *Parego extensions for multi-objective optimization of expensive evaluation functions*. Dans World Congress on Global Optimization, Gainesville, United States, février 2015. (*Présentation orale réalisée par J.DAVINS-VALLDAURA*)
2. Joan DAVINS-VALLDAURA, Saïd MOUSSAOUI, Franck PLESTAN et Guillermo PITA-GIL. *Optimisation des paramètres d'un système de surveillance de la pression des pneumatiques d'un véhicule automobile*. XXVème Colloque GRETSI. Lyon, 2015. (*Présentation poster réalisée par J.DAVINS-VALLDAURA*)
3. Joan DAVINS-VALLDAURA, Franck PLESTAN, Saïd MOUSSAOUI et Guillermo PITA-GIL. *Sliding mode observer design for the road curvature estimation in Traffic Jam Pilot system*. Dans Workshop on Variable Structure Systems, Nanjing, Chine, 2016 (*Présentation orale acceptée, à réaliser en Juin 2016 par F.PLESTAN*)

1.2.5 Communications dans des colloques ou des journées scientifiques sans actes

1. Joan DAVINS-VALLDAURA, Guillermo PITA-GIL, Saïd MOUSSAOUI et Franck PLESTAN. *Control algorithm : Tuning and optimization*. Training in Embedded Predictive control and Optimization (TEMPO). Guyancourt, 2015. (*Présentation orale réalisée par J.DAVINS-VALL-DAURA*)
2. Joan DAVINS-VALLDAURA, Saïd MOUSSAOUI, Guillermo PITA-GIL et Franck PLESTAN. *Multi-objective optimization for tuning driver assistance systems using large databases*. Workshop on Recent Advances in Multi-Objective Optimization. Nantes, 2015. (*Présentation orale réalisée par J.DAVINS-VALLDAURA*)
3. Joan DAVINS-VALLDAURA, Saïd MOUSSAOUI, Franck PLESTAN et Guillermo PITA-GIL. *Optimisation d'un système de surveillance de la pression des pneumatiques*. Groupe de Travail en Automatique et Automobile. Nantes, 2015. (*Présentation orale réalisée par J.DAVINS-VALLDAURA*)
4. Joan DAVINS-VALLDAURA, Saïd MOUSSAOUI, Franck PLESTAN et Guillermo PITA-GIL. *Optimisation des paramètres d'un système de surveillance de la pression des pneumatiques d'un véhicule automobile*. La Journée de Doctorants de l'école doctorale STIM. Angers, 2015. (*Présentation poster réalisée par J.DAVINS-VALLDAURA*)

1.2.6 Documents techniques

1. Joan DAVINS-VALLDAURA et Philippe SAINT-LOUP. *Project ATPMS – Tuning Algorithm - Functional Specification*. N.65616-2015-05, 1–39, Renault, 2015. (*Document confidentiel*)
2. Joan DAVINS-VALLDAURA et Guillermo PITA-GIL. *Project AD1 - Low level identification and tuning - Functional Specification*. N.65616-2015-06, 13–20, Renault, 2015. (*Document confidentiel*)

1.3 Autres contributions

Un des avantages de réaliser une thèse dans un contexte industriel est l'opportunité de travailler sur d'autres projets internes à l'entreprise. En effet, plusieurs contributions ont été réalisées en traitant de sujets différents des motivations principales de la thèse.

D'autres brevets ont été déposés concernant le projet du *Système de Surveillance de la Pression Pneumatique indirect* :

1. Joan DAVINS-VALLDAURA, Guillermo PITA-GIL et Philippe SAINT-LOUP. *Fuzzy-logic-based decision support method in a system for monitoring motor vehicle tyre pressure*. N.Brevet : WO2015071556. Publié en Mai 2015. (*Auteur principal du brevet*)
2. Guillermo PITA-GIL, Philippe SAINT-LOUP et Joan DAVINS-VALLDAURA. *Process of detection of a curved section of roadway with transverse slope starting from a motor vehicle in displacement on this roadway*. N.Brevet : FR3015413. Publié en Octobre 2014. (*Coauteur du brevet*)
3. Guillermo PITA-GIL, Philippe SAINT-LOUP et Joan DAVINS-VALLDAURA. *Method for detecting an imbalance of a vehicle wheel while the vehicle is rolling*. N.Brevet : WO2015044552. Publié en Avril 2015. (*Coauteur du brevet*)
4. Guillermo PITA-GIL, Philippe SAINT-LOUP et Joan DAVINS-VALLDAURA. *Neural-network-based decision support method in a system for monitoring motor vehicle tyre pressure*. N.Brevet : WO2015071557. Publié en Mai 2015. (*Coauteur du brevet*)

5. Philippe SAINT-LOUP, Guillermo PITA-GIL et Joan DAVINS-VALLDAURA. *Method for decision-making assistance by an empirical and matrix-based approach in a system for monitoring the pressure of the tyres of a motor vehicle*. N.Brevet : WO2015071558. Publié en Mai 2015. (Coauteur du brevet)
6. Philippe SAINT-LOUP, Guillermo PITA-GIL et Joan DAVINS-VALLDAURA. *Bayesian-approach-based decision support method in a system for monitoring motor vehicle tyre pressure*. N.Brevet : WO2015071559. Publié en Mai 2015. (Coauteur du brevet)
7. Stéphanie LESCARRET, Guillermo PITA-GIL, Philippe SAINT-LOUP et Joan DAVINS-VALLDAURA. *Stratégie de détection indirecte de sous-gonflage par identification d'un écart de fréquence inter essieu*. N.Brevet : PJ-15-0063 (Renault). Brevet en cours de dépôt. (Coauteur du brevet)
8. Sébastien SALIOU, Guillermo PITA-GIL, Philippe SAINT-LOUP et Joan DAVINS-VALLDAURA. *Système d'aide à l'identification de sous-gonflage pneumatique indirect par analyse multicritère des vitesses angulaires*. N.Brevet : PJ-15-0064 (Renault). Brevet en cours de dépôt. (Coauteur du brevet)

Les brevets réalisés concernant le projet du *Traffic Jam Pilot* :

1. Iris BALLESTEROS, Renaud DEBORNE, Sorin OLARU et Joan DAVINS-VALLDAURA. *Procédé de contrôle de la trajectoire prédictif d'un véhicule automobile autonome en virage*. N.Brevet : PJ-16-0019 (Renault). Déclaration d'invention en cours de validation. (Coauteur du brevet)
2. Iris BALLESTEROS, Maud GEOFFRIAULT, Renaud DEBORNE et Joan DAVINS-VALLDAURA. *Procédé de contrôle de la trajectoire d'un véhicule automobile autonome en virage avec courbure feedforward*. N.Brevet : PJ-15-0700 (Renault). Déclaration d'invention en cours de validation. (Coauteur du brevet)

1.4 Organisation du manuscrit

Cette thèse est divisée en deux grandes parties : la première est focalisée sur l'optimisation globale et son application à la mise au point du *Système de Surveillance de la Pression Pneumatique*. La seconde partie est consacrée à la synthèse d'observateurs et leur optimisation dans le cadre du contrôle latéral du *Traffic Jam Pilot*.

PARTIE I - Optimisation globale de fonctions coûteuses et boîtes noires

Chapitre 2 - État de l'art. Dans ce chapitre, différentes méthodes d'optimisation globale sont présentées en fonction du nombre d'objectifs à optimiser. Tout d'abord, les algorithmes mono-objectif (déterministes, stochastiques directs et stochastiques indirects) sont présentés brièvement. Afin de traiter l'optimisation de fonctions coûteuses avec un nombre d'évaluations limité, l'optimisation avec modèles de substitution est expliquée en détail : les modèles de substitution les plus courants, les fonctions de covariance, la sélection des paramètres de covariance, les plans d'expérience et les critères d'échantillonnage. Ensuite, les algorithmes multi-objectif de référence sont présentés, en particulier les algorithmes *Non-dominated Sorting Genetic Algorithm* (NSGA2) et *Pareto Efficient Global Optimization* (ParEGO), ainsi que quelques algorithmes multi-objectif évolutionnaires (MOE). Une attention particulière est portée sur les avantages et inconvénients de chacun.

Chapitre 3 - Optimisation multi-objectif avec une stratégie de double *Krigeage*. Un nouvel algorithme d'optimisation globale multi-objectif, conçu spécialement pour optimiser des fonctions inconnues et coûteuses, est présenté dans ce chapitre. Cette nouvelle méthode, appelée *Kriging for Expensive Evaluations Pareto* (KEEP), est une extension de l'algorithme d'optimisation globale multi-objectif ParEGO basé sur l'utilisation d'un modèle de substitution (*krigeage*). La principale innovation de KEEP est l'introduction d'un second modèle de substitution, afin d'estimer la probabilité d'appartenir à l'ensemble de

Pareto (*Pareto Set*), ce qui permet de converger plus rapidement vers les solutions proches du front de Pareto (*Pareto Front*) en utilisant les idées principales de ParEGO. Après une comparaison entre KEEP et son prédécesseur ParEGO, une analyse comparative des algorithmes d'optimisation globale multi-objectif est faite pour tester la performance de ce nouvel algorithme en utilisant les fonctions test ZDT et DTLZ.

Chapitre 4 - Système de Surveillance de la Pression des Pneumatiques. Ce chapitre s'intéresse à la mise au point automatique d'un système de surveillance de la pression des pneumatiques d'un véhicule sans capteur de pression. Ce système fonctionne grâce à des algorithmes qui, à partir de l'analyse temporelle et spectrale des signaux de vitesses angulaires des roues, sont capables d'alerter le conducteur d'un dégonflage ou d'une chute anormale de la pression. La complexité du système et la grande taille de la base de données d'apprentissage incitent à l'utilisation d'une méthode d'optimisation globale pour le réglage optimal des paramètres du système de détection. La nouvelle méthode KEEP est appliquée pour l'optimisation des différentes parties du système, ce qui permet d'obtenir un jeu de configurations optimales (front de Pareto) tout en minimisant le nombre d'évaluations des fonctions qui sont inconnues et très coûteuses. La stratégie de la mise au point du système et les résultats obtenus sont détaillés.

PARTIE II - Observateurs pour les systèmes d'aide à la conduite

Chapitre 5 - Introduction aux observateurs. Dans ce chapitre, les observateurs linéaires (Kalman et Luenberger) et non linéaires (observateur à grand gain et observateur par mode glissant) sont détaillés. En introduction de la présentation des différents observateurs, les concepts d'observabilité, principe de séparation et forme canonique sont rappelés.

Chapitre 6 - Estimation d'état dans le cadre du *Traffic Jam Pilot*. L'objectif de ce chapitre est de présenter une solution alternative à la méthode d'estimation d'état actuellement envisagée par Renault/Nissan dans le cadre du contrôle latéral du système *Traffic Jam Pilot*. Après l'introduction de la dynamique latérale du véhicule et du système *Traffic Jam Pilot*, la solution basée sur un observateur linéaire (Kalman) et les nouvelles solutions proposées basées sur des observateurs non linéaires (grand gain et mode glissant) sont détaillées. Ensuite, la nouvelle méthode d'optimisation multi-objectif KEEP est appliquée pour la mise au point des gains des observateurs, ce qui permettra d'utiliser une grande base de données d'enregistrements de roulage. Finalement, les trois observateurs sont testés tout d'abord en simulation, puis en utilisant des données réelles.

Conclusion générale et perspectives. Cette partie de la thèse a le but de rappeler les différentes contributions à propos de l'optimisation multi-objectif de fonctions coûteuses et à propos des solutions d'observateurs proposées. A partir des résultats obtenus, une conclusion générale est faite afin de remarquer les aspects plus importants du travail réalisé. Finalement, les perspectives de cette thèse sont exposées afin de les prendre en compte pour les futures applications.

Annexe A - Autres systèmes d'aide à la conduite. D'autres ADAS et systèmes de détection en développement chez Renault sont présentés afin de montrer que les contraintes et les difficultés traitées dans la thèse pour le *Système de Surveillance de la Pression des Pneumatiques* et le *Traffic Jam Pilot* existent aussi présentes d'autres systèmes.

Annexe B - Réglage de la boucle du contrôle latéral du *Traffic Jam Pilot*. Une interface graphique a été créée afin de réaliser un réglage automatique du contrôle latéral du système *Traffic Jam Pilot* proposé par Renault/Nissan. D'une manière équivalente à l'optimisation des observateurs non linéaires, la nouvelle méthode KEEP est utilisée pour optimiser les gains de l'observateur *et* de la commande.



Optimisation globale de fonctions coûteuses et boîtes noires

État de l'art

Sommaire

2.1	Notions fondamentales	12
2.2	Optimisation globale mono-objectif	15
2.2.1	Algorithmes déterministes	16
2.2.2	Algorithmes stochastiques directs	16
2.2.3	Algorithmes stochastiques indirects	17
2.2.4	Modèles de substitution	18
2.2.5	Fonctions de covariance	24
2.2.6	Estimation de paramètres de covariance	26
2.2.7	Plan d'expérience	27
2.2.8	Critère d'échantillonnage	29
2.3	Optimisation globale multi-objectif	33
2.3.1	Quelques définitions	34
2.3.2	<i>Nondominated Sorting Genetic Algorithm 2</i>	35
2.3.3	<i>Pareto Efficient Global Optimization</i>	36
2.3.4	<i>Multi-Objective Particle Swarm Optimization</i>	37
2.3.5	<i>Pareto Envelope-based Selection Algorithm 2</i>	37
2.3.6	<i>Strength Pareto Evolutionary Algorithm 2</i>	38
2.3.7	Récapitulatif	38
2.4	Conclusion	39

L'objectif de ce chapitre est de présenter les algorithmes d'optimisation globale les plus représentatifs de la littérature, avant d'aborder les problèmes d'optimisation liés aux deux applications industrielles étudiées dans la thèse.

Dans une première partie, les notions et concepts basiques d'optimisation (minimum global, gradient, exploration, intensification ...) et les notations utilisées dans le chapitre (optimisation itérative classique) sont introduites. Ensuite, les différentes méthodes d'optimisation globale sont présentées. Bien que les travaux de cette thèse soient focalisés sur l'optimisation multi-objectif, les algorithmes mono-objectif seront aussi détaillés afin de faciliter la compréhension des différentes approches multi-objectif.

La deuxième partie a pour but de présenter brièvement les algorithmes mono-objectif classiques en les classifiant en déterministes, stochastiques directs (métaheuristiques) et stochastiques indirects (modèles de substitution). Vu l'intérêt de cette thèse pour l'optimisation de fonctions coûteuses avec un

nombre d'évaluations limité, l'optimisation basée sur une stratégie d'optimisation par modèles de substitution est expliquée en détail.

La troisième partie présente les algorithmes multi-objectif qui seront utilisés dans la suite du manuscrit. Le notion d'optimum de Pareto est introduite avant de présenter les approches qui permettent d'estimer le front de Pareto (ensemble de solutions non dominées). Les algorithmes multi-objectif de référence utilisés pour résoudre les problèmes d'optimisation globale dans un contexte industriel (réalisation de la mise au point des applications et des systèmes), concrètement les algorithmes NSGA2 et ParEGO, ainsi que les algorithmes évolutionnaires multi-objectif les plus employés, seront détaillés.

Finalement, un récapitulatif des avantages et des inconvénients de chaque algorithme est fait afin de montrer les caractéristiques de chaque solution, ce qui sera très utile avant de proposer une nouvelle méthode d'optimisation pour les fonctions coûteuses (voir Section 3.1) et de réaliser une analyse comparative des algorithmes d'optimisation multi-objectif (voir Section 3.3).

2.1 Notions fondamentales

Les ingénieurs et les chercheurs sont confrontés quotidiennement à des problèmes d'optimisation complexes. Certaines applications, systèmes et lois de commandes ont besoin d'une étape de mise au point pour obtenir un réglage permettant d'avoir les meilleures performances. Ce type de problèmes peut s'exprimer généralement comme un problème d'optimisation dans lequel on cherche à régler les différents *paramètres* de l'application par rapport à un ou plusieurs critères de performance, qui composent la *fonction objectif*. A titre d'exemple, [Shen et al., 2014] présente une optimisation pour la conception des batteries des véhicules afin de minimiser la dimension du système de stockage d'énergie (système moins volumineux et moins cher) et de maximiser les cycles de vie de la batterie ; [Qin-man et al., 2010] présente une optimisation pour la conception de la suspension des véhicules afin de maximiser la fréquence naturelle des ressorts et de réduire le coût du matériel utilisé.

Considérons une *fonction objectif* $f(\mathbf{x}) : \mathcal{X} \rightarrow \mathcal{F}$ qui dépend de la *configuration de paramètres* \mathbf{x} . L'*espace de recherche*¹ \mathcal{X} est défini comme un sous-espace borné de \mathbb{R}^m où m est le nombre de paramètres à optimiser ($\mathbf{x} = \{x_1, \dots, x_m\} \mid m \in \mathbb{N}$). Chaque paramètre à optimiser x_p ($p = \{1, \dots, m\}$) a son intervalle de valeurs dans l'espace de recherche, défini comme $x_p \in [\underline{x}_p, \overline{x}_p]$, où \underline{x}_p et \overline{x}_p sont les valeurs minimale et maximale, respectivement. L'*espace de performances* \mathcal{F} est défini par la projection de \mathbf{x} en utilisant la fonction objectif $f(\mathbf{x})$, définie dans un espace \mathbb{R}^n , où n est le nombre d'objectifs de la fonction ($f(\mathbf{x}) = \{f_1(\mathbf{x}), \dots, f_n(\mathbf{x})\} \mid n \in \mathbb{N}$).

Remarque 2.1 Si le problème d'optimisation a un seul paramètre à mettre au point $m = 1$ ou un seul objectif $n = 1$, f et \mathbf{x} seront notés " x " ou " f " respectivement. ■

D'une façon générale, dans un contexte de *minimisation*, on peut exprimer le problème d'optimisation par

$$\begin{cases} \min_{\mathbf{x} \in \mathcal{X}} & f(\mathbf{x}) \\ \text{s.c} & \mathbf{g}(\mathbf{x}) < 0 \\ & \mathbf{h}(\mathbf{x}) = 0 \end{cases} \quad (2.1)$$

en désignant par $\mathbf{g}(\mathbf{x})$ et $\mathbf{h}(\mathbf{x})$ les fonctions de contraintes d'inégalité et égalité, respectivement (s.c signifie sous contraintes).

Remarque 2.2 Dans le reste du manuscrit, on cherchera toujours à "*minimiser*" la fonction objectif. Ceci n'est pas restrictif dans le cas de la maximisation de $f(\mathbf{x})$ car le problème se ramène à la minimisation de la fonction $-f(\mathbf{x})$. ■

Remarque 2.3 Dans le reste du manuscrit, on cherchera toujours à optimiser des variables continues. L'optimisation de variables discrètes ou variables catégorielles ne sera pas traitée. ■

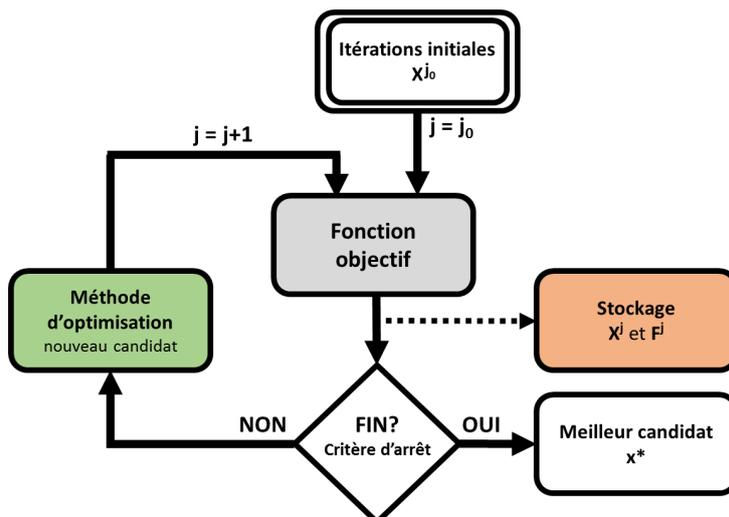


FIGURE 2.1: Schéma d'optimisation itérative classique sans parallélisation.

Un algorithme d'optimisation est habituellement exprimé à travers une structure itérative (voir Fig.2.1). L'algorithme commence en réalisant un certain nombre d'évaluations initiales j_0 de la fonction objectif jusqu'à un nombre d'évaluations maximal J . Le nombre d'évaluations est noté j . Dans la boucle d'optimisation, une méthode spécifique à chaque algorithme est utilisée pour proposer une nouvelle configuration de paramètres pour évaluer la fonction objectif, appelée *nouveau candidat* $\mathbf{x}^{(j+1)}$. Les configurations de paramètres et les valeurs de performance sont stockées dans les matrices $\mathbf{X}^{(j)} = \{\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(j)}\}$ et $\mathbf{F}^{(j)} = \{\mathbf{f}(\mathbf{x}^{(1)}), \dots, \mathbf{f}(\mathbf{x}^{(j)})\}$. Si le critère d'arrêt est atteint, l'algorithme d'optimisation proposera son meilleur candidat \mathbf{x}^* ; sinon, l'algorithme continuera l'optimisation avec une nouvelle itération.

Définition 2.1 [Minoux, 1983] *Le "critère d'arrêt" est la condition que l'algorithme doit vérifier pour considérer la fin de l'optimisation. Ce critère est typiquement défini pour un nombre maximal d'évaluations J ou pour la condition $|\mathbf{f}^\bullet - \mathbf{f}^*| < \epsilon$, avec ϵ une constante suffisamment petite. Idéalement, ce critère doit permettre de conclure que la solution obtenue \mathbf{f}^* est proche de la solution du problème \mathbf{f}^\bullet .* ■

Définition 2.2 [Minoux, 1983] *La "vitesse de convergence" est le nombre d'itérations nécessaires pour trouver une solution proche de l'optimal ou vérifier la condition du critère d'arrêt.* ■

Minimum global et minimum local

Définition 2.3 [Minoux, 1983] *Une solution \mathbf{f}^\bullet , aussi appelée "minimum global", est la solution obtenue avec la configuration de paramètres \mathbf{x}^\bullet qui minimise la fonction objectif $\mathbf{f}(\mathbf{x})$ sur l'ensemble de \mathcal{F} , i.e*

$$\mathbf{f}^\bullet = \mathbf{f}(\mathbf{x}^\bullet) < \mathbf{f}(\mathbf{x}), \forall \mathbf{x} \in \mathcal{X} \text{ avec } \mathbf{x} \neq \mathbf{x}^\bullet \quad (2.2)$$

Définition 2.4 [Minoux, 1983] *Une solution \mathbf{f}° , aussi appelée "minimum local", est la solution obtenue avec la configuration de paramètres \mathbf{x}° qui minimise la fonction objectif $\mathbf{f}(\mathbf{x})$ dans un voisinage de paramètres $V(\mathbf{x}^\circ) \subset \mathcal{X}$ tel que $\mathbf{x} \in V(\mathbf{x}^\circ)$, i.e*

$$\mathbf{f}^\circ = \mathbf{f}(\mathbf{x}^\circ) < \mathbf{f}(\mathbf{x}), \forall \mathbf{x} \in V(\mathbf{x}^\circ) \text{ avec } \mathbf{x} \neq \mathbf{x}^\circ \quad (2.3)$$

¹Dans la littérature, il est aussi appelé *espace de facteurs, espace de paramètres* ou *domaine*

Gradient et boîtes noires

Définition 2.5 [Minoux, 1983] *Le "gradient" ou première dérivée de la fonction objectif au point x apporte l'information de la direction optimale d'optimisation d'une configuration de paramètres dans un voisinage $V(x)$ tel que $V(x) \subset \mathcal{X}$.* ■

Certains algorithmes d'optimisation, spécialement dans le contexte d'optimisation locale, utilisent l'information du *gradient* pour augmenter la vitesse de convergence. Néanmoins, l'utilisation du *gradient* implique qu'il faut connaître l'expression analytique de la fonction objectif pour calculer son gradient, ce qui n'est pas le cas pour l'optimisation de *boîtes noires*². Dans la littérature, les algorithmes d'optimisation qui n'utilisent pas l'information du gradient et les algorithmes stochastiques où le gradient contient un terme d'erreur, sont appelées *derivative-free* [Rios et Sahinidis, 2013].

Remarque 2.4 *Dans la suite du manuscrit, l'attention sera focalisée sur l'optimisation de boîtes noires et sur les méthodes d'optimisation sans calcul du gradient.* ■

Exploration vs intensification

Définition 2.6 [Dréo et al., 2003] *"L'exploration" est la capacité d'un algorithme d'optimisation à chercher les zones avec une forte probabilité d'avoir une valeur optimale dans tout l'espace des paramètres \mathcal{X} .* ■

Définition 2.7 [Dréo et al., 2003] *"L'intensification" est la capacité d'un algorithme d'optimisation à minimiser la fonction objectif en priorisant la recherche dans les zones de l'espace de recherche \mathcal{X} où il y a une forte probabilité d'avoir une valeur optimale.* ■

Les algorithmes d'optimisation peuvent adopter différentes stratégies pour favoriser les deux concepts précédents. Par exemple, un algorithme d'optimisation *élitiste*³ favorise la recherche dans le voisinage des meilleures configurations de paramètres (*intensification*); par contre, un algorithme qui injecte de l'aléatoire dans le critère de sélection des nouveaux candidats priorise la recherche globale (*exploration*). Trouver un compromis entre les deux concepts est essentiel pour guider les algorithmes d'optimisation vers la solution globale du problème f^\bullet , en évitant les pièges que représentent les minima locaux f° .

Algorithme direct et indirect

Définition 2.8 [Rios et Sahinidis, 2013] *Un algorithme est appelé "direct" s'il n'utilise que l'information de performance d'une configuration de paramètres obtenue par l'évaluation de la fonction objectif.* ■

Définition 2.9 [Rios et Sahinidis, 2013] *Un algorithme est appelé "indirect" s'il utilise l'information de performance d'une configuration des paramètres obtenue par un modèle de substitution, ou modèle mathématique.* ■

Un algorithme *indirect* utilise les évaluations de la fonction objectif pour la création d'un modèle de substitution, qui sera utilisé par l'algorithme d'optimisation pour réaliser l'approximation des valeurs de la fonction pour des configurations de paramètres candidats. L'avantage des algorithmes *indirects* est la réduction du nombre d'évaluations de la fonction objectif (très intéressant pour l'optimisation de fonctions objectif coûteuses); par contre, les algorithmes *directs* n'ont besoin ni de calculer ni d'utiliser un modèle de substitution (très intéressant pour des problèmes d'optimisation avec la possibilité de réaliser un nombre d'évaluations élevé).

²Lorsque la fonction objectif n'a pas d'expression analytique et ne peut être évaluée que numériquement.

³Algorithmes qui stockent les configurations de paramètres des meilleures évaluations obtenues pendant l'optimisation.

Fonctions convexe et concave

Définition 2.10 [Minoux, 1983] On dit que la fonction $f(\mathbf{x}) : \mathbb{R}^m \rightarrow \mathbb{R}$ (cas mono-objectif) est "convexe", si pour deux configurations de paramètres quelconques, \mathbf{x}_a et \mathbf{x}_b , il est vérifié

$$\begin{aligned} \forall \mathbf{x}_a \in \mathcal{X} \quad \forall \mathbf{x}_b \in \mathcal{X} \quad \forall \lambda \in [0, 1] \\ f(\lambda \mathbf{x}_a + (1 - \lambda) \mathbf{x}_b) \leq \lambda f(\mathbf{x}_a) + (1 - \lambda) f(\mathbf{x}_b) \end{aligned} \quad (2.4)$$

■

Définition 2.11 [Minoux, 1983] On dit que la fonction $f(\mathbf{x}) : \mathbb{R}^m \rightarrow \mathbb{R}$ (cas mono-objectif) est "strictement convexe", si et seulement si l'inégalité de (2.4) est stricte, pour $\mathbf{x}_a \neq \mathbf{x}_b$ et $\lambda \in]0, 1[$. ■

D'une façon équivalente, on peut dire que \mathcal{F} est un ensemble de solutions *convexe* si le segment entre deux solutions quelconques, \mathbf{f}_a et \mathbf{f}_b , est toujours contenu dans \mathcal{F} . De cette façon, toute solution dans l'espace des performances \mathcal{F} peut être exprimé comme une combinaison linéaire d'autres j évaluations

$$\sum_{g=1}^j \lambda_g = 1, \quad \mathbf{f} = \sum_{g=1}^j \lambda_g \mathbf{f}(\mathbf{x}_g) \quad (2.5)$$

où $\lambda_g \in [0, 1]$. Dans le cas contraire, on dit que la fonction est *concave*, ou simplement *non convexe*.

2.2 Optimisation globale mono-objectif

Le problème d'optimisation mono-objectif présenté dans cette section est défini à partir du problème (2.1) où la fonction objectif est notée $f(\mathbf{x})$ ($\mathbf{f}(\mathbf{x}) \in \mathbb{R}^1$). Les algorithmes d'optimisation de fonctions continues et non linéaires (voir Fig.2.2), peuvent se diviser en méthodes locales et méthodes globales.

Dans le contexte d'*optimisation non linéaire locale*, les méthodes d'optimisation classiques directes [Hooke et Jeeves, 1961] restent très populaires en raison de leur simplicité, flexibilité et fiabilité. Un exemple est l'algorithme du simplexe de "Nelder-Melder" [Nelder et Mead, 1965] [Conn et al., 2009]. Cette solution évalue à chaque itération les sommets d'un simplexe⁴ dans l'espace de paramètres \mathcal{X} . Le pire résultat est remplacé pour un nouveau point qui génère un nouveau simplexe. Cette méthode est typiquement connue pour ces problèmes de stagnation ; [Kelley, 1999] propose une approximation du gradient pour renforcer la condition de décroissance et de minimisation. Un autre exemple est l'algorithme *Generalized pattern search* [Torczon, 1997]. Cette méthode réalise à chaque itération des évaluations d'exploration avant de définir une distribution de points dans l'espace \mathcal{X} . Elle est capable de garantir une distribution correcte des évaluations dans l'espace de paramètres \mathcal{X} grâce à l'utilisation d'une matrice. Un autre algorithme similaire, le *Mesh adaptive direct search* (MADS) [Audet et Dennis, 2006] prend en compte deux nouveaux critères : la taille de la région de recherche et la taille de la grille utilisée. MADS incorpore une région d'espace dynamique qui priorise la direction dans l'espace où elle va focaliser l'optimisation pendant les itérations suivantes. Dans la littérature, on trouve aussi des méthodes locales indirectes, utilisées dans le contexte d'optimisation locale de fonctions coûteuses. Néanmoins, ces méthodes sont moins fiables et plus complexes que les méthodes locales directes. Dans ce groupe de méthodes, on peut mentionner des méthodes comme la *région de confiance* [Powell, 1994] et le *Implicit filtering* [Gilmore et Kelley, 1995].

Dans le contexte de l'*optimisation globale*, les méthodes sont classifiées en trois groupes : déterministes, stochastiques directes⁵ et stochastiques indirectes. Ci-après, ces méthodes d'optimisation globale seront résumées en détaillant les algorithmes les plus utilisés.

Pour une classification complète et une description détaillée des méthodes d'optimisation globale, on peut consulter par exemple [Berthiau et Siarry, 2001] [Rios et Sahinidis, 2013] [Dréo et al., 2003].

⁴Généralisation d'un triangle d'une dimension quelconque.

⁵Dans la littérature, les méthodes stochastiques directes sont généralement appelées simplement *algorithmes stochastiques*.

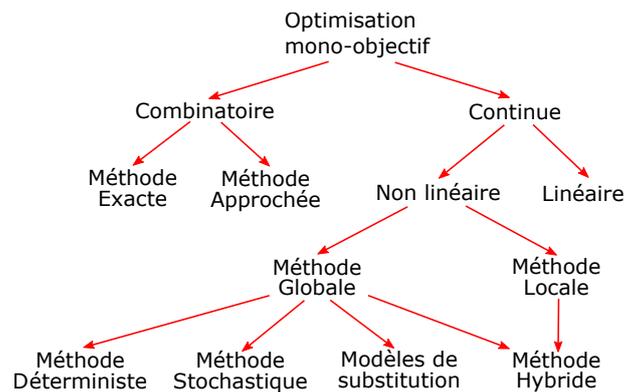


FIGURE 2.2: Classification générale de l'optimisation mono-objectif. (source de l'image : [Siarry, 2014])

2.2.1 Algorithmes déterministes

La plupart des algorithmes déterministes partent du principe que la fonction objectif soit *Lipschitzienne*⁶. Cette hypothèse permet de construire et d'optimiser globalement une fonction qui sous-estime la fonction objectif. Un exemple est l'algorithme *DIRECT* [Jones et al., 1993] qui divise l'espace de recherche en hypercubes et sélectionne ceux qui ont un fort potentiel de réduction de la fonction objectif. Ce potentiel est défini comme un compromis entre la diminution de la valeur de la fonction objectif (optimisation locale) et la taille de l'hypercube (optimisation globale). Un autre algorithme très utilisé est le *Branch-and-Bound* [Pintér, 2013]. Cet algorithme divise l'espace de recherche en plusieurs régions et détermine des limites supérieures et inférieures de chaque région. L'avantage de cette méthode est le fait de réduire l'espace de recherche en éliminant les régions où la minimisation de la fonction objectif n'est pas possible. Dans le groupe des algorithmes déterministes non-Lipschitziens, on peut citer des algorithmes comme le *Multilevel coordinate search* [Huyer et Neumaier, 1999].

2.2.2 Algorithmes stochastiques directs

Les algorithmes stochastiques sont des approches basées sur des critères non-déterministes. La littérature des méthodes stochastiques est très fournie [Dréo et al., 2003]. Un des groupes les plus importants concerne les algorithmes *métaheuristiques* [Boussaïd et al., 2013] : la recherche avec tabous [Siarry et Berthiau, 1997], l'algorithme de colonie de fourmis [Dorigo et al., 1996], la méthode du recuit simulé [Siarry, 1995]... Ci-après, deux des algorithmes les plus utilisés seront présentés : l'algorithme génétique et l'essaim de particules.

Algorithmes génétiques

Les algorithmes génétiques (GA) [Holland, 1992] [Chelouah et Siarry, 2000] fonctionnent de façon similaire à l'évolution des espèces pour lesquelles les individus sont soumis à des règles d'évolution (voir Fig.2.3). Chaque individu représente une solution appartenant à l'espace de recherche du problème d'optimisation. L'ensemble des individus traités simultanément par l'algorithme génétique constitue une *population*. Celle-ci évolue pendant une succession d'itérations appelées *générations*. Pendant une génération, une succession d'opérateurs (sélection, croisement, mutation, remplacement) est appliquée aux individus pour engendrer une nouvelle population. Les individus utilisés par un opérateur sont appelés *parents* (notés μ), et les individus résultants *enfants* (notés λ) (voir Fig.2.3). Un critère d'arrêt permet de stopper les itérations lorsque la qualité de la nouvelle population est suffisante. La difficulté des algorithmes génétiques est que chaque opérateur possède ses propres paramètres de réglage. Au total, le

⁶Méthodes basées sur la construction d'un sous-estimateur de $f(x)$ défini comme $|f(x_a) - f(x_b)| \leq L\|x_a - x_b\|$ où $x_a, x_b \in \mathcal{X}$ et L est une constante strictement positive [Shubert, 1972].

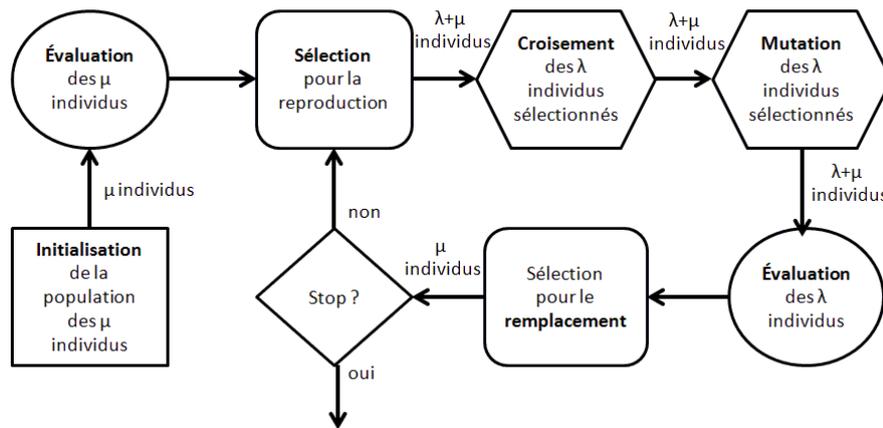


FIGURE 2.3: Structure classique d'un algorithme génétique. (source de l'image : [Dréo et al., 2003])

nombre de paramètres nécessaires pour la mise au point de l'algorithme est supérieur à celui des autres algorithmes métaheuristiques.

Essaim de particules

L'optimisation par essaims de particules ou *particle swarm optimization* (PSO) [Kennedy et Eberhart, 1995][Poli et al., 2007] peut être vue comme inspirée des comportements collectifs des déplacements d'animaux. En effet, chez certains groupes d'animaux, on peut observer des dynamiques de déplacements relativement complexes, alors que les individus eux-mêmes n'ont accès qu'à des informations limitées. Ils utilisent des règles simples comme : rester proche des autres individus, aller dans la même direction et aller à la même vitesse. L'idée principale de la méthode est de mettre en jeu de grands groupes de particules se déplaçant dans l'espace de recherche \mathcal{X} . Chaque particule i est caractérisée par sa position \mathbf{x}_i et un vecteur de vitesse \mathbf{v}_i . La difficulté de la méthode est de bien définir la valeur de la vitesse, mais aussi d'autres paramètres. La socio-psychologie suggère que les individus se déplaçant sont influencés par leur comportement passé et par celui de leurs voisins. De cette manière, pour chaque particule, l'algorithme propose de prendre en compte sa position précédente, sa vitesse, sa meilleure position précédente \mathbf{x}_i^{best} et la meilleure position parmi les voisins \mathbf{x}_{all}^{best} . La mise à jour de la position d'une particule est définie par

$$\begin{cases} \mathbf{v}_i &= \mathbf{v}_i(t-1) + \varphi_1 (\mathbf{x}_i^{best} - \mathbf{x}_i(t-1)) + \varphi_2 (\mathbf{x}_{all}^{best} - \mathbf{x}_i(t-1)) \\ \mathbf{x}_i &= \mathbf{x}_i(t-1) + \mathbf{v}_i(t-1) \end{cases} \quad (2.6)$$

où les paramètres φ_1 et φ_2 sont des paramètres qui ont pour objectif de pondérer l'expérience individuelle et la communication entre les individus du groupe, respectivement.

2.2.3 Algorithmes stochastiques indirects

En général, les algorithmes d'optimisation directs (déterministes et stochastiques) ont besoin de beaucoup d'évaluations de la fonction objectif avant de converger vers la solution optimale ; pour cette raison, ils sont peu utilisés pour résoudre des problèmes d'optimisation où la fonction objectif est très coûteuse. Dans cette situation, les solutions indirectes deviennent une alternative efficace [Voutchkov et Keane, 2010]. L'estimation de la fonction objectif, obtenue grâce à la construction d'un modèle de substitution⁷, permettra d'utiliser les différentes méthodes d'optimisation sur ce modèle mathématique (pas de surcoût temporel significatif). Les modèles de substitution sont définis généralement comme des processus stochastiques créés à partir d'évaluations précédentes (disponibles) de la fonction objectif.

⁷Dans la littérature, aussi appelé modèle mathématique ou "metamodel".

La notion de modèles de substitution a été introduite dans les années 50 [Box et Wilson, 1951], où a été présentée l'obtention d'une approximation optimale d'une fonction à partir d'un plan d'expérience. Dans un premier temps, les modèles de substitution ont été adaptés afin de résoudre des problèmes statistiques [Sacks et Ylvisaker, 1970] et de la modélisation géostatistique [Journel et Huijbregts, 1978]. Une des premières utilisations des modèles de substitution dans un contexte d'optimisation est apparue dans le domaine de la conception optimale de structures [Schoofs, 1988]. L'idée est basée sur le choix de plusieurs jeux de paramètres à évaluer sur la fonction objectif, et sur l'utilisation de résultats pour construire un modèle de substitution, sur lequel sera effectué l'optimisation. Ce principe d'optimisation a été nommé *Design and analysis of computer experiments* (DACE) [Sacks et al., 1989]. Néanmoins, les algorithmes étaient encore limités à des espaces de faible dimension, très dépendant du plan d'expérience initial et du nombre d'évaluations déjà faites. À la fin des années 90, l'amélioration des outils de calcul et le perfectionnement des modèles de substitution ont permis de commencer à utiliser cette procédure pour des problèmes d'optimisation globale en plus grande dimension. Une des solutions les plus répandues a été l'utilisation des algorithmes génétiques pour chercher les configurations optimales de modèles de substitution [Robinson et Keane, 1999] [Ratle, 1998] [El-Beltagy et Keane, 1999]. Ces travaux proposent de réaliser un plan d'expérience initial pour la construction d'un premier modèle de substitution. Ensuite, ce modèle est utilisé à la place du modèle physique pendant un nombre fixe d'itérations. De cette façon, l'optimisation est faite en utilisant l'algorithme génétique sur le modèle de substitution qui est mis à jour avec les nouvelles évaluations. Une idée similaire est proposée dans [Praveen et Duvigneau, 2009], où l'algorithme génétique est remplacé par un algorithme à essais particuliers (PSO). Au début des années 2000, l'article [Jones et al., 1998] est devenu la référence sur l'utilisation des modèles de substitution dans l'optimisation globale mono-objectif, avec sa nouvelle méthode appelée *Efficient global optimization* (EGO). Cette idée a été utilisée avec des modèles de *krigeage* [Jones, 2001], avec des fonctions de base radiale [Gutmann, 1999] et aussi pour des problèmes d'optimisation sous contraintes [Sasena, 2002].

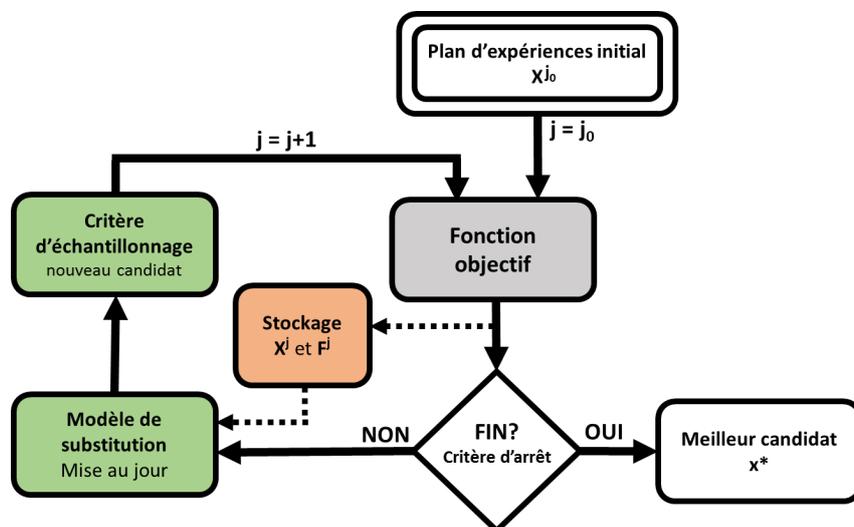


FIGURE 2.4: Schéma d'optimisation itérative avec modèles de substitution.

Les fonctions de covariance utilisées pour la construction de ces modèles sont introduites ainsi que les techniques d'optimisation de leurs paramètres. Ensuite, les différentes méthodes utilisées pour la réalisation d'un plan d'expérience et le critère d'échantillonnage pour la recherche des meilleurs candidats sont détaillés.

2.2.4 Modèles de substitution

Dans la littérature, plusieurs travaux ont fait une comparaison exhaustive des différents modèles de substitution [Bompard, 2011], [Rios et Sahinidis, 2013]. Une attention particulière est portée au *krigeage* car cette solution a été retenue dans les travaux qui ont été réalisés dans cette thèse.

Régression multivariée par splines adaptatives (MARS)

La méthode *Multivariate Adaptive Regression Splines* (MARS) [Friedman, 1991] est basée sur l'utilisation de fonctions bilatérales tronquées comme fonctions de base. Elles sont définies comme

$$h_{k,m}(\mathbf{x}_{k,m} - \mathbf{t}_{k,m})_+ = \begin{cases} \mathbf{x}_{k,m} - \mathbf{t}_{k,m} & \mathbf{x}_{k,m} > \mathbf{t}_{k,m} \\ 0 & \text{sinon} \end{cases} \quad (2.7)$$

où \mathbf{t} désigne une valeur de référence (intersection ou noeud de la fonction de base). L'ordre est noté K ($k \in \{1, \dots, K\}$) et le nombre de fonctions de base est noté M ($m \in \{1, \dots, M\}$).

Ce type de fonctions de base est couramment utilisé pour approcher une fonction inconnue $f(\mathbf{x})$ en utilisant une approche itérative

$$\hat{f}(\mathbf{x}) = B_0 + \sum_{m=1}^M B_m H_{(k,m)}(\mathbf{x}) \quad (2.8)$$

en désignant par B_0 et B_m des constantes ou gains du modèle de substitution liés à chacune des fonctions de base. La fonction $H_{(k,m)}(\mathbf{x})$ est définie comme

$$H_{(k,m)}(\mathbf{x}) = \prod_{k=1}^K h_{k,m}(\mathbf{x}_{k,m} - \mathbf{t}_{k,m})_+ \quad (2.9)$$

Dans la littérature, des travaux comme [Jin et al., 2000] ont testé et comparé différents modèles de substitution. Ce travail montre que, dans un contexte d'optimisation difficile, les résultats obtenus par un modèle de substitution basé sur MARS sont moins satisfaisants qu'aux obtenus via d'autres modèles de substitution (comme le *krigeage* ou les fonctions de base radiales).

Machines à Vecteurs de Support (SVM)

La méthode *Support Vector Regression* (SVM) est à la base un algorithme d'apprentissage utilisé pour la classification de données. Cette méthode repose sur la recherche d'un hyperplan (ou fonction) de séparation optimal [Smola et Schölkopf, 2004] défini en maximisant la *marge*⁸ entre les classes. Ce même principe est utilisé pour trouver une fonction de substitution optimale en réduisant la *marge* (erreur d'estimation) aux j évaluations faites avec la fonction objectif. Si le modèle de substitution est défini comme une fonction linéaire $f(\mathbf{x}) = \langle \mathbf{w}, \mathbf{x} \rangle + b$ (avec b une constante, \mathbf{x} une configuration de paramètres et \mathbf{w} la normale de l'hyperplan de séparation), la fonction optimale est obtenue en résolvant le problème d'optimisation suivant

$$\min_{\mathbf{w}, b, \xi} \left(\frac{1}{2} \|\mathbf{w}\|^2 + C_0 \sum_{t=1}^j \xi^{(t)} \right), \quad (2.10)$$

sous les contraintes

$$\begin{aligned} y^{(t)}(\langle \mathbf{w}, \mathbf{x}^{(t)} \rangle + b) &\leq \xi^{(t)} \quad \forall t \in \{1, \dots, j\}, \\ C_0, \xi^{(t)} &\geq 0 \quad \forall t \in \{1, \dots, j\}, \end{aligned}$$

où $y^{(t)} \in \{-1, 1\}$. Le paramètre positif C_0 est défini comme la tolérance à l'erreur d'estimation et les termes $\xi^{(t)}$ sont ajoutés pour éviter que la valeur de l'expression à minimiser soit trop grande. En appliquant le principe de dualité de Lagrange [Bompard, 2011], un algorithme de programmation quadratique est utilisé pour trouver les coefficients $\alpha^{(t)}$. La valeur de b correspondra à la variable duale associée à la contrainte d'égalité obtenue directement par le solveur quadratique. Alors, le modèle de substitution est redéfini comme

$$\hat{f}(\mathbf{x}) = \langle \mathbf{w}, \mathbf{x} \rangle + b = \sum_{t=1}^j \left(\alpha^{(t)} y^{(t)} \langle \mathbf{x}^{(t)}, \mathbf{x} \rangle \right) + b. \quad (2.11)$$

L'inconvénient de cette méthode par rapport à l'utilisation du *krigeage* ou des fonctions de base radiale est que la méthode est plus complexe en termes de calculs.

⁸Distance minimale entre la fonction de séparation et la valeur la plus proche d'une classe.

Fonctions à Base Radiale (RBF)

La méthode *Radial Basis Functions* (RBF) [Orr, 1996] [Gutmann, 1999] a un fonctionnement similaire à un réseau de neurones.

Remarque 2.5 Un "réseau de neurones" est un modèle de calcul inspiré du fonctionnement des neurones biologiques. En général, il est composé d'une succession de couches (de neurones) dont chacune prend ses entrées sur les sorties de la précédente. À chaque synapse (connexion entre couches), un poids est associé à chaque neurone afin de combiner (typiquement en utilisant l'addition) l'information des neurones. ■

Concrètement, la méthode RBF est basée sur un réseau de neurones à deux couches : une couche inférieure de N^c cellules qui appliquent une fonction d'activation radiale (ou fonction de covariance), et une couche supérieure composée de neurones linéaires. La valeur de la sortie est définie par

$$\hat{f}(\mathbf{x}) = \sum_{i=1}^{N^c} \mathbf{w}^{(i)} k(\mathbf{x}, \mathbf{w}^{(i)}), \quad (2.12)$$

en désignant par $\mathbf{w}^{(i)}$ le poids de chaque couche cachée et $k(\cdot, \cdot)$ la fonction de covariance (détaillé dans la section 2.2.5). L'avantage de cette méthode est sa rapidité et de facilité pour construire un modèle de substitution ; par contre, l'approximation obtenue est peu précise s'il y a beaucoup de paramètres à mettre au point ou si les données fournies par la fonction objectif sont bruitées.

Krigeage

Le *krigeage* a été introduit par l'ingénieur minier sud-africain D.G. Krige. Dans les années 50, il a développé une série de méthodes statistiques empiriques [Krige, 1951]. Quelques années plus tard, son travail a été formalisé mathématiquement par G. Matheron à l'École des Mines de Paris [Matheron, 1962]. L.S. Gandin a utilisé un principe similaire dans le domaine de la météorologie [Gandin et Hardin, 1965]. Ce n'est que vers la fin des années 80 que le *krigeage* a été utilisé pour l'approximation de fonctions inconnues [Sacks et al., 1989]. Depuis les années 90, l'utilisation du *krigeage* a pris plus d'ampleur et plusieurs variantes et modifications ont été proposées [Cressie, 2015], toujours en respectant les règles basiques formulées pour Krige et Matheron.

Pour une bonne compréhension du fonctionnement du *krigeage*, les principes fondamentaux des processus gaussiens (stochastiques) sont brièvement introduits.

Définition 2.12 [Kolmogorov, 1950] Un "espace probabilisé" $(\Omega, \mathcal{A}, \mathcal{P})$ est défini comme un ensemble Ω (univers) avec des événements \mathcal{A} . La mesure de la probabilité \mathcal{P} de chaque événement \mathcal{A} est définie dans l'ensemble de l'espace $\mathcal{P}(\mathcal{A}) \in \Omega$. ■

Définition 2.13 [Kolmogorov, 1950] Un "processus gaussien" est une fonction $Y(x, \omega)$ à valeurs réelles où x et ω appartiennent à l'espace de recherche et à un espace probabilisé, respectivement. ■

Définition 2.14 [Kolmogorov, 1950] Une "variable gaussienne" $Y(\mathbf{x})$ est définie par la somme d'une quantité déterministe $\mu(\mathbf{x})$ et d'une quantité aléatoire $\epsilon(\mathbf{x})$ d'espérance nulle

$$Y(\mathbf{x}) = \mu(\mathbf{x}) + \epsilon(\mathbf{x}). \quad (2.13)$$

En utilisant l'écart-type $\sigma(\mathbf{x})$ associé à la quantité aléatoire, la variable gaussienne est définie par

$$Y(\mathbf{x}) \sim \mathcal{N}(\mu(\mathbf{x}), \sigma(\mathbf{x})). \quad (2.14)$$

■

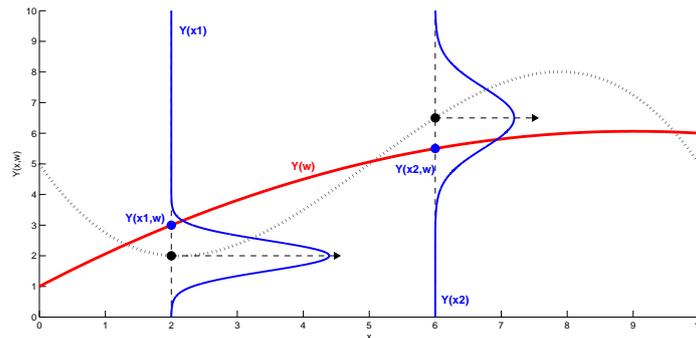


FIGURE 2.5: Exemple d'un processus gaussien. La moyenne du processus gaussien ou quantité déterministe $\mu(x)$ est représentée par la ligne pointillée, ainsi que deux exemples de processus gaussiens $Y_x(\omega)$ à x constante (lignes bleues) et un exemple de processus gaussien $Y_w(x)$ à ω constante (ligne rouge).

Récemment, les problèmes d'optimisation globale multi-objectif ont connu une croissance notable dans le monde scientifique et industriel. En pratique, quelques hypothèses sont faites [Knowles et Hughes, 2005], afin de pouvoir traiter ces problèmes avec des méthodes d'optimisation basées sur le *krigeage* :

Hypothèse 2.1 *L'espace de recherche à modéliser est de petite dimension (moins de 10 paramètres).* ■

Hypothèse 2.2 *L'espace de performances à modéliser est localement lisse et continu.* ■

Hypothèse 2.3 *Le nombre d'évaluations de la fonction objectif est limité en raison de contraintes temporelles (fonction coûteuse).* ■

Hypothèse 2.4 *A chaque évaluation de la fonction objectif, le modèle de substitution sera mis à jour de façon itérative.* ■

Dans la littérature, plusieurs types de *krigeage* sont proposés pour la modélisation d'une fonction inconnue.

a) *Krigeage ordinaire*

Hypothèse 2.5 *Le krigeage ordinaire ($\hat{F}(x) \sim (\hat{f}(x), \hat{\sigma}(x))$) suppose que la variable gaussienne équivalente de la fonction objectif ($F(x) \sim (\mu(x), \sigma(x))$) ait le terme déterministe $\mu(x)$ (voir (2.13)) constant et inconnu.* ■

Hypothèse 2.6 *Pour une configuration de paramètres x , le krigeage ordinaire suppose qu'il y a une valeur unique de sortie. Si on répète l'évaluation avec exactement la même configuration d'entrée x , le résultat obtenu sera le même, i.e il n'y a pas dispersion de résultats.* ■

Hypothèse 2.7 *Le krigeage ordinaire considère les valeurs obtenues par la fonction objectif comme valeurs sans bruit et sans erreur de mesure.* ■

En général, la valeur obtenue par une configuration de paramètres x est corrélée aux valeurs obtenues par les configurations voisines dans \mathcal{X} . Le *krigeage* modélise la fonction objectif $f(x)$ en estimant la valeur de n'importe quelle configuration de paramètres x grâce à une combinaison linéaire des valeurs déjà observées $\mathbf{F}^{(j)}$, où j est le nombre d'évaluations disponibles :

$$\hat{f}(x) = \sum_{g=1}^j \lambda_g(x) f(x^{(g)}) = \boldsymbol{\lambda}(x)^T \mathbf{F}^{(j)} \quad (2.15)$$

où $\boldsymbol{\lambda}(\mathbf{x}) = \{\lambda_1(\mathbf{x}), \lambda_2(\mathbf{x}), \dots, \lambda_j(\mathbf{x})\}^T$ est le vecteur de coefficients des solutions du *krigeage*. L'influence entre deux configurations de paramètres $\{\mathbf{x}_a, \mathbf{x}_b\} \in \mathcal{X}$ est définie par une fonction de covariance $k(\mathbf{x}_a, \mathbf{x}_b)$, qui sera définie dans la Section 2.2.5.

$$k(\mathbf{x}_a, \mathbf{x}_b) = \text{cov}(f(\mathbf{x}_a), f(\mathbf{x}_b)). \quad (2.16)$$

À partir de la fonction de covariance précédente, on définit la matrice de covariance \mathbf{K} de taille $(j \times j)$ entre toutes les évaluations réalisées :

$$\mathbf{K} = (k(\mathbf{x}_a, \mathbf{x}_b)) \text{ avec } (a, b) \in \{1, 2, \dots, j\}. \quad (2.17)$$

Notons $\mathbf{k}(\mathbf{x})$ le vecteur de covariance entre une configuration de paramètres quelconque \mathbf{x} et les j évaluations réalisées et disponibles de la fonction objectif $\{\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(j)}\}$:

$$\mathbf{k}(\mathbf{x}) = \left[k(\mathbf{x}^{(1)}, \mathbf{x}), k(\mathbf{x}^{(2)}, \mathbf{x}), \dots, k(\mathbf{x}^{(j)}, \mathbf{x}) \right]^t. \quad (2.18)$$

La création d'un modèle de substitution par *krigeage* ordinaire est basée sur les conditions suivantes :

Condition 1 : Prédiction sans biais

$$\mathbb{E}(\hat{F}(\mathbf{x}) - F(\mathbf{x})) = 0 \quad (2.19)$$

Comme l'espérance d'une variable gaussienne est égale à sa moyenne, $\mu(\mathbf{x})$, selon l'Hypothèse 2.5, on peut réécrire l'équation précédente comme :

$$\hat{f}(\mathbf{x}) - \mu(\mathbf{x}) = 0. \quad (2.20)$$

En utilisant (2.15), on peut redéfinir la condition de non-biais (2.20) par :

$$\begin{aligned} \sum_{g=1}^j \lambda_g(\mathbf{x}) \mu(\mathbf{x}) - \mu(\mathbf{x}) &= 0, \\ \sum_{g=1}^j \lambda_g(\mathbf{x}) &= 1. \end{aligned} \quad (2.21)$$

Condition 2 : Minimisation de la variance de l'erreur quadratique moyenne ■

$$\hat{\sigma}^2(\mathbf{x}) = \mathbb{E} \left[\left(\hat{F}(\mathbf{x}) - F(\mathbf{x}) \right)^2 \right] \quad (2.22)$$

La variance de l'erreur estimé $\hat{\sigma}^2(\mathbf{x})$ peut être exprimée à partir des fonctions de covariance (2.16, 2.17, 2.18) comme :

$$\hat{\sigma}^2(\mathbf{x}) = k(\mathbf{x}, \mathbf{x}) + \boldsymbol{\lambda}(\mathbf{x})^T \mathbf{K} \boldsymbol{\lambda}(\mathbf{x}) - 2 \boldsymbol{\lambda}(\mathbf{x})^T \mathbf{k}(\mathbf{x}). \quad (2.23)$$

Pour minimiser la variance de l'erreur (2.23), on utilise la méthode de Lagrange sous la contrainte $(0 < \lambda_g < 1, \forall g \in [1, \dots, j])$. La nouvelle expression de la variance est :

$$\boldsymbol{\lambda}(\mathbf{x})^T \mathbf{K} \boldsymbol{\lambda}(\mathbf{x}) - 2 \boldsymbol{\lambda}(\mathbf{x})^T \mathbf{k}(\mathbf{x}) + 2\gamma(\mathbf{x})^T \boldsymbol{\lambda}(\mathbf{x}). \quad (2.24)$$

où $\gamma(\mathbf{x})$ est le vecteur de multiplicateurs de Lagrange. En annulant le gradient par rapport à $\boldsymbol{\lambda}(\mathbf{x})$, on obtient :

$$\mathbf{K} \boldsymbol{\lambda}(\mathbf{x}) - \mathbf{k}(\mathbf{x}) + \gamma(\mathbf{x}) = \mathbf{0}. \quad (2.25)$$

■

À partir des deux conditions précédentes, la minimisation de la variance de l'erreur quadratique (2.25) et la prédiction sans biais (2.21), on obtient le système matriciel suivant :

$$\begin{pmatrix} \mathbf{K} & \mathbf{1} \\ \mathbf{1}^T & 0 \end{pmatrix} \begin{pmatrix} \boldsymbol{\lambda}(\mathbf{x}) \\ \gamma(\mathbf{x}) \end{pmatrix} = \begin{pmatrix} \mathbf{k}(\mathbf{x}) \\ 1 \end{pmatrix}, \quad (2.26)$$

où $\mathbf{1}$ désigne un vecteur de taille $(j \times 1)$ dont toutes les composantes sont égales à 1. Alors, les solutions du système sont :

$$\begin{cases} \gamma(\mathbf{x}) = (\mathbf{1}^T \mathbf{K}^{-1} \mathbf{1})^{-1} (\mathbf{1}^T \mathbf{K}^{-1} \mathbf{k}(\mathbf{x}) - 1) \\ \boldsymbol{\lambda}(\mathbf{x}) = \mathbf{K}^{-1} (\mathbf{k}(\mathbf{x}) - \gamma(\mathbf{x}) \mathbf{1}) \end{cases} \quad (2.27)$$

A partir des solutions du système précédent (2.27), on peut calculer l'espérance de l'approximation de la fonction inconnue $\hat{f}(\mathbf{x})$ selon (2.15), et l'estimation de la variance de l'erreur $\hat{\sigma}^2(\mathbf{x})$ à partir de (2.23)

$$\begin{cases} \hat{f}(\mathbf{x}) = \boldsymbol{\lambda}(\mathbf{x}) \mathbf{F}^{(j)} \\ \hat{\sigma}^2(\mathbf{x}) = k(\mathbf{x}, \mathbf{x}) - \boldsymbol{\lambda}^T(\mathbf{x}) \mathbf{k}(\mathbf{x}) - \gamma(\mathbf{x}) \end{cases} \quad (2.28)$$

b) Krigeage simple

Il s'agit d'un cas particulier du *krigeage* ordinaire avec le terme déterministe nul ($\mu(\mathbf{x}) = 0$). En utilisant la même notation et les mêmes principes que le *krigeage* ordinaire, on arrive à exprimer l'espérance de l'approximation de la fonction inconnue $\hat{f}(\mathbf{x})$ et l'estimation de la variance de l'erreur $\hat{\sigma}^2(\mathbf{x})$ par

$$\begin{cases} \hat{f}(\mathbf{x}) = \mathbf{k}(\mathbf{x})^T \mathbf{K}^{-1} \mathbf{F}^{(j)} \\ \hat{\sigma}^2(\mathbf{x}) = k(\mathbf{x}, \mathbf{x}) - \mathbf{k}(\mathbf{x})^T \mathbf{K}^{-1}(\mathbf{x}) \mathbf{k}(\mathbf{x}) \end{cases} \quad (2.29)$$

Si la fonction à optimiser présente des valeurs proches de 0, les performances du *krigeage ordinaire* et *simple* sont très similaires ; par contre, si les valeurs de la fonction sont très éloignées de 0, l'approximation du *krigeage simple* n'est pas acceptable (voir Fig. 2.6). Par définition, l'approximation du *krigeage* ordinaire est indépendante de la valeur moyenne de la fonction objectif.

c) Krigeage additif

Il s'agit d'une modification du *krigeage ordinaire*. Les modèles additifs donnent une approximation de la fonction inconnue à travers l'addition de fonctions qui dépendent d'un seul paramètre. En utilisant la même notation que pour le *krigeage* ordinaire, on définit l'approximation de la fonction objectif $\hat{f}(\mathbf{x})$ comme

$$\hat{f}(\mathbf{x}) = \mu(\mathbf{x}) + \sum_{i=1}^m \hat{f}_i(\mathbf{x}(i)). \quad (2.30)$$

Le principe des modèles additifs est basé sur l'espace de Hilbert ($\|x\| = \sqrt{\langle x, x \rangle}$). Cette approche est proposée et détaillée dans [Durrande, 2011]. En utilisant les équations obtenues par *krigeage* simple (2.29) et l'hypothèse $\mu(\mathbf{x}) = 0$, on peut réécrire l'approximation de la fonction inconnue $\hat{f}(\mathbf{x})$ et l'estimation de la variance de l'erreur $\hat{\sigma}^2(\mathbf{x})$ comme

$$\begin{cases} \hat{f}(\mathbf{x}) = \left(\sum_{i=1}^m \mathbf{k}(x_i) \right)^T \left(\sum_{i=1}^m \mathbf{K}_i \right) \mathbf{F}^{(j)} \\ \hat{\sigma}^2(\mathbf{x}) = \left(\sum_{i=1}^m k(x_i, x_i) \right) - \left(\sum_{i=1}^m \mathbf{k}(x_i) \right)^T \left(\sum_{i=1}^m \mathbf{K}_i \right)^{-1} \left(\sum_{i=1}^m \mathbf{k}(x_i) \right) \end{cases} \quad (2.31)$$

Les différences les plus significatives du *krigeage* additif par rapport au *krigeage* simple et au *krigeage* ordinaire sont :

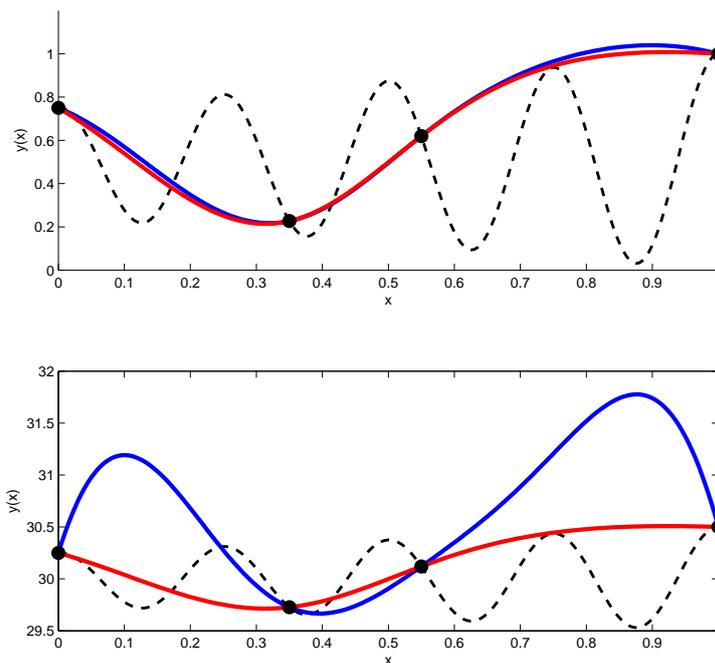


FIGURE 2.6: Différence entre *krigeage* ordinaire et *krigeage* simple. La courbe noire en trait pointillé correspond à la fonction réelle et inconnue. Les points noirs correspondent aux évaluations de la fonction objectif. La courbe bleue correspond à l'approximation par *krigeage* simple, et la courbe rouge correspond à l'approximation par *krigeage* ordinaire. (En haut) Représentation d'une fonction de moyenne 0,5 ($\mu(\mathbf{x}) = 0,5$), (en bas) représentation de la même fonction précédente, mais avec ($\mu(\mathbf{x}) = 30$).

- le nombre d'évaluations nécessaires du *krigeage* additif par rapport au nombre de paramètres à optimiser augmente de manière linéaire ($O(m)$), alors que pour le *krigeage* simple et ordinaire ce nombre augmente de manière exponentielle (O^m);
- pour les problèmes de petite dimension, lorsque le nombre d'évaluations augmente, le modèle additif devient très instable, car il ne prend pas en compte la corrélation entre paramètres.

Remarque 2.6 Dans la littérature, on trouve des extensions plus complexes du *krigeage*. Un exemple est le "co-*krigeage*" [Villemonteix, 2009], qui prend en compte les phénomènes corrélés entre objectifs ; cette stratégie est moins sensible au bruit de calcul de la fonction à approcher. ■

2.2.5 Fonctions de covariance

Les modèles de substitution donnent des approximations d'une fonction objectif à partir de quelques évaluations de cette fonction. Le nombre d'évaluations et la distribution des configurations de paramètres \mathbf{x} dans l'espace de recherche \mathcal{X} ont une influence très forte sur la qualité du modèle de substitution. Mais il y a d'autres facteurs à prendre en considération, comme l'utilisation d'une fonction de covariance adaptée. Dans cette section, on présente les fonctions de covariance les plus utilisées pour l'optimisation avec des modèles de substitution, en faisant attention à la sélection des paramètres internes des fonctions de covariance. Une mauvaise sélection de ces paramètres peut conduire à une mauvaise estimation de la fonction objectif par le modèle de substitution, ce qui implique une mauvaise optimisation. Les fonctions de covariance permettent de définir l'influence et le poids d'une configuration de paramètres dans \mathcal{X} par rapport aux configurations de paramètres déjà évaluées \mathbf{X}^j .

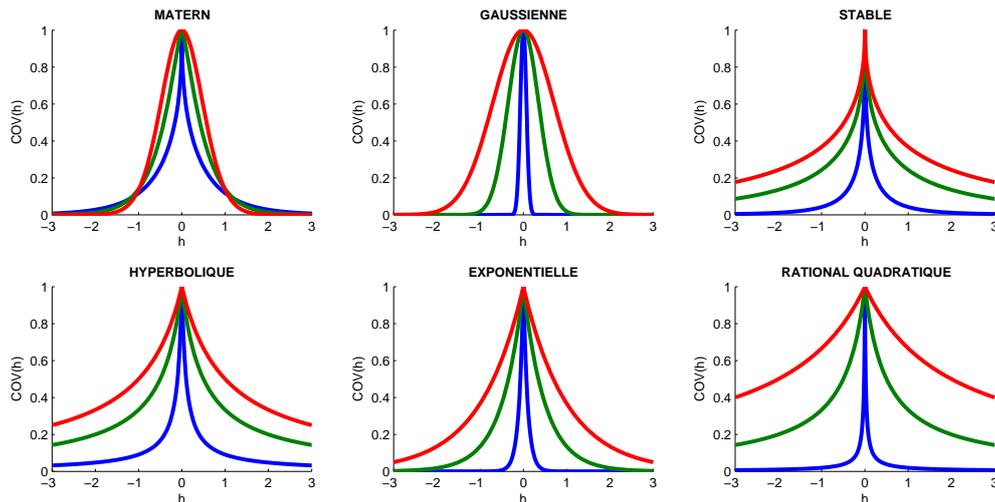


FIGURE 2.7: Différentes classes de fonctions de covariance. Les valeurs du paramètre ρ sont fixées à 0,1 (lignes bleues), 0,5 (lignes vertes) et 1 (lignes rouges).

Typiquement, les fonctions de covariance choisies sont *isotropes*. Ce type de covariances fait l'hypothèse que tous les m paramètres à optimiser ont la même influence sur les résultats obtenus. Alors, pour calculer la distance, on prend en compte que toute direction dans \mathcal{X} a la même influence sur $f(\mathbf{x})$. Les types de fonction distance les plus utilisés sont la distance euclidienne h_{eucl} et la distance rectangulaire h_{rect}

$$\begin{aligned} h_{eucl}(\mathbf{x}_a, \mathbf{x}_b) &= \sqrt{(x_{a1} - x_{b1})^2 + \cdots + (x_{am} - x_{bm})^2}, \\ h_{rect}(\mathbf{x}_a, \mathbf{x}_b) &= |x_{a1} - x_{b1}| + \cdots + |x_{am} - x_{bm}|, \end{aligned} \quad (2.32)$$

où $\{\mathbf{x}_a, \mathbf{x}_b\} \in \mathcal{X}$.

Les fonctions de covariance les plus utilisées dans la conception de modèles de substitution sont la covariance de Matérn et la covariance gaussienne. Dans la littérature, d'autres fonctions de covariance sont proposées [Rasmussen et Williams, 2006]; on peut citer la covariance stable, la covariance hyperbolique, la covariance exponentielle et la covariance rationnelle quadratique (voir Fig. 2.7).

Fonction de covariance de Matérn

C'est la fonction la plus utilisée avec les modèles de substitution par *krigeage*. Elle s'exprime par

$$k(h) = \frac{r^2}{2^{\nu-1}\Gamma(\nu)} \left(\frac{2\nu^{\frac{1}{2}}h}{\rho} \right)^\nu \mathbb{K}_\nu \left(\frac{2\nu^{\frac{1}{2}}h}{\rho} \right) \quad (2.33)$$

en désignant par h la valeur de la distance, Γ la fonction *gamma*⁹, \mathbb{K}_ν la fonction de Bessel de deuxième espèce et r^2 la valeur de covariance de référence ($k(0) = r^2 = 1$). Les deux paramètres de mise au point de la fonction de covariance sont le contrôle de régularité ν (dérivabilité en zéro) et la portée de la covariance ρ (distance de corrélation). Cette fonction de covariance s'adapte très bien à n'importe quelle distribution de paramètres dans \mathcal{X} , mais le problème est qu'elle a 2 paramètres à spécifier (ν, ρ). Le choix de ces paramètres prendra une partie très importante dans le temps de calcul du *krigeage*, particulièrement en grande dimension ou avec un nombre élevé d'évaluations.

Remarque 2.7 Dans le reste du manuscrit, on utilisera la distance euclidienne $h = h_{eucl}$ et la fonction de covariance de Matérn. ■

⁹En mathématiques, elle est une fonction complexe considérée également comme une fonction spéciale qui prolonge la fonction factorielle à l'ensemble des nombres complexes [Cody, 1976].

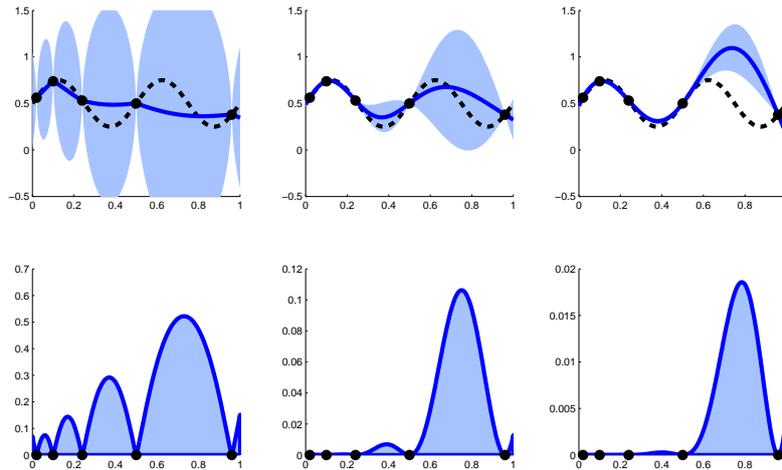


FIGURE 2.8: Influence des paramètres de la fonction de covariance. (En haut) Trois figures avec l'estimation de la fonction objectif par *krigeage*. (En bas) La valeur de la variance du *krigeage* correspondant à chacune des figures. (A gauche) Un modèle de substitution avec une variance sur-estimée. (A droite) Un modèle de substitution avec une variance sous-estimée. (Au milieu) Un modèle de substitution avec un choix de paramètres de covariance correct.

Fonction de covariance gaussienne

C'est la fonction de covariance la plus basique, avec un seul paramètre d'ajustement. Elle s'adapte bien aux modèles d'optimisation si les configurations de paramètres évaluées \mathbf{X}^j sont bien distribuées dans tout l'espace \mathcal{X} ; elle est définie par

$$k(h) = r^2 \exp\left(-\frac{h^2}{2\rho^2}\right) \quad (2.34)$$

2.2.6 Estimation de paramètres de covariance

Les paramètres de la covariance ont un fort impact sur l'estimation des modèles de substitution (voir Figure 2.8). La solution la plus simple est de définir les paramètres *a priori*, mais il faut bien connaître le problème à optimiser et la distribution des configurations de paramètres déjà évalués dans l'espace de recherche. Les critères les plus utilisés pour la sélection de paramètres sont la méthode du maximum de vraisemblance [Stein, 1999] et la méthode de validation croisée [Wahba, 1999]. Bien qu'aucune de ces deux méthodes ne soit supérieure à l'autre, on a décidé d'utiliser le critère de maximum de vraisemblance, car elle c'est une solution plus simple à implémenter et elle a déjà été testée avec modèles de substitution basés sur le *krigeage* [Villemonteix, 2009] [Bettinger, 2009]. Ensuite, les critères de maximum de vraisemblance seront introduits brièvement. Pour plus de détails, consulter [Aldrich, 1997] et [Myung, 2008].

Maximum de vraisemblance

Supposons un modèle de substitution défini par une variable gaussienne $\hat{F}(\mathbf{x}) \sim (\hat{f}(\mathbf{x}), \hat{\sigma}(\mathbf{x}))$ estimée à partir de j observations $\mathbf{F}^{(j)}$. Si la valeur moyenne $\hat{f}(\mathbf{x})$ est connue, on peut chercher une combinaison optimale des paramètres θ de la fonction de covariance $\mathbf{k}(\theta)$ en maximisant la fonction de log-vraisemblance l_{mv}

$$l_{mv}(\mathbf{F}^{(j)}, \theta) = -\frac{j}{2} \log(2\pi) - \frac{1}{2} \log(\det(\mathbf{K}(\theta))) - \frac{1}{2} (\mathbf{F}^{(j)})^T \mathbf{K}(\theta)^{-1} \mathbf{F}^{(j)} \quad (2.35)$$

Généralement, cette méthode n'est pas utilisée pour l'optimisation de modèles de substitution, car la valeur moyenne du modèle de substitution $\hat{f}(\mathbf{x})$ est supposée inconnue.

Maximum de vraisemblance restreint

Comme la valeur moyenne du modèle de substitution $\hat{f}(\mathbf{x})$ est inconnue, cette méthode propose de la définir comme $\hat{f}(\mathbf{x}) = \beta^t \mathbf{p}(\mathbf{x})$, avec $\mathbf{p}(\mathbf{x})$ un vecteur de fonctions connues, typiquement $\mathbf{p}(\mathbf{x}) = \mathbf{1}_{m \times 1}$, et β un vecteur de m constantes inconnues. Cette approche a été initialement proposée par [Patterson et Thompson, 1971] et ultérieurement complétée par [Wilson, 1989] et [McCullagh et Nelder, 1989]. Le but est d'estimer les paramètres de covariance θ à travers une combinaison linéaire de j observations réalisées avec la fonction objectif, ces observations ne dépendant pas du vecteur inconnu β . Une projection de la variable gaussienne $F(\mathbf{x})$ est définie comme une nouvelle variable gaussienne $M(\mathbf{x})$ de moyenne nulle, afin d'annuler la valeur moyenne du modèle de substitution $\hat{f}(\mathbf{x})$

$$\begin{aligned} \mathbf{P}^{(j)} &= (\mathbf{p}(\mathbf{x}^{(1)}), \dots, \mathbf{p}(\mathbf{x}^{(j)}))^T \\ \mathbf{M}^{(j)} &= \left(\mathbf{I}_j - \mathbf{P}^{(j)} \left((\mathbf{P}^{(j)})^T \mathbf{P}^{(j)} \right)^{-1} (\mathbf{P}^{(j)})^T \right) \mathbf{F}^{(j)} \end{aligned} \quad (2.36)$$

où \mathbf{I}_j est une matrice identité de dimension j et $\mathbf{M}^{(j)}$ est la projection des évaluations $\mathbf{F}^{(j)}$. La nouvelle formulation de log-vraisemblance l_{mvr} obtenue à partir du l_{mv} (2.35) et la projection (2.36) s'écrit

$$\begin{aligned} l_{mvr}(\mathbf{M}^{(j)}, \theta) &= -\frac{j-1}{2} \log(2\pi) - \frac{1}{2} \log(\det(\mathbf{K}(\theta))) - \frac{1}{2} \log(\det(B(\theta))) - \\ &\quad - \frac{1}{2} (\mathbf{M}^{(j)})^T \left(\mathbf{K}(\theta)^{-1} - \mathbf{K}(\theta)^{-1} \mathbf{P}^{(j)} B(\theta)^{-1} (\mathbf{P}^{(j)})^T \mathbf{K}(\theta)^{-1} \right) \mathbf{M}^{(j)} \end{aligned} \quad (2.37)$$

où $B(\theta) = (\mathbf{P}^{(j)})^T \mathbf{K}(\theta)^{-1} \mathbf{P}^{(j)}$. Le choix des paramètres optimaux de θ sera fait en maximisant la log-vraisemblance l_{mvr} (2.37). En pratique, comme les fonctions de covariance présentées dans le manuscrit (voir Section 2.2.5) ont au maximum 2 paramètres de réglage ($\theta = [\nu \rho]$), et comme le critère à optimiser (2.37) n'a qu'un maximum, l'utilisation des algorithmes *mono-objectif non-linéaires locaux* (Nelder-Melder, MADS) est l'option la plus adaptée.

2.2.7 Plan d'expérience

Le *plan d'expérience* (PdE) ou *design of experiments* est la planification d'une distribution correcte des configurations initiales des paramètres $\mathbf{X}^{(j_0)} = \{\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(j_0)}\}$ sur l'espace de recherche $\mathcal{X} \subset \mathbb{R}^m$, où j_0 est le nombre d'évaluations initiales de la fonction objectif $f(\mathbf{x})$. La plupart des algorithmes d'optimisation doivent utiliser un PdE optimal avant de lancer leur propre *critère d'échantillonnage* (voir section 2.2.8). Pour les algorithmes d'optimisation basés sur les modèles de substitution, quelques évaluations initiales $\mathbf{F}^{(j_0)}$ de la fonction objectif sont indispensables pour commencer la modélisation. Le problème principal des PdE est qu'en général aucune information sur $f(\mathbf{x})$, ni sur sa distribution dans l'espace de recherche, n'est disponible.

Les méthodes de *remplissage de l'espace* ou *space-filling methods* ont pour objectif de garantir une distribution uniforme sur tout l'espace \mathcal{X} . Par exemple, une méthode qui remplit aléatoirement l'espace de recherche ne sera pas une bonne solution. Seulement les critères les plus utilisés et la solution retenue sont présentés brièvement dans la section suivante.

Critères stochastiques

Ces critères ont été très utilisés au début des années 90 car l'utilisation des modèles de substitution, comme la *krigeage*, permettent d'utiliser très intuitivement des méthodes de remplissage probabilistes. Malheureusement, ces méthodes sont exigeantes en temps de calcul et l'optimalité du PdE dépend directement de la fonction de covariance choisie. Un changement des paramètres de la fonction de covariance implique que le PdE obtenu sera différent.

Deux critères stochastiques classiques sont le critère introduit par [Box et Hill, 1967], basé sur le principe de l'entropie de Shannon, et le critère défini dans [Box et Draper, 1959], basé sur l'erreur quadratique moyenne intégrée et le principe de minimisation de l'écart entre la valeur estimée et la valeur réelle.

Critères déterministes

Ces critères d'échantillonnage ont pour objectif de distribuer les configurations de paramètres dans l'espace de recherche \mathcal{X} en se basant sur la *fonction distance*¹⁰ $h(\mathbf{x}_a, \mathbf{x}_b)$ [Johnson et al., 1990].

- Le plan *maximin*. Ce PdE est basé sur la maximisation de la distance minimale entre toutes les valeurs de configurations des paramètres initiaux $\mathbf{X}^{(j_0)}$ dans l'espace de recherche \mathcal{X} . Ce critère a tendance à concentrer les points sur les limites de l'espace de recherche, ce qui est un problème pour les PdE en grande dimension et un nombre réduit de configurations de paramètres.

$$\max_{\mathbf{x}_a \in \mathbf{X}^{(j_0)}} \min_{\mathbf{x}_b \in \mathbf{X}^{(j_0)}} h(\mathbf{x}_a, \mathbf{x}_b) \text{ avec } (a, b) = \{1, \dots, j_0\} \quad (2.38)$$

- Le plan *minimax*. Ce PdE est basé sur la minimisation de la distance maximale entre toutes les valeurs de l'espace de recherche et toutes les configurations de paramètres initiales. Ce critère utilise une grille \mathcal{G} de l'espace de recherche avec un nombre limité de configurations de paramètres $\mathbf{x}_{\mathcal{G}}$ afin de réduire le temps de calcul.

$$\min_{\mathbf{x}_{\mathcal{G}} \subset \mathcal{G} \in \mathcal{X}} \max_{\mathbf{x}_a \in \mathbf{X}^{(j_0)}} h(\mathbf{x}_{\mathcal{G}}, \mathbf{x}_a) \text{ avec } a = \{1, \dots, j_0\} \quad (2.39)$$

Hypercube latin

Le critère de l'*hypercube latin* ou *latin hypercube design* (HCL ou LHS) [McKay et al., 1979] est défini par le nombre de configurations de paramètres initiales à distribuer j_0 et par le nombre de paramètres à optimiser m . Les différentes étapes de la méthode sont :

1. Partition. Pour chaque paramètre à optimiser \mathbf{x}_p , son intervalle de valeurs $[\underline{x}_p, \overline{x}_p]$ est divisé en j_0 parties de la même longueur.

$$\underline{x}_p, \underline{x}_p + \frac{\overline{x}_p - \underline{x}_p}{j_0}, \dots, \underline{x}_p + (j_0 - 1) \frac{\overline{x}_p - \underline{x}_p}{j_0}, \overline{x}_p \quad (2.40)$$

2. Distribution. On définit une matrice $\mathbf{\Pi}$ de taille $(j_0 \times m)$ où chaque colonne est une permutation aléatoire de $p = \{1, \dots, j_0\}$.
3. Positionnement. À partir de la matrice $\mathbf{\Pi}$ obtenue, la distribution sur l'intervalle des valeurs est définie. Le matrice $\mathbf{\Pi}$ permet d'identifier le sous-espace disjoint élu. Habituellement, on prend la valeur du centre de chaque sous-espace, mais il existe d'autres méthodes comme, par exemple, prendre une valeur aléatoire dans le sous-espace.

Bien que la méthode de l'HCL offre la garantie que les configurations de paramètres sont bien distribuées sur l'espace de recherche, cette distribution n'est pas toujours optimale (voir Fig. 2.9).

Solution retenue

L'utilisation d'un PdE non adapté à l'espace de recherche impactera négativement les performances de l'optimisation, typiquement avec des problèmes de *clustering*¹¹. La solution utilisée dans ce manuscrit est une combinaison du critère de l'*hypercube latin* et du critère déterministe *maximin*. Cette procédure consiste à générer plusieurs HCL, et à retenir le meilleur HCL selon le critère *maximin* (2.38).

Remarque 2.8 Notons que, si le problème est de très grande dimension, ce qui n'est pas le cas traité dans cette thèse, le critère "minimax" peut être utilisé pour la sélection du meilleur HCL, car le critère "maximin" a tendance à concentrer les paramètres au bord du domaine. ■

¹⁰Décrite à la Section 2.2.5.

¹¹Points générés aléatoirement avec une tendance à se concentrer dans certaines zones de l'espace de recherche \mathcal{X} .

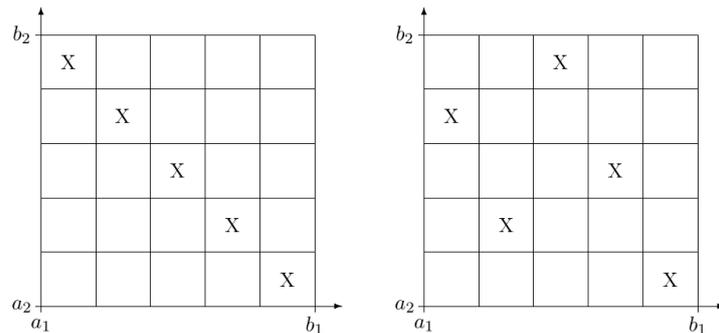


FIGURE 2.9: Exemple de deux plans d'expérience, sur un espace de recherche de dimension deux, obtenus par la méthode de l'hypercube latin. (A gauche) Un PdE non-optimal. Les configurations de paramètres ne sont pas distribuées correctement dans l'espace de recherche et la distance entre configurations voisines est très petite. (A droite) Un PdE obtenu par la solution retenue (HCL+maximin).

Remarque 2.9 La fonction retenue existe déjà sur MATLAB [`lhsdesign(j0,m,...)`], qui permet de générer des HCL normalisés¹² en introduisant le nombre de paramètres à optimiser m , le nombre de configurations de paramètres du PdE j_0 , et le nombre de HCL générés avant de choisir le meilleur. En utilisant cette solution, le temps nécessaire pour trouver le PdE est considéré comme négligeable par rapport au temps d'optimisation (spécialement dans le contexte de fonctions coûteuses). De plus, le calcul de l'HCL n'est fait que dans l'itération initiale (pas dans la boucle d'optimisation). ■

2.2.8 Critère d'échantillonnage

L'optimisation globale d'une fonction devient un problème difficile lorsqu'elle n'est pas convexe ou s'il y a plusieurs minima locaux. De plus, si la dimension de l'espace de recherche est élevée, on a besoin de réaliser un nombre important d'évaluations. La méthode de sélection d'une nouvelle configuration des paramètres candidats $\mathbf{x}^{(j+1)} \in \mathcal{X}$ à évaluer avec la fonction objectif $f(\mathbf{x})$, est appelée *critère d'échantillonnage*. Les critères d'échantillonnage les plus performants et utilisés par l'optimisation avec modèles de substitution [Droesbeke et al., 1997] [Müller, 2007] sont présentés ci-dessous.

Minimisation de la borne inférieure de confiance

Le critère de minimisation de la *borne inférieure de confiance* ou *lower confidence bound* (LCB) [Cox et John, 1997] utilise l'information de la prédiction $\hat{f}(\mathbf{x})$ et la variance $\hat{\sigma}^2(\mathbf{x})$ estimée par le *krigeage* pour construire des bornes de confiance. La borne de confiance inférieure est définie par

$$\text{LCB}(\mathbf{x}) = \hat{f}(\mathbf{x}) - \alpha \hat{\sigma}(\mathbf{x}) \quad (2.41)$$

où α est un paramètre de contrôle toujours positif. Une grande valeur de α privilégie une recherche globale (exploration), et une petite valeur de α privilégie une recherche locale (intensification). Une valeur typique est $\alpha = 1,96$, où la borne inférieure correspond à l'intervalle de confiance à 95%, c'est-à-dire :

$$\text{prob} \left(F(\mathbf{x}) < \hat{f}(\mathbf{x}) - 1,96 \hat{\sigma}(\mathbf{x}) \right) = 0,025 \quad (2.42)$$

La probabilité que la valeur de la fonction estimée soit inférieure à la valeur minimale observée par la fonction objectif $f_{min}^{(j)}$ est définie pour toute configuration des paramètres dans l'espace de recherche. La configuration de paramètres avec la plus grande probabilité d'améliorer la fonction estimée sera proposée comme la nouvelle configuration candidate $\mathbf{x}^{(j+1)}$

$$\arg \max_{\mathbf{x} \in \mathcal{X}} (f_{min}^{(j)} - \text{LCB}(\mathbf{x})) \quad (2.43)$$

¹²Avec valeurs entre 0 et 1

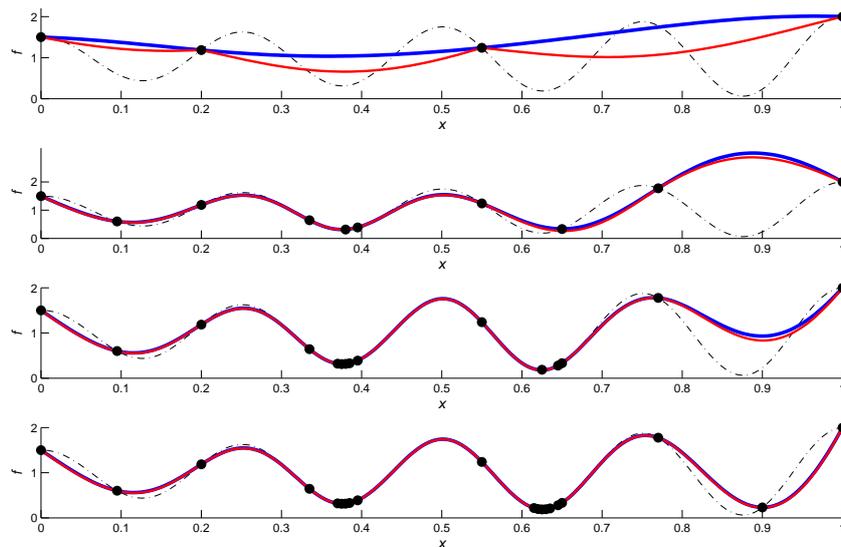


FIGURE 2.10: Exemple du fonctionnement du critère *minimisation de la borne inférieure de confiance*. Utilisation du critère LCB pour optimiser la fonction objectif inconnue (représentée en pointillés). Les courbes bleues correspondent aux approximations par *krigeage* et les courbes rouges correspondent aux bornes inférieures estimées par *krigeage*. (De haut en bas) Les figures correspondent à l'optimisation avec *krigeage* en utilisant 4, 10, 15 et 20 évaluations (points noirs).

L'optimisation sera terminée lorsque la prédiction par *krigeage* ne propose aucune configuration de paramètres qui améliore la fonction objectif, c'est-à-dire

$$(f_{min}^{(j)} - \text{LCB}(\mathbf{x})) < 0, \forall \mathbf{x} \in \mathcal{X} \quad (2.44)$$

Le problème de ce critère d'échantillonnage est qu'il est peu robuste par rapport à un mauvais choix des paramètres de la fonction de covariance ou de valeur de α . Un exemple de ces limitations est présenté dans la Fig. 2.10. Dans cet exemple, une sous-estimation de la fonction objectif fait que l'optimisation avec le critère LCB se focalise dans les zones avec de minima locaux f° , ce qui fait qu'un surcoût d'évaluations sera nécessaire pour réussir à bien identifier la zone qui contient le minimum global f^\bullet .

Maximisation de la probabilité d'amélioration - PI

Le critère de la *probabilité d'amélioration* ou *probability improvement* (PI) [Kushner, 1964] est basé aussi sur l'utilisation de la prédiction \hat{y} et la variance $\hat{\sigma}^2$ obtenue par *krigeage* à partir de j évaluations. La valeur de probabilité d'amélioration est définie comme

$$\text{PI}(\mathbf{x}) = \Phi\left(\frac{T - \hat{f}(\mathbf{x})}{\hat{\sigma}(\mathbf{x})}\right), \quad (2.45)$$

en désignant par Φ la fonction de répartition d'une distribution gaussienne, et T une valeur constante typiquement définie *a priori*. La valeur du $\text{PI}(\mathbf{x})$ correspond à la probabilité que la variable gaussienne estimée par *krigeage* $F(\mathbf{x})$ soit inférieure à la valeur cible T . La nouvelle configuration candidate $\mathbf{x}^{(j+1)}$ sera proposée en maximisant le critère $\text{PI}(\mathbf{x})$, c'est-à-dire

$$\mathbf{x}^{(j+1)} = \operatorname{argmax}_{\mathbf{x} \in \mathcal{X}} \text{PI}(\mathbf{x}). \quad (2.46)$$

Cependant, dans [Jones, 2001] un choix de T a été proposé, de manière à s'adapter automatiquement aux évaluations de la fonction objectif. On a

$$T = f_{min}^{(j)} - \alpha (f_{max}^{(j)} - f_{min}^{(j)}) \quad (2.47)$$

où α est un paramètre de contrôle positif, $f_{max}^{(j)}$ et $f_{min}^{(j)}$ l'évaluation maximale et minimale respectivement. La valeur de α permet de régler le niveau d'intensification et d'exploration par rapport à l'amplitude des résultats $\mathbf{F}^{(j)}$. L'inconvénient principal de ce critère est qu'il est fortement sensible à un mauvais choix de T ou de α . L'exemple proposé (voir Fig. 2.11) montre qu'un choix d'une valeur α trop petite se traduit par une recherche trop locale (pièges des minima locaux) et un choix d'une valeur α trop grande concentrera l'optimisation sur la réduction de la variance (répartition des évaluations sur tout l'espace de recherche sans chercher la configuration optimale).

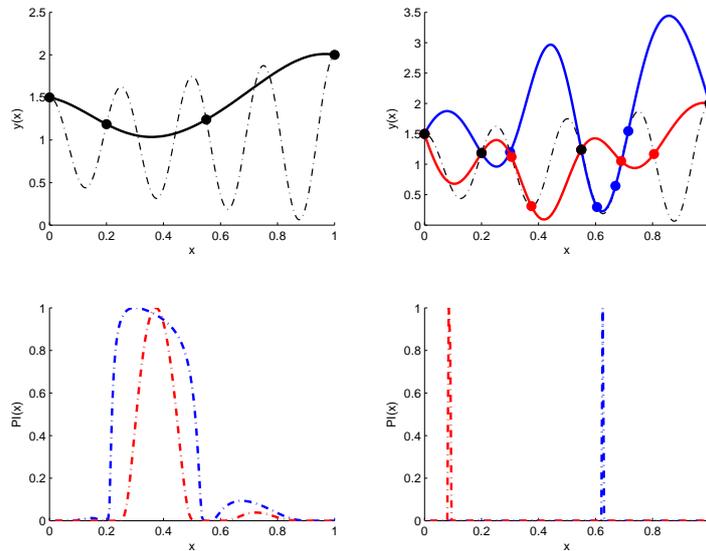


FIGURE 2.11: Exemple des problèmes du critère *maximisation de la probabilité d'amélioration* (PI). (En haut) A gauche, l'approximation initiale avec *krigeage* à partir de 4 évaluations (points noirs). La courbe en trait pointillé correspond à la fonction objectif inconnue. La courbe en trait plein correspond à l'approximation faite par *krigeage*. A droite, deux estimations obtenues par *krigeage* après 8 évaluations de la fonction objectif (4 évaluations avec le critère PI) : la courbe bleue avec un paramètre α petit ($\alpha = 0,05$) et la courbe rouge avec un paramètre α grand ($\alpha = 0,7$). (En bas) Les figures correspondent aux valeurs $PI(x)$ de la figure supérieure (bleue $\alpha = 0,05$, rouge $\alpha = 0,7$). La configuration de paramètres possédant la valeur maximale de $PI(x)$ sera le nouveau candidat à évaluer par la fonction objectif.

Maximisation de l'espérance de l'amélioration - EGO

La méthode *Efficient Global Optimization* (EGO) est basée sur le calcul de l'*espérance de gain* ou *Expected Improvement* (EI). Le principe est défini dans [Jones et al., 1998] et détaillé dans [Jones, 2001]; cependant, la structure et les étapes principales de cet algorithme sont résumées dans l'*Algorithme 2.1*. Ce critère définit le *gain de performance* ou *improvement* $I(\mathbf{x})$ comme l'écart de l'amélioration possible par rapport à la meilleure évaluation réalisée $f_{min}^{(j)}$

$$I(\mathbf{x}) = \begin{cases} f_{min}^{(j)} - f(\mathbf{x}) & \text{si } f(\mathbf{x}) < f_{min}^{(j)} \\ 0 & \text{sinon} \end{cases}. \quad (2.48)$$

Alors, le calcul de l'espérance de gain $EI(\mathbf{x})$ est définie par

$$EI(\mathbf{x}) = \mathbb{E}_{F(\mathbf{x})} [I(\mathbf{x})]. \quad (2.49)$$

Comme $F(\mathbf{x})$ est estimé par le *krigeage* ($F(\mathbf{x})$ gaussien), on peut redéfinir le critère comme

$$EI(\mathbf{x}) = \begin{cases} \left[\left(f_{min}^{(j)} - \hat{f}(\mathbf{x}) \right) \Phi \left(\frac{f_{min}^{(j)} - \hat{f}(\mathbf{x})}{\sigma(\mathbf{x})} \right) \right] + \left[\sigma(\mathbf{x}) \phi \left(\frac{y_{min}^{(j)} - \hat{f}(\mathbf{x})}{\sigma(\mathbf{x})} \right) \right] & \text{si } \sigma(\mathbf{x}) > 0 \\ 0 & \text{si } \sigma(\mathbf{x}) = 0 \end{cases}, \quad (2.50)$$

où ϕ est la fonction de densité et Φ la fonction de répartition (d'une loi $\mathcal{N}(0, 1)$). Pour trouver le candidat $\mathbf{x}^{(j+1)}$, on cherchera les configurations de paramètres qui maximisent cette espérance de gain, c'est-à-dire

$$\mathbf{x}^{(j+1)} = \operatorname{argmax}_{\mathbf{x} \in \mathcal{X}} \operatorname{EI}(\mathbf{x}) \quad (2.51)$$

Le critère d'arrêt proposé pour la méthode EGO est

$$\left| \frac{\operatorname{argmax}_{\mathbf{x} \in \mathcal{X}} \operatorname{EI}(\mathbf{x})}{f_{min}^{(j)}} \right| < S \quad (2.52)$$

où S est un seuil d'arrêt. Dans l'exemple proposé (voir Fig. 2.12), on peut observer que ce critère est très efficace pour des faibles dimensions. Si le problème a un nombre élevé de paramètres, la méthode a tendance à explorer l'espace de recherche en essayant de minimiser la variance globale (faible intensification).

Plan d'expériences initial : $\mathbf{X}^{(j)}$, $\mathbf{F}^{(j)}$ et $j = j_0$
Tant que ($j < J$) **faire**
 Modèle de substitution : $(\hat{f}(\mathbf{x})^{(j)}, \hat{\sigma}(\mathbf{x})^{(j)}) \leftarrow \text{Krigage}\{\mathbf{X}^{(j)}, \mathbf{F}^{(j)}\}$
 Nouveau candidat : $\mathbf{x}^{(j+1)} \leftarrow \operatorname{argmax}_{\mathbf{x}} \operatorname{EI}(\mathbf{X}^{(j)}, \hat{f}(\mathbf{x})^{(j)}, \hat{\sigma}(\mathbf{x})^{(j)})$
 Évaluation de la fonction objectif : $f^{(j+1)} \leftarrow f(\mathbf{x}^{(j+1)})$
Fin Tant que
Sorties : $\mathbf{X}^{(J)}$ et $\mathbf{F}^{(J)}$

Algorithme 2.1 : Structure principale de l'algorithme EGO [Jones et al., 1998].

Entropie conditionnelle des minimiseurs

L'algorithme *Approche Informationnelle pour l'Optimisation Globale* ou *Informational Approach to Global Optimization* (IAGO) [Villemonteix et al., 2009] utilise la même structure que l'algorithme EGO. Néanmoins, le critère d'échantillonnage proposé est différent. Ce nouveau critère est appelé *Entropie Conditionnelle des Minimiseurs* (ECM). L'idée principale est de générer C simulations conditionnelles¹³ à partir du modèle de substitution, de créer une grille \mathcal{G} par la discrétisation de l'espace de recherche \mathcal{X} avec un total de G configurations de paramètres, et de calculer la probabilité d'avoir un minimum global $P_{\mathbf{x}_G^*}$ pour chaque simulation conditionnelle c et pour chaque configuration de paramètres qui appartient à la grille ($\mathbf{u} = \mathbf{x} \in \mathcal{G}$). La valeur de probabilité est définie comme

$$P_{\mathbf{x}_G^*}(\mathbf{u}) = \frac{1}{G} \quad \forall \mathbf{u}. \quad (2.53)$$

Cette valeur de probabilité est utilisée pour calculer la valeur de l'entropie conditionnelle $H(\mathbf{u})$ définie selon

$$H(\mathbf{u}) = \sum_{c=1}^C \frac{-1}{C} \sum_{\mathbf{u} \in \mathcal{G}} P_{\mathbf{x}_G^*}(\mathbf{u}) \log_2 P_{\mathbf{x}_G^*}(\mathbf{u}) \quad (2.54)$$

La minimisation de l'entropie conditionnelle permettra de proposer la nouvelle configuration candidate. Ce critère d'échantillonnage est une solution robuste qui s'adapte bien à des fonctions bruitées. Quelques

¹³Représentations possibles de $f(\mathbf{x})$ générées à partir d'un processus gaussien $F(\mathbf{x})$, lequel a été créé à partir de j évaluations d'une fonction objectif.

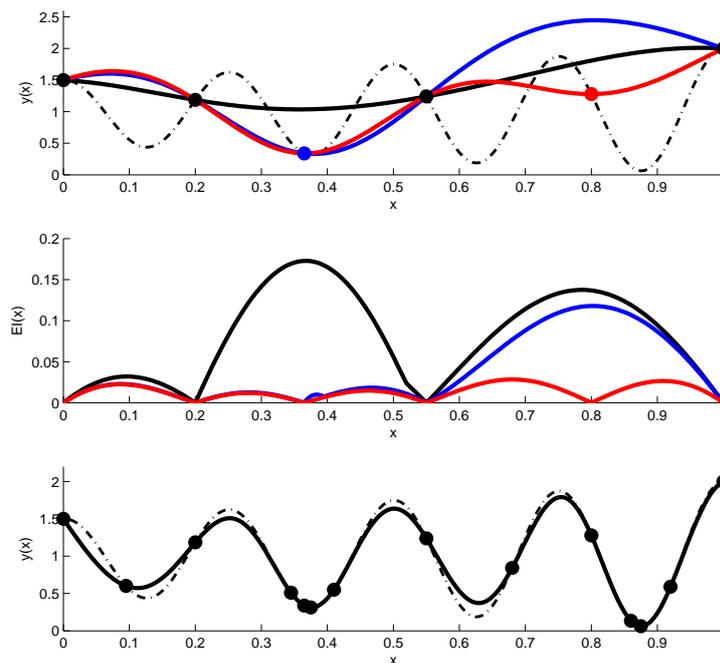


FIGURE 2.12: Exemple du fonctionnement de la méthode *efficient global optimization* (EGO). (De haut en bas) Le premier graphe donne l'approximation initiale avec *krigeage* (trait plein et noir) à partir de 4 évaluations (points noirs) de la fonction objectif inconnue (trait pointillé). Les courbes bleue et rouge correspondent aux approximations par *krigeage* après 1 et 2 itérations (c'est-à-dire 5 et 6 évaluations), respectivement. Dans le deuxième graphe, les courbes noire, bleue et rouge correspondent aux valeurs de EI après 0 (initiale), 1 et 2 itérations respectivement. Le troisième graphe correspond à l'approximation par *krigeage* obtenu après 10 itérations de l'EGO.

extensions de la méthode IAGO sont présentées dans [Villemonteix et al., 2009] pour exploiter l'information du gradient et prendre en compte des contraintes. Néanmoins, le bon fonctionnement de la méthode dépend de plusieurs facteurs : qualité de l'approximation du modèle de substitution, bon choix des fonctions de covariance et définition intelligente de la grille qui s'adapte correctement à l'espace de recherche par rapport aux configurations de paramètres déjà évaluées. De plus, un nombre élevé de configurations de paramètres de la grille G ou de simulations conditionnelles C augmentera considérablement la complexité de l'algorithme.

2.3 Optimisation globale multi-objectif

L'optimisation d'une fonction ayant plusieurs objectifs à optimiser est appelée optimisation *multi-objectif*. Dans l'industrie, les systèmes sont généralement évalués avec des critères antagonistes, ce qui fait que l'optimisation n'est pas une tâche facile. Une grande partie des algorithmes d'optimisation globale multi-objectif sont des extensions d'algorithmes d'optimisation globale mono-objectif [Minoux, 1983] [Boyd et Vandenberghe, 2004]. En règle générale, les différents objectifs de la fonction à optimiser sont combinés linéairement avec des poids définis *a priori* en obtenant un seul objectif à traiter. Néanmoins, trouver un bon compromis entre les différents objectifs de la fonction est étudié par d'autres algorithmes d'optimisation multi-objectif [Collette et Siarry, 2003].

Dans cette section, après avoir introduit quelques notions basiques sur l'optimisation multi-objectif, les algorithmes d'optimisation globale multi-objectif de référence seront présentés : le *Non-dominated Sorting Genetic Algorithm 2* (NSGA2) [Deb et al., 2000], le *Pareto Efficient Global Optimization* (ParEGO)

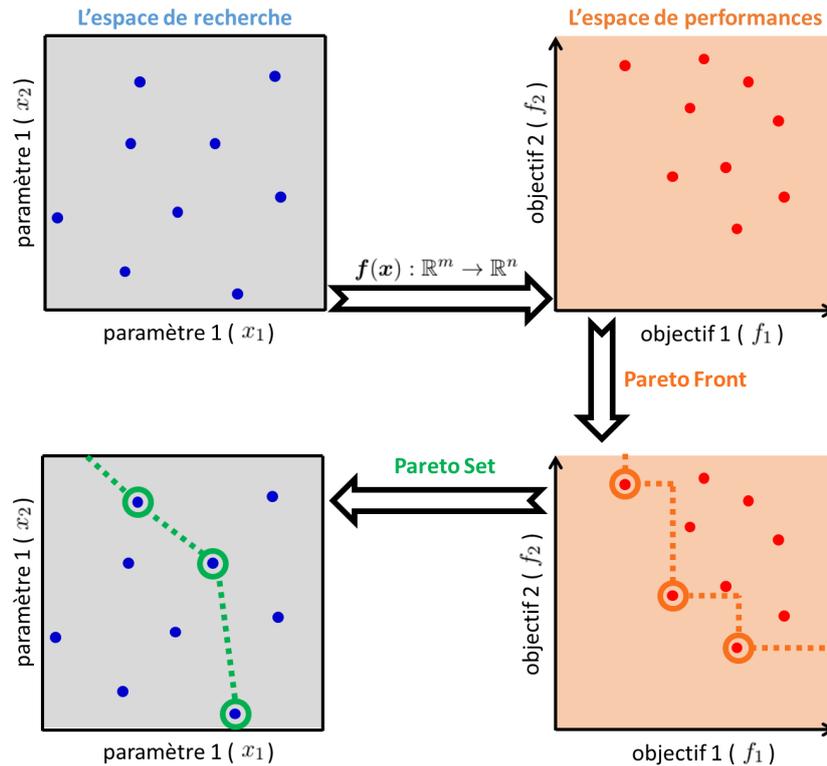


FIGURE 2.13: Représentation du front de Pareto (*Pareto Front*) et de l'ensemble de Pareto (*Pareto Set*). Exemple d'une fonction bi-objectif ($n = 2$) avec deux paramètres à optimiser ($m = 2$). (A gauche) L'espace de paramètres $\mathcal{X} \in \mathbb{R}^m$ avec quelques configurations de paramètres (points bleus). (A droite) L'espace de performances $\mathcal{F} \in \mathbb{R}^n$ avec les résultats obtenus (points rouges) en évaluant les configurations de paramètres par la fonction objectif $f(x)$. (En bas) Représentation du front de Pareto (*Pareto Front*) et de l'ensemble de Pareto (*Pareto Set*) obtenus à partir du principe de la dominance.

[Knowles, 2005], le *Multi-Objective Particle Swarm Optimization* (MOPSO) [Coello et al., 2004], le *Pareto Envelope-based Selection Algorithm 2* (PESA2) [Corne et al., 2001] et le *Strength Pareto Evolutionary Algorithm 2* (SPEA2) [Zitzler et al., 2001]. Les algorithmes NSGA2 et ParEGO seront expliqués avec plus de détail en raison de leur usage fréquent dans l'industrie automobile. Dans la littérature, on trouve des travaux de référence sur l'optimisation multi-objectif comme [Coello et al., 2007] concernant les algorithmes d'optimisation évolutionnaires, et [Voutchkov et Keane, 2010] pour ce qui est des algorithmes d'optimisation avec modèles de substitution.

2.3.1 Quelques définitions

Définition 2.15 [Collette et Siarry, 2003] Supposons deux évaluations de la fonction objectif $f(x) : \mathbf{f}_a = \{f_{a1}, \dots, f_{an}\}$ et $\mathbf{f}_b = \{f_{b1}, \dots, f_{bn}\}$. Si toutes les composantes de \mathbf{f}_a sont inférieures ou égales aux composantes de \mathbf{f}_b (avec une composante strictement inférieure), alors on dit que l'évaluation \mathbf{f}_a "domine" l'évaluation \mathbf{f}_b . ■

Définition 2.16 [Collette et Siarry, 2003] Si une évaluation de la fonction objectif n'est pas "dominée" par aucune autre évaluation, celle-ci est appelée "solution non dominée" (*non dominated solution*). ■

Définition 2.17 [Collette et Siarry, 2003] Le front de Pareto ou "*Pareto Front*" (PF) est défini, dans l'espace des performances, comme l'ensemble des "solutions non dominées". ■

Définition 2.18 [Collette et Siarry, 2003] L'ensemble de Pareto ou "*Pareto Set*" (PS) est défini, dans l'espace de recherche, comme les configurations de paramètres qui correspondent à l'ensemble des "solutions non dominées". ■

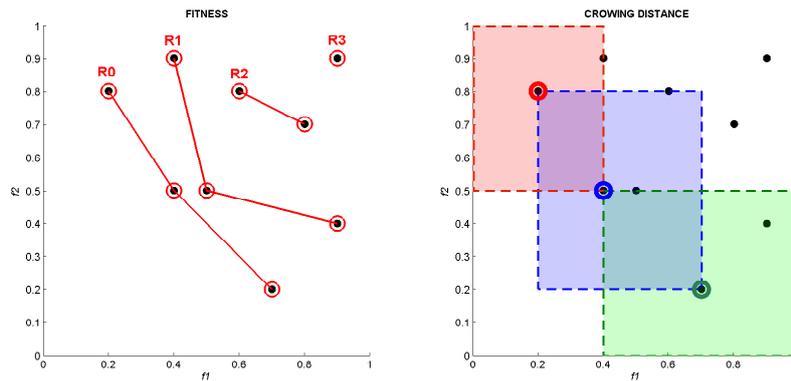


FIGURE 2.14: Concepts de rang et distance de l'algorithme NSGA2. (source de l'image : [Deb et al., 2000])

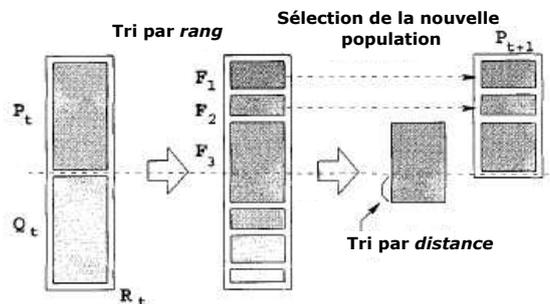


FIGURE 2.15: La boucle principale de l'algorithme NSGA2. (source de l'image : [Deb et al., 2000])

La *dominance* est un des critères de comparaison des performances d'une fonction multi-objectif utilisée comme alternative à la combinaison linéaire des différents objectifs. Ce principe est utilisé pour définir le front de Pareto et l'ensemble de Pareto (voir Fig.2.13). Du point de vue de l'optimalité, on considère que toutes les configurations de paramètres et d'évaluations qui appartiennent au PS et PF respectivement sont les meilleures solutions trouvées par l'algorithme d'optimisation ($f(\text{PS})=\text{PF}$). Néanmoins, un compromis arbitraire entre les différents objectifs sera utilisé après l'optimisation, pour choisir une configuration de paramètres parmi l'ensemble des solutions optimales PS. Ce choix dépendra de l'application.

2.3.2 Nondominated Sorting Genetic Algorithm 2

L'algorithme *Nondominated sorting genetic algorithm 2* (NSGA2) [Deb et al., 2000] est l'algorithme multi-objectif de référence depuis le début des années 2000. L'idée principale de cet algorithme est d'utiliser l'information du PF obtenue à partir des évaluations sur la fonction réelle. Deux concepts sont introduits (voir Fig.2.14) :

- Rang (*fitness*). Pour définir le rang, l'algorithme cherche le PF. Les solutions qui appartiennent au PF sont considérées de rang 0. Ensuite, l'algorithme les enlève de l'espace des performances et cherche de nouveau le PF. Cette procédure est répétée jusqu'à ce que toutes les évaluations soient associées à un rang. Le rang apportera une valeur de performance de chaque évaluation par rapport aux autres.
- Distance (*Crowing distance*). Elle est définie comme la distance entre deux points voisins ayant le même rang.

L'algorithme NSGA2 privilégiera les évaluations de rang petit et de grande distance en lui donnant beaucoup de poids pendant l'optimisation. Le concept de rang permettra d'optimiser les bonnes régions de l'espace (exploration) et la distance permettra d'obtenir un PF mieux défini (intensification).

Bien que l'algorithme NSGA2 soit un des algorithmes multi-objectif de référence, son utilisation présente quelques inconvénients :

- Si la fonction objectif dépend d'un nombre élevé de paramètres, l'algorithme a besoin d'une grande population N pour bien explorer tout l'espace de recherche.
- Si le nombre d'objectifs est supérieur à trois ou quatre, la performance de l'optimisation est très mauvaise [Knowles et Hughes, 2005].
- Généralement, l'algorithme est rapide en termes de temps de calcul par itération, mais il a besoin de beaucoup d'évaluations de la fonction objectif avant de converger vers une solution optimale. Dans un contexte d'optimisation de fonctions coûteuses, l'algorithme NSGA2 ne paraît pas être le meilleur choix.

Création d'une population aléatoire P_t sur l'espace de recherche.

Évaluation de la population initiale avec la fonction objectif.

Tant que ($j < J$) **faire**

Application d'un algorithme génétique où P_t (parents) est la population obtenue par l'itération antérieure et Q_t (enfants) la population proposée par l'algorithme génétique. Les deux populations ont le même nombre d'individus N .

Évaluation de la nouvelle population Q_t .

Tri par *rang* des individus des deux populations $P_t \cup Q_t$.

Tri par *distance* des valeurs de chaque *rang*.

Sélection des meilleurs N individus pour former une nouvelle population P_{t+1} .

Fin Tant que

Algorithme 2.2 : Structure principale de l'algorithme NSGA2 [Deb et al., 2000].

2.3.3 Pareto Efficient Global Optimization

L'algorithme *Pareto Efficient Global Optimization* (ParEGO) [Knowles, 2005] est une extension de la méthode EGO adaptée à l'optimisation multi-objectif. Cet algorithme est la principale référence des algorithmes d'optimisation globale multi-objectif pour des fonctions coûteuses et boîtes noires. L'idée principale est de convertir le problème multi-objectif en un problème mono-objectif de manière "intelligente", et ensuite, d'utiliser la méthode EGO. Pour fusionner les n différents objectifs, un vecteur de poids aléatoire $\lambda^{(j)}$ est créé à partir d'une distribution uniforme (voir Fig.2.16) définie par :

$$\lambda^{(j)} = \left(\lambda_1^{(j)}, \dots, \lambda_n^{(j)} \right) \mid \sum_{i=1}^n \lambda_i^{(j)} = 1 \wedge \forall i, \lambda_i^{(j)} = \frac{l}{s}, l \in \{0, 1, \dots, s\}. \quad (2.55)$$

Le vecteur $\lambda^{(j)}$ sera recalculé à chaque itération, afin de bien explorer le PF. Le poids associé à chaque objectif $\lambda_i^{(j)}$ est utilisé par la fonction de *Tchebycheff* [Knowles, 2005] pour combiner les différents objectifs et créer une valeur de performance unique définie par :

$$f_{\lambda}^{(j)}(\mathbf{x}) = \max_{i=1, \dots, n} \left(\lambda_i^{(j)} f_i^{(j)}(\mathbf{x}) \right) + \rho \sum_{i=1}^n \lambda_i^{(j)} f_i^{(j)}(\mathbf{x}) \quad (2.56)$$

où ρ est une constante fixée à 0,05. La structure et les étapes principales de ParEGO sont résumées dans l'Algorithme 2.3.

Plan d'expériences initial : $\mathbf{X}^{(j)}$, $\mathbf{F}^{(j)}$ et $j = j_0$
Tant que ($j < J$) **faire**
 Poids des objectifs : $\lambda^{(j)} \leftarrow \text{rand}(n)$ avec $\sum_{i=1}^n \lambda_i^{(j)} = 1$
 Combinaison des objectifs : $\mathbf{F}_\lambda^{(j)} \leftarrow \text{Tchebycheff}(\mathbf{F}^{(j)}, \lambda^{(j)})$
 Modèle de substitution : $(\hat{f}_\lambda(\mathbf{x})^{(j)}, \hat{\sigma}_\lambda(\mathbf{x})^{(j)}) \leftarrow \text{Kriging}\{\mathbf{X}^{(j)}, \mathbf{F}_\lambda^{(j)}\}$
 Nouveau candidat : $\mathbf{x}^{(j+1)} \leftarrow \arg \max_{\mathbf{x}} \text{EI}(\mathbf{X}^{(j)}, \hat{f}_\lambda(\mathbf{x})^{(j)}, \hat{\sigma}_\lambda(\mathbf{x})^{(j)})$
 Évaluation de la fonction objectif : $\mathbf{f}^{(j+1)} \leftarrow \mathbf{f}(\mathbf{x}^{(j+1)})$
Fin Tant que
Sorties : $\mathbf{X}^{(J)}$, $\mathbf{F}^{(J)}$ et $\mathbf{PF}^{(J)}$

Algorithme 2.3 : Structure principale de l'algorithme ParEGO [Knowles, 2005].

Les principaux inconvénients de l'algorithme ParEGO sont :

- Si la bonne zone d'optimisation n'est pas trouvée dans l'espace de recherche ou si la dimension de l'espace de recherche est trop élevée, il faut beaucoup d'évaluations pour minimiser l'erreur du *krigeage*.
- Valeurs élevées du critère EI aux limites de l'espace de recherche. Tendance à faire beaucoup d'évaluations aux bornes de l'espace de recherche.

2.3.4 Multi-Objective Particle Swarm Optimization

L'algorithme *Multi-Objective Particle Swarm Optimization* (MOPSO) [Coello et al., 2004] est une extension de l'algorithme mono-objectif PSO. Cette méthode utilise les bases de la méthode PSO combinées avec le principe de dominance du PF et la technique de quadrillage de l'espace de recherche. Une *population* de *particules* (configurations de paramètres) est distribuée dans l'espace de recherche en utilisant une méthode de remplissage de l'espace (voir Section 2.2.7). Une fois la population évaluée par la fonction objectif, l'ensemble de particules non-dominées PS est enregistré dans une sous-population nommée *entrepôt* ou archive. Les repères utilisés pour définir la direction de chaque particule sont :

- la meilleure position globale (population). Chaque particule de la population pourra choisir une particule *meneuse* dans l'ensemble de particules de l'entrepôt ;
- la meilleure position locale (individu). Chaque particule utilisera la meilleure position qu'elle a depuis toutes les itérations de l'optimisation.

Les particules de l'entrepôt qui appartiennent à des régions de la grille avec un nombre élevé de particules, seront pénalisées par rapport aux autres particules non-dominées. De cette façon, l'algorithme évite de concentrer les évaluations dans une même région de l'espace de recherche (problème du *clustering*) et permet à les particules d'explorer les autres zones de l'espace de recherche.

2.3.5 Pareto Envelope-based Selection Algorithm 2

L'algorithme *Pareto Envelope-based Selection Algorithm 2* (PESA2) [Corne et al., 2001] est la nouvelle version de l'algorithme multi-objectif évolutionnaire PESA [Corne et al., 2000]. L'idée principale de cet algorithme est d'utiliser une grille sur l'espace de performance pour créer des sous-régions, appelées *hyper-boîtes*. Un algorithme génétique est utilisé pour optimiser une *population* d'*individus* distribués sur l'espace de recherche.

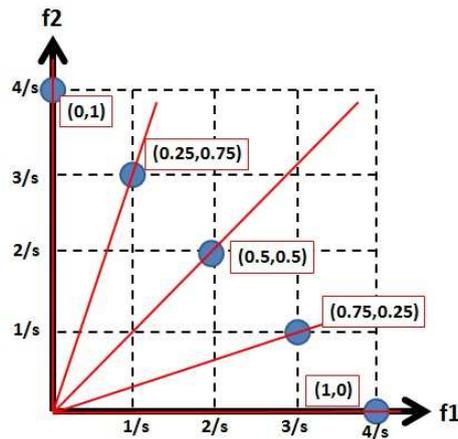


FIGURE 2.16: Exemple des vecteurs λ possibles (avec $s = 4$) et deux fonctions objectifs ($n = 2$)

La nouveauté de cette méthode est que les critères d'optimisation ne sont pas définis par rapport à la performance des individus ; ils sont définis par rapport au nombre d'individus qu'il y a à chaque hyper-boîte. Si, dans une hyper-boîte, il y a plusieurs individus, le meilleur d'entre eux sera choisi aléatoirement. La valeur affectée à chaque hyper-boîte sera proportionnelle au nombre d'évaluations non dominées associées, c'est-à-dire, les hyper-boîtes avec peu d'évaluations du FP seront priorisées par la méthode d'optimisation.

L'avantage d'optimiser les hyper-boîtes est d'obtenir une bonne répartition du FP sur l'espace de performances, sans concentrer les solutions non-dominées dans un nombre réduit d'hyper-boîtes.

2.3.6 Strength Pareto Evolutionary Algorithm 2

L'algorithme *Strength Pareto Evolutionary Algorithm 2* (SPEA2) [Zitzler et al., 2001] est l'évolution de l'algorithme multi-objectif évolutionnaire SPEA [Zitzler et Thiele, 1998]. L'idée principale de cette méthode est d'utiliser une archive externe pour enregistrer, à chaque itération de l'optimisation, les solutions non-dominées. Deux critères sont utilisés pour définir la performance des évaluations :

- Valeurs de rangs. À chaque itération de l'algorithme, deux valeurs sont calculées. La première valeur est proportionnelle au nombre d'évaluations que celle-ci domine. La seconde est, quant à elle, proportionnelle au nombre d'évaluations qui la dominent.
- Valeur de densité. Le principe de dominance est utilisé pour calculer la distance entre les évaluations du PF afin de définir la densité des évaluations proches, permettant de guider la recherche plus efficacement.

Pour le calcul des critères précédents, les évaluations de l'archive externe sont prises en compte. Une particularité de cet algorithme est la définition de la taille de l'archive externe. Le nombre maximal d'évaluations à enregistrer est un paramètre très important, car une valeur trop grande provoquera une recherche locale de l'optimisation (intensification), et une valeur trop petite incitera une recherche globale (exploration).

2.3.7 Récapitulatif

Avant de conclure ce chapitre sur l'état de l'art des algorithmes d'optimisation globale, un récapitulatif des méthodes de référence présentées dans ce chapitre a été réalisé. Comme la plupart des algorithmes multi-objectif sont basés sur les méthodes mono-objectif, le résumé est fait tant pour les algorithmes mono-objectif (voir Tableau 2.1) que pour les algorithmes multi-objectif (voir Tableau 2.2). Pour chaque algorithme, le principe sera introduit brièvement, conjointement aux principaux avantages et limitations.

2.4 Conclusion

Les travaux réalisés dans cette thèse ont été focalisés sur l'optimisation globale multi-objectif de fonctions coûteuses. Afin de choisir l'algorithme le plus approprié pour les deux applications industrielles étudiées dans cette thèse, un aperçu succinct des différents algorithmes d'optimisation globale multi-objectif a été présenté dans ce chapitre. Notons que les méthodes d'optimisation globale mono-objectif ont été aussi introduites, car la plupart des algorithmes multi-objectif sont des extensions de ces dernières.

En général, les algorithmes d'optimisation évolutionnaires multi-objectif utilisent indirectement l'information du front de Pareto à travers certains critères, comme par exemple le rang ou la distance entre les solutions. De plus, les populations sont constituées par un nombre élevé d'individus afin de garantir une bonne exploration dans l'espace des paramètres. Dans le cas des algorithmes d'optimisation basés sur des modèles de substitution, comme l'algorithme ParEGO, un seul modèle de substitution est créé grâce à la combinaison des objectifs (le problème devient mono-objectif). Leur but est d'optimiser la fonction objectif vers toutes les directions du front de Pareto en changeant le compromis entre les critères à chaque itération. Finalement, on remarque que tous les algorithmes présentés dans ce chapitre n'utilisent ni l'information du front de Pareto de manière directe, ni l'information de l'ensemble de Pareto ; ceci est dommage, dans un contexte d'optimisation difficile, car cette information pourrait aider les algorithmes d'optimisation à converger plus rapidement.

À partir des notions, des définitions et des algorithmes présentés dans ce chapitre, un nouvel algorithme d'optimisation globale multi-objectif pour les fonctions coûteuses est présenté dans le Chapitre 3. Cette nouvelle stratégie va bénéficier des avantages des algorithmes basés sur des modèles de substitution (nombre réduit d'évaluations de la fonction objectif), tout en utilisant l'information relative au front de Pareto et de l'ensemble de Pareto.

TABLEAU 2.1: Récapitulatif des algorithmes mono-objectif les plus importants présentés dans le chapitre.

Algorithme	Principe	Avantages	Inconvénients
Algorithme génétique (GA) [Holland, 1992]	Stochastique direct. Algorithme basé sur l'imitation de l'évolution des espèces.	<ul style="list-style-type: none"> Bonne exploration de l'espace de recherche. Capacité à trouver le minimum global de fonctions avec plusieurs minima locaux. 	<ul style="list-style-type: none"> Utilisation de plusieurs opérateurs qui possèdent leurs propres paramètres de réglage.
Essaim de particules (PSO) [Kennedy et Eberhart, 1995]	Stochastique direct. Analogie avec les comportements collectifs des déplacements d'animaux.	<ul style="list-style-type: none"> Deux paramètres de réglage. Très performance à basse dimension. 	<ul style="list-style-type: none"> En grande dimension, il faut une population d'individus importante afin d'explorer tout l'espace de recherche.
<i>Efficient Global Optimization</i> (EGO) [Jones et al., 1998]	Stochastique indirect. Utilisation d'un modèle de substitution par <i>krigeage</i> et calcul de l'espérance de gain.	<ul style="list-style-type: none"> Besoin d'un nombre réduit d'évaluations de la fonction objectif. Réalisation d'une approximation de la fonction objectif. 	<ul style="list-style-type: none"> En grande dimension, difficulté à trouver un bon compromis entre exploration et intensification. Solution pas adaptable aux problèmes avec une fonction objectif rapide à calculer.
Approche informelle pour l'optimisation globale (IAGO) [Villemonteix et al., 2009]	Stochastique indirect. Utilisation d'un modèle de substitution par <i>krigeage</i> et calcul de l'entropie conditionnelle des minimiseurs.	<ul style="list-style-type: none"> Solution adaptée à des fonctions objectifs bruitées. Possibilité d'utiliser l'information du gradient et d'ajouter des contraintes d'optimisation. 	<ul style="list-style-type: none"> Difficulté à bien définir une grille de discrétisation de l'espace de recherche en prenant en compte la position des évaluations disponibles. Augmentation importante de la complexité de l'algorithme pour les problèmes de grande dimension.

TABLEAU 2.2: Récapitulatif des algorithmes multi-objectif les plus importants présentés dans le chapitre.

Algorithme	Principe	Avantages	Inconvénients
<i>Non-dominated Sorting Genetic Algorithm</i> (NSGA2) [Deb et al., 2000]	Utilisation d'un <i>algorithme génétique</i> (GA) qui prend en compte les critères de rang et de distance entre solutions.	<ul style="list-style-type: none"> Algorithme multi-objectif de référence grâce à sa simplicité ; offre un bon compromis entre intensification et exploration. 	<ul style="list-style-type: none"> Besoin d'une taille de population importante pour des problèmes de grande dimension. Optimisation dégradée avec plus de 2 objectifs. Opérations de l'algorithme rapides, mais besoin d'un nombre très élevé d'évaluations de la fonction objectif.
<i>Pareto Efficient Global Optimization</i> (ParEGO) [Knowles, 2005]	Extension multi-objectif de l'algorithme EGO. Utilisation d'un modèle de substitution par <i>krigeage</i> obtenu après la combinaison des objectifs.	<ul style="list-style-type: none"> Besoin d'un nombre réduit d'évaluations de la fonction objectif. 	<ul style="list-style-type: none"> Performance dégradée en grande dimension, du fait de l'exploration aux limites de l'espace de recherche.
<i>Multi-Objective Particle Swarm Optimization</i> (MOPSO) [Coello et al., 2004]	Extension multi-objectif de l'algorithme PSO. Utilisation d'une sous-population des meilleurs individus comme référence.	<ul style="list-style-type: none"> Très bon compromis entre exploration et intensification. 	<ul style="list-style-type: none"> Besoin d'une population d'individus importante, ce qui augmente considérablement les évaluations de la fonction objectif.
<i>Pareto Envelope-based Selection Algorithm</i> (PESA2) [Corne et al., 2001]	Optimisation des sous-espaces de l'espace de recherche en utilisant un GA.	<ul style="list-style-type: none"> Très bonne exploration de l'espace de recherche. 	<ul style="list-style-type: none"> Optimisation par sous-espace engendrant une faible intensification dans un même sous-espace.
<i>Strength Pareto Evolutionary Algorithm</i> (SPEA2) [Zitzler et al., 2001]	Archivage des meilleures solutions non-dominées qui seront utilisées pour définir le rang et la densité des solutions à optimiser avec un GA.	<ul style="list-style-type: none"> Une fois la bonne région d'optimisation identifiée, sa vitesse de convergence est supérieure aux autres MOEA. 	<ul style="list-style-type: none"> La taille de l'archivage doit être définie <i>a priori</i>, ce qui a un impact direct sur la performance de l'optimisation. Optimisation vers les solutions non dominées, ce qui comporte un défaut d'exploration de l'espace de recherche.

Double *krigeage* pour l'optimisation multi-objectif

Sommaire

3.1 Nouvelle méthode d'optimisation multi-objectif	44
3.2 Comparaison des algorithmes KEEP et ParEGO	46
3.3 Analyse comparative des performances	47
3.3.1 Conditions d'optimisation	49
3.4 Conclusion	52

Dans le chapitre précédent, un aperçu succinct des algorithmes d'optimisation globale multi-objectif a permis de présenter les avantages et les inconvénients de chaque méthode. Dans un contexte d'optimisation de fonctions coûteuses, les algorithmes évolutionnaires ne constituent pas une bonne option car ils nécessitent de réaliser un nombre important d'évaluations de la fonction objectif avant de converger vers la solution optimale. Par contre, les algorithmes basés sur l'utilisation d'un modèle de substitution, comme l'algorithme *Pareto Efficient Global Optimization* (ParEGO), présentent l'avantage d'utiliser les critères d'optimisation sur le modèle de substitution, ce qui réduit notablement le nombre d'évaluations de la fonction objectif. Néanmoins, la méthode ParEGO présente une dégradation de la performance dans le cas de problèmes en grande dimension, ce qui est un inconvénient important pour l'optimisation d'applications industrielles.

L'objectif de ce chapitre est de présenter un nouvel algorithme d'optimisation globale multi-objectif conçu spécialement pour optimiser des fonctions inconnues et coûteuses. Cette nouvelle méthode, appelée *Kriging for Expensive Evaluations Pareto* (KEEP) [Davins-Valldaura et al., 2016b], est une extension de l'algorithme ParEGO et introduit une innovation basée sur un second modèle de substitution afin d'estimer la probabilité d'appartenir à l'ensemble de Pareto (*Pareto Set*). Notons que l'information de l'ensemble de Pareto n'est pas utilisée pour des autres algorithmes multi-objectif présentés dans le Chapitre 2. Cette innovation permet à l'algorithme KEEP de converger plus rapidement vers les solutions optimales en exploitant l'information du front de Pareto (*Pareto Front*, PF) et de l'ensemble de Pareto (*Pareto Set*, PS).

Dans la première partie du chapitre, la méthode KEEP est détaillée. Une comparaison de l'algorithme KEEP avec son prédécesseur ParEGO est faite afin de montrer et de ressortir les aspects innovants de

cette nouvelle stratégie d'optimisation. Pour finir, une analyse comparative basée sur des fonctions test multi-objectif (les fonctions ZDT, DTLZ et IMI) est réalisée afin de tester la performance de la nouvelle proposition. L'analyse est faite en utilisant les algorithmes KEEP, ParEGO et les algorithmes multi-objectif évolutionnaires (MOEA) de référence présentés dans le Chapitre 2 : le *Non-dominated Sorting Genetic Algorithm* (NSGA2), le *Multi-Objective Particle Swarm Optimization* (MOPSO), le *Pareto Envelope-based Selection Algorithm* (PESA2) et le *Strength Pareto Evolutionary Algorithm* (SPEA2).

3.1 Nouvelle méthode d'optimisation multi-objectif

L'optimisation globale multi-objectif est un sujet d'intérêt pour l'ingénierie en raison de son utilisation pour le réglage et la mise au point d'applications et de systèmes industriels avec plusieurs critères ou objectifs à optimiser. Dans la plupart des cas, les différents objectifs sont combinés directement pour convertir les problèmes d'optimisation multi-objectif en mono-objectif, en obtenant des problèmes d'optimisation plus facile à résoudre. Néanmoins, les objectifs à optimiser sont généralement antagonistes et trouver un bon compromis entre eux n'est pas évident, car les fonctions sont complexes ou inconnues. De plus, les systèmes peuvent avoir besoin d'une très grande base de données pour réaliser la mise au point avec un temps d'évaluation d'une seule configuration de paramètres très élevé (fonction objectif coûteuse). En pratique, l'étape d'optimisation doit être réalisée en un temps limité à cause des exigences du projet, ce qui fait que le nombre d'évaluations possibles est réduit.

Remarque 3.1 Dans cette section, on utilisera les notations d'optimisation itérative et d'optimisation multi-objectif présentées dans les Sections 2.1 et 2.3, respectivement. ■

Remarque 3.2 Les étapes principales des algorithmes EGO, ParEGO et KEEP sont résumées à "Algorithme 2.1" (dans la Section 2.2.8), "Algorithme 2.3" (dans la Section 2.3) et "Algorithme 3.1" respectivement.

La première étape, commune aux algorithmes EGO, ParEGO et KEEP, est le plan d'expérience initial (PdE). Comme présentée précédemment (Section 2.2.7), la solution retenue est une combinaison de la méthode HCL et du critère déterministe *maximin*. Le nombre d'évaluations initiales j_0 est fixé à $(11m-1)$ comme propose [Jones et al., 1998], avec m le nombre de paramètres à optimiser (et dimension de l'espace de recherche). Une fois le PdE initial $\mathbf{X}^{(j_0)}$ est évalué par la fonction objectif, en obtenant $\mathbf{F}^{(j_0)}$, les algorithmes d'optimisation entrent dans la boucle principale de l'optimisation.

Remarque 3.3 Concernant les modèles de substitution utilisés pour les trois algorithmes, ils sont basés sur le "krigeage ordinaire" (Section 2.2.4). La fonction de covariance (Section 2.2.5) choisie est la fonction de "Matèrn" (2.33), dont les paramètres sont mis au point en utilisant la méthode du "maximum de vraisemblance restreint" (2.37). ■

À chaque itération j de l'algorithme KEEP, le premier modèle de substitution $\hat{f}_\lambda(\mathbf{x})^{(j)}$ est mis à jour en utilisant la stratégie du ParEGO : un vecteur de poids des objectifs $\lambda^{(j)}$ est défini aléatoirement (différent à chaque itération), et est ensuite utilisé pour combiner linéairement tous les objectifs de la fonction à optimiser en utilisant la fonction de Tchebycheff.

Remarque 3.4 Bien que la fonction Tchebycheff (2.56) ait un terme non-linéaire, elle est considérée comme une fonction de "combinaison linéaire" des objectifs. ■

À partir des évaluations de la fonction objectif $\mathbf{F}^{(j)}$, on définit l'actuel PF (ensemble de solutions non dominées) et ses configurations de paramètres correspondants dans l'espace de recherche, c'est-à-dire le PS. Pour la création du second modèle de substitution, on définit pour chaque configuration de paramètres évaluée avec la fonction objectif $\mathbf{X}^{(j)}$, une probabilité d'appartenir au PS par

$$p_\lambda(\mathbf{x} \in \mathbf{X}^{(j)}) = \begin{cases} 1 & \text{si } \mathbf{x} \in \text{PS} \\ 0 & \text{sinon} \end{cases} \quad (3.1)$$

c'est-à-dire, si une configuration de paramètres évaluée par la fonction objectif appartient au PS, elle aura une probabilité 1 ; sinon, elle aura une probabilité de 0. Les probabilités de $\mathbf{X}^{(j)}$ sont stockées dans les vecteurs $\mathbf{P}_\lambda^{(j)} = \{p_\lambda(\mathbf{x}^{(1)}), \dots, p_\lambda(\mathbf{x}^{(j)})\}^T$, qui sont utilisés par la suite pour la création du second modèle $\hat{p}_\lambda(\mathbf{x})^{(j)}$. Les valeurs de $\hat{p}_\lambda(\mathbf{x})^{(j)}$ estimées pour le second modèle de substitution sont limitées à une probabilité minimale de 0 et une probabilité maximale de 1.

Finalement, le critère d'échantillonnage de l'algorithme KEEP est basé sur une nouvelle stratégie appelée *Pareto Expected Improvement* (PEI), qui prend en compte la valeur obtenue par les deux modèles de substitution précédents

$$\text{PEI}(\mathbf{x}) = \hat{p}_\lambda(\mathbf{x})^{(j)} \cdot \text{EI}_\lambda(\mathbf{x})^{(j)} \quad (3.2)$$

avec $\text{EI}_\lambda(\mathbf{x})^{(j)}$ le critère *Expected improvement* de la méthode EGO (2.50) défini en utilisant $\hat{f}_\lambda(\mathbf{x})^{(j)}$.

Plan d'expériences initial : $\mathbf{X}^{(j)}$, $\mathbf{F}^{(j)}$ et $j = j_0$

Tant que ($j < J$) **faire**

Poids des objectifs : $\lambda^{(j)} \leftarrow \text{rand}(n)$ avec $\sum_{i=1}^n \lambda_i^{(j)} = 1$

Combinaison des objectifs : $\mathbf{F}_\lambda^{(j)} \leftarrow \text{Tchebycheff}(\mathbf{F}^{(j)}, \lambda^{(j)})$

1er modèle de substitution : $(\hat{f}_\lambda(\mathbf{x})^{(j)}, \hat{\sigma}_\lambda(\mathbf{x})^{(j)}) \leftarrow \text{Kriging}\{\mathbf{X}^{(j)}, \mathbf{F}_\lambda^{(j)}\}$

Probabilité du "Pareto Set" : $\mathbf{P}_\lambda^{(j)} \leftarrow \text{ParetoSet}\{\mathbf{X}^{(j)}, \mathbf{F}^{(j)}\}$

2ème modèle de substitution : $(\hat{p}_\lambda(\mathbf{x})^{(j)}, \hat{\sigma}_\lambda(\mathbf{x})^{(j)}) \leftarrow \text{Kriging}\{\mathbf{X}^{(j)}, \mathbf{P}_\lambda^{(j)}\}$

Nouveau candidat : $\mathbf{x}^{(j+1)} \leftarrow \arg \max_{\mathbf{x}} \text{PEI}(\mathbf{X}^{(j)}, \hat{f}_\lambda(\mathbf{x})^{(j)}, \hat{p}_\lambda(\mathbf{x})^{(j)}, \hat{\sigma}_\lambda(\mathbf{x})^{(j)})$

Evaluation de la fonction objectif : $\mathbf{f}^{(j+1)} \leftarrow \mathbf{f}(\mathbf{x}^{(j+1)})$

Fin Tant que

Sorties : $\mathbf{X}^{(J)}$, $\mathbf{F}^{(J)}$, $\mathbf{PF}^{(J)}$ et $\mathbf{PS}^{(J)}$

Algorithme 3.1 : Structure principale de l'algorithme KEEP.

Une configuration de paramètres avec une valeur élevée du critère PEI est un bon candidat qui sera évalué par la fonction objectif parce que :

- la valeur de performance estimée par le modèle de substitution $\hat{f}_\lambda(\mathbf{x})^{(j)}$ est plus petite que la meilleure évaluation faite avec la fonction objectif $f_{\lambda_{\min}}^{(j)}$ (minimisation de la valeur de la fonction objectif) ;
- l'erreur du modèle de *krigeage* $\hat{\sigma}_\lambda(\mathbf{x})^{(j)}$ a une grande valeur (réduction de l'erreur d'approximation, amélioration de l'estimation du modèle de substitution) ;
- la configuration de paramètres \mathbf{x} a une forte probabilité $\hat{p}_\lambda(\mathbf{x})^{(j)}$ d'être proche du PS (optimisation du PF et du PS).

Un *algorithme génétique* (GA) (Section 2.2.2), détaillé par l'*Algorithme 3.2*, a été adapté pour la recherche d'une nouvelle configuration candidate en utilisant deux modèles de substitution et en maximisant le critère PEI. Les deux modèles de substitution utilisés dans le GA pour évaluer les individus de la population sont : *1er modèle*) $\hat{f}_1(\mathbf{x}) = \hat{f}_\lambda^{(j)}(\mathbf{x})$, la performance obtenue par la combinaison linéaire des objectifs de la fonction à optimiser avec le vecteur de poids λ , *2ème modèle*) $\hat{f}_2(\mathbf{x}) = \hat{p}_\lambda(\mathbf{x})^{(j)}$ la probabilité d'appartenir au PS ; avec $\hat{\sigma}_\lambda(\mathbf{x})^{(j)}$ l'erreur associé aux deux modèles de substitution avec *krigeage* (même distribution des configurations de paramètres $\mathbf{X}^{(j)}$ dans l'espace de recherche). Le critère

d'évaluation de la performance utilisé est le PEI (3.2). À chaque génération¹ i , une nouvelle population est sélectionnée parmi les meilleurs parents et enfants. Après G générations, le meilleur individu de la population \mathbf{P}_x^G en termes de PEI est proposé pour être évalué par la fonction objectif.

Entrées : \mathbf{X} , $\hat{f}_1(\mathbf{x})$, $\hat{f}_2(\mathbf{x})$ et $\hat{\sigma}(\mathbf{x})$

Plan d'expérience initial : \mathbf{P}_x^0

Évaluation du 1er modèle : $[\mathbf{P}_{F1}^0, \mathbf{P}_\sigma^0] \leftarrow \text{Kriging}(\hat{f}_1(\mathbf{x}), \hat{\sigma}(\mathbf{x}), \mathbf{P}_x^0)$

Évaluation du 2ème modèle : $[\mathbf{P}_{F2}^0, \cdot] = \text{Kriging}(\hat{f}_2(\mathbf{x}), \hat{\sigma}(\mathbf{x}), \mathbf{P}_x^0)$

Perf. parents : $\text{PEI}^0 = \text{ParetoExpectedImprovement}(\mathbf{P}_x^0, \mathbf{P}_{F1}^0, \mathbf{P}_{F2}^0, \mathbf{P}_\sigma^0)$

Tant que ($i < G$) **faire**

 Sélection des parents : $\mathbf{P}_A^i(\mathbf{P}_x^i)$ et $\mathbf{P}_B^i(\mathbf{P}_x^i)$

 Croisement et reproduction : $\mathbf{Q}_{i_x}^i(\mathbf{P}_A^i, \mathbf{P}_B^i)$

 Mutation des enfants : $\mathbf{Q}_x^i(\mathbf{Q}_{i_x}^i)$

 Évaluation du 1er modèle : $[\mathbf{Q}_{F1}^i, \mathbf{Q}_\sigma^0] = \text{Kriging}(\hat{f}_1(\mathbf{x}), \hat{\sigma}(\mathbf{x}), \mathbf{Q}_x^i)$

 Évaluation du 2ème modèle : $[\mathbf{Q}_{F2}^i, \cdot] = \text{Kriging}(\hat{f}_2(\mathbf{x}), \hat{\sigma}(\mathbf{x}), \mathbf{Q}_x^i)$

 Perf. enfants : $\text{PEI}^i = \text{ParetoExpectedImprovement}(\mathbf{Q}_x^i, \mathbf{Q}_{F1}^i, \mathbf{Q}_{F2}^i, \mathbf{Q}_\sigma^i)$

 Sélection de la nouvelle population : $\mathbf{P}_x^i(\text{PEI}^{i-1}, \text{PEI}^i)$

Fin Tant que

Nouveau candidat : $\mathbf{x}^{(j+1)} \leftarrow \arg \max_{\mathbf{x}} \text{PEI}^G$

Sorties : $\mathbf{x}^{(j+1)}$

Algorithme 3.2 : Algorithme génétique utilisé par KEEP.

Notons que d'autres algorithmes mono-objectif peuvent être adaptés pour la maximisation du PEI. Les algorithmes stochastiques directs paraissent comme le choix le plus raisonnable en raison de l'absence de contraintes sur le nombre d'évaluations (du modèle de substitution); de plus, le critère à optimiser présente beaucoup de minima locaux. L'algorithme par essaim de particules (PSO) (Section 2.2.2) a été aussi utilisé pour optimiser le critère PEI; cependant, les résultats n'ont pas été satisfaisants (trop de minima locaux).

3.2 Comparaison des algorithmes KEEP et ParEGO

Les algorithmes ParEGO et KEEP (le 1er modèle de substitution) sont basés sur le même principe : la combinaison linéaire des objectifs de la fonction à optimiser (différents poids des objectifs à chaque itération) en utilisant la fonction de Tchebycheff (2.56), plus l'utilisation du critère EI (2.50) comme critère d'échantillonnage. Néanmoins, l'introduction d'une stratégie à double *krigeage* permet d'utiliser un nouveau critère d'échantillonnage appelé PEI (3.2), qui peut être vu comme une évolution du critère EI.

Pour montrer les différences entre les deux algorithmes, un exemple est présenté dans la Figure 3.1. Ces résultats ont été obtenus avec deux nombres d'itérations différentes (j_0 étant le nombre d'évaluation initiales nécessaires pour la réalisation du HCL égale à 21), avec 22 évaluations ($j_0 + 1$) et 41 évaluations ($j_0 + 20$). Les valeurs représentées sont

- *Expected Improvement* : Le critère d'échantillonnage EI utilisé par l'algorithme ParEGO et EGO. La nouvelle configuration candidate est sélectionnée en maximisant ce critère.

¹itération dans un algorithme génétique

- *Pareto Set Probability* : La valeur d'estimation du second modèle de substitution $\hat{p}_\lambda(\mathbf{x})^{(j)}$, qui correspond à la probabilité d'appartenir au PS.
- *Pareto Expected Improvement* : Le critère d'échantillonnage PEI utilisé par l'algorithme KEEP. La nouvelle configuration candidate est sélectionnée en maximisant ce critère.

Le but de ces deux critères d'échantillonnage (EI et PEI) est de proposer la meilleure configuration candidate possible à chaque itération. Le problème est que, pour de grandes dimensions, les modèles de substitution utilisés par l'approximation de la performance $\hat{f}_\lambda(\mathbf{x})^{(j)}$ ont plusieurs minima locaux, spécialement aux limites de l'espace de recherche où le *krigeage* a une erreur très élevée (principale limitation de l'algorithme ParEGO). L'ajout d'un second modèle de substitution par l'algorithme KEEP présente l'avantage de concentrer les évaluations dans des zones plus intéressantes de l'espace de recherche (d'un point de vue de l'optimisation multi-objectif) à partir de la probabilité d'appartenir au PS.

Pour illustrer le comportement des GA sur les deux critères d'échantillonnage (critère EI pour l'algorithme ParEGO et le critère PEI pour l'algorithme KEEP), un exemple en petite dimension est présenté dans la Figure 3.2. Après 31 évaluations (21 du PdE initial + 10 de l'algorithme d'optimisation), le critère EI présente plus de maximum locaux (12) que PEI (9)². De plus, les maxima présentés pour le critère EI sont éloignés du vrai PS et concentrés aux limites de l'espace de recherche, alors que le critère PEI présente des maxima plus proches du vrai PS et moins dispersés dans l'espace de recherche. En général, les GA sont plus efficace en optimisant le PEI que le EI, à cause du fait que le critère EI a trop de maxima répartis sur tout l'espace de recherche (problème de grande dimension) et a des phénomènes d'aiguilles³ (problème à petite dimension). Dans l'exemple proposé, on peut remarquer que, après 10 itérations d'optimisation avec chaque algorithme, le ParEGO a proposé 4 configurations de paramètres proche du vrai PS alors que l'algorithme KEEP n'a proposé 11 (PS très bien défini).

3.3 Analyse comparative des performances

Dans cette section, les résultats de test sur un *benchmark* standard d'optimisation globale multi-objectif est présenté pour évaluer la pertinence du nouvel algorithme KEEP. Ces résultats sont comparés à ceux obtenus en utilisant l'algorithme ParEGO et des *algorithmes multi-objectif évolutionnaires* (MOEA) de référence (présentés Section 2.3) : le *Non-dominated Sorting Genetic Algorithm* (NSGA2) [Deb et al., 2000], le *Pareto Efficient Global Optimization* (ParEGO) [Knowles, 2005], le *Multi-Objective Particle Swarm Optimization* (MOPSO) [Coello et al., 2004], le *Pareto Envelope-based Selection Algorithm* (PESA2) [Corne et al., 2001] et le *Strength Pareto Evolutionary Algorithm* (SPEA2) [Zitzler et al., 2001]. Les fonctions test utilisées sont les fonctions ZDT, DTLZ et IMI [Chase et al., 2009].

Remarque 3.5 *Bien que les fonctions test utilisées soient bi-objectif, aucun des algorithmes d'optimisation utilisé est limité à l'utilisation de seulement deux objectifs.* ■

Remarque 3.6 *Considérant les fonctions test comme des fonctions objectifs très coûteuses, le temps utilisé pour la mise à jour du krigeage est considéré nul par rapport au temps d'évaluation de la fonction objectif.* ■

Remarque 3.7 *La restriction proposée par [Knowles et Hughes, 2005] sur le nombre d'évaluations utilisées pour la création du modèle de substitution de la fonction (un maximum de $[11m - 1 + 25]$ évaluations utilisées par le krigeage) n'est pas appliquée (toutes les évaluations sont utilisées).* ■

Remarque 3.8 *Comme les expressions analytiques des fonctions test utilisées par le benchmark sont connues, on fait la différence entre le "vrai front de Pareto" ou ensemble de solutions optimales de la fonction objectif, et le "front de Pareto" ou ensemble de solutions optimales proposé par les algorithmes d'optimisation.* ■

²Un critère avec un nombre réduit de maxima locaux permet au GA de trouver le maximum global plus facilement, spécialement à grande dimension.

³Vallées autour des configurations de paramètres (avec une valeur élevée du critère à maximiser) pas suffisamment larges, qui sont très difficiles à trouver par les algorithmes génétiques.

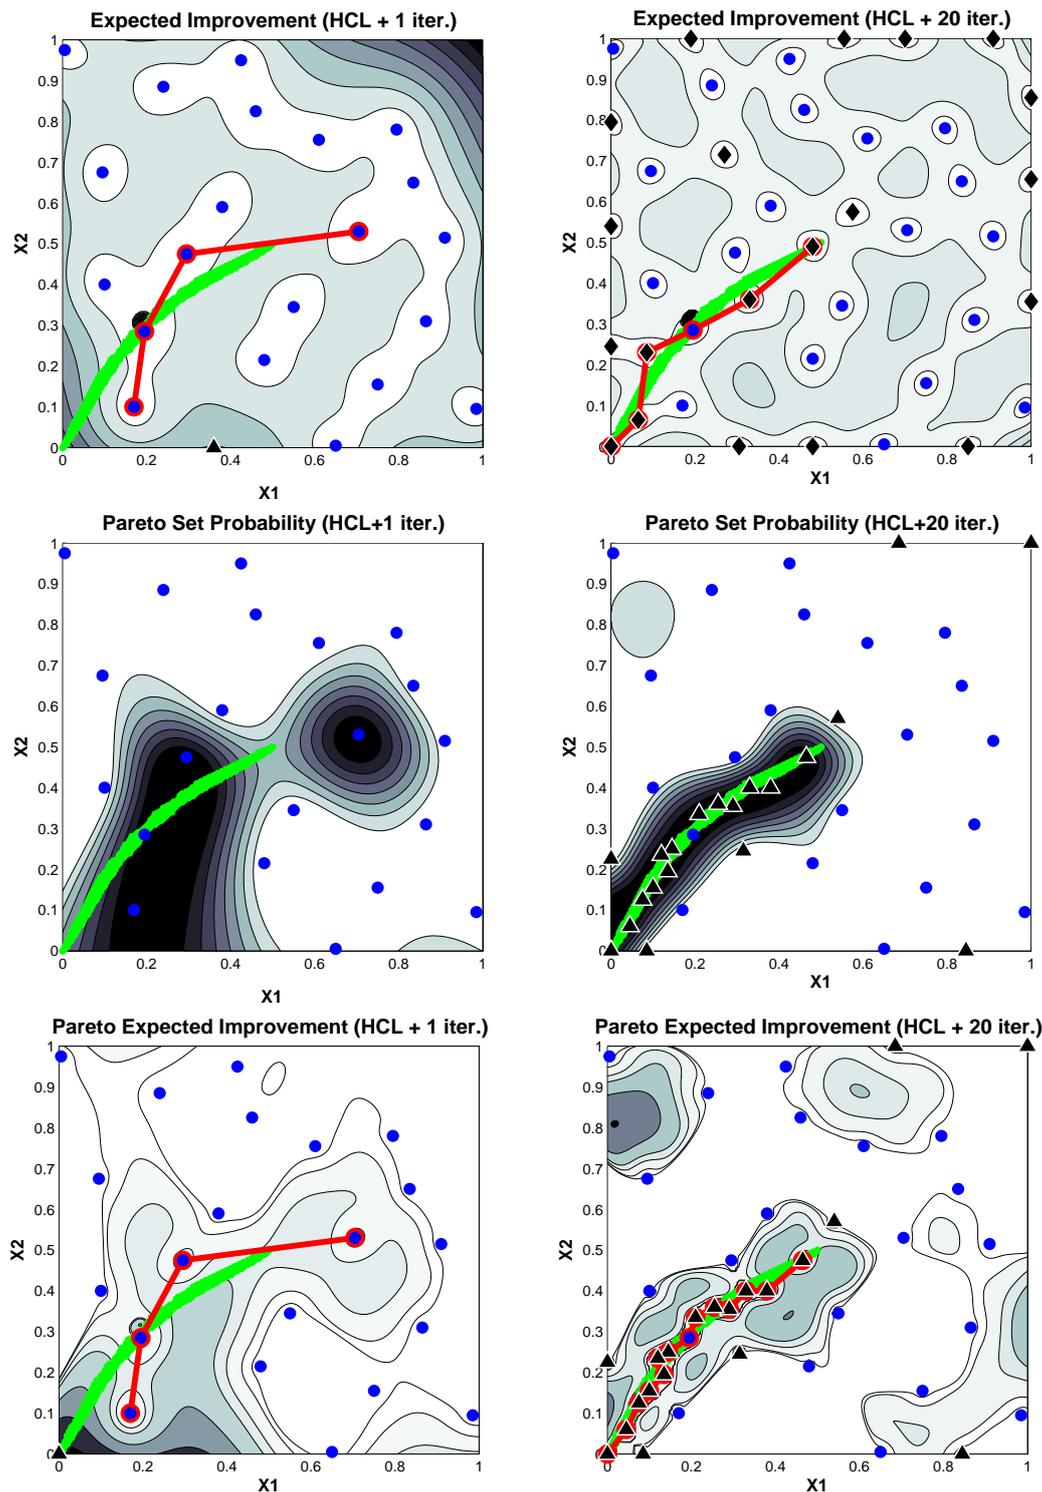


FIGURE 3.1: Fonctionnement de ParEGO et de KEEP. Exemple (fonction bi-objectif) avec 2 paramètres d'optimisation (X_1 et X_2) après $[j_0 + 1]$ évaluations (*gauche*) et après $[j_0 + 20]$ évaluations (*droite*), avec $j_0 = 21$. Les points bleus représentent les évaluations du PdE initial réalisées avec la fonction objectif, les losanges noirs représentent les évaluations réalisées par ParEGO et les triangles noirs les évaluations réalisées par KEEP. Le vrai PS est représenté en vert et le PS obtenu avec l'algorithme d'optimisation est représenté en rouge. Les valeurs de chaque critère sont représentées en niveaux de gris sur l'espace de recherche (où le blanc est la valeur minimale et le noir la valeur maximale).

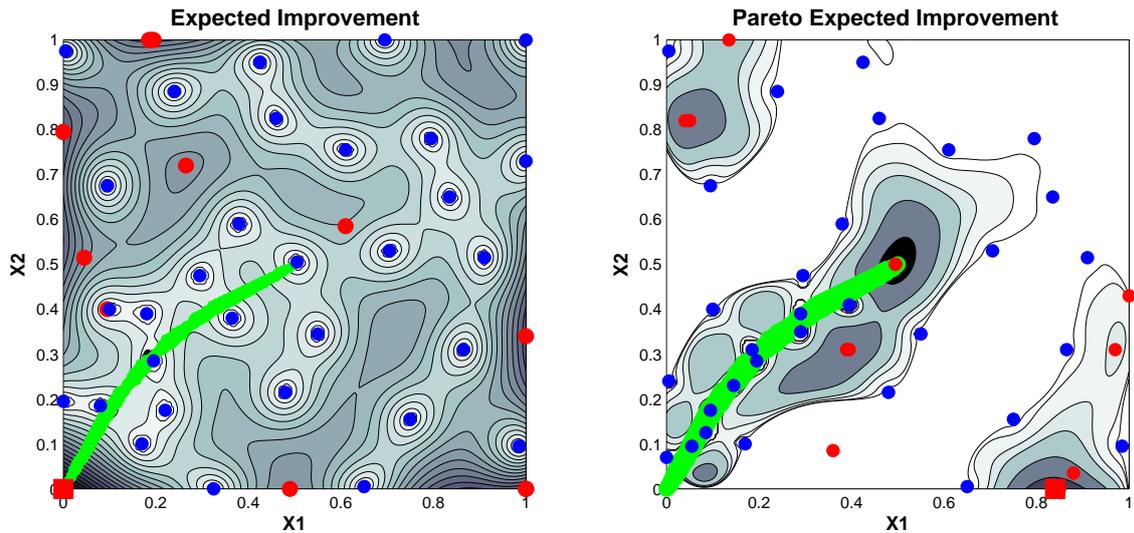


FIGURE 3.2: Performance de l'algorithme génétique pour différents critères d'échantillonnage. Exemple bi-objectif avec 2 paramètres à optimiser ($X1$ et $X2$) après $[j_0 + 10]$ évaluations (avec $j_0 = 21$ évaluations). L'EI (*gauche*) et le PEI (*droite*) sont les critères à maximiser (représenté en niveau de gris sur l'espace de recherche, où le blanc est la valeur minimale et le noir la valeur maximale). Les points bleus représentent les évaluations de la fonction objectif, les points rouges correspondent à la population finale obtenue avec le GA (où le carré rouge représente la meilleure configuration candidate) et en vert le vrai PS.

Fonctions Test

Les fonctions test utilisées pour l'analyse comparative des performances des algorithmes correspondent aux ZDT-fonctions, DTLZ-fonctions et la IMI-fonction, qui sont fréquemment utilisées pour les comparaisons d'algorithmes d'optimisation multi-objectif [Chase et al., 2009] [Huband et al., 2006]. Chacune de ces fonctions possède des particularités de représenter des configurations différentes dans l'optimisation d'une fonction objectif (voir Tableau 3.1). Le but est de mettre les algorithmes d'optimisation en difficulté, en testant leur vitesse de convergence et leur définition du PF. Une attention particulière est faite à la géométrie du *vrai* PF et à son impact sur la performance des algorithmes.

3.3.1 Conditions d'optimisation

Toutes les fonctions test sont fixées à 12 paramètres à optimiser (dimension de l'espace de recherche, $m = 12$). Le nombre d'évaluations réalisées pour la création du PdE initial j_0 , avec la méthode HCL, est par définition $j_0 = 11m - 1$, c'est-à-dire $j_0 = 131$ évaluations. Pour soumettre les algorithmes dans un contexte d'optimisation de fonction coûteuses, le nombre d'évaluations à réaliser pour les algorithmes d'optimisation est fixé à 250 évaluations⁴. Aussi, un total de 381 évaluations de la fonction objectif est fait par *simulation* ($J = 381$).

Définition 3.1 On appelle "*simulation*" ou "*run*" un processus d'optimisation réalisé à partir d'un PdE initial (avec j_0 évaluations) jusqu'à un nombre d'évaluations maximal J . ■

Sachant que le PdE initial a un impact direct sur la performance de l'optimisation, 10 simulations indépendantes sont faites en utilisant 10 PdE initiaux différents. Le but est de quantifier la robustesse et les performances des algorithmes d'optimisation. Les PdE initiaux seront aussi utilisés par les autres algorithmes d'optimisation afin de réaliser la comparaison entre algorithmes sous les mêmes conditions initiales.

⁴Valeur choisie arbitrairement afin de simuler un budget d'évaluations limité (similaire au budget disponible dans le système de surveillance de la pression pneumatique présenté au Chapitre 4).

TABLEAU 3.1: Fonctions multi-objectif test utilisées pour l'analyse comparative des performances des algorithmes multi-objectif avec 12 paramètres à optimiser ($x_p \in [0, 1] \forall p = \{1, \dots, 12\}$)

Fonctions	Objectifs (f_1 et f_2)	Géométrie du PF
ZDT1	$f_1 = x_1$ $f_2 = gh$ $g = 1 + 9 \sum_{p=2}^{12} x_p / 11$ $h = 1 - \sqrt{f_1/g}$	convexe
ZDT2	comme ZDT1, sauf $h = 1 - (f_1/g)^2$	concave
ZDT3	comme ZDT1, sauf $h = 1 - \sqrt{f_1/g} - (f_1/g) \sin(10\pi f_1)$	discontinue
ZDT6	$f_1 = 1 - \exp(-4y_1) \sin^6(6\pi y_1)$ $f_2 = gh$ $g = 1 + 9(\sum_{p=2}^{12} x_p / 11)^{0,25}$ $h = 1 - (f_1/g)^2$	concave
DTLZ1	$f_1 = 0,5(1 + g)x_1$ $f_2 = 0,5(1 + g)(1 - x_1)$ $g = 100(11 + \sum_{p=2}^{12} [(x_p - 0,5)^2 - \cos(20\pi(x_p - 0,5))])$	linéaire
DTLZ2	$f_1 = (1 + g) \cos(x_1\pi/2)$ $f_2 = (1 + g) \sin(x_1\pi/2)$ $g = \sum_{p=2}^{12} (x_p - 0,5)^2$	concave
DTLZ7	$f_1 = x_1$ $f_2 = (1 + g)(2 - [f_1(1 + \sin(3\pi f_1))/(1 + g)])$ $g = 1 + 9 \sum_{p=2}^{12} x_p / 11$	discontinue
IMI	$f_1 = 2\sqrt{3x_1 + 1}$ $f_2 = (3x_1 + 1)(-\sum_{p=2}^{12} (x_p)/11) + 5$	concave

Algorithmes d'optimisation

L'algorithme ParEGO a été utilisé pour l'optimisation avec des paramètres internes fixés aux valeurs décrites dans [Knowles et Hughes, 2005]. Pour les algorithmes MOEAs, la taille de la population, archive ou entrepôt a été fixée à 30 individus⁵.

Critères de performances

Généralement, dans l'analyse comparative des méthodes d'optimisation multi-objectif, l'efficacité et la performance des différents algorithmes sont évaluées en utilisant plusieurs *indicateurs de performances* [Knowles et Hughes, 2005]. Un indicateur de performances très utilisé, dans un contexte d'optimisation globale bi-objectif, est l'indicateur de l'hypervolume ou *hypervolume indicator*⁶ [Zitzler et al., 2002].

Définition 3.2 La valeur du "hypervolume indicator" (HI) correspond à la surface définie entre le PF et le vrai PF dans l'espace de performances. ■

Définition 3.3 La valeur d'amélioration de performance ou "performance improvement" (PI_{HI}) est définie par (3.3) avec HI_o la valeur de HI obtenu après le PdE initial (j_0 évaluations) et HI_f la valeur de HI obtenu à la fin de l'optimisation (J évaluations) [voir Figure 3.3], c'est-à-dire

$$PI_{HI} = 100 \left(\frac{HI_o - HI_f}{HI_o} \right) \quad (3.3)$$

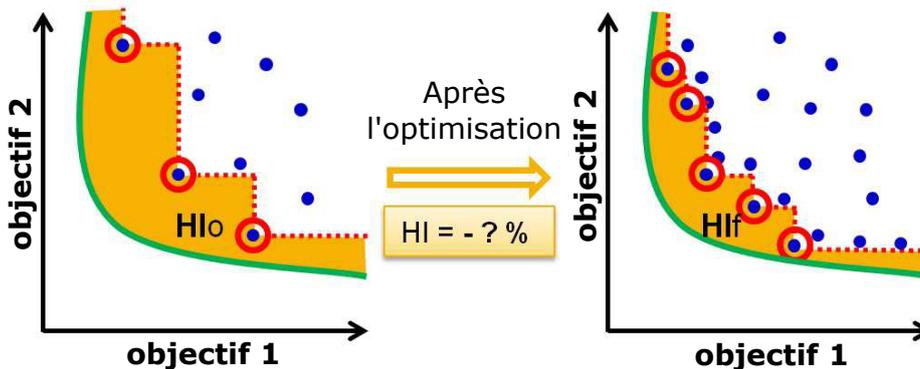


FIGURE 3.3: Représentation de la performance d'amélioration avec HI_o and HI_f , les valeurs de HI après le PdE et après l'optimisation, respectivement.

La valeur de HI est calculée pour chaque algorithme et chaque simulation, après le PdE initial HI_o et à la fin de la simulation HI_f . Ces valeurs permettent de calculer la valeur PI_{HI} de chaque simulation et d'obtenir une valeur numérique qui soit une possible représentation de la performance de chaque algorithme d'optimisation. Ces résultats seront montrés à travers une représentation graphique du type *boîte à moustaches* (voir Figure 3.4).

Pour résumer graphiquement la performance de chaque algorithme testé, les PF obtenus à la fin des simulations sont montrés sur les Figures 3.5 et 3.6. Comme plusieurs simulations ont été réalisées, une simplification de la représentation graphique a été utilisée pour faciliter la compréhension ; toutes les évaluations qui appartiennent au PF à la fin de chaque simulation sont prises en compte par la réalisation de deux figures différentes :

⁵ Avant de réaliser l'ensemble de fonctions tests d'optimisation multi-objectif, une mise au point manuelle de la taille de la population a été faite pour l'optimisation de 12 paramètres et 381 évaluations.

⁶ Aussi appelé *uncovered hypervolume* [Auger et al., 2012]

- *Worst-PF*. Représente les pires valeurs parmi tous les PF obtenus après 10 simulations. Cette courbe permet d'avoir une idée des limitations des performances obtenues par l'algorithme d'optimisation.
- *Median-PF*. Représente les valeurs médianes parmi tous les PF obtenus après 10 simulations. Cette courbe permet d'avoir une idée de la performance finale attendue de l'optimisation.

Pour montrer la distribution des fonctions test dans l'espace de performance et la difficulté de les optimiser, chaque fonction a été évaluée 38 100 fois (100 fois plus que les 381 évaluations réalisées par les algorithmes d'optimisation). Ces évaluations sont faites à partir de configurations de paramètres choisies aléatoirement.

Résultats obtenus

Les résultats obtenus sur les fonction ZDT montrent, que l'algorithme KEEP a fourni les meilleures performances du PI_{HI} et une variance plus petite (sauf pour ZDT6). L'algorithme SPEA2 est le meilleur MOEA en termes de PI_{HI} , suivi du PESA2 et du NSGA2.

Les *median-PF* illustrent que tous les algorithmes testés optimisent dans toutes les directions de l'espace de performances. Les *worst-PF* montrent que KEEP et SPEA2, avec un mauvais choix de PdE, sont capables de trouver un meilleur PF que la recherche aléatoire.

Concernant les fonctions DTLZ et la fonction IMI, il faut remarquer que les performances des MOEAs sont moins bonnes que celles de ParEGO et KEEP. Par exemple, avec la fonction DTLZ2, la variance de PI_{HI} des MOEAs est très grande. Par contre, les algorithmes basés sur des modèles de substitution ont une bonne valeur PI_{HI} (sauf le ParEGO avec DTLZ7) et une petite variance (moins d'influence du PdE initial).

La *median-PF* de la fonction DTLZ2 de tous les algorithmes est similaire à l'exception des points extrêmes du PF, où les MOEAs ne sont pas capables de trouver les solutions non dominées (par conséquent, les valeurs de PI_{HI} sont mauvaises).

Par rapport à la géométrie du PF, les résultats de l'optimisation prouvent que les méthodes d'optimisation basées sur les modèles de substitution ont de bonnes performances (similaires aux meilleures MOEAs) si le PF est convexe ou concave (à l'exception des cas des fonctions DTLZ1 et DTLZ2 où ils sont meilleurs). Par contre, la méthode ParEGO ne fonctionne pas trop bien si le PF a des discontinuités (ZDT3 et DTLZ7). L'introduction d'un deuxième modèle de substitution fait que KEEP est capable de bien optimiser toutes les fonctions (sans perte de performances) indépendamment de la géométrie du PF.

3.4 Conclusion

L'inconvénient d'avoir un nombre limité d'évaluations de la fonction objectif est contraignante pour les algorithmes d'optimisation multi-objectif. Par exemple, les MOEAs, qui sont très utilisés dans un contexte d'optimisation globale en raison de leur simplicité et de leur adaptabilité à n'importe quelle fonction, ont besoin d'utiliser une population de taille raisonnable (proportionnelle à la dimension de l'espace de recherche) qui doit être évaluée pendant un minimum de générations afin de garantir une bonne recherche dans tout l'espace. Par conséquent, le nombre d'évaluations de la fonction objectif pour définir correctement le PF est élevé. Une alternative pour réduire les évaluations à réaliser est d'utiliser des algorithmes basés sur l'utilisation d'un modèle de substitution (*krigeage*), comme par exemple l'algorithme ParEGO. Les résultats obtenus montrent que ParEGO a une performance similaire aux meilleures MOEAs (SPEA2), présentant une amélioration aux résultats des fonctions DTLZ1 et DTLZ2. Le problème est que certaines distributions des solutions non dominées, ont un impact négatif sur la performance finale de l'algorithme ParEGO.

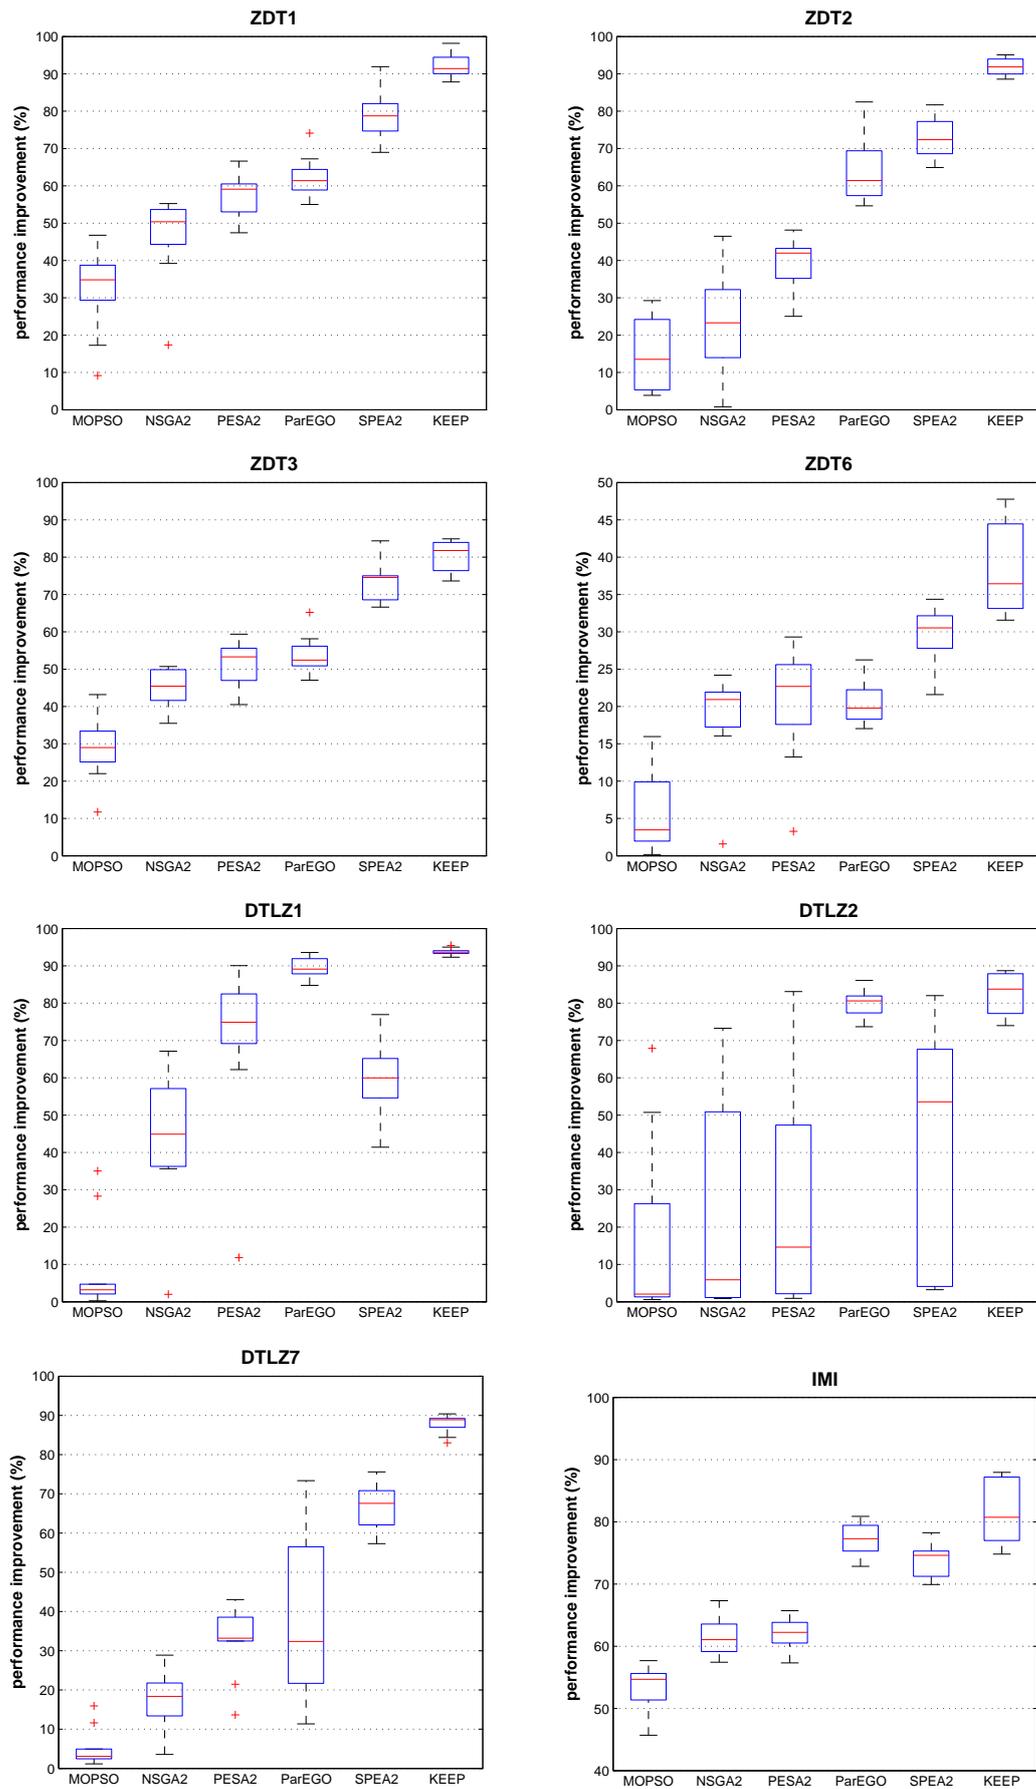


FIGURE 3.4: Comparaison de la *performance d'amélioration* de chaque algorithme d'optimisation obtenue après 10 simulations de 381 évaluations en utilisant une représentation graphique du type *boîte à moustaches*.

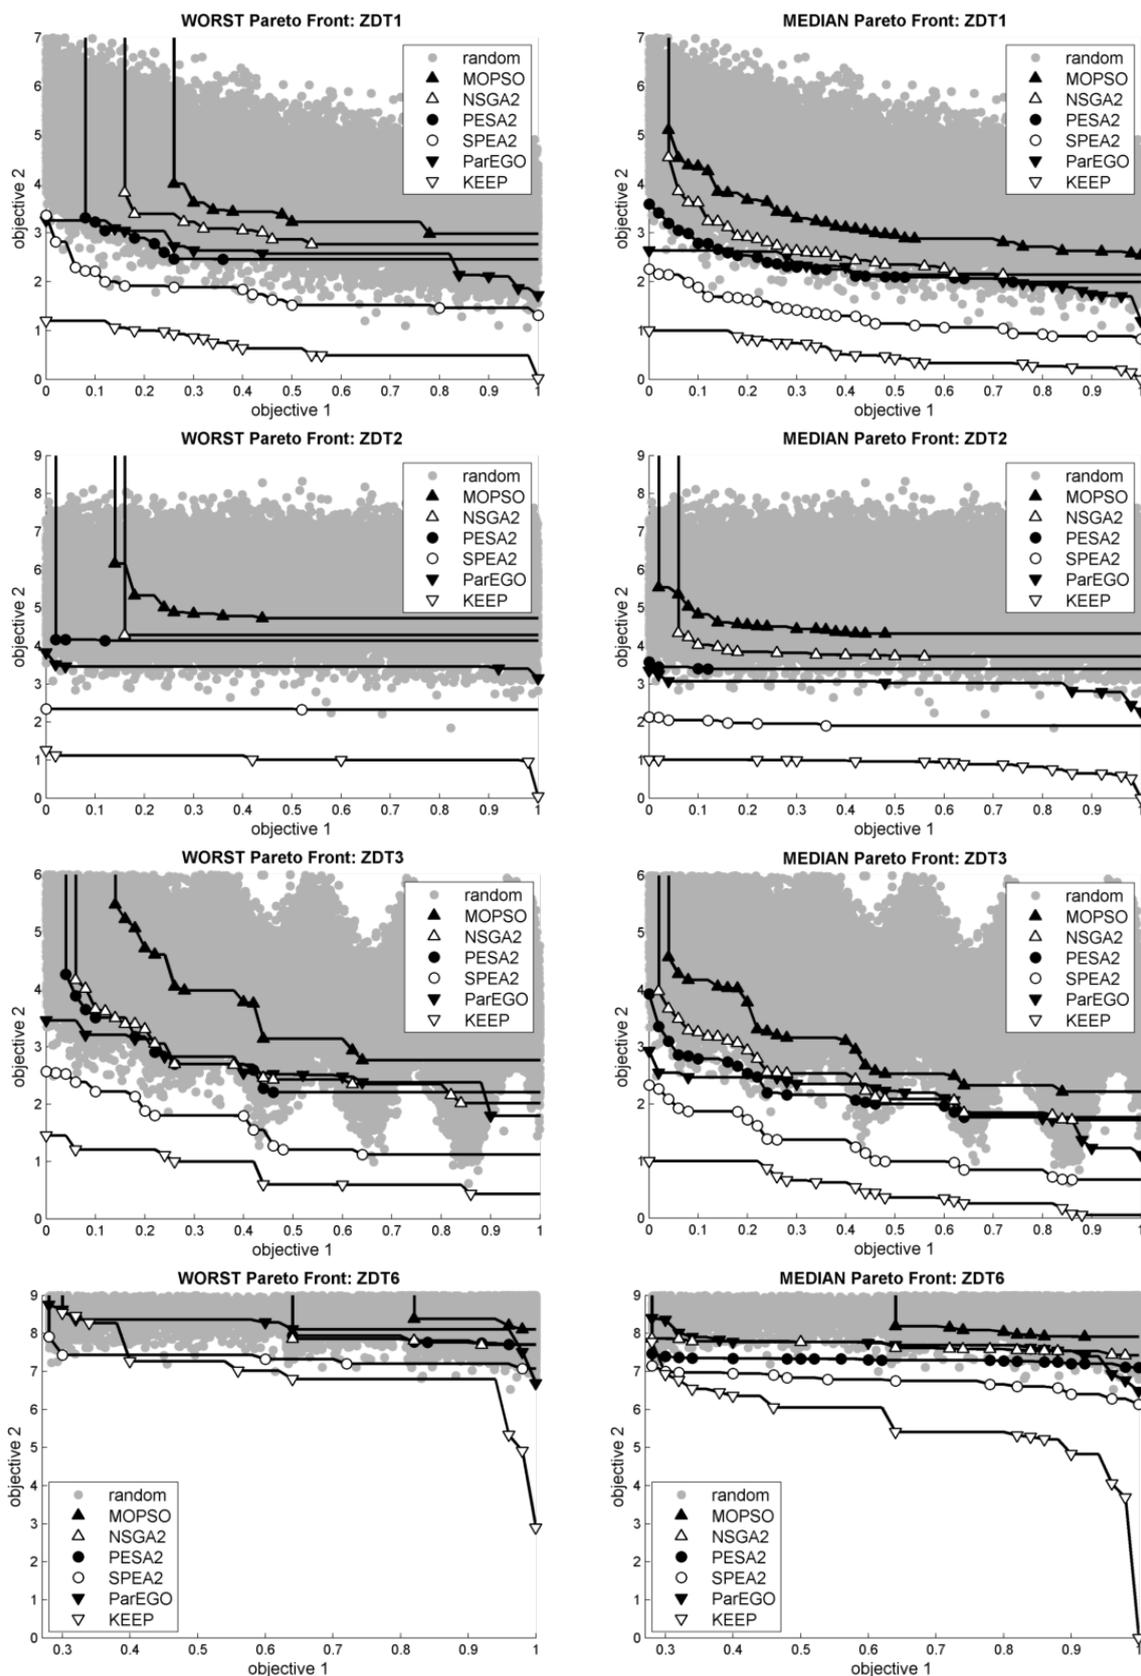


FIGURE 3.5: Résultats d'optimisation des fonctions ZDT. Considérant tous les PF obtenus avec chaque algorithme, après 10 simulations de 381 évaluations [$j_0 + 250$] évaluations, (à gauche) le pire cas ou *worst case* et (à droite) le médian cas ou *median case* sont comparés par rapport aux 38 100 évaluations aléatoires (*random*).

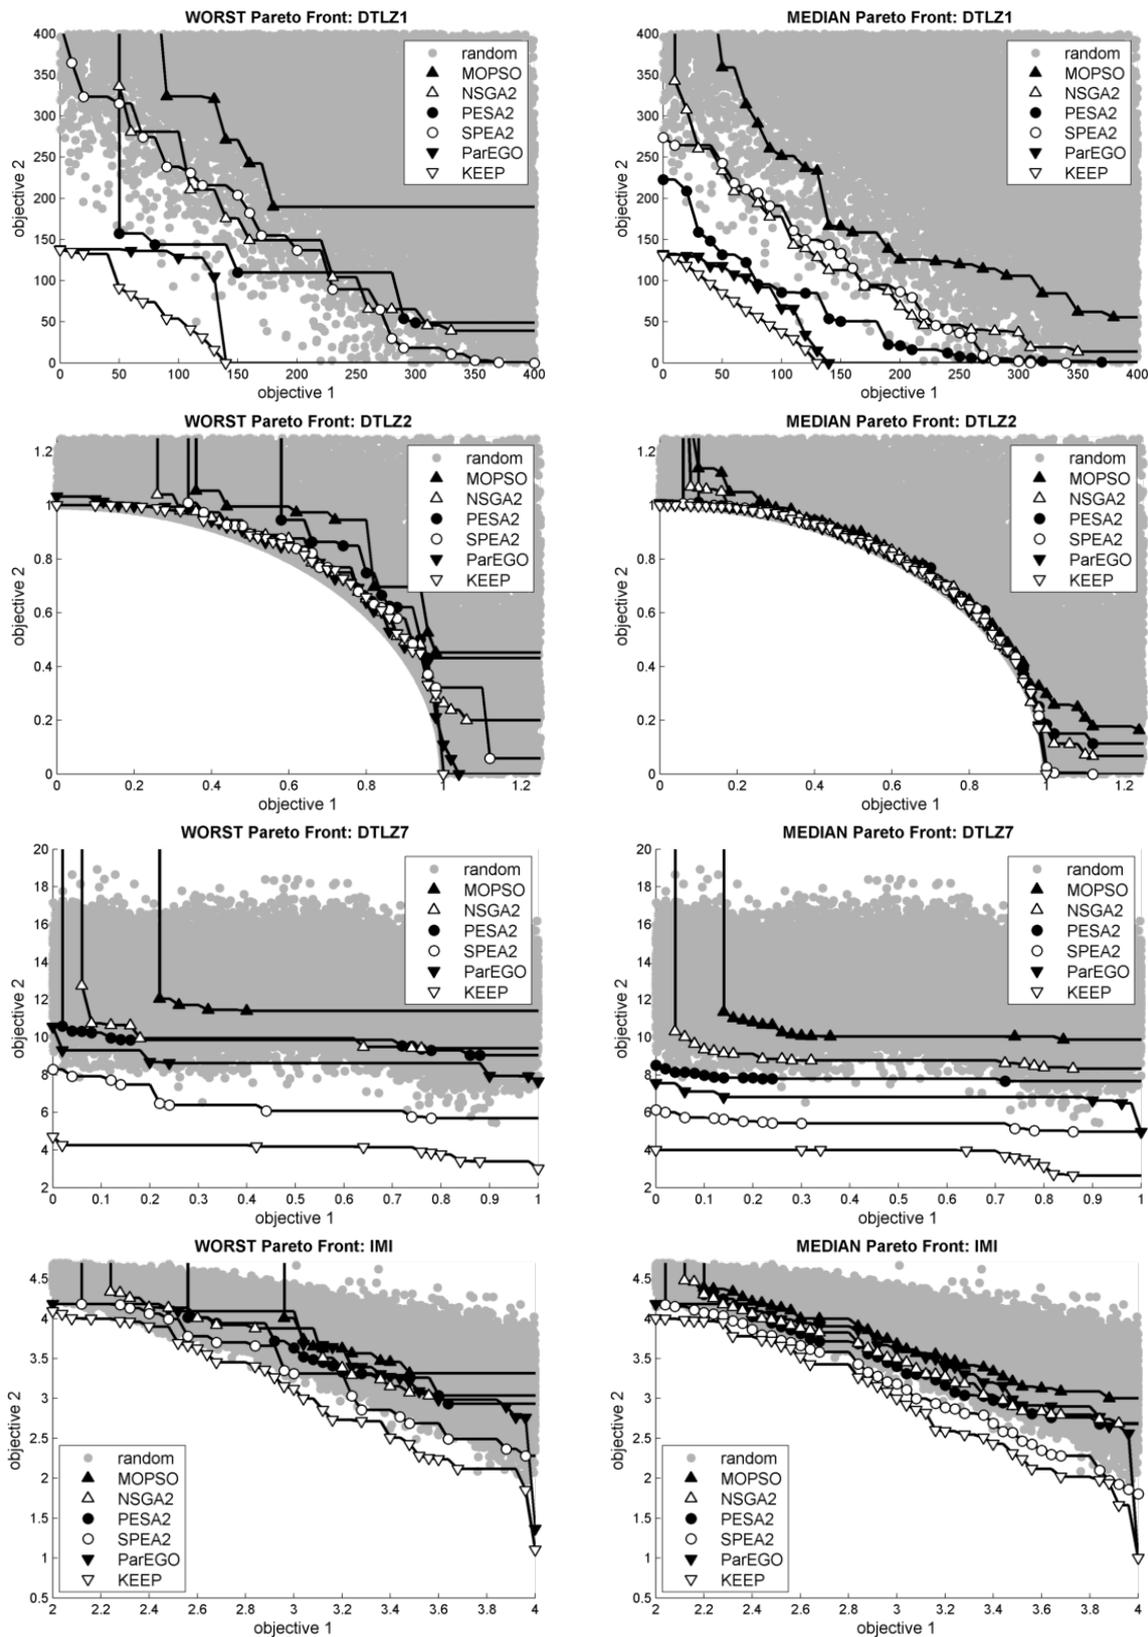


FIGURE 3.6: Résultats d'optimisation des fonctions DTLZ et la fonction IMI. Considérant tous les PF obtenus avec chaque algorithme, après 10 simulations de 381 évaluations [$j_0 + 250$] évaluations, (à gauche) le pire cas ou *worst case* et (à droite) le médian cas ou *median case* sont comparés par rapport aux 38 100 évaluations aléatoires (*random*).

Un nouvel algorithme KEEP, présenté dans ce chapitre, propose une amélioration du critère EI en utilisant la définition d'une probabilité d'appartenir au PS à partir d'un second modèle de substitution (*krigeage*). Les résultats de l'analyse comparative des performances montrent que l'algorithme KEEP présente des résultats similaires ou meilleurs (en terme de PI_{HI}) que les autres algorithmes testés. Les PF obtenus par cet algorithme sont bien définis et distribués dans l'espace de recherche. De plus, avec la plupart des fonctions, ces résultats présentent une faible variance, c'est-à-dire, qu'un mauvais choix du PdE a peu d'impact sur les performances finales. Concernant la vitesse de convergence, l'algorithme KEEP a été la méthode la plus rapide à converger vers le PF de la fonction objectif et à identifier la distribution du PS dans l'espace de recherche.

Remarquons que l'analyse comparative des performances a été faite en utilisant des fonctions de 12 paramètres, ce qui est au delà des limitations imposées par l'utilisation du *krigeage* (8-10 paramètres maximum). L'optimisation d'une fonction avec plus de paramètres expérimentera une dégradation de la performance.

Dans le prochain chapitre, le nouvel algorithme KEEP sera utilisé afin de réaliser une mise au point d'un système de surveillance de la pression des pneumatiques sous les contraintes d'avoir un nombre réduit d'évaluations de la fonction objectif et un nombre important de paramètres de réglage (36 paramètres en total).

Système de surveillance de la pression des pneumatiques

Sommaire

4.1	Introduction	58
4.2	Système de détection du SSPP indirect	59
4.2.1	Système de Détection de Crevaisson (SDC)	59
4.2.2	Système de Détection de Diffusion (SDD)	61
4.2.3	Algorithme de décision	62
4.3	Base de données de tests	64
4.3.1	Niveaux de sous-gonflages	64
4.3.2	Types de routes	65
4.3.3	Charge du véhicule	65
4.3.4	Type de pneumatiques	65
4.4	Plan de validation	65
4.4.1	Critères de performance	66
4.5	Mise au point du SSPP indirect	68
4.5.1	Mise au point du SDC	69
4.5.2	Mise au point du SDD	71
4.5.3	Étape intermédiaire	73
4.5.4	Mise au point de l'algorithme de décision	74
4.6	Conclusion	77

Ce chapitre s'intéresse à la mise au point automatique d'un système de surveillance de la pression des pneumatiques d'un véhicule par une approche indirecte, c'est-à-dire sans l'utilisation de capteurs de pression. Deux algorithmes ont été conçus, dans le cadre de la thèse [El Tannoury et al., 2013], pour alerter le conducteur d'un dégonflage ou d'une chute anormale de la pression, à partir de l'analyse temporelle et spectrale des signaux de vitesses angulaires des roues. La complexité du système et la grande taille de la base de données d'apprentissage incitent à l'utilisation d'une méthode d'optimisation globale pour la mise au point optimale des paramètres de mise en œuvre du système de détection. La nouvelle méthode d'optimisation globale multi-objectif KEEP, présentée dans le Chapitre 3, est appliquée pour l'optimisation des différentes parties du système. La stratégie du réglage et la mise au point du système sont détaillées en montrant les résultats obtenus.

4.1 Introduction

La pression des pneumatiques d'un véhicule a un impact direct sur la dynamique de ce dernier, sur le confort, la tenue de route et la sécurité de la conduite. Un sous-gonflage provoque une usure rapide du pneumatique et une augmentation de la consommation de carburant et de l'émission de polluant générée par le véhicule. Pour cette raison, depuis 2014, la réglementation européenne [**Economic Commission for Europe, 2009**] impose à ce que tous les nouveaux véhicules (de moins de 3,5 tonnes et moins de 9 passagers) soient dotés d'un *système de surveillance de la pression des pneumatiques* (SSPP) ou *tire pressure monitoring system* (TPMS). Ce système a comme objectif de réduire les émissions de CO₂ causée par un sous-gonflage, d'allonger la durée de vie des pneumatiques et d'augmenter la sécurité des passagers en réduisant le risque d'accidents.

La réglementation exige au SSPP d'avertir le conducteur de toute perte de pression supérieure à -20 % de la pression nominale. Pour garantir une bonne détection, la réglementation introduit une étape initiale dite *phase d'apprentissage*¹, qui permet aux SSPP de s'adapter aux caractéristiques et aux conditions du véhicule. Ensuite, en cas de sous-gonflage, la réglementation fait la distinction entre deux type de perte de pression :

- *Crevasion*. Forte chute de pression sur une ou plusieurs roues. La détection doit être faite avant 10 minutes de roulage entre 40 et 100 $km \cdot h^{-1}$
- *Diffusion*. Lente perte de pression sur plusieurs roues. La détection doit être faite avant une heure de roulage entre 40 et 120 $km \cdot h^{-1}$

En aucun cas, la réglementation n'exige de localiser la roue (ou les roues) présentant un sous-gonflage. Le SSPP ne doit que *détecter* le problème de pression des pneumatiques et non pas le localiser.

Plusieurs SSPP ont été proposés par les constructeurs automobiles ces dernières années. On distingue deux grandes familles : les SSPP directs et les SSPP indirects.

La première famille, utilisée actuellement par Renault, est le *SSPP direct*. Ce système est basé sur l'installation d'un capteur de pression sur chaque valve des roues du véhicule [**Schimetta et al., 2000**], ce qui permet d'obtenir la valeur des pressions en temps-réel. Ce système n'est pas trop complexe d'un point de vue de l'instrumentation et il est relativement facile à mettre au point. Néanmoins, les SSPP directs ont quelques inconvénients [**Velupillai et Guveng, 2007**]. Le premier est que les pneumatiques doivent être adaptés à l'installation des capteurs, ce qui n'est pas le cas de tous les pneumatiques qui existent sur le marché. Le deuxième problème est que les capteurs de pression nécessitent une maintenance régulière pour minimiser le risque de défauts et conserver leur capacité de détection. La dernière contrainte est que les capteurs de pression ont un coût de fabrication et d'entretien significatifs.

Une deuxième solution, en phase de développement chez Renault, est le *SSPP indirect*. Ce système est capable d'estimer un dégonflage à partir de l'analyse des signaux présents sur le bus CAN (angle volant, vitesses angulaires, régime moteur et accélérations) qui sont déjà requis par d'autres systèmes comme par exemple l'ESP². L'idée est d'utiliser des grandeurs physiques comme indicateurs de l'état de la pression, permettant ainsi de détecter les anomalies sans utiliser de capteurs de pression [**Persson et al., 2002**]. En revanche, les systèmes indirects sont plus complexes que les solutions directes et plus difficiles à mettre au point. Les principaux SSPP indirects présents sur le marché sont le DDS [**Edling et al., 2012**] et DDS+ [**Lou et al., 2002**] de *Continental teeves*, le TPM-C/F [**De-Rinaldis et al., 2012**] de *Bosch* et le TPI [**Hall et Gustavsson, 2013**] de *Nira Dynamics*. Renault a aussi développé un SSPP indirect [**El-Tannoury, 2012**]. L'objectif de ce chapitre est de présenter brièvement le SSPP de Renault, ainsi que la base de données et le plan de validation conçus pour la mise au point du système. En raison

¹Minimum 30 minutes de roulage avec le SSPP actif.

²Système actif d'anti-dérapiage destiné à l'amélioration du contrôle de la trajectoire du véhicule.

de la complexité du réglage du SSPP indirect, la mise au point sera basée sur la technique d'optimisation multi-objectif présentée Chapitre 3.

4.2 Système de détection du SSPP indirect

Le système SSPP indirect qui fait l'objet de ce chapitre a été développé dans [El-Tannoury, 2012]. Celui-ci est constitué de deux algorithmes de détection et d'un algorithme de décision.

Le premier algorithme de détection se base sur une analyse comparative des rayons dynamiques des roues à partir des signaux de vitesses angulaires. En effet, une baisse du rayon dynamique a comme conséquence directe une augmentation de la vitesse angulaire de la roue [Mayer, 1994]. Cet algorithme appelé *système de détection de crevaison* (SDC) permet de détecter efficacement toute baisse de pression dans une roue.

Le deuxième algorithme est basé sur l'analyse spectrale des signaux de vitesses angulaires. Il a été constaté que la baisse de la pression engendre une diminution des fréquences caractéristiques des vibrations du véhicule et de la roue, apparaissant dans le signal de vitesse angulaire [Zhang et al., 2009]. Cet algorithme est capable de détecter un dégonflage de plusieurs roues et il est très utile pour détecter les faibles pertes de pression accumulées après une longue période de roulage ; ce système est appelé *système de détection de diffusion* (SDD).

L'algorithme de décision (AdD) [Persson et al., 2002] fusionne les probabilités fournies par SDC et SDD afin d'estimer une unique probabilité d'avoir une crevaison ou une diffusion, ce qui permet d'alerter le conducteur si la probabilité d'anomalie est suffisamment élevée.

Définition 4.1 *Tous les calculs des algorithmes SDC et SDD sont réalisés indépendamment sur 5 "plages de vitesse" (PdV) différentes :*

$$\begin{aligned} \text{SDC} &\rightarrow [20 \ 50], [50 \ 70], [70 \ 90], [90 \ 110], [110 \ 200] \text{ km}\cdot\text{h}^{-1} \\ \text{SDD} &\rightarrow [10 \ 40], [40 \ 60], [60 \ 80], [80 \ 100], [100 \ 150] \text{ km}\cdot\text{h}^{-1} \end{aligned} \quad (4.1)$$

■

Remarque 4.1 *Le SDC et le SDD fournissent à l'AdD une valeur de probabilité (P) et une confiance³ (T) par roue et par plage de vitesse.*

■

Dans cette section, une brève explication des trois algorithmes (SDC, SDD et AdD) est faite afin d'introduire les paramètres à optimiser pendant la mise au point du SSPP indirect.

4.2.1 Système de Détection de Crevaison (SDC)

Définition 4.2 [Gillespie, 1992] *Le "rayon effectif" d'un pneumatique est le rapport entre la vitesse longitudinale v_x du véhicule et la vitesse angulaire Ω de la roue, c'est-à-dire*

$$R_{\text{eff}} = \frac{v_x}{\Omega} \quad (4.2)$$

■

L'idée principale de cette approche est basée sur la décroissance du rayon effectif lorsqu'il y a un sous-gonflage. Plusieurs travaux [De-Rinaldis et al., 2012] [El-Tannoury, 2012] ont mis en évidence cette relation entre le rayon effectif et la pression dans le pneumatique. Un exemple de cette variation a été mesuré en utilisant un véhicule *Renault Laguna II*⁴. Les résultats sont représentés Figure 4.1.

³Valeur définie à partir du temps d'apprentissage réalisé.

⁴Essais réalisés avec des pneumatiques de largeur 195 mm, hauteur du côté 127 mm, rayon nominal 310 mm, diamètre de la jante 15 pouces (381 mm).

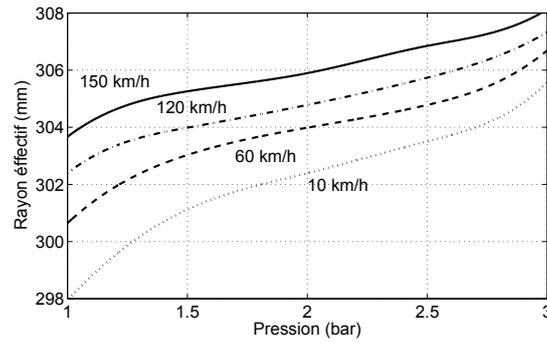


FIGURE 4.1: Relation entre la pression du pneumatique et le rayon effectif de la roue pour différentes vitesses du véhicule. (source de l'image : [De-Rinaldis et al., 2012])

Notons que la relation n'est pas linéaire car le rayon effectif dépend de la pression mais aussi d'autres grandeurs comme la température, la charge, l'usure et le glissement [Gillespie, 1992]. Par conséquent, la valeur du rayon effectif d'un seul pneumatique n'est pas suffisante pour déterminer la pression dans le pneumatique. En plus, une variation de pression de -20 % par rapport à la pression nominale correspond seulement à une variation du rayon de l'ordre de 0,4 %, ce qui exige une très bonne précision d'estimation. La solution proposée dans l'algorithme SDC est de comparer les vitesses angulaires Ω des différentes roues entre elles afin d'isoler les variations liées à la pression de chaque pneumatique [Neyrat et Crosnier, 1992] [Mayer, 1994]. Les trois critères proposés (*diag*, *axle* et *side*) sont définis Figure 4.2.

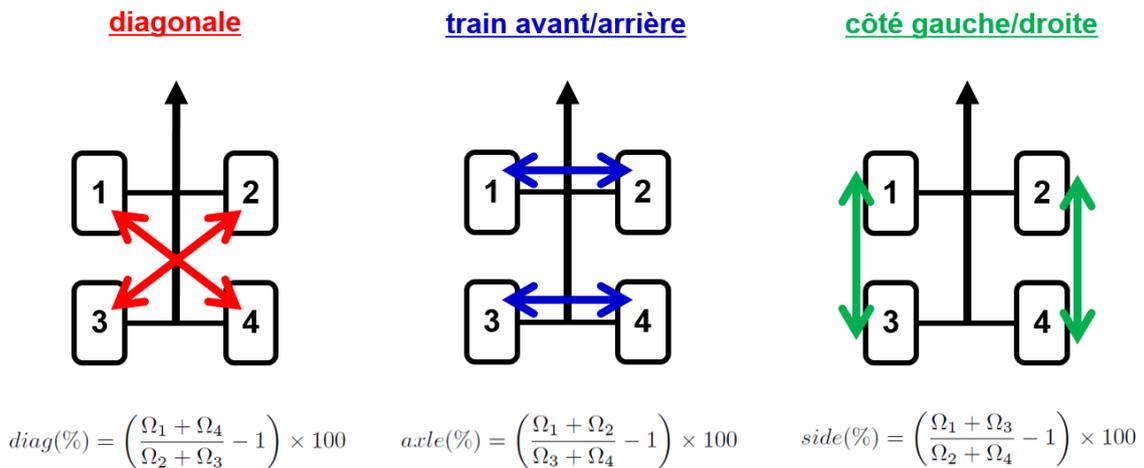


FIGURE 4.2: Critères de comparaison des vitesses angulaires des roues. (source des critères : [Mayer, 1994])

Un critère supplémentaire proposé dans [Saliou et al., 2015], et dite *alpha-axle*, est basé sur la relation entre l'angle volant et le critère *axle*, qui varie par rapport à la pression des pneumatiques.

Remarque 4.2 *Le SDC, basé sur une comparaison des vitesses angulaires des roues, est capable de détecter rapidement les sous-gonflages dans une seule roue. Néanmoins, si plusieurs roues ont une chute de pression, sa performance est dégradée. Notons, que si les 4 roues ont un sous-gonflage similaire (diffusion), le SDC sera incapable de le détecter.* ■

Paramètres de mise au point

Les paramètres de réglage de l'algorithme SDC sont (voir aussi Tableau 4.1)

1. *CRiDetectionTime*. Paramètre qui permet de définir la largeur de la *fenêtre temporelle*⁵ sur laquelle

⁵Durée fixe au cours de laquelle on regarde les événements passés pour la réalisation des calculs de l'algorithme.

est calculée la durée de moyennage des différents critères (*diag*, *axle* et *side*);

2. *L2DetectionTime*. Paramètre définissant la largeur de la fenêtre temporelle sur laquelle est calculée la durée de moyennage du critère *alpha-axle* ;
3. *LiGainDelta*. Paramètres (un pour chaque PdV) qui permettent d'adapter la probabilité estimée par rapport aux variations des différents critères ;
4. *WheelDeltaRadius2*. Paramètres (un pour chaque PdV) définissant un seuil de détection, à partir des variations relatives estimées du rayon effectif de chaque pneumatique.

Dimension	Nom du paramètre	Vmin	Vmax	Valeur par défaut
1	CRiDetectionTime	30	450	100
1	L2DetectionTime	120	450	300
5	LiGainDelta	0,4	1	0,6
5	WheelDeltaRadius2	0,002	0,010	0,005

TABLEAU 4.1: Paramètres de réglage du SDC. Chacun des paramètres *LiGainDelta* et *WheelDeltaRadius2* correspond à une PdV différente.

Remarque 4.3 *Le système SDC possède 12 paramètres à mettre au point. Tous les paramètres doivent être optimisés ensemble à cause de l'interaction entre paramètres dans le fonctionnement du SDC. Il n'est donc pas possible de découpler le problème d'optimisation.* ■

4.2.2 Système de Détection de Diffusion (SDD)

Le système est basé sur le principe de mesure de la vitesse angulaire obtenue grâce à l'utilisation d'un codeur incrémental installé sur chaque roue du véhicule. L'analyse du contenu spectral montre l'existence de 4 *mode vibratoires* [El-Tannoury, 2012] [Persson et al., 2002] (voir Figure 4.3) :

- Bande verticale (BV). Ce mode reflète la vibration verticale du véhicule ;
- Bande torsionnelle (BT). Ce mode reflète la torsion longitudinale du pneumatique ;
- Bande de roulement (BR). Ce mode reflète le contact entre la bande de roulement du pneumatique avec la chaussée ;
- Bande de haute fréquence (BH). Ce mode reflète les vibrations hautes fréquences.

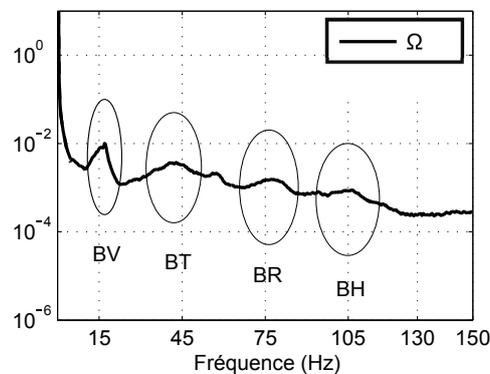


FIGURE 4.3: Exemple d'allure de la densité spectrale de puissance du signal de la vitesse angulaire Ω avec les 4 modes vibratoires identifiés (BV, BT, BR, BH). (source de l'image : [El-Tannoury, 2012])

Comme la position de ces modes vibratoires changent en fonction de la pression du pneumatique, cette information peut être utilisée pour l'identification des problèmes de dégonflage.

Remarque 4.4 Après un retour d'expériences du SDD sur des véhicules réels, il a été remarqué que la bande torsionnelle (BT) et la bande de roulement (BR) permettent d'identifier correctement tous les problèmes de sous-gonflages. Par conséquent, les autres bandes vibratoires (BV et BH) ne seront pas utilisées par le SDD Renault. ■

Un critère supplémentaire (δ -BT) a été utilisé. Il est basé sur le fait que lorsqu'une des roues présente un sous-gonflage, un écart de fréquences significatif sur les roues d'un même train est détecté [Lescarret et al., 2015].

Paramètres de mise au point

Remarque 4.5 Les paramètres de mise au point du SDD peuvent être réglés par chaque combinaison entre mode vibratoire (BT, BR et δ -BT) et train du véhicule (avant et arrière), ce qui donne 6 sous-problèmes d'optimisation. Afin de simplifier la notation, les 6 combinaisons possibles seront notées (*). ■

Les paramètres de réglage de l'algorithme SDD sont (voir aussi Tableau 4.2) :

1. *DetectionTime*(*). Paramètre définissant la largeur de la fenêtre temporelle sur laquelle est calculée la durée de moyennage des fréquences (de l'ordre de 300s) ;
2. *Threshold*(*). Paramètre définissant le seuil fréquentiel pour déterminer la probabilité de sous-gonflage.
3. *Lambda*(*). Facteur d'oubli permettant de gérer le niveau de lissage de la fréquence estimée, ce qui définit la réactivité à une variation de fréquence.

Dimension	Nom du paramètre	Vmin	Vmax	Valeur par défaut
6	DetectionTime(*)	10	10000	200
6	Threshold(*)	0.1	1.6	1
6	Lambda(*)	0,99900	0,99999	0,99990

TABLEAU 4.2: Paramètres de réglage du SDD. Le signe (*) représente les 6 combinaisons de fréquences et de trains (voir Remarque 4.5).

Remarque 4.6 Le système SDD possède 18 paramètres à mettre au point. L'avantage du SDD est que la mise au point est décomposée en 6 sous-problèmes d'optimisation indépendants (voir Remarque 4.5). ■

4.2.3 Algorithme de décision

Remarque 4.7 Les estimations de sous-gonflages du SDC et du SDD sont faites pour chaque roue. Pour simplifier la notation, l'Add détaillé dans cette section correspond à la détection d'un problème de chute de pression dans une seule roue. ■

Le but de l'Add est de fusionner la probabilité P et la confiance T d'avoir une anomalie de pression détecté par le SDC (P_{SDC} et T_{SDC}) et le SDD (P_{SDD} et T_{SDD}) en utilisant différentes plages de vitesse. En sortie de l'algorithme, une variable booléenne doit indiquer s'il faut activer une alerte de sous-gonflage ou pas. L'Add est constitué de trois parties différentes (voir Figure 4.4)

1. *Identification* d'un problème de pression. Pour chaque système de détection (SDC et SDD), les valeurs de P et T dans toutes les PdV sont prises en compte pour l'estimation d'une probabilité finale d'avoir un sous-gonflage (P_{SDC}^F et P_{SDD}^F) ;
2. *Fusion* des méthodes de détection. Les probabilités finales estimées pour chaque système de détection sont utilisées pour créer une valeur de probabilité finale unique (P^F) ;

3. Activation de l'Alerte. Afin d'avoir un système robuste, cette partie contrôle le niveau de P^F par rapport au temps avant d'alerter le conducteur d'un problème de pression de pneumatiques.

Plusieurs solutions ont été proposées pendant la conception de l'AdD. Le choix final (en ayant un compromis entre le nombre de paramètres à régler, l'empreinte mémoire⁶ et la complexité de la solution) a été :

1. *Identification* : approche bayésienne. Cette solution a l'avantage d'utiliser les résultats de la base de données afin d'identifier la probabilité d'avoir un sous-gonflage plus la probabilité de ne pas avoir un sous-gonflage. En fonction des paramètres de risque ou de coût, ainsi que de la confiance de chaque valeur, l'approche fusionnera les deux probabilités précédentes entre toutes les PdV afin d'obtenir une probabilité finale d'avoir un sous-gonflage (P_{SDC}^F et P_{SDD}^F).
2. *Fusion* : approche logique floue [Davins-Valldaura, 2012]. Cette solution permet de fusionner les probabilités fournies par l'approche bayésienne en utilisant les principes de *fuzzification* et de *défuzzification* de quatre *variable linguistiques*⁷, à savoir les probabilités forte (H) ou faible (L) d'avoir un sous-gonflage du SDC et du SDD (P_{SDC}^H et P_{SDC}^L , P_{SDD}^H et P_{SDD}^L) ;
3. *Alerte* : À partir de la probabilité calculée par la logique floue (P^F), une valeur de *pente* est définie. À chaque échantillonnage, un *intégrateur*⁸ est mis à jour grâce à la valeur de la pente. Si la valeur de l'intégrateur dépasse un seuil, l'alerte de sous-gonflage sera activée.

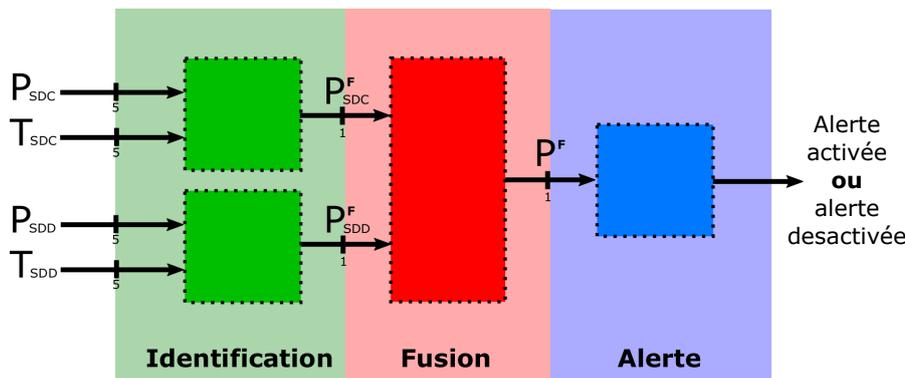


FIGURE 4.4: Structure de l'AdD du SSPP indirect. La partie d'identification est basée sur un approche bayésien, la fusion sur un approche de logique floue et l'alerte est contrôlée pour un intégrateur.

Paramètres de mise au point

Les paramètres de réglage de l'AdD sont (voir aussi Tableau 4.3)

1. *SDCCostWarnOnIFNominal*. Paramètre définissant le coût d'activation d'une alerte si l'algorithme SDC détecte un problème de pression ;
2. *SDDCostWarnOnIFNominal*. Paramètre définissant le coût d'activation d'une alerte si l'algorithme SDD détecte un problème de pression ;
3. *MDLPointFlow*. Paramètre définissant le poids de l'estimation P_{SDD}^L sur la pente de l'intégrateur ;
4. *MDLPointFhigh*. Paramètre définissant le poids de l'estimation P_{SDD}^H sur la pente de l'intégrateur ;
5. *MDLPointFlow*. Paramètre définissant le poids de l'estimation P_{SDC}^L sur la pente de l'intégrateur ;
6. *MDLPointThigh*. Paramètre définissant le poids de l'estimation P_{SDC}^H sur la pente de l'intégrateur.

Remarque 4.8 L'AdD possède 6 paramètres à mettre au point. Deux de ces paramètres sont utilisés dans l'approche bayésienne et quatre par l'approche de logique floue. ■

⁶Elle désigne la quantité de mémoire allouée à l'application lors de son exécution.

⁷Variable internes utilisées dans tout processus de logique floue.

⁸Responsable d'augmenter ou réduire la valeur du niveau d'alerte du système.

Dimension	Nom du paramètre	Vmin	Vmax	Valeur par défaut
1	SDCCostWarnOnIFNominal	0	1	0,6
1	SDDCostWarnOnIFNominal	0	1	0,8
1	MDLPointFlow	0	20	15
1	MDLPointFhigh	-20	0	-10
1	MDLPointFlow	0	20	12
1	MDLPointThigh	-20	0	-10

TABLEAU 4.3: Paramètres de l'Add à mettre au point.

4.3 Base de données de tests

Pour réaliser la *mise au point* du premier véhicule équipé d'un système SSPP indirect (voiture de type *Renault Kangoo II phase-II*), une grande *base de données* (BdD) a été utilisée. Une flotte de 4 véhicules, dont 2 véhicules particuliers (VP) et 2 véhicules utilitaires (VU), a roulé pendant quelques mois sous différentes conditions de conduite afin d'enregistrer toutes les données du bus CAN et de l'odométrie du véhicule.

Remarque 4.9 *Les caractéristiques véhicule des VP et des VU sont différentes (par exemple, les rapports de boîte de vitesse et la masse du véhicule). Celles-ci sont identifiées a priori et prises en compte pendant la mise au point. Néanmoins, les paramètres à optimiser du système SSPP indirect doivent être réglés pour les deux types de véhicule (une seule configuration de paramètres).* ■

Tous les signaux du véhicule ont été stockés sur des unités d'enregistrement dites *essais* (voir Figure 4.5), qui correspondent entre 60 et 120 *minutes* de roulage sans changer les conditions de roulage (même pression des pneumatiques). La base de données finale est constituée de 1 300 essais environs, ce qui équivalent à 1 800 heures de roulage et 115 000 km.

Ensuite, les différentes conditions et caractéristiques prises en compte pendant l'enregistrement des essais sont présentées : les niveaux de sous-gonflages, les types de routes, les charges du véhicule et le type de pneumatiques.

4.3.1 Niveaux de sous-gonflages

Plusieurs types d'essais avec différentes combinaisons de sous-gonflage ont été enregistrés pendant la création de la BdD afin d'illustrer l'ensemble des problèmes qu'on peut rencontrer dans une situation de roulage réelle. Les différents sous-gonflages (par rapport à la pression nominale du pneumatique) utilisés pour réaliser les enregistrements sont :

- *Sous-gonflage 0 %*. Roue à pression nominale, pas de problème de pression ;
- *Sous-gonflage -8 %*. Roue légèrement sous-gonflée. Le système ne le détecte pas comme un problème de chute de pression ;
- *Sous-gonflage -32 %*. Roue avec un fort sous-gonflage. Le système doit le détecter comme un problème de chute de pression ;
- *Sous-gonflage -18%*. Niveaux de sous-gonflage seulement utilisés pour réaliser une transition entre des dégonflages de -8% à -32% (chute lente de pression).

En classifiant les essais par rapport au nombre de roues avec un problème de pression, on fait la distinction entre (voir Figure 4.5) :

- *Essais de robustesse* : enregistrements avec aucune roue sous-gonflée ;
- *Essais de détection de crevaison* : enregistrements avec 1 roue sous-gonflée ;
- *Essais de détection de diffusion* : enregistrements avec 4 roues sous-gonflées ;
- *Essais particuliers* : enregistrements avec 2 ou 3 roues sous-gonflées.

Remarque 4.10 Dans ce chapitre, toute roue avec un problème de pression qui correspond à un sous-gonflage de -32 % est dite "roue sous-gonflée". ■

4.3.2 Types de routes

Les essais sont faits pour cinq types de routes :

- *Autoroute* : Essais à haute vitesse (majoritairement dans la plage de 100-130 $km \cdot h^{-1}$);
- *Ville* : Essais à basse vitesse (moins de 50 $km \cdot h^{-1}$) et arrêts fréquents ;
- *Bonne route* : Essais à vitesse moyenne et haute, route départementale ;
- *Mauvaise route*. Essais à moyenne et basse vitesse, routes avec nombreux virages ;
- *Mixte*. Une combinaison des différents types de routes et plages de vitesse.

4.3.3 Charge du véhicule

La masse du véhicule a un fort impact sur la performance des SSPP indirects. Les essais de la BdD ont été enregistrés en prenant en compte différentes charges :

- *Véhicule en ordre de marche (VODM) + 1* : Poids de référence du véhicule plus poids d'un conducteur ;
- *VODM + 5* : Poids de référence du véhicule plus poids de cinq personnes ;
- *Coffre chargé* : Poids de référence du véhicule VODM avec le conducteur, plus le coffre chargé de 180 kg ;
- *Masse maximale autorisée de charge du véhicule (MMAC)* : Poids de référence plus charge de 475 kg . Le poids total du véhicule est supposé être bien distribué, de manière équilibré entre les trains avant et arrière.

La charge VODM des véhicules utilisées pour la réalisation de la BdD, est de 1 475 kg . Le poids estimé pour une personne est de 75 kg .

4.3.4 Type de pneumatiques

Plusieurs types de pneumatiques ont été utilisés pour vérifier la performance de la mise au point et l'impact qu'a le type de pneumatiques sur les performances du SSPP indirect. Les pneumatiques sélectionnés pour créer la BdD ont différentes dimensions (de 15 *pouces* à 17 *pouces* de rayon nominal), différents niveaux d'usure (pneumatiques neufs ou très usés) et différents fabricants (Continental, Michelin, Kléber, Barum, entre d'autres).

4.4 Plan de validation

Pour valider les système SSPP indirect, les constructeurs automobiles ont l'habitude de tester le système dans des situations de roulage réalistes, soit un roulage défini par la réglementation soit un roulage typique d'un conducteur client, afin de vérifier la robustesse et la performance de détection. La stratégie utilisée pour l'évaluation du SSPP indirect Renault est basée sur la concaténation d'essais de la BdD afin de créer un roulage du véhicule de plusieurs heures, dite *cas d'usage* (CdU). L'ensemble de CdU, dit *plan de validation*, est constitué de plus de 1 380 000 km de roulage.

Remarque 4.11 Pour la création de chaque CdU, seuls les essais avec le même véhicule et les mêmes pneumatiques (mêmes ou différentes pressions) sont concaténés. ■

Pour respecter les exigences de la réglementation, les CdU (voir Figure 4.6) sont divisés en deux phases :

- La *phase d'apprentissage*. Elle est constituée toujours de 5 essais concaténés à pression nominale tant en respectant la Remarque 4.11. Cette phase permet au SSPP indirect de s'adapter aux conditions actuelles des pneumatiques, et servira de référence au système pour identifier un futur problème de pression. Notons que, pendant la phase d'apprentissage, le SSPP n'est pas soumis à la nécessité de détecter les sous-gonflages ;
- La *phase de détection*. Elle est constituée de 2 à 4 essais, ceci dépendant du fait que le CdU simule une chute de pression rapide ou lente. Pendant cette phase, le SSPP indirect doit détecter tout problème de chute de pression dans le temps imposé par la réglementation (voir Section 4.1)

Concernant le plan de validation, deux types de CdU sont définis afin d'évaluer la performance globale du système :

- Analyse de *robustesse*. C'est l'ensemble de CdU avec un sous-gonflage maximal de -8 % pendant la phase de détection, c'est-à-dire que seuls les essais de robustesse sont utilisés. Ces CdU permettent de tester si le SSPP indirect ne déclenche pas une alerte inutile lorsqu'il n'y a qu'un petit sous-gonflage, situation connue comme **fausse alerte** (FA).
- Analyse de *détection*. C'est l'ensemble de CdU avec un sous-gonflage de -32 % pendant la phase de détection. Ces CdU permettent de tester si le SSPP indirect ne signale pas l'alerte lorsqu'il y a effectivement un sous-gonflage, situation connue comme **non détection** (ND). En fonction du nombre de roues avec un problème de pression, les CdU peuvent être classifiés en :
 - CdU de *crevaison*. Utilisation d'une concaténation d'essais avec 1 roue sous-gonflée pendant la phase de détection ;
 - CdU de *diffusion*. Utilisation d'une concaténation d'essais avec 4 roues sous-gonflées pendant la phase de détection ;
 - CdU *particulières*. Utilisation d'une concaténation d'essais avec 2 ou 3 roues sous-gonflées pendant la phase de détection.

Quelques exemples de CdU utilisés pour le plan de validation du SSPP sont représentés Figure 4.6.

4.4.1 Critères de performance

Pour réaliser une comparaison avec la solution SSPP indirecte de Renault et une solution de la concurrence, chaque CdU a été pondéré en fonction de la probabilité de le rencontrer dans la réalité, cette probabilité ayant été définie à partir d'études statistiques. Les poids ont été fixés par rapport à

- *Profil du conducteur*, à partir du type de route sur laquelle le conducteur a l'habitude de rouler, ce qui correspond aux essais utilisés pendant la phase d'apprentissage.
- *Profil de la route*, à partir du type de route utilisé pendant la phase de détection.
- *Situation du CdU*. Plusieurs CdU ont été définis avec des conditions particulières afin de couvrir toutes les situations possibles : changement de masse ou type de route entre la phase d'apprentissage et la détection, pneumatiques avec différents niveaux d'usure, dégonflage de 2 ou 3 roues... Chacune de ces situations a été pondérée avec un poids spécifique.

Le poids final de chaque CdU sera donc obtenu en combinant les trois critères précédents. Les deux critères de performance du SSPP indirect à minimiser, le pourcentage de FA et le pourcentage de ND, seront pondérés par rapport au poids final attribué à chaque CdU, ce qui définit de nouvelles valeurs de performance pour le plan de validation notées $\%oFA_{PV}$ et $\%oND_{PV}$.

Remarque 4.12 Pour des raisons de confidentialité, les poids des différents CdU, ainsi que les poids des différents profils et situations, ne seront pas détaillés dans cette thèse. Par conséquent, tout au long du chapitre, les valeurs de performances obtenues pour l'optimisation d'essais (pourcentage de FA et ND) et pour l'optimisation des CdU ($\%oFA_{PV}$ et $\%oND_{PV}$) ne seront pas affichées sur les figures des résultats.



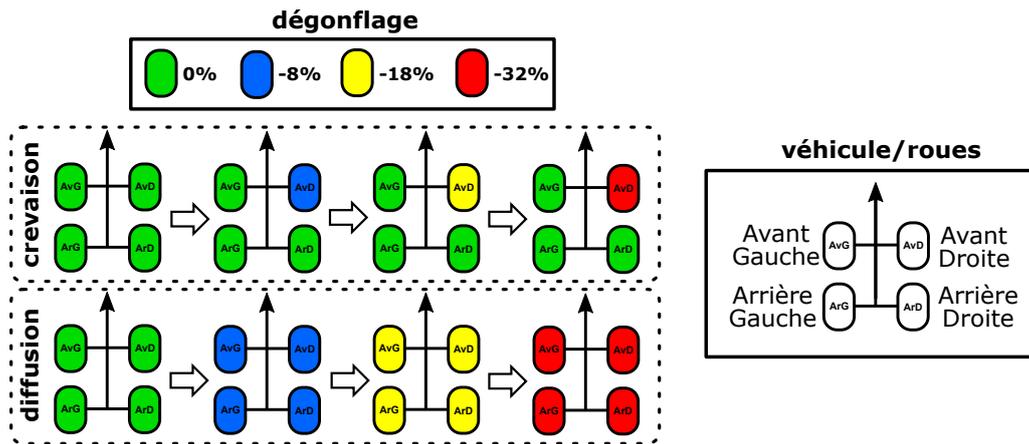


FIGURE 4.5: Type d'essais enregistrés dans la BdD pour la réalisation de la mise au point du SSPP indirect. Enregistrements de crevaisson (*haut*) et diffusion (*bas*) obtenus à partir d'un dégonflage progressif (de gauche à droite) de 1 et 4 roues respectivement, dégonflage réalisé manuellement au début de chaque essai.

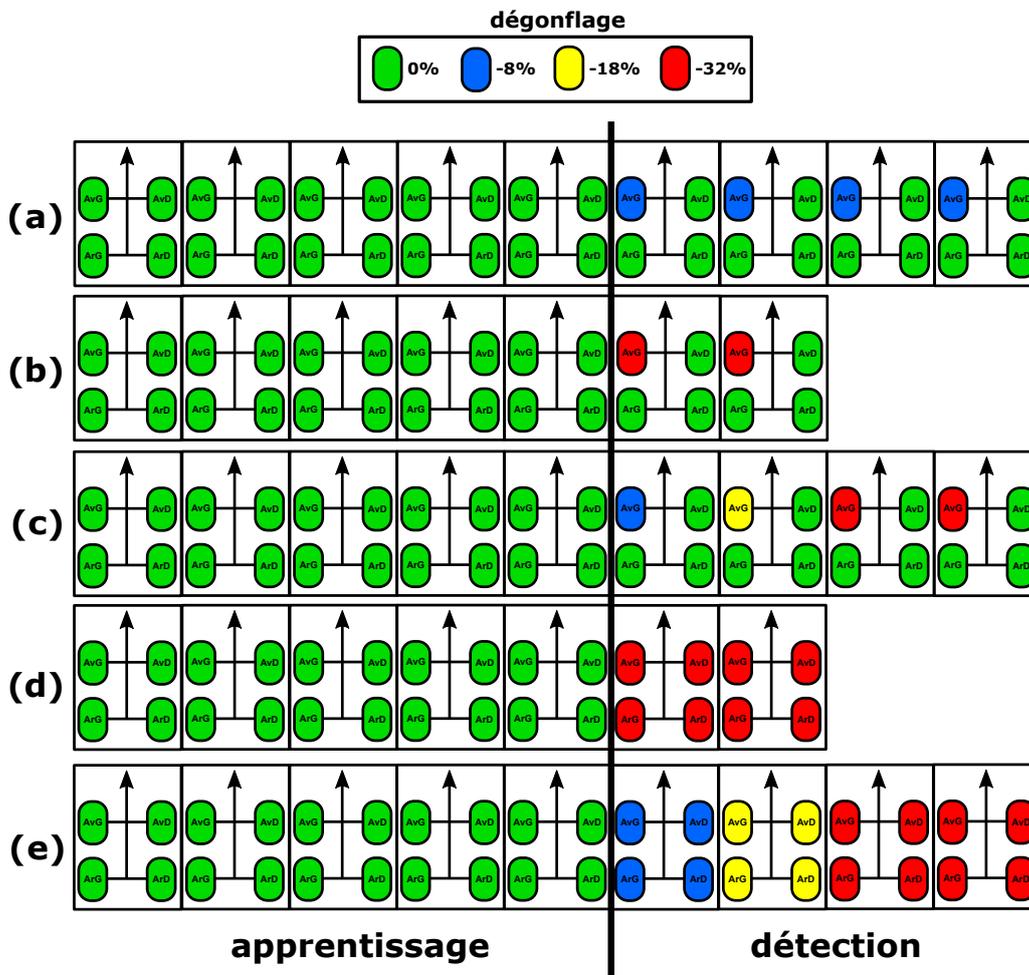


FIGURE 4.6: Type de CdU utilisés pour le plan de validation du SSPP indirect. Chaque CdU (ligne), est composé par la concaténation de 5 *essais* à pression nominale (phase d'apprentissage) plus quelques *essais* de détection. (a) CdU pour l'analyse de robustesse, (b) CdU pour la détection d'une crevaisson rapide, (c) CdU pour la détection d'une crevaisson lente, (d) CdU pour la détection d'une diffusion rapide et (e) CdU pour la détection d'une diffusion lente.

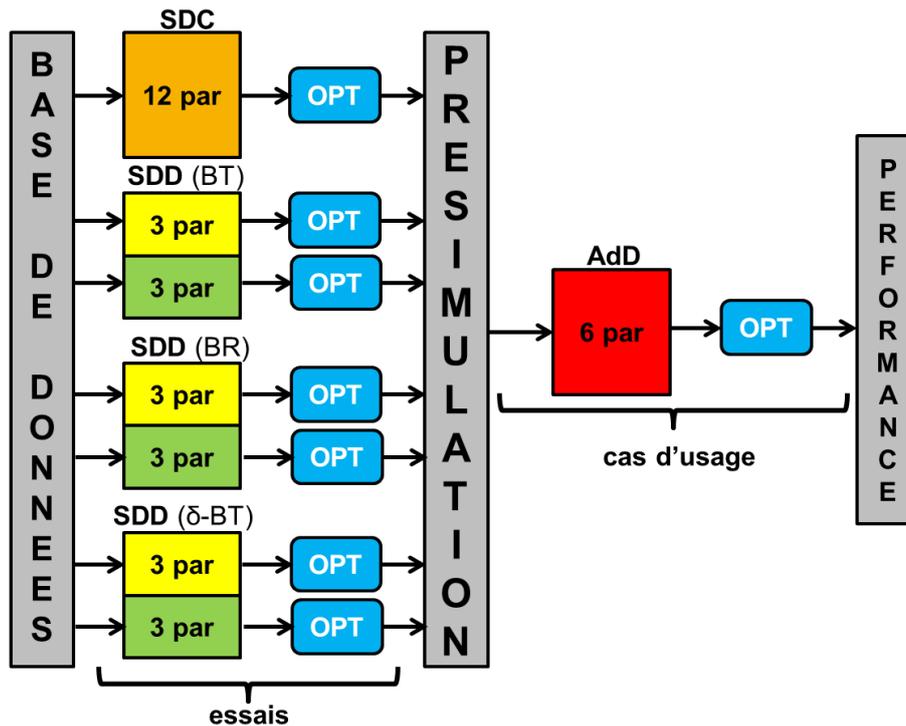


FIGURE 4.7: Structure de la mise au point du SSPP indirect. Le bloc orange représente le SDC, les blocs jaune et vert le SDD (train avant et arrière) avec les 3 modes vibratoires (BT, BR et δ -BT), le bloc rouge l'AdD et les blocs bleus les sous-problèmes d'optimisation.

4.5 Mise au point du SSPP indirect

Remarque 4.13 Pour la mise au point du SSPP indirect, deux ordinateurs HP Z600 Workstation avec deux processeurs Intel(R) Xeon(R) X5560 @2.80 GHz, une mémoire RAM installée de 48 Go et 12 cœurs, ont été utilisés.

La mise au point du SSPP indirect est tel que son réglage n'est pas une tâche aisée :

- **Grande BdD.** Le nombre d'essais réalisés pour la conception de la BdD permet de créer un plan de validation avec plus de 1 380 000 *km* de roulage à simuler. La simulation de toute la BdD pour une unique configuration des paramètres du SSPP indirect nécessite 21 jours en utilisant les ordinateurs décrits Remarque 4.13 ;
- **Temps limité.** L'idée est d'optimiser tout le système (SDC, SDD et AdD) en moins de 3 mois ;
- **Complexité du système.** Le réglage du SSPP indirect est complexe à réaliser car il est constitué de plusieurs parties basées sur différents principes. Au total, le système SSPP indirect a 36 paramètres de mise au point : 12 paramètres pour le SDC (Remarque 4.3), 18 paramètres pour le SDD (Remarque 4.6) et 6 paramètres pour l'AdD (Remarque 4.8) ;
- **Complexité de l'optimisation.** Le système SSPP indirect doit être optimisé en utilisant deux critères antagonistes (optimisation bi-objectif) : le taux de fausses alertes et le taux de non détections ($\%FA_{PV}$ et $\%ND_{PV}$).

Afin de prendre en compte les contraintes précédentes, une stratégie d'optimisation a été proposée (voir Figure 4.7). Plutôt que de réaliser une optimisation directe sur tous les paramètres du système, la solution adoptée consiste à réaliser plusieurs optimisations indépendantes de sous-parties du système afin de réduire le temps de mise au point.

La première étape consiste à optimiser les systèmes de détection (SDC et SDD) en parallèle. La mise au point des systèmes de détection est divisée en 7 sous-problèmes d'optimisation : 1 problème de 12 paramètres (Remarque 4.3) et 6 problèmes de 3 paramètres (Remarque 4.6). L'optimisation est faite en utilisant les essais de la Bdd en minimisant le %oFA et %oND. Une fois la configuration de paramètres optimaux du SDC et du SDD est sélectionnée et fixé, la deuxième étape consiste à réaliser une pré-simulation de toute la Bdd afin d'enregistrer tous les résultats et variables intermédiaires (sorties du SDC et SDD). L'avantage de cette stratégie est que l'AdD utilisera directement les variables intermédiaires stockées sans avoir besoin de ré-simuler toute la Bdd. Le gain temporel est très significatif : de 21 jours de simulation, on passe à seulement 3 heures de simulation de l'AdD en utilisant les variables intermédiaires stockées. La dernière étape est l'optimisation de l'AdD qui correspond à un problème de 6 paramètres (Remarque 4.8). L'optimisation est faite en respectant le plan de validation sur tout l'ensemble de CdU, en minimisant le %oFA_{PV} et %oND_{PV}.

Remarque 4.14 *Dans cette section, on présente les résultats obtenus pour la mise au point du SSPP indirect. À cause de l'important temps nécessaire pour réaliser la mise au point de tout le système (entre 2 et 3 mois), un seul algorithme a été utilisé pour le réglage. La méthode choisie pour optimiser tous les sous-problèmes a été l'algorithme KEEP, en raison de ses meilleures performances obtenues dans l'analyse comparative d'algorithmes multi-objectif réalisée dans le Chapitre 3.* ■

Remarque 4.15 *Les problèmes d'optimisation n'admettent pas une solution unique mais plutôt un ensemble de solutions optimales admissibles qui seront comparées à l'aide du concept de dominance de Pareto (Définition 2.15) et du front de Pareto (Pareto Front, PF) (Définition 2.18).* ■

4.5.1 Mise au point du SDC

Remarque 4.16 *Lors de la réalisation de la mise au point automatique du SDC, une mise au point manuelle a été réalisée en parallèle par un ingénieur expert dans le domaine. La configuration de paramètres qu'il a proposée, dite "configuration manuelle", sera comparée avec les résultats obtenus de manière automatique avec KEEP.* ■

En termes d'optimisation, la mise au point du SDC est la plus contraignante temporellement car il possède 12 paramètres à optimiser (le sous-problème d'optimisation du SSPP indirect avec une dimension plus grande), et nécessite un nombre élevé d'itérations pour garantir une convergence vers un ensemble de configurations de paramètres optimaux.

Afin de réduire le temps d'optimisation, on propose d'utiliser une partie représentative de la Bdd, dite *petite Bdd*, et de vérifier les résultats optimaux avec la Bdd complète, dite *grande Bdd*. Les résultats de l'optimisation des paramètres SDC (Tableau 4.1) avec la petite Bdd sont montrés dans la Figure 4.8. Ensuite, les résultats du FP obtenus sont évalués avec la grande Bdd (voir Figure 4.9).

La première observation est que l'algorithme KEEP optimise correctement le SDC. Notons que KEEP est capable d'améliorer les résultats des évaluations initiales (131 évaluations) avec un nombre très limité d'évaluations d'optimisation (262 évaluations). Les résultats montrent que le PF obtenu a été optimisé dans toutes les directions en obtenant un PF bien défini. Une autre remarque est que, en re-simulant les configurations de paramètres avec la grande Bdd, on voit que les deux PF gardent la même distribution et forme avec des valeurs similaires. Par conséquent, pour l'optimisation du SDC, l'utilisation d'une Bdd représentative paraît une stratégie correcte afin de réduire le temps d'optimisation. Les deux optimisations (automatique et manuelle) ont été faites pendant trois semaines (optimisation et simulations). Les résultats de l'optimisation manuelle et automatique montrent qu'il est possible de trouver des performances à un niveau similaire. L'inconvénient est que pour réaliser le réglage manuel, il faut avoir une bonne connaissance de la structure et du fonctionnement du SDC et de dédier beaucoup de temps pour comprendre l'influence de chaque paramètre sur la performance finale. De plus, une seule configuration de paramètres est obtenue par la mise au point manuelle ; par contre, KEEP est capable de fournir un

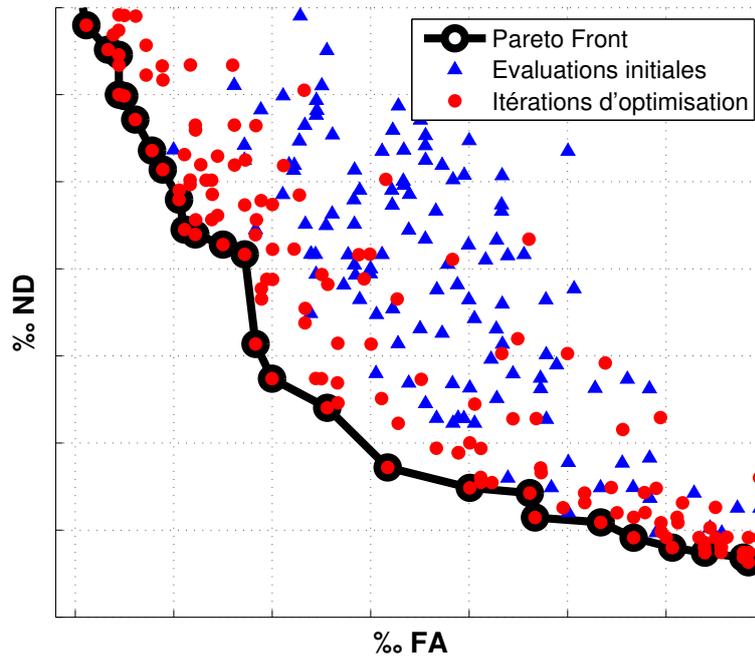


FIGURE 4.8: Résultats obtenus par l'optimisation du SDC avec la petite BdD. Les valeurs ne sont pas affichées pour des raisons de confidentialité.

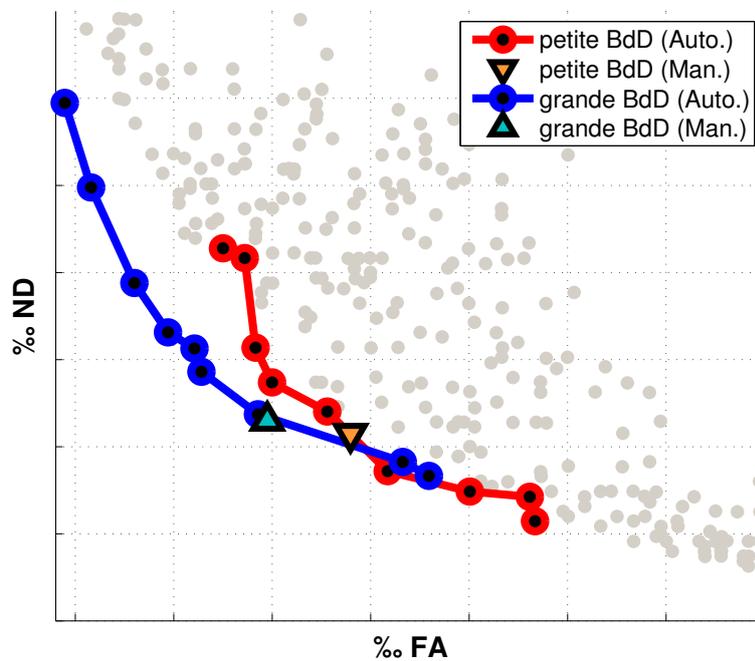


FIGURE 4.9: Comparaison des résultats du SDC obtenus en utilisant la petite et la grande BdD. Une sélection de configurations de paramètres du PF obtenus en utilisant la méthode (Auto.) ont été utilisées par re-simuler les SDC avec la grande BdD. Les performances du SDC avec la configuration manuelle (Man.) sont calculées pour les deux BdD. Les valeurs ne sont pas affichées pour des raisons de confidentialité.

ensemble de solutions optimales, ce qui permettra de choisir une solution avec le compromis souhaité entre FA et ND .

4.5.2 Mise au point du SDD

La mise au point du SDD est divisée en 6 sous-problèmes d'optimisation (voir Remarque 4.5), qui ont 3 paramètres de réglage (voir Tableau 4.2). La particularité de la mise au point du SDD est que chaque sous-problème n'utilise que les essais contenant des défaut qu'il est capable de détecter. Par exemple, si la roue AvG est la seule à avoir un sous-gonflage, les méthodes SDD du train arrière ne seront pas capables de détecter la chute de pression. Le Tableau 4.5.2 détermine chaque sous-problème du SDD (combinaison de mode vibratoire et train) associé à chaque combinaison de pression des pneumatiques. L'optimisation de chaque sous-problème est faite avec un nombre d'évaluations très limité : 32 évaluations initiales plus 64 évaluations d'optimisation proposées par KEEP.

Toutes les combinaisons de pression des pneumatiques				Sub-problème utilisé pour la mise au point			
AvG	AvD	ArG	ArD	Av(BT,BR)	Av(δ -BT)	Ar(BT,BR)	Ar(δ -BT)
PN	PN	PN	PN	oui	oui	oui	oui
PN	PN	PN	S-G	non	non	oui	oui
PN	PN	S-G	PN	non	non	oui	oui
PN	PN	S-G	S-G	non	non	oui	non
PN	S-G	PN	PN	oui	oui	non	non
PN	S-G	PN	S-G	oui	oui	oui	oui
PN	S-G	S-G	PN	oui	oui	oui	oui
PN	S-G	S-G	S-G	oui	oui	oui	non
S-G	PN	PN	PN	oui	oui	non	non
S-G	PN	PN	S-G	oui	oui	oui	oui
S-G	PN	S-G	PN	oui	oui	oui	oui
S-G	PN	S-G	S-G	oui	oui	oui	non
S-G	S-G	PN	PN	oui	non	non	non
S-G	S-G	PN	S-G	oui	non	oui	oui
S-G	S-G	S-G	PN	oui	non	oui	oui
S-G	S-G	S-G	S-G	oui	non	oui	non

TABLEAU 4.4: Situations de sous-gonflages utilisées pour la mise au point de chaque partie du SDD. Pour chaque situation (ligne) : à gauche, toutes les situations possibles (PN=pression nominale, SG=sous-gonflage) ; à droite, la réponse oui/non si la combinaison des pressions est utilisée ou pas pour la mise au point.

À partir des résultats de l'optimisation du SDD (voir Figure 4.10), on peut signaler que le mode vibratoire BR est moins performant et efficace pour la détection d'un problème de pression que le reste de modes vibratoires. Par contre, les résultats obtenus à travers les modes BT et δ -BT sont très intéressants, spécialement pour le train avant.

Une autre observation est que les sous-problèmes à mettre au point, d'un point de vue optimisation, sont considérés comme des fonctions d'optimisation très plates car l'amélioration obtenue en modifiant les paramètres est très faible.

Une possible amélioration pourrait être la définition d'un nouvel intervalle de valeurs pour les paramètres (descendre V_{min} et augmenter V_{max}) ou l'ajout d'autres paramètres du SDD afin de permettre à l'algorithme KEEP d'explorer et d'améliorer de manière plus efficace le SDD.

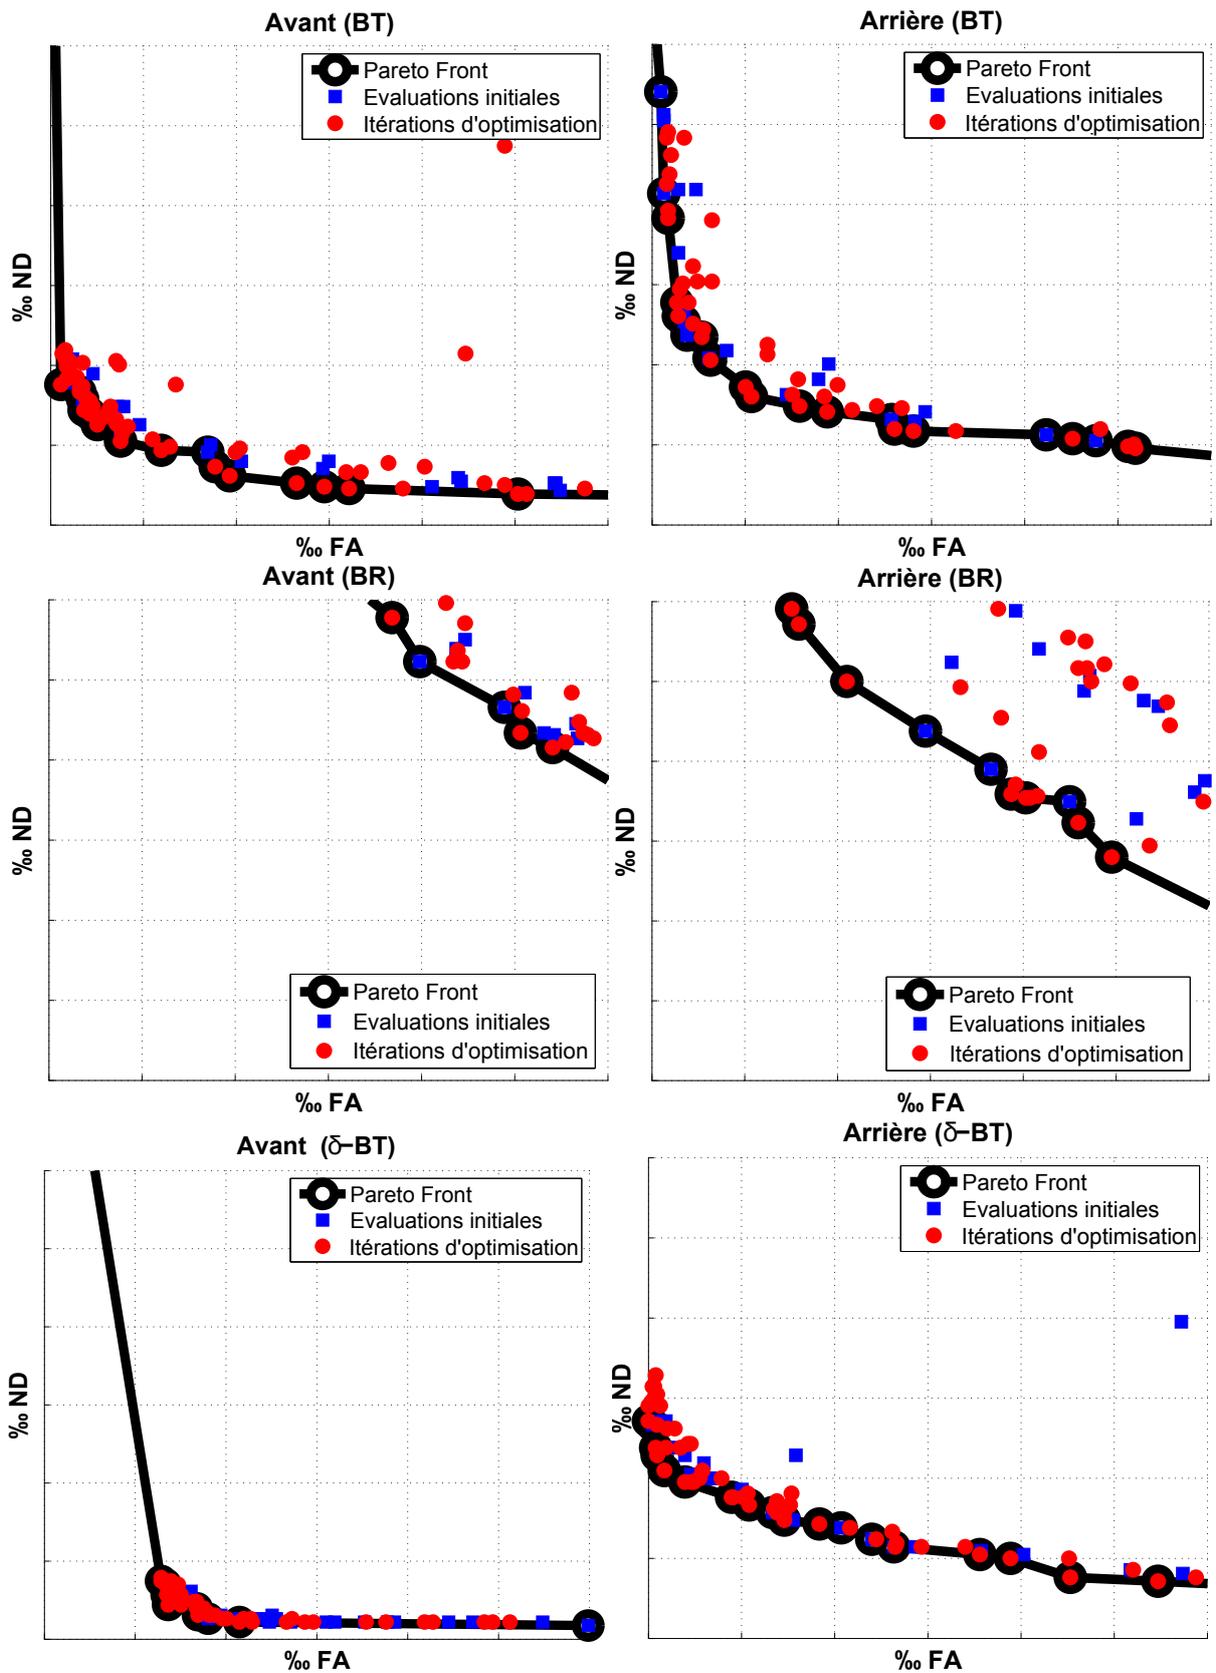


FIGURE 4.10: Résultats obtenus pendant l'optimisation du SDD. Les six figures sont représentées à la même échelle (valeurs non affichées pour des raisons de confidentialité).

4.5.3 Étape intermédiaire

Dans cette étape, aucune optimisation n'est faite. L'idée est de fixer les paramètres du SDC et SDD, pour ensuite lancer une pré-simulation du SDC et SDD sur toute la Bdd.

Choix des paramètres optimaux du SDC et du SDD

Une fois l'optimisation des systèmes de détection terminée, il faut choisir la configuration de paramètres optimale des 7 PF obtenus. La solution traditionnelle consiste à définir un compromis entre les FA et les ND, et ensuite, de choisir la configuration de paramètres de chaque PF qui respecte le plus ce compromis.

Partons de la supposition que le SDC et le SDD sont des systèmes de détection antagonistes, c'est-à-dire que le SDC détecte efficacement les crevaisons et le SDD les diffusions. En partant de cette idée, on a combiné toutes les configurations de paramètres des 7 PF entre elles, en regardant sur toute la Bdd, les critères %oFA et %oND. Dans un premier temps, on a trouvé les combinaisons minimisant les critères précédents en exigeant qu'au moins un des deux systèmes détecte le problème de sous-gonflage (SDC **ou** SDD). Un ensemble de solutions à 0 %oFA et 0 %oND a été obtenu. Ensuite, en utilisant ce dernier ensemble de solutions optimales, on a cherché les configurations de paramètres qui minimisent les mêmes critères mais en imposant que les deux systèmes détectent le problème de sous-gonflage (SDC **et** SDD). Finalement, à partir du PF obtenu avec les configurations (SDC **et** SDD), la meilleure configuration de paramètres a été choisie à travers un compromis entre %oFA et %oND. Ce poids a été défini arbitrairement en prenant en compte les exigences du projet SSPP.

Remarque 4.17 Pour définir si le SDD détecte ou pas un problème de pression, on a pris la valeur maximale entre les 6 parties du SDD ; c'est-à-dire que si une seule partie détecte un sous-gonflage, le SDD considère qu'il y a une chute de pression. Par conséquent, ce choix est très stricte par rapport à la robustesse du système car si une seule partie considère de manière erronée un sous-gonflage, on considère que le système SDD a fait une FA. ■

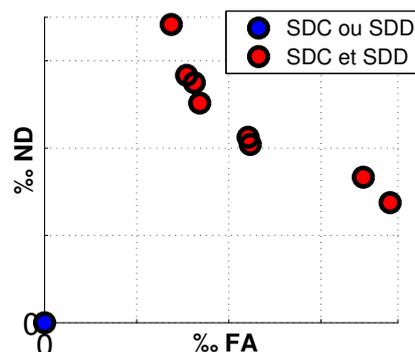


FIGURE 4.11: Résultat optimales obtenus en combinant toutes les PF des algorithmes de détection. Les valeurs ne sont pas affichées pour des raisons de confidentialité.

Pré-simulation du SDC et SDD

Une fois les configurations de paramètres du SDC et SDD fixées, on simule toute la Bdd avec les systèmes de détection afin d'enregistrer toutes ses sorties, dites *variables intermédiaires*. Cette tâche a été réalisée avec les deux ordinateurs disponibles, un pour la simulation du SDC et l'autre pour le SDD. En total, la *pré-simulation* (simulation et enregistrement des variables intermédiaires) a duré 3 semaines.

4.5.4 Mise au point de l'algorithme de décision

La mise au point de l'AdD consiste en la résolution d'un problème d'optimisation de 6 paramètres de réglage (voir Remarque 4.8) bi-objectif (minimisation du $\%oFA_{PV}$ et du $\%oND_{PV}$). Cette optimisation est faite une fois les paramètres des systèmes de détection fixés et les variables intermédiaires disponibles. Le temps d'évaluation de l'AdD en utilisant tous les CdU composant le plan de validation est d'environ 3 heures. Le nombre d'évaluations de l'AdD a été très limité à cause des exigences temporelles du projet (24 jours d'optimisation pour l'AdD) : 65 évaluations initiales plus 130 évaluations d'optimisation proposées par KEEP.

Les résultats obtenus après l'optimisation de l'AdD sont montrés Figure 4.12. On peut constater que KEEP a permis de trouver un PF très bien défini avec un nombre élevé de configurations de paramètres, ce qui nous permet de choisir les paramètres finaux pour adapter le compromis entre $\%oFA_{PV}$ et $\%oND_{PV}$ souhaité.

Remarque 4.18 *Une solution externe du SSPP indirecte (de la concurrence) a été proposée comme alternative du SSPP indirecte Renault. Les deux systèmes ont été comparés en utilisant le même plan de validation et les mêmes critères de performances ($\%oFA_{PV}$ et $\%oND_{PV}$).* ■

Remarque 4.19 *Bien que le plan de validation utilisé pour les deux SSPP indirects soit le même (solution Renault et solution externe), les deux systèmes sont "différents". La comparaison de performance finale entre les deux SSPP indirect sera utilisée pour justifier la viabilité du SSPP indirect Renault ; par contre, on ne pourra pas l'utiliser pour justifier la performance de l'optimisation du KEEP.* ■

Sur l'ensemble des solutions du PF, les configurations plus représentatives ont été comparées avec les résultats de la solution SSPP indirect externe (voir Figure 4.13). Les configuration de paramètres finales de chaque système sont des solutions non dominées entre elles car aucune est plus optimale (sur les deux critères) que les autres. Pour cette raison, on confirme que le SSPP indirect Renault et le SSPP indirect externe ont une performance très similaire et qu'aucun des deux n'est meilleur que l'autre.

Fonctionnement du SSPP indirect optimisé

Trois simulations faites sur des CdU de données réelles ont été réalisées avec la meilleure configuration de paramètres obtenue par la méthode KEEP (les CdU ont la même structure que dans le plan de validation). Les simulations (Figure 4.14) commencent par une phase d'apprentissage qui est suivie d'une phase de détection. Les probabilités de sous-gonflage de chaque roue sont représentées avec une couleur différente afin de montrer l'indépendance des estimations faites aux quatre roues (voir Remarque 4.7). L'objectif est de détecter l'existence d'un problème de pression avant le temps réglementaire (moins de 10 minutes après le sous-gonflage d'une seule roue ou 60 minutes si le sous-gonflage concerne plusieurs roues simultanément). Les résultats obtenus avec les exemples de simulation sont :

- **Simulation 1** : CdU d'analyse de robustesse (aucune roue sous-gonflée). Les probabilités finales obtenus avec les systèmes de détections ont des valeurs faibles, ce qui les systèmes de détection ne détectent pas un sous-gonflage.
- **Simulation 2** CdU de détection de crevaison (1 roue sous-gonflée). Le SDC est capable de détecter le problème correctement avant le temps réglementaire ; le SDD le détecte aussi mais trop tard.
- **Simulation 3** CdU de détection de diffusion (4 roues sous-gonflée). Le SDC n'arrive pas à détecter le problème de pression mais le SDD le détecte bien et dans le temps réglementaire.

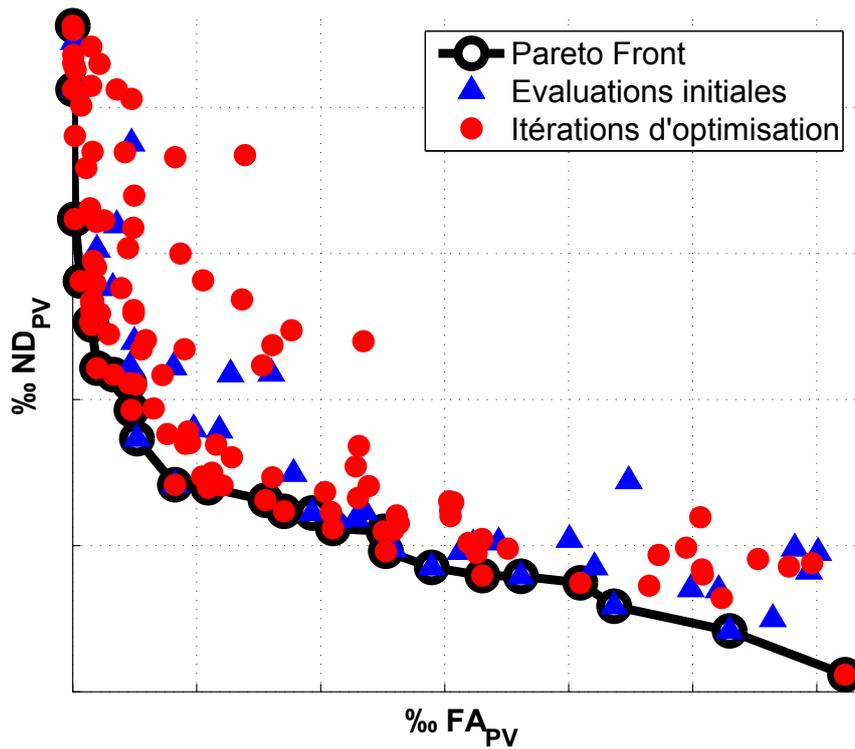


FIGURE 4.12: Résultats finaux de la mise au point du système SSPP indirect obtenus avec l'optimisation de l'AdD avec KEEP. Les valeurs de probabilité ne sont pas affichées pour des raisons de confidentialité.

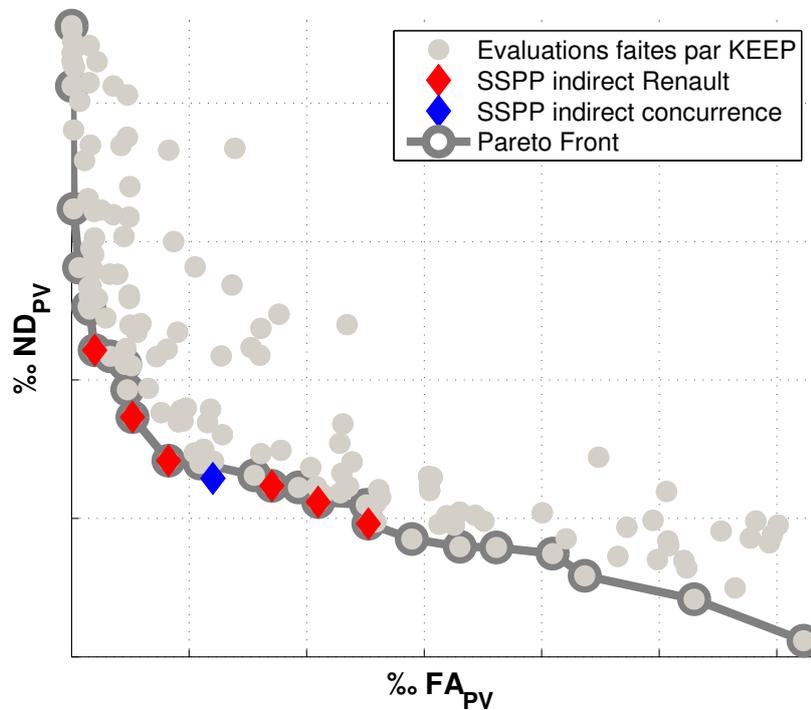


FIGURE 4.13: Résultats des configurations de paramètres proposées pour la solution SSPP indirect Renault. Avec des losanges rouges, les 6 configurations de paramètres finales proposées et la performance finale avec le système SSPP indirect Renault ; repérée par un losange bleu, la performance obtenue avec le SSPP indirect de la concurrence, dite solution externe. Les valeurs ne sont pas affichées pour des raisons de confidentialité.

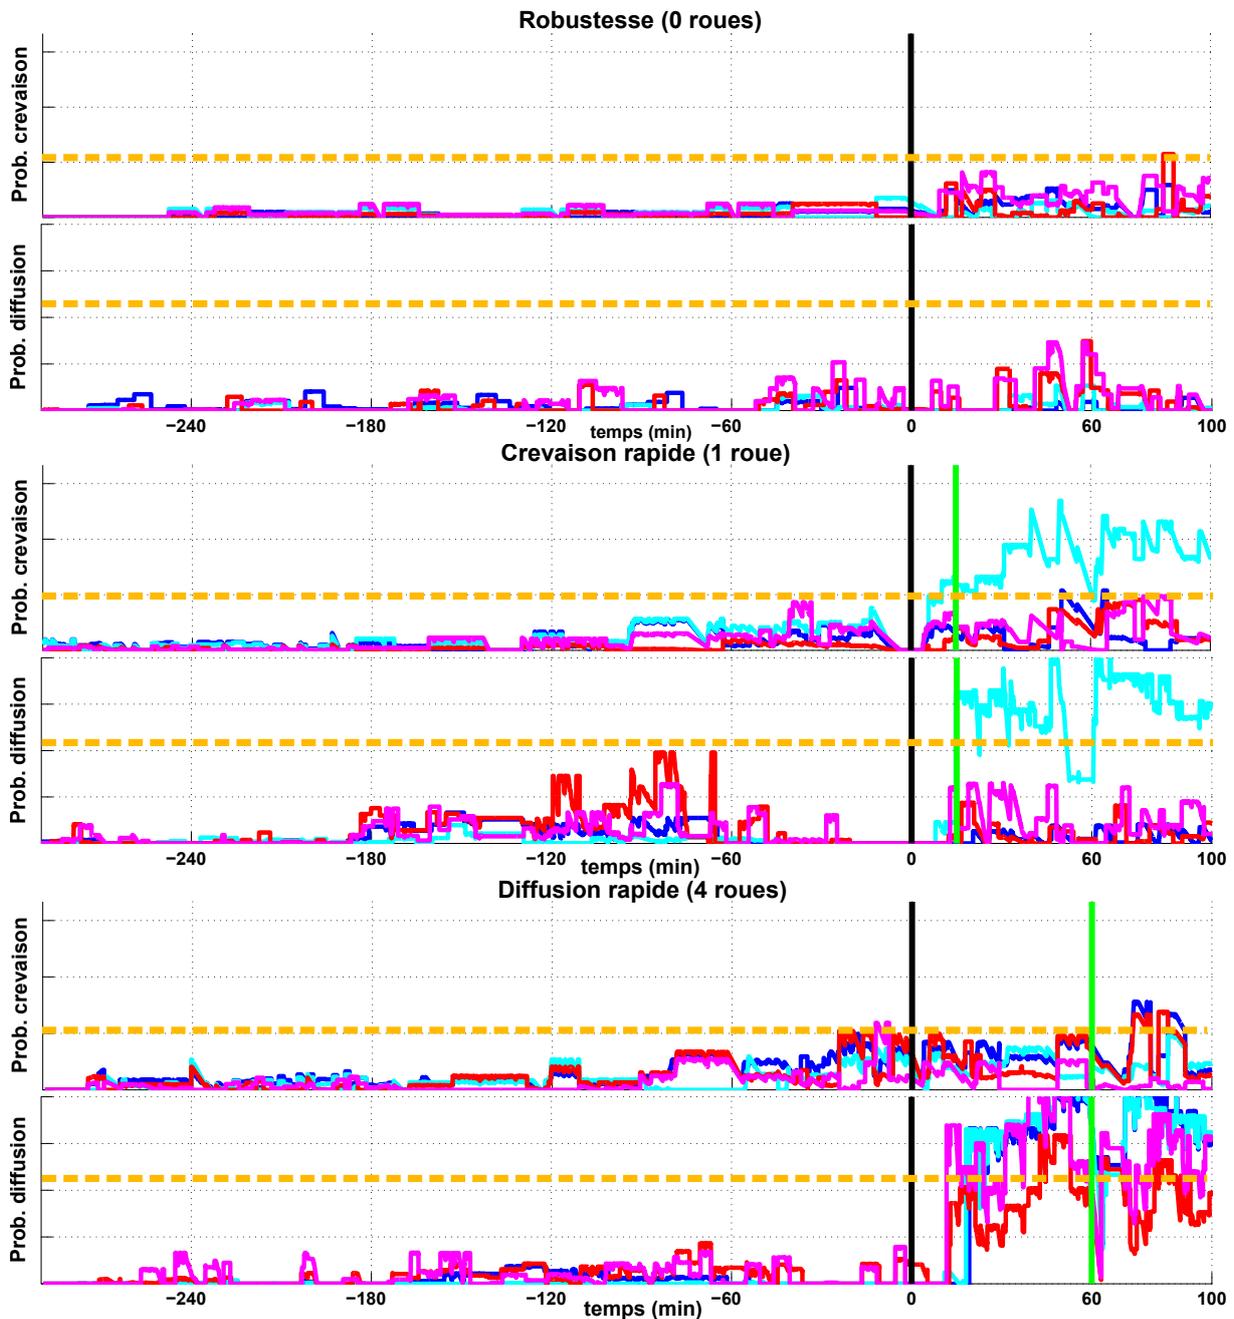


FIGURE 4.14: Exemples de résultats finaux obtenus par les CdU de robustesse, de crevaison rapide et de diffusion rapide. Les probabilités finales obtenues par les systèmes de détection : prob. crevaison (P_{SDD}^F) et prob. diffusion (P_{SDC}^F). Concrètement, les quatre fonctions représentent les probabilités estimées pour chaque roue (bleu, rouge, rose et bleu clair). En temps négatif, le roulage en phase d'apprentissage ; en positif, le roulage en phase de détection. La ligne verte représente le temps limite de détection imposé par la réglementation. La ligne orange représente le seuil de détection. Les valeurs de probabilité ne sont pas affichées pour des raisons de confidentialité.

4.6 Conclusion

Dans ce chapitre, une application réelle consistant en la mise au point d'un système d'aide à la conduite pour la surveillance des pressions des pneumatiques d'un véhicule automobile (SSPP indirect) a été présentée. Pour faire face à la complexité de ce système et tenir en compte de la grande base de données utilisée pour le réglage, une méthode d'optimisation globale multi-objectif dans le cas de fonctions coûteuses (KEEP) a été utilisée. Chaque partie du SSPP indirect présenté par Renault a été mise au point de manière indépendante. Ce découpage a permis de gagner du temps et de réaliser une optimisation dans le temps dédié.

Le premier système, le SDC, a permis de prouver que les optimisations faites par KEEP d'une part, et par un ingénieur spécialiste d'autre part, permettent d'atteindre des niveaux de performance comparables. Néanmoins, l'avantage de KEEP a été de réaliser l'optimisation sans avoir une connaissance du fonctionnement du SDC, et de fournir un ensemble de solutions optimales. Par rapport à la base de données utilisée, on a montré que l'utilisation d'une partie représentative est suffisante pour l'optimisation du SDC, qui est contraint d'avoir 12 paramètres à mettre au point en un temps très limité.

Le deuxième système, le SDD, a été optimisé en 6 sous-problèmes différents. On a constaté que KEEP a eu des difficultés à optimiser de manière efficace à cause de la faible variation de performance du système par rapport à la variation des paramètres (sensibilité). Pour la mise au point des futurs véhicules, on propose d'augmenter la gamme de chaque paramètre (diminuer et augmenter les valeurs minimales et maximales respectivement), ou d'ajouter de nouveaux paramètres afin de permettre à KEEP d'optimiser plus efficacement. De plus, il faut signaler que les performances obtenues par le mode vibratoire BR sont loin des performances des autres modes vibratoires.

Le troisième système, le AdD, a permis de comparer les performances obtenues par le SSPP indirect Renault et par une solution de la concurrence, en utilisant le même plan de validation. Les performances obtenues par les deux systèmes sont très similaires ; néanmoins, l'optimisation avec KEEP permet au SSPP indirect Renault de choisir un compromis entre le taux de fausses alertes et le taux de non-détections *a posteriori*, sans avoir à relancer le processus d'optimisation.

On peut signaler qu'il a été possible de finaliser l'optimisation dans les 3 mois (délai imposé) : 1 mois pour l'optimisation du SDC et SDD, 1 mois pour la pré-simulation et 1 mois pour l'optimisation de l'AdD.



Observateurs pour les systèmes d'aide à la conduite

Introduction aux observateurs

Sommaire

5.1	Notations et notions mathématiques	81
5.2	Observateurs pour systèmes linéaires	82
5.2.1	Observateur de Luenberger	83
5.2.2	Observateur de Kalman	83
5.2.3	Observateur dans une boucle de commande	84
5.3	Observation des systèmes non linéaires	85
5.3.1	Forme canonique d'observabilité et synthèse d'observateurs	86
5.3.2	Observateurs à grand gain	89
5.3.3	Observateurs par mode glissant	90
5.4	Conclusion	92

L'objectif de ce chapitre est de présenter et de classer les différents techniques d'analyse d'observabilité de systèmes et de synthèse d'observateurs, en particulier pour les systèmes non linéaires. Dans une première partie, les notions et notations mathématiques utilisées dans le chapitre sont introduites. La deuxième partie décrit brièvement quelques observateurs de systèmes linéaires, après avoir énoncé le critère d'observabilité de tels systèmes. Des solutions standards, celles que l'observateur de Kalman et l'observateur de Luenberger, sont présentées. Le principe de séparation est aussi introduit afin de voir l'interaction entre la commande et l'observation. La troisième partie se focalise sur les observateurs non linéaires. Des concepts indispensables pour l'analyse de l'observabilité de tels systèmes sont introduits : observabilité locale, espace d'observabilité générique, forme canonique d'observabilité. Ensuite, deux techniques d'observation utilisées dans la suite de la thèse sont détaillées : l'observateur à grands gains et l'observateur par mode glissant.

5.1 Notations et notions mathématiques

Pour tout système à observer (linéaire et non linéaire), les variables sont notées comme décrit ci-dessous

- l'état $\mathbf{x} \in \mathcal{X} \subset \mathbb{R}^n$ avec $n \in \mathbb{N}$ le nombre de variables d'état ($\mathbf{x} = [x_1 \ x_2 \ \dots \ x_n]^T$) et \mathcal{X} l'espace opérationnel du système ;
- la sortie de mesure $\mathbf{y} \in \mathbb{R}^m$ avec $m \in \mathbb{N}$ le nombre de variables de sortie ($\mathbf{y} = [y_1 \ y_2 \ \dots \ y_m]^T$) ;
- et l'entrée de commande $\mathbf{u} \in \mathcal{U} \subset \mathbb{R}^p$ avec $p \in \mathbb{N}$ le nombre de variables d'entrée ($\mathbf{u} = [u_1 \ u_2 \ \dots \ u_p]^T$) et \mathcal{U} l'espace opérationnel de la commande.

Cette section rappelle quelques bases et principes mathématiques utilisés dans la suite du manuscrit.

Fonctions Lipschitziennes

Définition 5.1 Une fonction f est dite "lipschitzienne" par rapport à x si $\forall x_A \in \mathcal{X}$ et $\forall x_B \in \mathcal{X}$, $\exists \beta > 0$ tel que

$$\|f(x_A, t) - f(x_B, t)\| \leq \beta \|x_A - x_B\| \quad (5.1)$$

■

Dérivée de Lie

La dérivée de Lie sera utilisée dans le calcul de la condition de rang de la matrice d'observabilité afin de vérifier l'observabilité d'un système non linéaire.

Définition 5.2 La "dérivée de Lie" d'une fonction $h(x)$ le long d'un vecteur $f(x)$ est définie par

$$\mathcal{L}_f h(x) = \sum_{i=1}^n \frac{\partial h}{\partial x_i} f_i(x) \quad (5.2)$$

■

Définition 5.3 La "dérivée de Lie" d'une fonction $h(x)$ dérivée d fois le long d'un vecteur $f(x)$ est définie comme

$$\mathcal{L}_f^d h(x) = \frac{\partial \mathcal{L}_f^{d-1} h}{\partial x_i} f_i(x) \quad (5.3)$$

■

5.2 Observateurs pour systèmes linéaires

Considérons le système linéaire défini par

$$\begin{aligned} \dot{x}(t) &= Ax(t) + Bu(t) \\ y(t) &= Cx(t) \end{aligned} \quad (5.4)$$

En considérant comme seules informations connues y et u , l'estimation ou "observation" de l'état x sera possible si le système 5.4 satisfait la condition d'observabilité.

Définition 5.4 [Kalman, 1963] Un système est dit "observable" s'il existe un instant initial t_0 et un instant fini t_1 tels que la connaissance de $u(t_0, t_1)$ et $y(t_0, t_1)$ permettent de trouver un unique état initial ($x_0 = x(t_0)$). ■

La propriété d'observabilité est donc celle consistant à être capable d'estimer l'état à l'instant initial, à partir de mesures et d'entrées.

Définition 5.5 [Kalman, 1963] On dit que deux états initiaux $x_A(t_0)$ et $x_B(t_0)$ d'un système sont indistinguables (ou indiscernables) si les sorties $y_A(t)$ et $y_B(t)$ du système sont identiques $\forall t \geq t_0$ pour n'importe quelle valeur d'entrée du système. ■

L'indistinguabilité est une relation d'équivalence sur l'espace d'état : en notant $I(x_0)$ la classe d'équivalence d'un état x_0 quelconque, alors, le système linéaire (5.4) est observable si $I(x) = \{x\} \forall x \in \mathcal{X}$.

Pour tester l'observabilité d'un système linéaire, la condition du rang d'observabilité est introduite.

Définition 5.6 [Kalman, 1963] *Étant donné le système (5.4), définissons la matrice O telle que*

$$O = \begin{bmatrix} C \\ CA \\ \vdots \\ CA^{n-1} \end{bmatrix} \quad (5.5)$$

Le système linéaire (5.4) est dit "observable" si et seulement si le rang de la matrice O est égal au nombre de variables d'état n , c'est-à-dire

$$\text{Rang}[O] = n \quad (5.6)$$

La matrice O est appelée "matrice d'observabilité". ■

Remarque 5.1 *Notons que l'observabilité des systèmes linéaires ne dépend pas de l'entrée du système. Par contre, comme cela sera vu dans la suite, cela n'est pas vrai pour les systèmes non linéaires.* ■

5.2.1 Observateur de Luenberger [Luenberger, 1964] [Luenberger, 1966]

L'observateur de Luenberger, introduit dans les années 60, a été une des premières solutions qui permettait d'estimer les variables d'état non mesurables d'un système, afin de les utiliser dans une boucle de commande. Luenberger a proposé un observateur composé d'une copie de la dynamique du système linéaire à observer (5.4) et d'un terme correcteur ne dépendant que de l'erreur de mesure. La valeur initiale de l'état estimé \hat{x} peut être éloignée de la valeur réelle ; néanmoins, le terme correcteur permet de forcer \hat{x} à converger exponentiellement vers l'état réel du système x . L'observateur de Luenberger pour le système (5.4) s'écrit

$$\dot{\hat{x}} = A\hat{x} + Bu + L(y - C\hat{x}) \quad (5.7)$$

avec $L \in \mathbb{R}^{n \times m}$ la matrice de gains de l'observateur. En définissant l'erreur d'estimation entre l'état réel et l'état estimé $e = x - \hat{x}$, la dynamique de l'erreur est définie comme

$$\dot{e} = (A - LC)e. \quad (5.8)$$

Afin de garantir la convergence de l'observateur ($e \mapsto 0$), le terme $(A - LC)$ doit être impérativement Hurwitz¹. Le choix des gains de la matrice L permet d'ajuster la dynamique de l'erreur d'estimation.

Cette solution est classifiée comme étant déterministe car elle utilise une copie *exacte* de la dynamique du système ; elle n'est pas forcément très adaptée pour prendre en compte les bruits de mesure ou les perturbations agissant sur le système. Néanmoins, l'observateur de Luenberger est caractérisé par une synthèse simple et un réglage aisé, ce qui le rend intéressant.

5.2.2 Observateur de Kalman [Kalman, 1960]

Introduit également dans les années 60, l'observateur de Kalman est une des solutions les plus utilisées, que ce soit pour résoudre des problèmes d'automatique ou de traitement du signal [Doraiswami et al., 2014]. On considère le système linéaire (5.4) avec $w(t)$ un bruit du système ou d'évolution, qui peut être vu comme une perturbation, et $v(t)$ un bruit de mesure

$$\begin{aligned} \dot{x}(t) &= Ax(t) + Bu(t) + Gw(t) \\ y(t) &= Cx(t) + v(t) \end{aligned} \quad (5.9)$$

¹Les valeurs propres de la matrice $(A - LC)$ doivent être placées dans le demi-plan complexe gauche (partie réelle négative)

Plus concrètement, $w(t)$ et $v(t)$ sont définis comme des signaux aléatoires, gaussiens et indépendants qui agissent comme des perturbations additives sur la dynamique du système et la mesure respectivement. À partir des statistiques de $w(t)$ et $v(t)$, on déduit les matrices de covariance des bruits du système Q et de la mesure R définies par

$$E(w(t)) = E(v(t)) = 0, \quad Q = E(w(t)w(t)^T) \text{ et } R = E(v(t)v(t)^T) \quad (5.10)$$

L'observateur de Kalman pour le système (5.9) a une structure similaire à celle de l'observateur de Luenberger

$$\dot{\hat{x}} = A\hat{x} + Bu + \underbrace{L(y - C\hat{x})}_{\text{terme correcteur}} \quad (5.11)$$

en désignant par L la matrice des gains de l'observateur. Cette matrice est calculée à partir de la matrice de covariance de l'erreur d'état P par rapport x définie par

$$P = E((x - \hat{x})(x - \hat{x})^T) \quad (5.12)$$

En utilisant (5.9)-(5.11), la dérivée de P est calculée

$$\begin{aligned} \dot{P} &= E[(\dot{x} - \dot{\hat{x}})(\dot{x} - \dot{\hat{x}})^T], \\ &= E[(Ax + Gw - (A\hat{x} + L(Cx + v - C\hat{x}))(Ax + Gw - (A\hat{x} + L(Cx + v - C\hat{x})))^T], \quad (5.13) \\ &= E[(A(x - \hat{x}) + Gw - LC(x - \hat{x}) - Lv)(A(x - \hat{x}) + Gw - LC(x - \hat{x}) - Lv)^T]. \end{aligned}$$

Cette expression est simplifiée à partir de (5.10) et (5.12)

$$\dot{P} = (A + LC)P + P(A + LC)^T + GQG^T + LRL^T \quad (5.14)$$

En minimisant la norme de la matrice de covariance de l'erreur d'état, la matrice des gains de l'observateur optimal est définie par

$$L = PC^T R^{-1} \quad (5.15)$$

En général, afin de réaliser les calculs précédents, les matrices Q et R sont définies à partir de la quantification empirique des perturbations $w(t)$ et $v(t)$ grâce à des enregistrements réels. Le grand succès de cette méthode d'observation du type stochastique réside dans sa très bonne estimation et sa robustesse face aux bruits de mesure et aux perturbations.

5.2.3 Observateur dans une boucle de commande

Le rôle d'un observateur est d'estimer l'état réel d'un système (état réel qui n'est souvent pas totalement disponible) afin d'utiliser l'état estimé dans une loi de commande. Le lien entre la commande et l'observateur est très fort car la performance du contrôleur dépend directement de la qualité de l'estimation de l'observateur. En effet, le calcul de la commande est fait à partir de la valeur estimée par l'observateur. Supposons le système bouclé avec une commande par retour d'état statique ($u = K\hat{x}$). Le système à commander est représenté par le modèle linéaire (5.4); les équations du système et de l'observateur s'écrivent donc

$$\begin{cases} \dot{x} = Ax + Bu \\ \dot{\hat{x}} = A\hat{x} + Bu + L(y - C\hat{x}) \end{cases} \implies \begin{cases} \dot{x} = Ax + BK\hat{x} \\ \dot{\hat{x}} = LCx + (A - LC + BK)\hat{x} \end{cases} \quad (5.16)$$

En réalisant le changement de variables ($\hat{x} \mapsto e = x - \hat{x}$), les équations de l'ensemble système-observateur (5.16) se ré-écrivent

$$\begin{cases} \dot{x} = Ax + BKx - BK(x - \hat{x}) \\ \dot{e} = (A - LC)(x - \hat{x}) \end{cases} \quad (5.17)$$

Ce système peut être écrit sous forme matricielle

$$\begin{bmatrix} \dot{\mathbf{x}} \\ \dot{\mathbf{e}} \end{bmatrix} = \begin{bmatrix} A + BK & -BK \\ 0 & A - LC \end{bmatrix} \begin{bmatrix} \mathbf{x} \\ \mathbf{e} \end{bmatrix} \quad (5.18)$$

Pour garantir la stabilité du système bouclé, il suffit donc de vérifier *indépendamment* la stabilité de l'observateur à travers la matrice $(A - LC)$ d'une part, et la stabilité de la commande à travers la matrice $(A - BK)$ d'autre part. Cette propriété permet de proposer les solutions d'observation et de commande de manière indépendante, cela étant connu comme le *principe de séparation*.

Remarque 5.2 *La stabilité du système en boucle fermée avec commande et observateur nécessite une attention particulière dans le cas des systèmes non linéaires. En effet, un observateur assurant une convergence de l'erreur d'estimation vers zéro d'une part, et une loi de commande assurant la stabilisation du système autour d'un point d'équilibre d'autre part, n'impliquent pas forcément que le couple commande-observateur stabilise le système [Kokotovic, 1992]. Il est donc nécessaire de faire une analyse spécifique de la stabilité du système avec commande et observateur.*

Remarque 5.3 *Au delà de la conception de la loi de commande et de l'observateur, toute solution se doit d'assurer la robustesse du système bouclé face aux variations paramétriques, aux perturbations et aux bruits de mesure.* ■

Remarque 5.4 *Le but principal de ce travail étant de présenter différentes techniques d'observation, la stabilité du système en boucle fermée et le choix du type de lois de commande [Kokotovic, 1992] ne seront pas abordés dans cette thèse.* ■

5.3 Observation des systèmes non linéaires

Considérons le système non linéaire

$$\begin{aligned} \dot{\mathbf{x}}(t) &= \mathbf{f}(\mathbf{x}, \mathbf{u}, t) \\ \mathbf{y}(t) &= \mathbf{h}(\mathbf{x}, t) \end{aligned} \quad (5.19)$$

Le concept d'observabilité vu pour les systèmes linéaires est généralisé à cette classe de systèmes plus large ; les concepts d'observabilité locale et un critère algébrique de rang sont introduits. De plus, des solutions pour la synthèse d'observateurs sont également présentées, tant comme les concepts d'observabilité locale générique.

Définition 5.7 [Hermann et Krener, 1977] *Considérons deux états initiaux $\mathbf{x}_A(t_0)$ et $\mathbf{x}_B(t_0)$ dans un sous-ensemble U de \mathcal{X} . Ils sont appelés "U-distinguables" si les sorties $\mathbf{y}_A(t)$ et $\mathbf{y}_B(t)$ sont identiques $\forall t \geq t_0$ pour n'importe quelle valeur d'entrée du système et si les trajectoires de \mathbf{x}_A et \mathbf{x}_B sont dans U .* ■

Notons $I_U(x_0)$ l'ensemble d'états indistinguables dans un voisinage U de x_0 quelconque.

Définition 5.8 [Hermann et Krener, 1977] *En considérant U un voisinage ouvert d'un état \mathbf{x}_0 quelconque tel que $I_U(\mathbf{x}_0) = \{\mathbf{x}_0\}$, on dit que le système non linéaire (5.19) est "localement observable" si $I_U(\mathbf{x}) = \{\mathbf{x}\} \forall \mathbf{x} \in \mathcal{X}$ et $\forall \mathbf{u} \in \mathcal{U}$.* ■

Remarque 5.5 *Dans la suite du manuscrit, un système "localement observable" sera dit, avec abus de langage, "observable".* ■

Soit le vecteur $\Theta_{k_i}^{h_i}$, avec $h_i(\mathbf{x}, \mathbf{u}, \dot{\mathbf{u}}, \dots)$ la i -ème composante du vecteur $\mathbf{h}(\mathbf{x}, t)$, et $\Theta_{k_i}^{h_i}$ étant formé de la sortie y_i et d'un nombre fini $(k_i - 1)$ de ses dérivées, c'est-à-dire

$$\Theta_{k_i}^{h_i} = \begin{bmatrix} y_i \\ \dot{y}_i \\ \vdots \\ y_i^{(k_i-1)} \end{bmatrix}_{(k_i \times 1)} = \begin{bmatrix} h_i \\ \mathcal{L}_f h_i(\mathbf{x}) \\ \vdots \\ \mathcal{L}_f^{k_i-1} h_i(\mathbf{x}) \end{bmatrix}_{(k_i \times 1)} \quad (5.20)$$

en notant $v^{(d)}$ la d -ième dérivée temporelle d'une fonction v . On définit le vecteur Γ (avec $\sum_{i=1}^m k_i = n$) par

$$\Gamma = \begin{bmatrix} \Theta_{k_1}^{h_i} \\ \Theta_{k_2}^{h_i} \\ \vdots \\ \Theta_{k_m}^{h_i} \end{bmatrix} \quad (5.21)$$

Définition 5.9 Le système (5.19) est dite observable $\forall \mathbf{x} \in \mathcal{X}$ et $\forall \mathbf{u} \in \mathcal{U}$, si le rang du jacobien (5.21) de Γ est égal à la dimension d'état "n", i.e

$$\text{Rang} \left[\frac{\partial \Gamma}{\partial \mathbf{x}} \right]_{(n \times n)} = n \quad (5.22)$$

■

De manière équivalente, le système (5.19) est observable si le déterminant du jacobien de Γ est différent de 0, i.e

$$\det \left[\frac{\partial \Gamma(\mathbf{x})}{\partial \mathbf{x}} \right]_{(n \times n)} \neq 0 \quad (5.23)$$

Remarque 5.6 Notons que ces dernières conditions montrent que l'observabilité dépend de l'état \mathbf{x} et de l'entrée \mathbf{u} . ■

5.3.1 Forme canonique d'observabilité et synthèse d'observateurs

En se basant sur la forme de la dynamique latérale du véhicule utilisée dans la suite du manuscrit (Chapitre 6), considérons la classe de systèmes non linéaires suivante

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}, t) + \chi(\mathbf{u}, \mathbf{y}) + \Delta f(\mathbf{x}, t) \\ \mathbf{y} = \mathbf{h}(\mathbf{x}) \end{cases} \quad (5.24)$$

La dynamique de l'état est définie par le terme $\mathbf{f}(\mathbf{x}, t)$ qui ne dépend que de l'état et de paramètres variants dans le temps; $\chi(\mathbf{u}, \mathbf{y})$ ne dépend que de la sortie et de l'entrée, c'est-à-dire de grandeurs connues. Enfin, le terme d'incertitudes $\Delta f(\mathbf{x}, t)$ représente les dynamiques inconnues du système.

Forme canonique d'observabilité

Pour la représentation du système (5.24) en forme canonique, les hypothèses suivantes sont posées

Hypothèse 5.1 Le système (5.24) est observable. ■

L'Hypothèse 5.1 implique que le vecteur Γ défini par (5.21) soit une transformation de coordonnées d'état du système (5.24).

Remarque 5.7 [Krener et Respondek, 1985] Les m entiers $[k_1 \ k_2 \ \dots \ k_m]$ de Γ (5.21) sont appelés "indices d'observabilité". ■

Hypothèse 5.2 Le terme d'incertitudes $\Delta f(\mathbf{x}, t)$ est borné, i.e $\|\Delta f(\mathbf{x}, t)\| \leq F$ et $F < \infty$ tel que $\forall t \geq 0$ soit suffisamment dérivable. De plus, $\Delta f(\mathbf{x}, t)$ ne modifie pas l'observabilité du système (5.24). ■

L'hypothèse 5.2 permet donc de faire la synthèse de l'observateur en supposant le terme d'incertitudes nul ($\Delta f(\mathbf{x}, t) = 0$). D'un point de vue pratique, cette hypothèse n'est pas gênante car la dynamique introduite par les incertitudes est généralement beaucoup plus faible que la valeur de l'état. On considère donc le système (avec un abus de notation)

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}, t) + \chi(\mathbf{u}, \mathbf{y}) \\ \mathbf{y} = \mathbf{h}(\mathbf{x}) \end{cases} \quad (5.25)$$

Pour simplifier la synthèse de l'observateur, le terme $\chi(\mathbf{u}, \mathbf{y})$ entièrement connu peut être supprimé de la dynamique du système grâce à l'utilisation d'une *injection d'entrée-sortie* $-\chi(\mathbf{u}, \mathbf{y})$ [Plestan, 1997] [Lebastard et al., 2011].

Hypothèse 5.3 La fonction "injection d'entrée-sortie" $-\chi(\mathbf{u}, \mathbf{y})$ ne modifie pas l'observabilité du système (5.24). ■

D'un point de vue pratique, cette hypothèse est valable car le terme $\chi(\mathbf{u}, \mathbf{y})$ est bien connu et peut être séparé de la synthèse de l'observateur. Aussi, à partir de l'Hypothèse 5.3, en ajoutant le terme $-\chi(\mathbf{u}, \mathbf{y})$ au système (5.25), ce dernier s'écrit sous la forme suivante (avec abus de notation)

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}, t) \\ \mathbf{y} = \mathbf{h}(\mathbf{x}) \end{cases} \quad (5.26)$$

où $\mathbf{f}(\mathbf{x}, t) = [f_1(\mathbf{x}, t) \ f_2(\mathbf{x}, t) \ \dots \ f_n(\mathbf{x}, t)]^T$ et $\mathbf{h}(\mathbf{x}) = [h_1(\mathbf{x}) \ h_2(\mathbf{x}) \ \dots \ h_m(\mathbf{x})]^T$.

Alors, en utilisant le difféomorphisme $\zeta = \Gamma(\mathbf{x})$, un système localement équivalent au système (5.26) s'écrit sous la forme

$$\begin{cases} \dot{\zeta} = A_\zeta \zeta + \Phi_\zeta(\zeta) \\ \mathbf{y} = C_\zeta \zeta \end{cases} \quad (5.27)$$

où les matrices A_ζ , C_ζ et le vecteur $\Phi_\zeta(\zeta)$ sont définis par

$$A_\zeta = \begin{bmatrix} A_1 (k_1 \times k_1) & \mathbf{0}_{(k_1 \times k_2)} & \cdots & \mathbf{0}_{(k_1 \times k_m)} \\ \mathbf{0}_{(k_2 \times k_1)} & A_2 (k_2 \times k_2) & \cdots & \mathbf{0}_{(k_2 \times k_m)} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0}_{(k_m \times k_1)} & \mathbf{0}_{(k_m \times k_2)} & \cdots & A_m (k_m \times k_m) \end{bmatrix}_{(n \times n)} \quad \text{avec } A_i (k_i \times k_i) = \begin{bmatrix} 0 & 1 & \cdots & 0 \\ 0 & 0 & \ddots & \vdots \\ \vdots & \vdots & \ddots & 1 \\ 0 & 0 & \cdots & 0 \end{bmatrix},$$

$$C_\zeta = \begin{bmatrix} C_1 (1 \times k_1) & \mathbf{0}_{(1 \times k_2)} & \cdots & \mathbf{0}_{(1 \times k_m)} \\ \mathbf{0}_{(1 \times k_1)} & C_2 (1 \times k_2) & \cdots & \mathbf{0}_{(1 \times k_m)} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0}_{(1 \times k_1)} & \mathbf{0}_{(1 \times k_2)} & \cdots & C_m (1 \times k_m) \end{bmatrix}_{(m \times n)} \quad \text{avec } C_i (1 \times k_i) = [1 \ 0 \ \cdots \ 0],$$

$$\Phi_\zeta(\zeta) = \begin{bmatrix} \Phi_1(\zeta)_{(k_1 \times 1)} \\ \Phi_2(\zeta)_{(k_2 \times 1)} \\ \vdots \\ \Phi_m(\zeta)_{(k_m \times 1)} \end{bmatrix}_{(n \times 1)} \quad \text{avec } \Phi_i(\zeta)_{(k_i \times 1)} = \begin{bmatrix} 0 \\ \vdots \\ 0 \\ \phi_i(\zeta) \end{bmatrix},$$

en désignant par $\mathbf{0}_{(k_A \times k_B)}$ une matrice de zéros de taille $(k_A \times k_B)$ et $\phi_i(\zeta)$ la fonction $\mathcal{L}_f^{k_i} h_i(\mathbf{x})$ exprimé en ζ . On suppose que le terme $\Phi_\zeta(\zeta)$ peut être exprimé sous la forme d'une somme d'un terme nominal $\Phi_{N\zeta}(\zeta)$ et d'un terme incertain $\Delta\Phi_\zeta(\zeta)$, c'est-à-dire

$$\Phi_\zeta(\zeta) = \Phi_{N\zeta}(\zeta) + \Delta\Phi_\zeta(\zeta), \quad (5.29)$$

$$\Phi_{N\zeta}(\zeta) = \begin{bmatrix} \Phi_{N1}(\zeta)_{(k_1 \times 1)} \\ \Phi_{N2}(\zeta)_{(k_2 \times 1)} \\ \vdots \\ \Phi_{Nm}(\zeta)_{(k_m \times 1)} \end{bmatrix}_{(n \times 1)} \quad \text{avec} \quad \Phi_{Ni}(\zeta)_{(k_i \times 1)} = \begin{bmatrix} 0 \\ \vdots \\ 0 \\ \phi_{Ni}(\zeta) \end{bmatrix},$$

$$\text{et} \quad \Delta\Phi_\zeta(\zeta) = \begin{bmatrix} \Delta\Phi_1(\zeta)_{(k_1 \times 1)} \\ \Delta\Phi_2(\zeta)_{(k_2 \times 1)} \\ \vdots \\ \Delta\Phi_m(\zeta)_{(k_m \times 1)} \end{bmatrix}_{(n \times 1)} \quad \text{avec} \quad \Delta\Phi_i(\zeta)_{(k_i \times 1)} = \begin{bmatrix} 0 \\ \vdots \\ 0 \\ \Delta\phi_i(\zeta) \end{bmatrix}.$$

La représentation du système (5.26) sous la forme (5.27) est appelée *forme canonique d'observabilité*.

Synthèse d'observateurs

La forme canonique d'observabilité précédente peut être utilisée comme base pour la synthèse d'observateurs. Considérons le système suivant

$$\dot{\hat{\zeta}} = A_\zeta \hat{\zeta} + \Phi_{N\zeta}(\hat{\zeta}) + \kappa(y, \hat{\zeta}) \quad (5.30)$$

Définition 5.10 *Le système (5.30) est un observateur de (5.27) si $\hat{\zeta} \rightarrow \zeta$. Le terme $\kappa(y, \hat{\zeta})$ est appelé "terme de correction".* ■

Il y a plusieurs méthodes pour définir le terme de correction, selon les propriétés désirées comme le temps de convergence, la précision ou la robustesse.

Remarque 5.8 *Notons que la fonction $\kappa(\cdot)$ doit être choisie en tenant en compte du fait que le terme d'incertitudes Δf (5.24) dans l'espace des \mathbf{x} n'apparaît pas dans l'observateur (ce qui est évident comme celui-ci est inconnu); $\kappa(\cdot)$ doit donc rendre l'estimation de l'état robuste.* ■

Considérons que l'estimation de l'observateur dans l'espace des ζ est définie comme $\hat{\zeta} = \Gamma(\hat{\mathbf{x}})$; alors

$$\hat{\mathbf{x}} = \left[\frac{\partial \Gamma}{\partial \hat{\mathbf{x}}} \right]^{-1} \hat{\zeta} \quad (5.31)$$

Selon [Lebastard et al., 2011], un observateur du système (5.26) peut être défini comme

$$\dot{\hat{\mathbf{x}}} = f(\hat{\mathbf{x}}, t) + \left[\frac{\partial \Gamma}{\partial \hat{\mathbf{x}}} \right]^{-1} \kappa(\mathbf{y}, \hat{\mathbf{x}}) \quad (5.32)$$

En appliquant l'injection d'entrée-sortie $\chi(u, \mathbf{y})$ à l'observateur précédent, on obtient

$$\dot{\hat{\mathbf{x}}} = f(\hat{\mathbf{x}}, t) + \chi(u, \mathbf{y}) + \left[\frac{\partial \Gamma}{\partial \hat{\mathbf{x}}} \right]^{-1} \kappa(\mathbf{y}, \hat{\mathbf{x}}). \quad (5.33)$$

Notons que l'observateur (5.33) est alors composé d'une *copie* de la dynamique du système à laquelle s'ajoute un terme de correction, qui dépend du type d'observateur. Le choix de $\kappa(\mathbf{y}, \hat{\mathbf{x}})$ doit être fait de façon à obtenir un observateur (5.33) garantissant que $\hat{\mathbf{x}}$ converge vers \mathbf{x} (ou au moins, dans un voisinage) malgré le terme d'incertitude Δf .

Dans la suite du chapitre, seuls les observateurs à *grand gain* et les observateurs par *mode glissant* d'ordre supérieur seront présentés car il s'agit des solutions appliquées dans les prochains chapitres.

5.3.2 Observateurs à grand gain [Gauthier et al., 1992]

L'idée principale des observateurs à grand gain est d'avoir un terme de correction prédominant devant les non-linéarités du système afin de garantir une décroissance exponentielle de la norme de l'erreur d'estimation. Ils ont été introduits par [Gauthier et al., 1992] [Bornard et Hammouri, 1991] où des conditions nécessaires d'existence de ces observateurs sont données, en se basant sur la notion d'observabilité uniforme [Gauthier et Bornard, 1981]. Par la suite, [Esfandiari et Khalil, 1992] complètent les travaux précédents en présentant quel-ques limitations des observateurs à grands gains, comme l'impact des non-linéarités sur le temps de convergence et la déstabilisation de l'observation si l'observateur est utilisé dans un système bouclé (des valeurs de gains trop élevées font que le terme de correction est plus rapide que la dynamique de la variable d'état). Un autre inconvénient est qu'ils sont peu robustes faces aux erreurs de modélisation et aux perturbations du système.

Néanmoins, les observateurs à grands gains sont une solution applicable à une très large classe de systèmes réels, comme par exemple dans la chimie [Gauthier et al., 1992], l'électrotechnique [Marques, 1993], la robotique [Lee et Khalil, 1997], et l'industrie automobile [Said et al., 2011].

Structure. Considérons la forme canonique (5.27) définie à partir du système non linéaire (5.24). Un observateur à grand gain sous la forme (5.33) est défini via le terme de correction comme

$$\kappa(\mathbf{y}, \hat{\mathbf{x}}) = \Lambda^T K (\mathbf{y} - C_\zeta \hat{\mathbf{x}}) \quad (5.34)$$

avec les matrices de gain de l'observateur suivantes

$$K = \begin{bmatrix} K_1 (k_1 \times 1) & \mathbf{0} (k_1 \times 1) & \cdots & \mathbf{0} (k_1 \times 1) \\ \mathbf{0} (k_2 \times 1) & K_2 (k_2 \times 1) & \cdots & \mathbf{0} (k_2 \times 1) \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} (k_m \times 1) & \mathbf{0} (k_m \times 1) & \cdots & K_m (k_m \times 1) \end{bmatrix}_{(n \times n)} \quad \text{avec } K_i (k_i \times 1) = \begin{bmatrix} K_{i1} \\ K_{i2} \\ \vdots \\ K_{ik_i} \end{bmatrix},$$

$$\Lambda = \begin{bmatrix} \Lambda_1 (k_1 \times k_1) & \mathbf{0} (k_1 \times k_2) & \cdots & \mathbf{0} (k_1 \times k_m) \\ \mathbf{0} (k_2 \times k_1) & \Lambda_2 (k_2 \times k_2) & \cdots & \mathbf{0} (k_2 \times k_m) \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} (k_m \times k_1) & \mathbf{0} (k_m \times k_2) & \cdots & \Lambda_m (k_m \times k_m) \end{bmatrix}_{(n \times m)} \quad \text{avec } \Lambda_i (k_i \times k_i) = \text{diag} [\tau_i \tau_i^2 \dots \tau_i^{k_i}],$$

(5.35)

en désignant par $\{k_1, k_2, \dots, k_n\}$ les indices d'observabilité, n le nombre de variables d'état et m le nombre de sorties. Les gains τ_i apparaissant dans la matrice Λ sont strictement positifs. Par définition, $A_\zeta - KC_\zeta$ doit être Hurwitz avec (C_ζ, A_ζ) sous la forme canonique d'observabilité (5.27).

Gains d'observation. Concernant la mise au point de l'observateur à grand gain, les paramètres à régler sont

- Les n gains τ_i ($i = [1, \dots, n]$). Ces paramètres sont liés directement à l'erreur entre les sorties mesurées et les sorties reconstruites. La valeur des paramètres dépend principalement de deux

aspects. Le premier sort est l'ordre de grandeur de la mesure. Par exemple si la valeur est faible par rapport aux autres mesures, le paramètre τ sera aussi petit. Le deuxième aspect correspond à l'influence de la mesure. Par exemple, si la mesure n'est ni perturbée ni bruitée, sa valeur sera faible. Une valeur élevée signifie généralement une faible influence de la mesure.

- Les m gains K_j ($i = [1, \dots, m]$). Ces paramètres sont liés directement à l'état du système sous forme canonique, c'est-à-dire des mesures et ses dérivées. Généralement, la valeur des gains dépend de l'influence des erreurs de chaque sortie sur la correction. Le gain K d'une mesure est supérieur aux gains de ses dérivées, à l'exception de signaux très bruités.

Remarque 5.9 *Un observateur à grand gain du système non linéaire (5.24) a un total de $(n + m)$ paramètres de réglage.* ■

5.3.3 Observateurs par mode glissant [Levant, 1993]

Ce type d'observateurs reposent sur la théorie des modes glissants [Slotine et Li, 1991]. Plusieurs domaines utilisent cette solution, comme par exemple la robotique [De Wit et Slotine, 1991] [Filipescu et al., 2003] [Haouari et al., 2013], l'électronique [Hernandez, 1994] [Gorp et al., 2015], et dans l'industrie automobile [El Tannoury et al., 2013] [Imine et al., 2011]. Signalons [Perruquetti et Barbot, 2002] comme une des contributions les plus importantes sur la théorie et l'application des observateur par mode glissants à l'ingénierie.

Les caractéristiques principales des observateurs par mode glissant sont

- la convergence de l'erreur d'estimation en un temps fini ;
- la bonne robustesse face aux perturbations et incertitudes de mesure ou erreurs de modélisation.

Les premières solutions proposées (observateurs d'ordre 1) [Zinober, 1991] ont un terme correcteur basé sur l'utilisation d'une fonction de correction discontinue. La correction est définie en prenant en compte l'annulation des erreurs d'estimation des sortie, qui sont considérées comme les *variables de glissement* de l'observateur ($\sigma(\mathbf{x}, t) = \mathbf{y} - \hat{\mathbf{y}}$). Le principal problème est que l'utilisation de fonctions discontinues fait apparaître un phénomène de réticence ou *chattering*, dégradant la précision de l'observation. En général, la fonction discontinue utilisée est la fonction *sign*, mais d'autres approximations continues peuvent être utilisées pour la remplacer [Utkin, 2013]. L'avantage des fonctions continues est qu'elles permettent de réduire la réticence des valeurs observées, mais engendrent une perte significative de la robustesse. Dans [Bregeault, 2010], plusieurs fonctions de substitution de la fonction *sign* sont présentées, dont la fonction d'interpolation de puissance, la fonction pseudo-signe et la fonction arctangente.

Un autre solution (très utilisée), connue comme l'observateur par mode glissant *d'ordre supérieur* [Drakunov, 1992] [Utkin, 1993], est basée sur l'introduction de nouvelles dynamiques afin d'agir sur les dérivées d'ordre supérieur de l'erreur de reconstruction des sorties. Le but est de contraindre la convergence de σ et ses $(k_i - 1)$ dérivées vers 0 en un temps fini.

Définition 5.11 [Levant, 1993] *L'ensemble ou surface de glissement d'ordre supérieur par rapport à une variable de glissement $\sigma(\hat{\mathbf{x}}, \mathbf{y})$ est définie par*

$$S_i^k = \{\mathbf{x} \in \mathcal{X} \mid \sigma = 0, \dot{\sigma} = 0, \dots, \sigma^{[k_i-1]} = 0\}. \quad (5.36)$$

■

Les avantages de cette solution, par rapport aux observateurs par modes glissants d'ordre 1, sont :

- la conservation des qualités de robustesse et de convergence en temps fini ;
- la réduction de la réticence ;
- l'amélioration de la précision de l'observateur.

La solution retenue par la suite est la *différentiation par mode glissant d'ordre supérieur* proposée dans [Levant, 2003].

Structure. Considérons la forme canonique (5.27) définie à partir du système non linéaire (5.24). Un observateur de la forme (5.33) est utilisé, où le terme correcteur doit assurer la convergence de la variable d'état $\hat{\zeta} \rightarrow \zeta$.

Hypothèse 5.4 Considérons le système (5.27), il existe " m " constantes positives telles que

$$|\phi_{Ni\zeta}| \leq L_{\phi_i} \quad \text{avec} \quad i = [1 \ 2 \ \dots \ m] \quad (5.37)$$

■

En considérant l'Hypothèse 5.4, le terme correcteur κ du système (5.33) est défini à partir de [Levant, 2003] comme

$$\begin{aligned} \dot{\hat{\zeta}}_{i1} &= \hat{\zeta}_{i2} - \underbrace{s_1 L_{\phi_i}^{\frac{1}{k_i}} |\hat{\zeta}_1 - y_i|^{\frac{k_i-1}{k_i}} \text{sign}(\hat{\zeta}_1 - y_i)}_{\gamma_{i1}} \\ \dot{\hat{\zeta}}_{i2} &= \hat{\zeta}_{i3} - \underbrace{s_2 L_{\phi_i}^{\frac{1}{k_i-1}} |\gamma_{i1}|^{\frac{k_i-2}{k_i-1}} \text{sign}(\gamma_{i1})}_{\gamma_{i2}} \\ &\vdots \\ \dot{\hat{\zeta}}_{i(k_i-1)} &= \hat{\zeta}_{ik_i} - \underbrace{s_{(k_i-1)} L_{\phi_i}^{\frac{1}{2}} |\gamma_{i(k_i-2)}|^{\frac{1}{2}} \text{sign}(\gamma_{i(k_i-2)})}_{\gamma_{i(k_i-1)}} \\ \dot{\hat{\zeta}}_{ik_i} &= \phi_{i\zeta} - \underbrace{s_{k_i} L_{\phi_i} \text{sign}(\gamma_{i(k_i-1)})}_{\gamma_{ik_i}} \end{aligned} \quad (5.38)$$

en désignant par k_i l'indice d'observabilité et i l'indice correspondant à la sortie y_i . Les coefficients $[s_1 \ s_2 \ \dots \ s_{k_i}]$ et L_{ϕ_i} correspondent aux gains de l'observateur.

En considérant $\hat{\zeta} = \Gamma(\hat{\mathbf{x}})$, le terme de correction $\kappa_i(y_i, \hat{\mathbf{x}})$ correspondant au bloc associé à la sortie y_i et à ses $(k_i - 1)$ dérivées est défini comme

$$\kappa_i(y_i, \hat{\mathbf{x}}) = - [\gamma_{i(1)} \ \gamma_{i(2)} \ \dots \ \gamma_{i(k_i)}]^T. \quad (5.39)$$

Finalement, le terme de correction $\kappa(\mathbf{y}, \hat{\mathbf{x}})$ de l'observateur (5.33) est

$$\kappa(\mathbf{y}, \hat{\mathbf{x}}) = - [\kappa_1(y_1, \hat{\mathbf{x}})^T \ \kappa_2(y_2, \hat{\mathbf{x}})^T \ \dots \ \kappa_m(y_m, \hat{\mathbf{x}})^T]^T. \quad (5.40)$$

Gains d'observation

Concernant la mise au point de l'observateur par mode glissant, les paramètres à régler sont

- les gains " L_ϕ " (m paramètres en total). Ces paramètres influent directement l'erreur entre les sorties mesurées et les sorties reconstruites. La valeur des paramètres dépend principalement de deux aspects. Le premier aspect est l'ordre de grandeur de la mesure. Dans le cas d'avoir une valeur faible d'une mesure par rapport aux autres, son paramètre L_ϕ sera aussi faible. Le deuxième aspect correspond au grandeur de la mesure, c'est-à-dire que si la valeur de la mesure est faible, généralement signifie une influence faible.
- les gains " s " (n paramètres en total). Ils sont fixés typiquement selon des valeurs proposées par Levant [Levant, 2012] ou Fridman [Fridman et al., 2007]. Ces paramètres sont liés directement à l'état du système en forme canonique, c'est-à-dire des mesures et ses dérivées. Généralement, la valeur des gains dépend de l'influence des erreurs de chaque sortie sur la correction. Le gain s d'une mesure est supérieur aux gains de ses dérivées, en prenant des valeurs entre 5 et 0.

TABLEAU 5.1: Coefficients d'un observateur par mode glissants d'ordre supérieur.

	s_{k_i}	s_{k_i-1}	s_{k_i-2}	s_{k_i-3}	s_{k_i-4}
Levant	1.1	1,5	3	5	8
Fridman	1.1	1,5	2	3	5

Remarque 5.10 *Un observateur du système (5.24) par mode glissant d'ordre supérieur a $(m+n)$ gains à mettre au point. Si les paramètres "s" sont fixés en utilisant les valeurs standard (voir Tableau 5.1), le nombre de paramètres à régler est réduit à (m) .* ■

5.4 Conclusion

Dans ce chapitre, plusieurs solutions et techniques de synthèse d'observateurs ont été rappelées, en détaillant les observateurs classiques linéaires (Kalman et Luenberger) et non linéaires (grand gain et mode glissant). En pratique, la mise en œuvre de ces solutions nécessite un choix de paramètres qui doivent être réglés afin de garantir une bonne estimation de l'état. Ces gains ont été décrits pour chaque observateur afin de montrer la complexité de la mise au point et le nombre de paramètres à fixer si on souhaite utiliser ces observateurs dans des applications réelles. Ce choix peut être vu comme un problème d'optimisation dont la résolution dépend du contexte applicatif.

Les observateurs présentés dans ce chapitre seront utilisés dans la suite de ce manuscrit pour une application dans le contexte automobile, concernant un système de conduite automatique en embouteillage. Dans cette application, la synthèse des observateurs et la mise au point des gains des observateurs seront détaillées à partir des concepts introduits dans ce chapitre et par l'utilisation de la méthode d'optimisation développée dans le chapitre 3.

Estimation d'état dans le cadre du *Traffic Jam Pilot* (TJP)

Sommaire

6.1	Systèmes de contrôle et observateurs pour l'automobile	94
6.2	Dynamique latérale du véhicule	96
6.2.1	Classification des modèles du mouvement latéral du véhicule	98
6.2.2	Modèle bicyclette	98
6.2.3	Modèle bicyclette avec un véhicule cible	99
6.2.4	Radar et caméra	100
6.2.5	Colonne de direction	100
6.2.6	Modèle complet du véhicule	101
6.3	Contrôle latéral TJP	103
6.4	Observateur linéaire	105
6.4.1	Analyse de l'observabilité	105
6.4.2	Filtre de Kalman	105
6.5	Observateurs non linéaires	109
6.5.1	Observabilité et condition d'observabilité	110
6.5.2	Forme canonique d'observabilité	111
6.5.3	Observateur à grand gain	112
6.5.4	Observateur par mode glissant	113
6.6	Optimisation du réglage des observateurs non linéaires	114
6.6.1	Critères de performance	114
6.6.2	Optimisation des gains de l'observateur	115
6.6.3	Résultats de l'optimisation des observateurs	116
6.7	Installation expérimentale	117
6.8	Résultats par simulation	118
6.9	Résultats sur des données réelles	123
6.10	Conclusion	125

L'objectif de ce chapitre est de présenter une solution alternative à la méthode d'estimation d'état classiquement utilisée dans le cadre du contrôle latéral du système *Traffic Jam Pilot*. Il s'agit de proposer de nouvelles solutions qui réduisent la complexité du réglage du système. Dans une première partie, la dynamique latérale du véhicule et le système *Traffic Jam Pilot* sont introduites. La deuxième partie présente la solution basée sur un observateur linéaire (Kalman), et les nouvelles solutions proposées, basées sur des observateurs non linéaires (grand gain et mode glissant). Dans la troisième partie, la nouvelle procédure d'optimisation KEEP (présentée dans le Chapitre 3) est appliquée au contexte de mise au point des gains des observateurs, en utilisant une grande base de données d'enregistrements de roulage. Finalement, les trois observateurs seront testés d'abord en simulation, puis en utilisant de données réelles.

6.1 Systèmes de contrôle et observateurs pour l'automobile

Les systèmes autonomes sont conçus pour réaliser des actions ou tâches de façon automatique et sans interaction avec l'humain. Généralement, ils sont contrôlés par des lois de commande complexes qui utilisent des informations mesurées par plusieurs capteurs. La performance de tout système autonome dépendra directement de la qualité et de la précision des informations mesurées et de la façon dont le système l'utilise dans la commande. Les capteurs avec une grande précision sont souvent utilisés afin d'avoir des valeurs mesurées de bonne qualité, mais ces capteurs sont très coûteux, ce qui augmente le coût global du système. De plus, afin d'assurer la qualité du système, plusieurs capteurs peuvent être utilisés de manière redondante pour mesurer la même grandeur physique. Le but de cette redondance est de détecter et de prévenir la défaillance des capteurs. Par ailleurs, une maintenance périodique des capteurs est nécessaire car ils peuvent se détériorer du fait de leur utilisation, ce qui altère les valeurs mesurées.

Afin de résoudre les contraintes précédentes, une des solutions largement utilisées dans la commande des systèmes autonomes est l'utilisation d'*observateurs*. L'avantage de cette technique est qu'elle permet d'estimer toute l'information requise par les lois de commandes bien qu'elle ne soit pas toujours mesurée.

Le système autonome traité dans ce chapitre est le système dit *Traffic Jam Pilot* (TJP)¹, dont le but est d'aider les conducteurs dans des situations d'embouteillage à basse vitesse. Il est un des systèmes d'aide à la conduite les plus récents et une des priorités des constructeurs automobile (voir Chapitre 1). Le système est déjà présent sur des véhicules comme la BMW i3, la Mercedes-Benz S-Class et la Volkswagen Passat. Le système TJP est constitué de deux systèmes de contrôle du véhicule : un contrôle longitudinal et un contrôle latéral. Le *contrôle longitudinal* garantit une distance de sécurité suffisante entre *le véhicule* et *le véhicule cible*² en prenant en compte la vitesse des deux véhicules (voir Figure 6.1). Le *contrôle latéral* permet de guider le véhicule selon la trajectoire du véhicule *cible* et de l'environnement en modifiant l'angle au volant.

Les deux systèmes de contrôle précédents utilisent un radar et une caméra pour enregistrer l'information de l'environnement à chaque instant. Actuellement, les performances (précision et robustesse) des systèmes TJP sont détériorées dans des *situations difficiles* comme les carrefours et les routes en absence de marquage au sol³. Des situations complexes comme les changements de voie ou le dépassement du véhicule cible ne sont pas encore prises en compte dans le cahier de charge des systèmes TJP, mais cela est étudié pour de futures versions.

Comme indiqué auparavant, les systèmes autonomes ont besoin de nombreuses informations pour garantir la fiabilité du contrôle du système dans un environnement qui change. L'utilisation d'observateurs permet d'améliorer la qualité des informations mesurées, d'économiser le coût global du système en réduisant le nombre de capteurs, de sécuriser l'information donnée par les capteurs (redondance), de pallier des

¹Aussi appelé système *Auto-Steer*.

²Le *véhicule cible* est le véhicule plus proche du véhicule à contrôler (appelé simplement *véhicule*) dans la direction de l'avancement. Il roule sur la même voie que le véhicule (voir Figure 6.1).

³On ne considère ici que les lignes continues et discontinues peintes sur la chaussée.

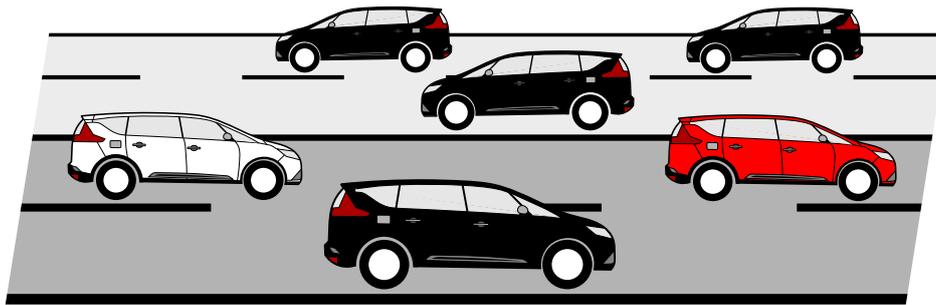


FIGURE 6.1: Situation *standard* du système TJP. Le *véhicule* à contrôler (en blanc) utilise l'information de position du *véhicule cible* (en rouge) et des autres véhicules (en noir), plus l'information du marquage sur la chaussée (lignes).

pertes d'information, et d'estimer les valeurs de variables non mesurables qui sont nécessaires pour le contrôle du système.

Les premiers observateurs utilisés dans un véhicule étaient basés sur des *approches linéaires*. Par exemple, dans [Senger et Schwartz, 1988], un observateur linéaire est utilisé pour estimer la vitesse latérale du véhicule en se basant sur un modèle de pneumatiques linéaire. Dans [Nardi et al., 2010], la vitesse latérale est estimée en utilisant un observateur de Luenberger à partir de la vitesse angulaire de lacet, l'accélération latérale, la vitesse longitudinale et l'angle au volant. Dans [Fukatani, 1997], l'angle de dérive est estimé à partir de la vitesse longitudinale et de l'angle au volant ; la solution est basée sur un observateur de Kalman dont les gains sont modifiés selon la vitesse du véhicule.

L'inconvénient de l'utilisation d'observateurs linéaires est que la linéarisation des dynamiques du véhicule fait que la précision et la robustesse des commandes et observateurs synthétisés à partir de ces modèles linéarisés, par rapport aux perturbations et incertitudes, sont souvent mises à mal. Pour cette raison, certaines solutions de commande sont basées sur des *observateurs non linéaires*. Par exemple, dans [Stotsky et Hu, 1997], un observateur par mode glissant est conçu afin d'estimer l'angle au volant pendant le suivi d'une trajectoire. Dans [Noh et Han, 2014], des observateurs non linéaires sont utilisés pour estimer la position dans la voie (écart latéral) en utilisant l'information du marquage sur la chaussée et des obstacles de la route afin d'évaluer un risque de collision. Dans [Bouibed et al., 2010], un observateur par mode glissant est proposé pour estimer la vitesse angulaire de lacet, la vitesse longitudinale et la vitesse latérale afin de détecter et isoler les capteurs en défaillance, qui sont utilisés pour le contrôle d'un véhicule électrique autonome. Dans [Dugard et al., 2012], un observateur $H-\infty$ est utilisé pour estimer l'état de la dynamique verticale du véhicule (en utilisant un nombre réduit de capteurs) afin d'utiliser l'estimation dans le contrôle des applications liées à la suspension du véhicule. Dans [Tudon-Martinez et al., 2014], un observateur $H-\infty$ est utilisé pour estimer le profil de la route en se basant sur une analyse de Fourier de la fréquence et amplitude des irrégularités de la route. Dans [Khemoudj et al., 2010], un observateur par mode glissant avec des gains adaptatifs est proposé pour estimer les forces aux pneumatiques d'un poids lourd. Dans [El Tannoury et al., 2013], un observateur à grand gain et un observateur par mode glissant sont proposés afin de détecter une perte de pression dans les pneumatiques, à partir d'un procédé d'estimation de la résistance au roulement d'une roue d'un véhicule.

Dans le contexte du *contrôle latéral* du véhicule autonome, certains travaux proposent des solutions basées sur des observateurs non linéaires. Dans [Kang et al., 2013], un observateur par mode glissant est utilisé pour estimer l'accélération latérale en utilisant la vitesse angulaire de lacet, l'angle de lacet et la distance latérale par rapport à la route. Dans [M'Sirdi et al., 2008], un observateur par mode glissant est utilisé pour estimer l'angle de lacet, la vitesse angulaire de lacet et la vitesse du véhicule. Dans [Fujimoto et al., 2004], une solution pour le contrôle d'un système anti-dérapiage est basée sur un double observateur. Le premier observateur est basé sur un modèle *une-roue* qui estime la traction du véhicule alors que le second observateur est basé sur un modèle *deux-roues* (une roue par axe) qui estime le moment d'inertie en lacet. Les deux observateurs permettent d'améliorer la stabilité et la robustesse du

contrôle du véhicule dans des conditions de route difficiles. Dans [Baffet et al., 2009], un observateur non linéaire est utilisé pour estimer la résistance au roulement, l'angle d'inclinaison latérale du véhicule et la rigidité des pneus en virage. Cette solution n'utilise que les mesures de capteurs déjà présents dans les véhicules actuels, tels que l'angle de braquage, la vitesse du véhicule et la vitesse angulaire de lacet.

Les nouvelles versions des systèmes TJP se doivent d'être plus précises et robustes pour un grand nombre de situations. Par conséquent, ils ont besoin d'utiliser des modèles de la dynamique du véhicule prenant en compte des informations de la route, tels que le marquage sur la chaussée, la trajectoire du véhicule cible et spécialement la courbure de la route. Certains travaux ont déjà étudié cette problématique et ils ont proposé des solutions afin d'estimer la valeur de la courbure de la route. Par exemple, dans [Dahmani et al., 2015], la courbure de la route est estimée par un observateur à logique floue basé sur un modèle Takagi-Sugeno [Takagi et Sugeno, 1985], afin de détecter les sorties de voies. La différence entre la valeur estimée de la courbure et la valeur mesurée par la caméra permet de calculer un indicateur de risque que le véhicule sorte de la voie. Dans [Yacine et al., 2013], la courbure est estimée en utilisant aussi un observateur basé sur le modèle Takagi-Sugeno, mais en considérant la vitesse longitudinale variant dans le temps. Le principal problème de ces deux dernières solutions est la complexité des observateurs par logique floue et leurs difficultés de mise au point. Dans [Dabladji et al., 2014], la courbure de la trajectoire du véhicule cible est estimée en se basant sur deux observateurs en cascade. Le premier observateur est utilisé pour estimer la vitesse latérale et la courbure de la route à partir de l'information du marquage au sol mesurée par le système de vision. Le second observateur est utilisé pour estimer les forces appliquées aux pneus et l'angle de roulis à partir de l'angle au volant, la vitesse angulaire de lacet et la vitesse latérale estimée. Dans les trois travaux précédents, la courbure est estimée par un observateur grâce à la connaissance du marquage sur la chaussée, information obtenue par la caméra. Néanmoins, il y a plusieurs situations où les marquages de la chaussée ne sont pas détectés :

- une faible distance longitudinale : le véhicule cible occulte à la caméra le marquage sur chaussée ;
- basse vitesse : les systèmes de vision actuels peuvent avoir des problèmes pour détecter de façon pertinente les lignes longitudinales sur la chaussée ;
- perte temporaire de la détection des marquages sur la chaussée en raison des conditions météorologiques ou d'une mauvaise détection de la caméra ;
- route sans marquage sur la chaussée : la caméra n'est plus capable d'estimer la courbure de la route.

Dans ce chapitre, des solutions d'observation pour l'estimation de l'état de la dynamique latérale du véhicule ont été proposées pour des conditions difficiles, en particulier quand la valeur de la courbure est inconnue (voir Figure 6.2), en considérant les hypothèses suivantes :

Hypothèse 6.1 *La caméra ne mesure pas le marquage sur chaussée ou cette information n'est momentanément pas disponible.* ■

Hypothèse 6.2 *L'information du véhicule cible est toujours disponible. La position du reste des véhicules ne sera pas utilisée.* ■

Hypothèse 6.3 *Le véhicule cible roule dans la voie (c'est-à-dire qu'il est bien centré par rapport au marquage sur chaussée). Par conséquent, sa trajectoire est considérée comme la référence à suivre.* ■

6.2 Dynamique latérale du véhicule

Dans ce chapitre, les travaux sont focalisés sur le contrôle latéral du système TJP sous les Hypothèses 6.1-6.3. La dynamique latérale du véhicule utilisée pour le système TJP à étudier sera basée sur l'information de la position du véhicule cible et la distance entre les deux véhicules (voir Figure 6.2).

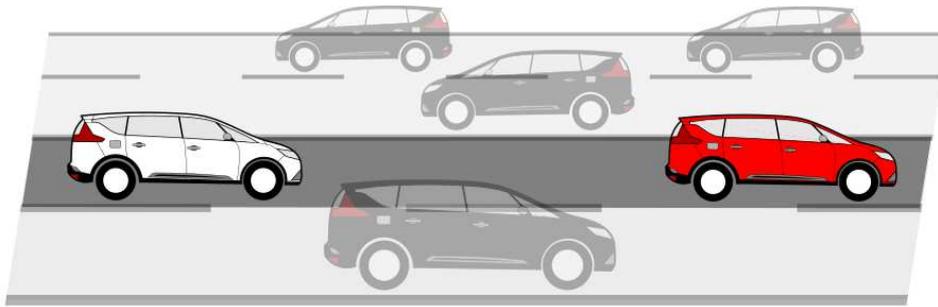


FIGURE 6.2: Situation difficile du système TJP à étudier. Le *véhicule* à contrôler (en blanc) ne dispose que de l'information du véhicule cible (rouge) [Hypothèse 6.2]. Cependant, l'information du marquage sur chaussée et celle des autres véhicules n'est pas disponible [Hypothèse 6.1].

Les modèles de référence sur la *dynamique latérale* des années 90 ont été rassemblés et comparés dans [Farrelly et Wellstead, 1996] et [Ray, 1997]. Ces deux travaux ont été complétés par [Pacejka, 2002] qui combine la dynamique du véhicule et des pneumatiques ; dans [Rajamani, 2006], un modèle *deux-roues*, dit aussi modèle bicyclette, est utilisé pour définir la dynamique à partir d'un système linéaire variant dans le temps défini à partir de 4 variables d'état. Le modèle bicyclette est devenu une référence sur lequel sont basés plusieurs travaux. Par exemple, dans [Dixon, 1996][Koo et al., 2004], ce modèle est utilisé pour étudier la relation entre les forces latérales et l'angle de dérive. Dans [Milliken, 2003], une adaptation du modèle est faite à partir des forces verticales du véhicule ; dans [Reza, 2008], le modèle est adapté en prenant en compte une route avec pente et dévers.

L'utilisation de modèles des dynamiques latérales du véhicule dans des systèmes comme le TJP présente la difficulté que certaines variables d'état ne sont pas mesurables par les capteurs. L'utilisation d'*observateurs* dans le contrôle latéral du véhicule permet d'estimer ces variables d'état inconnues, d'améliorer la qualité des mesures ou bien de réduire le nombre de capteurs nécessaires. Les premières solutions basées sur l'utilisation d'observateurs pour la dynamique latérale du véhicule ont été proposées dans [Senger et Kortum, 1989] en utilisant les observateur *linéaires* classiques (Luenberger et Kalman). Le problème est que la dynamique latérale du véhicule n'est pas linéaire, et les observateurs précédents sont réglés en utilisant la technique du placement de pôles, peu adaptée au regard d'une vitesse variable du véhicule [Kiencke et Daiß, 1997]. Néanmoins, les observateurs type Kalman ont été une des solutions d'observation les plus utilisées jusqu'à présent grâce à leur robustesse et leur précision face aux bruits de mesure. Par exemple, dans [Kim, 2009, Doumiati, 2009], ils sont utilisés pour l'identification des forces latérales aux pneumatiques ; dans [Sebsadji et al., 2008], une combinaison avec un observateur de Luenberger améliore l'estimation de la vitesse latérale. Dans [Wang et al., 2013], un observateur de Kalman est utilisé pour estimer l'angle de dérive.

Pour prendre en compte les *non linéarités* de la dynamique latérale, plusieurs solutions basées sur des observateurs non linéaires ont été proposées. Dans [Stephan, 2004], une comparaison entre les observateurs linéaires et les observateurs non linéaires est faite, laquelle montre la meilleure adaptation des solutions non linéaires face à une vitesse longitudinale du véhicule variable. Un observateur non linéaire par mode glissant, [Guldner et al., 1994] est un des travaux de référence dans le cadre du contrôle de l'angle au volant sur un véhicule automatique. Des travaux postérieurs sont aussi basés sur l'utilisation d'observateurs par mode glissant, pour l'estimation des forces latérales [Imine et Dolcemascolo, 2008], l'angle d'inclinaison latérale de la route [Menhour et al., 2011], l'angle de dérive [Stephant et al., 2007] ou l'estimation des forces pneumatique/roue et le profil de la route [Imine et al., 2011].

D'autres solutions non linéaires ont été proposées, comme par exemple dans [Sasaki et Nishimaki, 2000] où l'observateur est basé sur l'utilisation d'un réseau de neurones et dans [Shuming et Gao, 2005] dans lequel l'observateur est basée sur la logique floue. Il faut remarquer que l'observateur Takagi-Sugeno [Takagi et Sugeno, 1985] basé sur la logique floue est une solution très utilisée pour l'estimation

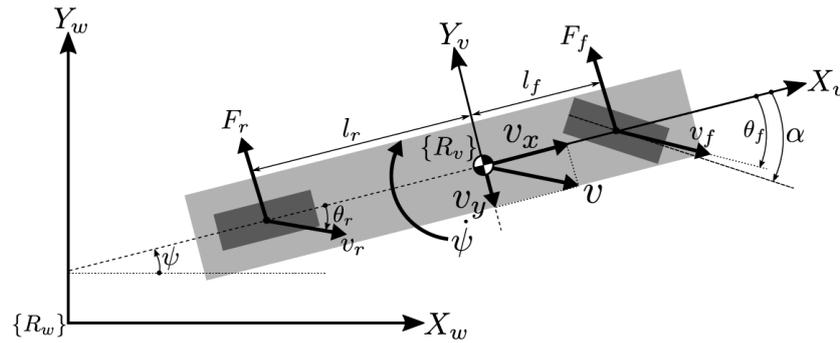


FIGURE 6.3: Représentation et notation du modèle bicyclette classique.

des dynamiques du véhicule [Dahmani et al., 2011, Geng et al., 2009]. Cette solution permet d'estimer les angles de dérive et de roulis en considérant la courbure de la route et son dévers comme deux entrées inconnues. Malheureusement, les applications sur des systèmes industriels ont besoin de solutions très robustes et suffisamment simples pour être implémentées en temps réel, ce qui n'est pas le cas des observateurs basés sur la logique floue et les réseaux de neurones.

6.2.1 Classification des modèles du mouvement latéral du véhicule

Pour contrôler le mouvement latéral du véhicule, plusieurs modèles du véhicule peuvent être utilisés. Ces modèles sont typiquement classés en fonction de leur complexité :

1. *Modèles particules*. Toute la masse du véhicule est représentée en un seul point, généralement le centre de masse. Les résultats de simulation sont caractérisés par une erreur importante de suivi de trajectoire en comparaison des véhicules réels [Gao et al., 2010].
2. *Modèles cinématiques*. La trajectoire (mouvement) du véhicule est définie géométriquement. Ces modèles ont une bonne représentation de la dynamique réelle tant que le véhicule n'a pas de manœuvres importantes⁴ ou de situations de glissement [Kong et al., 2015].
3. *Modèles dynamiques*. Ces solutions prennent en compte les forces et moments du véhicule pour décrire l'interaction véhicule-route.

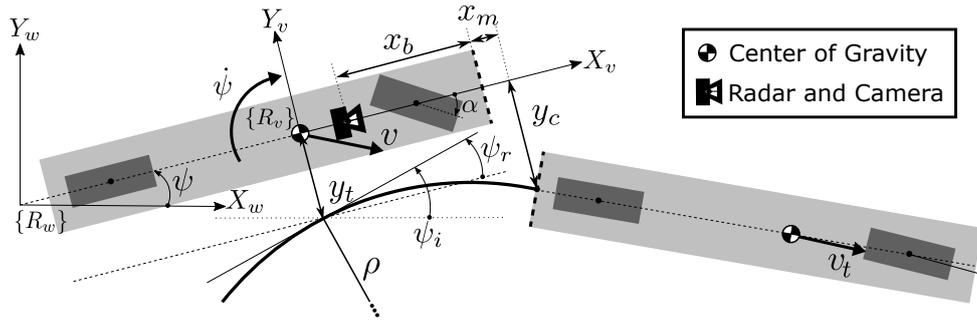
Dans la suite du chapitre, les équations utilisées pour décrire le mouvement latéral du véhicule sont basées sur un modèle dynamique de type *bicyclette* [Pacejka, 2002] [Rajamani, 2006].

6.2.2 Modèle bicyclette [Pacejka, 2002] [Rajamani, 2006]

Le modèle *bicyclette* est une approximation très utilisée pour la conception de la commande [Carvalho et al., 2015] ; ce modèle est caractérisé par le fait que les roues gauche et droite sont représentées par une seule roue (voir Figure 6.3). Ces modèles décrivent le déplacement du véhicule sur un espace infini, dit *world frame* $\{R_w\}$, en considérant le mouvement sur une route plate avec une pente et un dévers nuls. La vitesse du véhicule v est définie au centre de gravité (CoG) du véhicule, et est décomposée en une composante longitudinale v_x et une composante latérale v_y .

Remarque 6.1 Dans la modélisation utilisée de la dynamique du véhicule, la vitesse longitudinale v_x est supposée constante. ■

⁴Mouvement du véhicule avec un fort angle au volant, comme par exemple un manœuvres de parking ou un changement de voie à basse vitesse.

FIGURE 6.4: Représentation et notation du modèle bicyclette avec un véhicule *cible*.

En considérant un petit angle de dérive (glissement-latéral), les angles des vitesses des roues avant θ_f et arrière θ_r (voir Figure 6.3) sont définies par

$$\begin{cases} \theta_f = \frac{1}{v_x} (v_y + l_f \dot{\psi}) \\ \theta_r = \frac{1}{v_x} (v_y - l_r \dot{\psi}) \end{cases} \quad (6.1)$$

en désignant par $\dot{\psi}$ la vitesse angulaire en lacet, et l_f et l_r les distances longitudinales entre le CoG et les essieux avant et arrière respectivement. Aussi, les forces latérales des pneus avant F_{yf} et arrière F_{yr} peuvent être écrites

$$\begin{cases} F_{yf} = C_f (\alpha - \theta_f) + w_f^n \\ F_{yr} = C_r (-\theta_r) + w_r^n \end{cases} \quad (6.2)$$

en désignant par α l'angle de braquage de roues avant, w_f^n et w_r^n les perturbations dans les forces latérales aux roues avant et arrière respectivement, et C_f et C_r les coefficients de frottement visqueux aux roues avant et arrière respectivement.

Finalement, la dynamique latérale du véhicule est définie en combinant les équation de *forces* et de *moments*.

Forces. En appliquant la deuxième loi de Newton au mouvement de translation latérale du véhicule, l'expression obtenue est

$$M (\dot{v}_y + v_x \dot{\psi}) = F_{yf} + F_{yr} \quad (6.3)$$

en désignant par M la masse du véhicule.

Moments. Les équations des moments de l'axe vertical du véhicule permettent de définir la dynamique du lacet du véhicule comme

$$I_z \ddot{\psi} = l_f F_{yf} - l_r F_{yr} \quad (6.4)$$

en désignant par I_z le moment d'inertie en lacet du véhicule.

6.2.3 Modèle bicyclette avec un véhicule cible

Pour guider notre véhicule, la trajectoire faite par le véhicule cible est prise comme référence. Afin de simplifier les équations de la dynamique, le modèle bicyclette est exprimé dans le repère du véhicule, dite *vehicle frame* $\{R^v\}$, à la place du *world frame* $\{R^w\}$. Pour prendre en compte le véhicule cible, les nouvelles dynamiques du système seront déterminées à partir de la distance latérale du véhicule par rapport à la trajectoire du véhicule cible y_t , et à partir de l'angle relatif de lacet ψ_r (voir Figure 6.4). Cet

angle est défini comme la différence entre l'angle de lacet du véhicule ψ et l'angle idéal de lacet ψ_i défini par la trajectoire du véhicule cible [Peng et Tomizuka, 1990]. On obtient

$$\begin{cases} \dot{y}_t = v_y + v_x \psi_r \\ \dot{\psi}_r = \dot{\psi} - \dot{\psi}_i \end{cases} \quad (6.5)$$

Le terme $v_x \psi_r$ est une approximation faite pour un angle relatif de lacet faible, ce qui représente la différence de vitesse par rapport à la trajectoire à suivre [Tseng et al., 2005]; ψ_i est défini comme $\psi_i = v_x \rho$, ce qui est une approximation géométrique de l'impact de la courbure de la trajectoire ρ sur la dynamique de l'angle relatif [Peng et Tomizuka, 1990].

Alors, les dynamiques de $\dot{\psi}$ et \dot{y}_t (6.5) sont obtenues à partir des équations de forces et moments (6.3-6.4) et s'écrivent

$$\begin{cases} \ddot{\psi} = \frac{-1}{I_z v_x} (C_f l_f^2 + C_r l_r^2) \dot{\psi} + \frac{1}{I_z} (C_f l_f - C_r l_r) \psi_r \\ \quad + \frac{1}{I_z v_x} (C_r l_r - C_f l_f) \dot{y}_t + \frac{1}{I_z} (C_f l_f) \alpha + \frac{l_f}{I_z} w_f^n - \frac{l_r}{I_z} w_r^n \\ \ddot{y}_t = \frac{1}{M v_x} (-C_f l_f + C_r l_r) \dot{\psi} + \frac{1}{M} (C_f + C_r) \psi_r \\ \quad + \frac{-1}{M v_x} (C_f + C_r) \dot{y}_t + \frac{C_f}{M} \alpha - v_x^2 \rho_t + \frac{1}{M} w_f^n + \frac{1}{M} w_r^n \end{cases} \quad (6.6)$$

6.2.4 Radar et caméra

Dans des conditions difficiles, lorsque l'information du marquage sur la chaussée n'est pas disponible, le système TJP pourrait utiliser l'information du véhicule cible (voir les Hypothèses 6.1-6.3). Cette information est obtenue grâce à la fusion de mesures réalisées par un radar et une caméra⁵. Lorsque le véhicule cible est détecté, les informations mesurées utilisées pour le système TJP sont (voir Figure 6.4)

- la distance longitudinale entre les deux véhicules x_m , mesurée par rapport au pare-chocs avant du véhicule;
- la distance latérale entre les deux véhicules y_c , mesurée par rapport au CoG du véhicule.

Les deux mesures de distance précédentes prennent l'arrière du véhicule cible comme point de référence. Notons que la distance latérale y_c est différente de la distance latérale par rapport à la trajectoire du véhicule cible y_t . La relation entre les deux distances (voir Figure 6.5) est définie par [Tseng et al., 2005]

$$y_c = x_m \psi_r + y_t - 0,5 x_m^2 \rho \quad (6.7)$$

où ψ_r , y_t et ρ sont des variables inconnues, et y_c la valeur mesurée.

6.2.5 Colonne de direction

La colonne de direction est le système qui transforme un angle de braquage du volant, α_{in} , en un angle de braquage des roues, α . Plusieurs travaux ont étudié la modélisation de la colonne de direction pour la synthèse de la loi de commande [Reimpell et al., 2001]. Dans les cas de la thèse, on a considéré une version simplifiée du *electric power steering system* (EPS), où la colonne de direction est composée d'un arbre de direction unique, de joints de cardan, de la crémaillère de direction et des pignons. Cette simplification est faite à cause du caractère fortement non linéaire entre l'angle de braquage du volant et les efforts mécaniques exercés sur la colonne de direction. De plus, les inerties et les amortissements

⁵La position x_b de la caméra dans le véhicule est fixe, connue et définie par la distance longitudinale par rapport au pare-choc avant. Normalement, elle est située entre le CoG et l'essieu avant du véhicule.

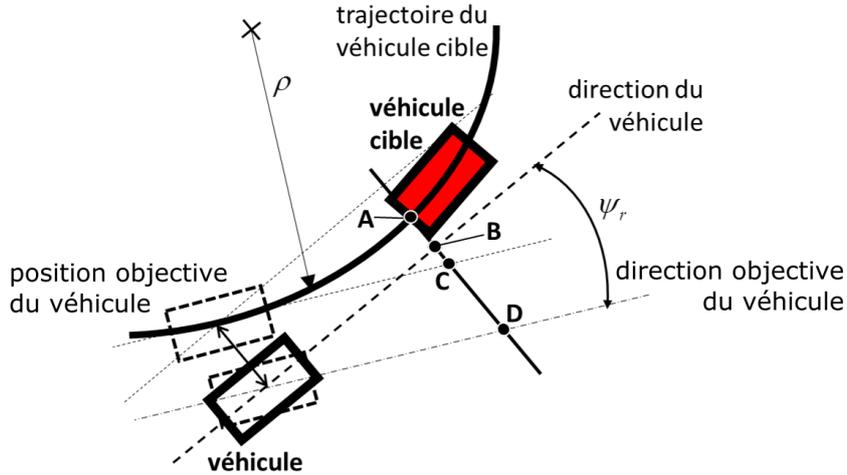


FIGURE 6.5: Relation entre la distance latérale fournie par la caméra y_c et la distance latérale par rapport à la trajectoire du véhicule cible y_t . La position des véhicules est représentée par des rectangles : le véhicule à contrôler (en blanc et trait continu), le véhicule cible (en rouge et trait continu) et la position objective du véhicule (en blanc et trait discontinu). La trajectoire du véhicule cible est représentée par une ligne continue en gras. Les termes de (6.7) sont représentés : \overline{AB} est y_c , \overline{AC} est " $0,5x_m^2\rho$ ", \overline{BD} est " $x_m\psi_r$ " et \overline{CD} est y_t .

des arbres sont des paramètres inconnus et difficiles à estimer. En utilisant cette version simplifiée, la dynamique de l'EPS est décrite par un système linéaire de second ordre, *i.e*

$$\frac{\alpha}{\alpha_{in}} = \frac{\omega_m^2}{s^2 + 2\xi\omega_m s + \omega_m^2} k_{eps} \quad (6.8)$$

en désignant par ω_m la fréquence propre et ξ le coefficient d'amortissement. Le gain k_{eps} prend en compte l'interaction des composants mécaniques pour la transformation du mouvement de rotation entre la crémaillère et le pignon.

6.2.6 Modèle complet du véhicule

Le modèle final de la dynamique latérale du véhicule est obtenu à partir du modèle bicyclette avec cible, de la dynamique de ψ_r et y_t (6.5, 6.6), et de la dynamique de la colonne de direction (6.8). Afin d'affronter la problématique de la non-disponibilité de la valeur de la courbure de la route, cette dernière est introduite dans l'état du modèle en considérant sa dynamique inconnue. Les mesures prennent en compte le positionnement du véhicule cible obtenu en utilisant le radar et la caméra (6.7), ainsi que les grandeurs de la vitesse de lacet $\dot{\psi}$ et l'angle de braquage des roues α (présents sur le réseau CAN du véhicule à cause de son utilisation pour d'autres systèmes, comme par exemple l'ABS⁶). On obtient donc le système suivant

$$\begin{cases} \begin{bmatrix} \dot{\mathbf{x}}_r \\ \dot{\rho} \end{bmatrix} = A \begin{bmatrix} \mathbf{x}_r \\ \rho \end{bmatrix} + Bu + G \begin{bmatrix} w_f^n \\ w_r^n \end{bmatrix} + \begin{bmatrix} \mathbf{0}_{(6 \times 1)} \\ r(t) \end{bmatrix} \\ \mathbf{y} = C \begin{bmatrix} \mathbf{x}_r \\ \rho \end{bmatrix} \end{cases} \quad (6.9)$$

où la dynamique de la courbure ρ est définie par une fonction inconnue variable dans le temps $r(t)$.

⁶Anti-lock Braking System ou système antiblocage des roues

Hypothèse 6.4 La fonction inconnue $r(t)$ est une fonction continue et dérivable. De plus, la fonction est supposée bornée. ■

Hypothèse 6.5 La courbure de la trajectoire du véhicule cible et la courbure de la route sont supposées identiques. ■

L'état \mathbf{x} , les mesures \mathbf{y} et la entrée u du système précédent sont définis comme

$$\begin{aligned}\mathbf{x} &= [\mathbf{x}_r^T \rho]^T = [x_1 \ x_2 \ x_3 \ x_4 \ x_5 \ x_6 \ x_7]^T \\ &= [\dot{\psi} \ \psi_r \ \dot{y}_t \ y_t \ \dot{\alpha} \ \alpha \ \rho]^T \\ \mathbf{y} &= [y_1 \ y_2 \ y_3]^T = [\dot{\psi} \ y_c \ \alpha]^T \\ u &= k_{eps} \alpha_{in}\end{aligned}\tag{6.10}$$

Les matrices du système (6.9) sont définies comme

$$A = \begin{bmatrix} a_{11}(t) & a_{12} & a_{13}(t) & 0 & 0 & a_{16} & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 & a_{27}(t) \\ a_{31}(t) & a_{32} & a_{33}(t) & 0 & 0 & a_{36} & a_{37}(t) \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & a_{55} & a_{56} & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix},\tag{6.11}$$

$$B = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ b_5 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \quad G = \begin{bmatrix} g_{11} & g_{12} \\ 0 & 0 \\ g_{31} & g_{32} \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \quad \text{et} \quad C = \begin{bmatrix} 1 & 0 & 0 \\ 0 & c_{22} & 0 \\ 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & c_{27} & 0 \end{bmatrix}^T.$$

Les coefficients des matrices (6.11) sont spécifiés dans les Tableaux 6.1-6.2.

Remarque 6.2 La matrice A (6.11) du système (6.9) a plusieurs composantes variant dans le temps en raison de la présence de la vitesse du véhicule v_x . Si la vitesse du véhicule est constante, alors la matrice A sera aussi constante. ■

Remarque 6.3 Dans le cadre de travaux antérieurs sur la synthèse de la courbure, la solution classique retenue par les constructeurs pour modéliser la fonction $r(t)$ du système (6.9) est de l'estimer par

$$\hat{r}(t) = -w_p \rho + w_p w^n\tag{6.12}$$

avec $w_p = 2\pi f_p$, f_p étant la fréquence de filtrage de la courbure et w^n un bruit blanc défini comme $\mathcal{N}(0, 0,01)$ ⁷; la dynamique de la courbure est donc vu comme un filtre passe-bas du premier ordre. Par conséquent, le système (6.9) est ré-écrit sous la forme

$$\begin{aligned}\dot{\mathbf{x}} &= A\mathbf{x} + \begin{bmatrix} 0 \\ -w_p \rho \end{bmatrix} + Bu + G \begin{bmatrix} w_f^n \\ w_r^n \end{bmatrix} + \begin{bmatrix} \mathbf{0}_{(6 \times 1)} \\ w_p w^n \end{bmatrix} = \\ &= A_k \mathbf{x} + Bu + G \begin{bmatrix} w_f^n \\ w_r^n \end{bmatrix} + \begin{bmatrix} \mathbf{0}_{(6 \times 1)} \\ w_p w^n \end{bmatrix}\end{aligned}\tag{6.13}$$

⁷Loi normale de moyenne 0 et écarte type 0,01. ■

Le système (6.13) correspond au modèle classique utilisé par les plupart des constructeurs automobiles et le modèle envisagée à être utilisé par Renault/Nissan. Ce système sera pris en compte dans le chapitre pour la proposition d'un observateur linéaire utilisé par les constructeurs automobiles.

6.3 Contrôle latéral TJP

Le contrôle latéral du système TJP permettrait de suivre la trajectoire (d'un point de vue latéral) du véhicule cible en agissant sur l'angle du volant. La valeur de l'angle au volant est obtenue grâce à une boucle de commande constituée d'un observateur et d'un correcteur (contrôleur). La structure est représentée Figure 6.6 où u est la commande, x l'état du système et y les valeurs mesurées (variables définies (6.10)).

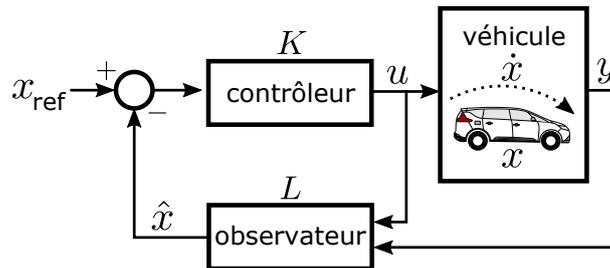


FIGURE 6.6: Boucle de commande du contrôle latéral du système TJP.

L'observateur du système a pour but d'estimer l'état x à partir des mesures y et de la commande u , avec L les gains de l'observateur. La commande est définie à partir de la solution classique d'un retour d'état statique ($u = K(x_{\text{ref}} - \hat{x})$) avec la matrice de gain du contrôleur K , l'état estimé \hat{x} et l'état de référence x_{ref} . Ce dernier est défini comme $x_{\text{ref}} = [0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0]^T$, ce qui représente la valeur d'état *souhaitée*

- $[x_1, x_2] \mapsto 0$: Un angle relatif nul ($\psi_r \mapsto 0$) fait que le véhicule roule dans la même direction que le véhicule cible ; cependant, la vitesse angulaire en lacet est minimisée ($\min \dot{\psi}$) afin de restreindre le mouvement en lacet (égale à 0 dans la situation souhaitée) ;
- $[x_3, x_4] \mapsto 0$: Une distance latérale nulle ($y_t \mapsto 0$) signifie qu'il n'y a pas d'écart latéral entre les deux trajectoires ; cependant, la vitesse latérale est minimisée ($\min \dot{y}_t$) pour restreindre le mouvement latéral aux routes sinueuses (égale à 0 dans la situation souhaitée) ;
- $[x_5, x_6] \mapsto 0$: Les valeurs de l'angle volant α et sa vitesse $\dot{\alpha}$ sont minimisées afin d'obtenir une solution qui tourne le moins possible le volant ;
- $[x_7] \mapsto 0$: La minimisation de la courbure est utilisée car on considère que la trajectoire du véhicule doit être la plus droite possible ($\rho = 0$ si la route est en ligne droite).

Remarque 6.4 Si le système TJP (6.9) était linéaire avec une matrice A (6.11) constante (voir Remarque 6.2), on peut alors appliquer le principe de séparation introduit dans la Section 5.2.3 et considérer que le contrôleur et l'observateur peuvent se régler indépendamment. ■

Remarque 6.5 Ni la stabilité de la boucle de commande du système TJP (voir Figure 6.6), ni le type de stratégie de commande ne font partie du sujet d'étude de la thèse. ■

Par la suite, la solution d'observation standard (issue de la littérature et qui est utilisée pour les constructeurs) pour les systèmes TJP, l'observateur de Kalman, sera présenté conjointement avec deux nouvelles propositions basées sur les observateurs non linéaires (observateur à grand gain et observateur par mode glissant).

TABLEAU 6.1: Exemple de valeurs numériques d'un véhicule de type Renault *ESPACE*.

Symbole	Paramètre	Valeur	Unité
C_f	Coefficient de frottement visqueux - pneumatiques avant	123 170	$N \cdot rad^{-1}$
C_r	Coefficient de frottement visqueux - pneumatiques arrières	139 600	$N \cdot rad^{-1}$
M	Masse du véhicule	1 910	kg
I_z	Moment d'inertie en lacet	3 846	$kg \cdot m^2$
l_f	Distance longitudinale du CoG à l'essieu avant	1,17	m
l_r	Distance longitudinale du CoG à l'essieu arrière	1,77	m
w_p	Pulsation de filtrage de la courbure	$2\pi 0,01$	$rad \cdot s^{-1}$
w_m	Pulsation propre de la colonne de direction	$2\pi 3$	$rad \cdot s^{-1}$
ξ	Facteur d'amortissement de la colonne de direction	0,7	.
w_f^n	Forces latérales de perturbation - roues avant	$20 \mathcal{N}(0, 1)$	N
w_r^n	Forces latérales de perturbation - roues arrières	$20 \mathcal{N}(0, 1)$	N
k_{eps}	Facteur d'amortissement de la colonne de direction	0,0612	.

TABLEAU 6.2: Coefficients des matrices du modèle complet du véhicule.

$$\begin{aligned}
a_{11}(t) &= \frac{-1}{I_z v_x} (C_f l_f^2 + C_r l_r^2) & a_{31}(t) &= \frac{1}{M v_x} (-C_f l_f + C_r l_r) \\
a_{12} &= \frac{1}{I_z} (C_f l_f - C_r l_r) & a_{32} &= \frac{1}{M} (C_f + C_r) \\
a_{13}(t) &= \frac{-1}{I_z v_x} (C_f l_f - C_r l_r) & a_{33}(t) &= \frac{-1}{M v_x} (C_f + C_r) \\
a_{16} &= \frac{C_f l_f}{I_z} & a_{36} &= \frac{C_f}{M} \\
a_{27}(t) &= -v_x & a_{37}(t) &= -v_x^2 \\
a_{55} &= -2\xi w_m & a_{56} &= -w_m^2 \\
b_5 &= w_m^2 \\
c_{22} &= x_m & c_{27} &= 0,5 x_m^2 \\
g_{11} &= \frac{l_f}{I_z} & g_{12} &= \frac{l_r}{I_z} \\
g_3 &= \frac{1}{M} & g_{77} &= w_p
\end{aligned}$$

6.4 Observateur linéaire

Dans cette section, l'observateur utilisé par les constructeurs et envisagé par Renault et Nissan dans le système TJP est présenté. Concrètement, il s'agit d'un observateur linéaire de type Kalman [Kalman, 1960] qui a été développé en supposant la vitesse longitudinale v_x constante (voir la Remarque 6.2) et qui est basé sur le système (6.13). Une des conséquences est que l'observateur ne sera efficace que sur une plage réduite de vitesse. Cela impose de prévoir un observateur par plage de vitesse.

6.4.1 Analyse de l'observabilité

Par définition, le système linéaire TJP (6.13) est *observable* si la matrice d'observabilité O (5.5) vérifie la condition de rang (5.6). Considérons la matrice O définie par

$$O = \begin{bmatrix} C \\ CA \\ (CA^2)_{(1 \times 7)} \end{bmatrix}_{(7 \times 7)} \quad (6.14)$$

où $(CA^2)_{(1 \times 7)}$ est la deuxième ligne de CA^2 . Si O est de rang plein, alors la matrice d'observabilité est de rang plein et le système (6.13) est observable. Afin de vérifier que la matrice O est de rang plein, on calcule son déterminant

$$\det(O) = a_{12}v_x(0,5x_m^2w_p^2 + x_mw_pv_x - v_x^2) \quad (6.15)$$

ce qui implique

$$\det(O) = 0 \quad \text{ssi} \quad v_x^2 - x_mw_pv_x - 0,5x_m^2w_p^2 = 0. \quad (6.16)$$

En considérant la solution positive de (6.16) ($v_x > 0$), le déterminant de O est nul si

$$v_x = \left(\frac{1 + \sqrt{3}}{2} x_m w_p \right) \approx 1,366 x_m w_p. \quad (6.17)$$

Une représentation graphique de la condition (6.17) de perte d'observabilité du système (6.13) est faite selon la vitesse longitudinale v_x , la fréquence de filtrage de la courbure f_p ($f_p = \frac{w_p}{2\pi}$) et la distance longitudinale x_m (voir Figure 6.7). En supposant la distance maximale de détection de l'ensemble caméra/radar à 140 m, on remarque que, pour des vitesses inférieurs à $45 \text{ km} \cdot \text{h}^{-1}$, une contrainte sur la distance longitudinale doit être respectée. En pratique, cette restriction n'est pas gênante car, à basses vitesses, la distance longitudinale de suivi est aussi très faible (par exemple dans les situations d'embouteillage).

Remarque 6.6 La valeur w_p a été fixée (Tableau 6.1) à une valeur de la fréquence de filtrage de la courbure $f_p = 0,01 \text{ Hz}$. Si, dans les futures versions du système TJP, la fréquence de filtrage de la courbure f_p est modifiée, l'observabilité du système sera directement impactée (voir Figure 6.7). ■

6.4.2 Filtre de Kalman

Principe

Dans le monde de l'automobile, le filtre de Kalman est une solution très utilisée pour le filtrage de données et l'estimation d'état à cause de son implémentation aisée dans les calculateurs et de sa bonne robustesse face aux bruits de mesure et perturbations. Pour le système TJP, la non linéarité par rapport à la vitesse longitudinale v_x fait que l'utilisation d'une solution linéaire ne sera réellement efficace que sur une plage de vitesses réduite. Pour cette raison, la solution envisagée par Renault et Nissan est basée sur l'utilisation de plusieurs observateurs de Kalman afin de linéariser la dynamique autour d'une vitesse de référence (VdR) sur une plage de vitesse (PdV) donnée.

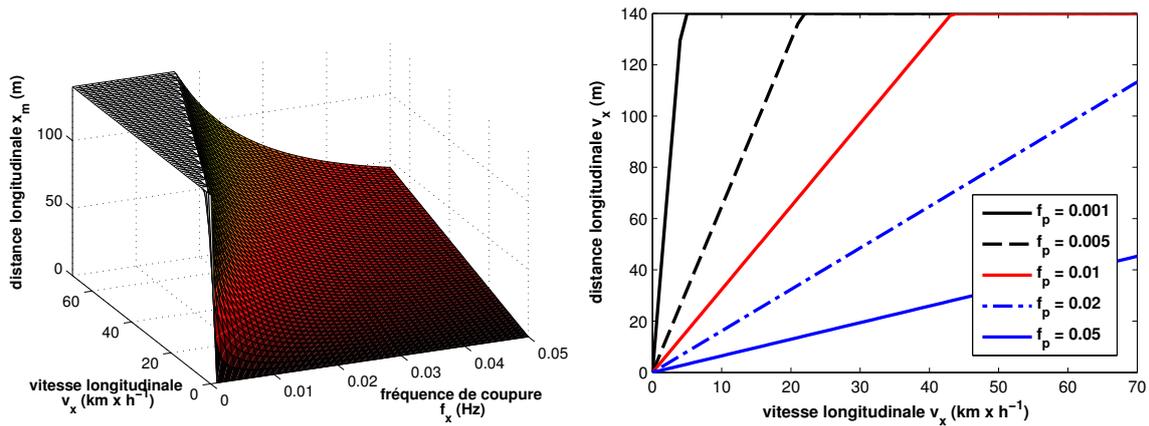


FIGURE 6.7: Représentation des conditions de perte d'observabilité sur v_x , f_p et x_m . (À gauche) Surface dans l'espace (v_x, f_p, x_m) pour lequel le système (6.13) est inobservable ; (à droite) Représentation des combinaisons (v_x, x_m) pour une valeur de f_p donnée pour lesquelles le système (6.13) est inobservable.

Définition 6.1 On appelle "plage de vitesses" (PdV) une gamme de vitesses comprises entre des valeurs de vitesse minimale v_{min} et maximale v_{max} , PdV = $[v_{min} v_{max}]$. ■

Remarque 6.7 Dans le cadre de cette thèse, on considère les vitesses de fonctionnement du système TJP envisagé par Renault/Nissan entre 0,9 et 90 km · h⁻¹, cet intervalle étant divisée par un des algorithmes utilisé par les constructeurs en 10 PdV ($[0,9 5], [5 10], [10 20], \dots, [80 90]$ km · h⁻¹) à partir de 10 "vitesses de référence" (VdR) fixées à $[5 10 20 30 40 50 60 70 80 90]$ km · h⁻¹. ■

En supposant la vitesse longitudinale v_x constante, l'algorithme utilisé par les constructeurs et envisagé par Renault/Nissan propose un observateur de Kalman de (6.13) sous la forme

$$\dot{\hat{x}} = A_k \hat{x} + Bu + L(y - C\hat{x}) \quad (6.18)$$

La matrice des gains de l'observateur L (pour une valeur de v_x fixée) est déterminée à partir de (5.15) en minimisant l'erreur de variance de l'estimation d'état. La matrices de covariance des bruits du système Q et celle de la mesure R sont définies sous la forme

$$Q = \begin{bmatrix} q_{11} & 0 & 0 \\ 0 & q_{22} & 0 \\ 0 & 0 & q_{33} \end{bmatrix} \quad \text{et} \quad R = \begin{bmatrix} r_{11} & 0 & 0 \\ 0 & r_{22} & 0 \\ 0 & 0 & r_{33} \end{bmatrix} \quad (6.19)$$

en désignant par $[q_{11} q_{22} q_{33} r_{11} r_{22} r_{33}]$ les paramètres de mise au point. Les deux matrices précédentes sont définies diagonales car on suppose qu'il n'y a pas de corrélation entre les grandeurs mesurées y .

Fonctionnement et mise au point

Le fonctionnement de l'algorithme utilisé par les constructeurs et envisagé par Renault/Nissan est divisé en deux étapes :

1ère étape : Optimisation.

A partir de la définition des PdV et des VdR de la solution envisagée par Renault/Nissan, une mise au point des paramètres $[q_{11} q_{22} q_{33} r_{11} r_{22} r_{33}]$ de l'observateur (6.18) est fait pour chaque VdR en fixant la valeur de la vitesse longitudinale (supposée constante). Comme chaque VdR a 6 paramètres de mise au point, l'algorithme a au total 60 paramètres. Une fois toutes les VdR optimisées, les matrices L correspondant à chaque VdR sont stockées dans le calculateur.

La mise au point de l'algorithme a été faite jusqu'à présent manuellement. Il s'agit d'un réglage fait sur véhicule par un ingénieur spécialisé dans le domaine qui optimise l'algorithme pour toutes les VdR. Cette mise au point est fastidieuse, car il y a beaucoup de paramètres de réglage, et elle prend beaucoup de temps (plusieurs jours de travail, réservation de pistes d'essai, utilisation d'un prototype...).

Une des contributions de la thèse a été d'adapter la méthode d'optimisation KEEP (Chapitre 3) pour la mise au point de l'observateur de Kalman de la solution envisagée par Renault/Nissan. Afin d'automatiser cette tâche, une interface graphique a été créée. Toute l'information concernant la mise au point de la solution envisagée par Renault/Nissan est détaillée à l'Annexe B. ■

2ème étape : Interpolation.

Bien que le réglage de l'observateur soit fait pour 1 VdR, le système TJP fonctionne à vitesse variable. Pour résoudre cette problématique, l'observateur (6.18) utilise les matrices A_k et L , qui ont été considérées constantes pendant la synthèse de l'observateur, mais dans les faits variables dans le temps. Aussi, la matrice $A_k(t)$ est calculée en utilisant la vraie valeur de la vitesse longitudinale $v_x(t)$ et la matrice $L(t)$ est calculée à chaque instant grâce à une *interpolation*. Cette interpolation linéaire est définie par

$$L(t) = \frac{v_{max}(t) - v_x(t)}{v_{max}(t) - v_{min}(t)} L_{v_{min}}(t) + \frac{v_x(t) - v_{min}(t)}{v_{max}(t) - v_{min}(t)} L_{v_{max}}(t) \quad (6.20)$$

en désignant par $v_{min}(t)$ et $v_{max}(t)$ les valeurs extrêmes de la PdV de $v_x(t)$, et $L_{v_{min}}(t)$ et $L_{v_{max}}(t)$ les matrices L optimisées au VdR $v_{min}(t)$ et $v_{max}(t)$.

Exemple 1 : Supposons que les matrices L ont été optimisées pour l'ensemble des VdR (1ère étape de l'algorithme). Si la vitesse actuelle $v_x(t)$ est de $28 \text{ km} \cdot \text{h}^{-1}$ ($v_x(t) \in PdV = [v_{min}(t) \ v_{max}(t)] = [20 \ 30] \text{ km} \cdot \text{h}^{-1}$), la matrice de gains de l'observateur de Kalman $L(t)$ est calculée à partir de (6.20), ce qui donne $L(t) = 0,2L_{20} + 0,8L_{30}$.

Exemple 2 : Considérons un élément de la matrice L ($L_{2,3}$). La Figure 6.8 donne les valeurs obtenues en utilisant l'interpolation linéaire (6.20) par rapport à la vitesse longitudinale. Concrètement, deux interpolations ont été réalisées à partir des matrices L optimisées par KEEP : la première utilise les VdR correspondant à l'algorithme utilisé par les constructeurs $[5 \ 10 \ 20 \ 30 \ 40 \ 50 \ 60] \text{ km} \cdot \text{h}^{-1}$, la seconde utilise un nombre élevé de VdR définies entre 0 et $60 \text{ km} \cdot \text{h}^{-1}$ avec un pas de $2 \text{ km} \cdot \text{h}^{-1}$.

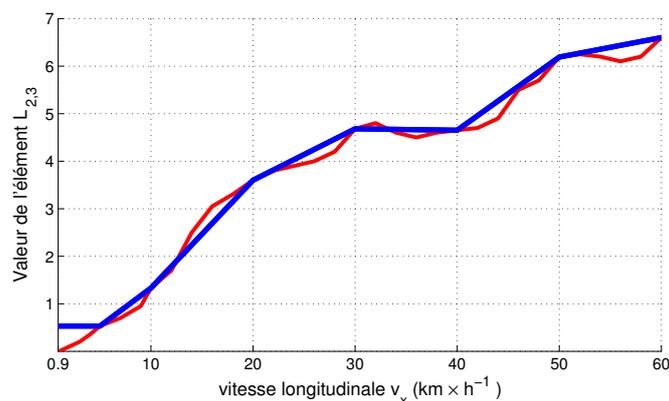


FIGURE 6.8: Exemple d'interpolation linéaire d'un élément de la matrice de gain L ($L_{3,2}$) en fonction de la vitesse longitudinale. (En bleu) l'interpolation obtenue avec les VdR de l'algorithme envisagé par Renault/Nissan ; (en rouge) l'interpolation obtenue avec les VdR définies avec un pas de $2 \text{ km} \cdot \text{h}^{-1}$.

Les résultats obtenus montrent qu'en pratique, la linéarisation des coefficients de L proposées par la solution classique n'est pas loin des valeurs obtenues en utilisant un nombre élevé de VdR. Néanmoins, notons que si la vitesse du véhicule est inférieure à $5 \text{ km} \cdot \text{h}^{-1}$, la valeur des coefficients de L proposée

par l'algorithme utilisé par les constructeurs est fixée à L_5 . ■

Bien que l'algorithme classique des constructeurs propose d'utiliser une solution linéaire standard et robuste (observateur de Kalman), quelques *problématiques* et contreparties techniques sont à relever en raison de la linéarisation des dynamiques latérales du véhicule et de la matrice de gains L :

- L'algorithme utilisé par les constructeurs a été déjà testé en simulation et embarqué sur un véhicule, obtenant dans les deux cas une performance d'estimation de l'état acceptable à partir de l'observateur de Kalman. Néanmoins, il n'y a pas de preuve formelle de la convergence de l'observateur en raison du caractère variable de la matrice de gain L et des approximations d'interpolation.
- Chaque vitesse de référence a besoin d'une mise au point indépendante (10 VdR en total). La complexité du modèle fait qu'un *réglage manuel* est fastidieux et complexe avec des paramètres qui ont un sens physique peu évident. De plus, une nouvelle mise au point devrait être faite pour chaque nouveau modèle de véhicule car les paramètres et constantes du véhicule varient d'un modèle à l'autre.
- Le nombre de gains de l'observateur à régler est élevé, 60 au total. De plus, plusieurs matrices L (1 matrice L par VdR) devront être pré-enregistrées dans le calculateur, ce qui augmente l'espace de mémoire nécessaire (10 matrices L de taille 7×3 donnent un total de 210 valeurs à stocker). La complexité du système TJP (contrôle latéral + contrôle longitudinal) impose que l'espace de la mémoire soit limité.
- L'utilisation d'un observateur de Kalman (6.18) est une solution robuste avec une estimation de l'état acceptable (déjà testé sur voitures réelles). Néanmoins, à basse vitesse, l'estimation de l'état est peu précise, ce qui entraîne une altération de la précision d'estimation (voir estimation des coefficients L à basse vitesse sur la Figure 6.8).

Nous avons déposé un brevet [Davins-Vallaura et al., 2015a] afin de réduire les inconvénients de l'observateur de Kalman. La solution proposée est d'utiliser une technique basée sur la *réduction* du nombre de PdV en fixant les VdR de manière optimale (les VdR sont fixées *a priori*). Cette idée est très intéressante car il avait été remarqué pendant l'optimisation de l'algorithme envisagée par Renault/Nissan que la plupart des gains de l'observateur sont plus variants à basse vitesse que à haute vitesse, ce qui fait qu'une solution est de considérer des plages de vitesse moins larges à basse vitesse et plus larges à haute vitesse (voir Figure 6.9). De plus, une réduction du nombre de VdR fait que la mise au point est plus rapide car il y a moins de gains de l'observateur à régler.

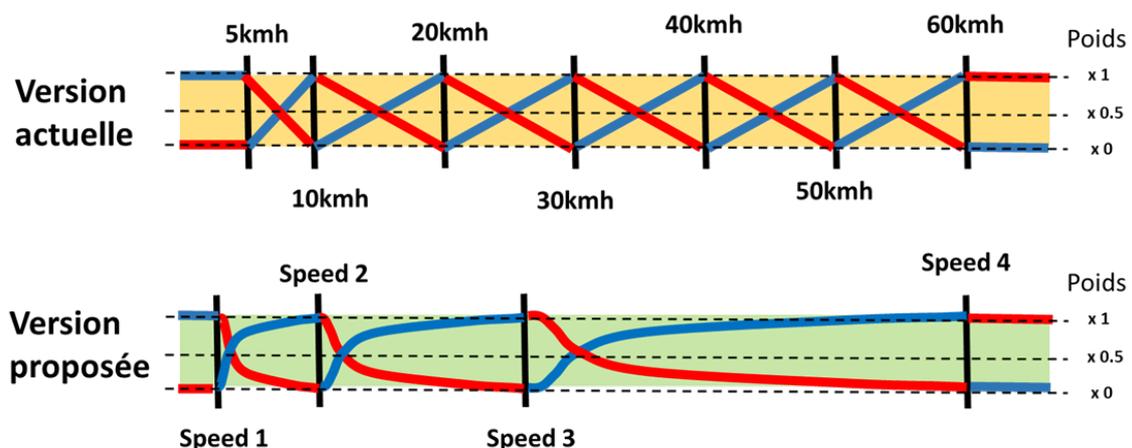


FIGURE 6.9: Représentation graphique des poids de chaque vitesse de référence (VdR) en utilisant l'interpolation linéaire (algorithme envisagée par Renault/Nissan) et en utilisant l'interpolation non linéaire (version proposée, plages de vitesse variables). (En noir) les vitesses de référence, (en bleu) le poids correspondant aux paramètres réglés à la plage de vitesse supérieure ($poids_{v_{max}}$) et (en rouge) le poids correspondant aux paramètres réglés à la plage de vitesse inférieure ($poids_{v_{min}}$).

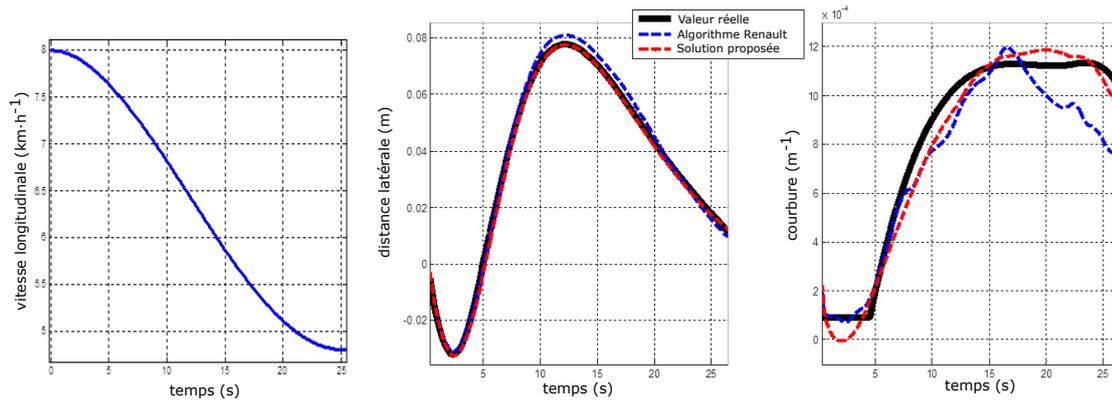


FIGURE 6.10: Exemple de l'estimation de la distance latérale et la courbure à basse vitesse en utilisant l'interpolation linéaire (algorithme classique) et l'interpolation non linéaire (solution proposée) en simulation.

Une deuxième idée a été de proposer une interpolation non linéaire de L . Parmi une liste de méthodes d'interpolation non linéaires (Gregory-Newton, Lagrange, polynomiale, géométrique, splines ...), on a cherché une méthode simple et facile à calculer car elle doit être implantée dans un calculateur. L'interpolation non linéaire choisie est

$$L(t) = \underbrace{\frac{P_{A1}(t)P_{A2}(t)}{P_{A1}(t)P_{A2}(t) + P_{B1}(t)P_{B2}(t)}}_{\text{poids}_{v_{\min}}} L_{v_{\min}}(t) + \underbrace{\frac{P_{B1}(t)P_{B2}(t)}{P_{A1}(t)P_{A2}(t) + P_{B1}(t)P_{B2}(t)}}_{\text{poids}_{v_{\max}}} L_{v_{\max}}(t) \quad (6.21)$$

avec

$$d(t) = v_{\max}(t) - v_{\min}(t); \quad d_{\max}(t) = v_{\max2}(t) - v_{\max}(t); \quad d_{\min}(t) = v_{\min}(t) - v_{\min2}(t);$$

$$P_{A1}(t) = \frac{v_{\max}(t) - v_x(t)}{d(t)}; \quad P_{A2}(t) = \frac{v_{\max}(t) - v_x(t)}{d(t) + d_{\max}(t)}; \quad P_{B1}(t) = \frac{v_x(t) - v_{\min}(t)}{d(t)}; \quad P_{B2}(t) = \frac{v_x(t) - v_{\min}(t)}{d(t) + d_{\min}(t)}.$$

A titre d'exemple (voir Figure 6.10), une simulation (à partir de données simulées, non de données réelles) à basse vitesse a été réalisée afin de comparer les performances de l'algorithme envisagée par Renault/Nissan avec l'interpolation (6.20) et la solution proposée basée sur l'interpolation (6.21). Les résultats obtenus montrent une amélioration significative de l'estimation de la courbure ; une plus faible amélioration mais néanmoins réelle sur l'estimation de la distance latérale est aussi constatée (mais seulement de quelque centimètre).

Remarque 6.8 Pour le reste du manuscrit, l'algorithme classique utilisé par les constructeurs et envisagée par Renault/Nissan (observateur de Kalman) basé sur l'interpolation linéaire (6.20) sera la solution de référence utilisée pour la comparaison des performance des observateurs. ■

6.5 Observateurs non linéaires

Les travaux de cette thèse, sur le contrôle latéral du système TJP, se sont également focalisés sur la proposition de nouveaux observateurs non linéaires. Comme dit précédemment, la solution basée sur un observateur linéaire de Kalman présente des inconvénients qui incitent à l'utilisation d'observateurs non linéaires : par exemple, l'idée est d'avoir un unique observateur pour toute valeur de vitesse longitudinale, ce qui induit une mise au point facilitée par un nombre réduit de paramètres à régler.

Considérons le système (6.9) sous la forme non linéaire suivante

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}, t) + \chi(u, \mathbf{y}) + \Delta \mathbf{f}(\mathbf{x}, t) \\ \mathbf{y} = \mathbf{h}(\mathbf{x}) \end{cases} \quad (6.22)$$

avec

$$f(\mathbf{x}) = \begin{bmatrix} a_{11}(t)x_1 + a_{12}x_2 + a_{13}(t)x_3 + a_{16}x_6 \\ x_1 + a_{27}(t)x_7 \\ a_{31}(t)x_1 + a_{32}x_2 + a_{33}(t)x_3 + a_{36}x_6 + a_{37}(t)x_7 \\ x_3 \\ a_{55}x_5 + a_{56}x_6 \\ x_5 \\ 0 \end{bmatrix}, \chi(\mathbf{y}, \mathbf{u}) = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ b_5u \\ 0 \\ 0 \end{bmatrix} \text{ et } \Delta f = \begin{bmatrix} \eta_1 \\ 0 \\ \eta_3 \\ 0 \\ 0 \\ 0 \\ \eta_7 \end{bmatrix}$$

où $f(\mathbf{x}, t)$ est dépendant de l'état et de paramètres variants dans le temps, $\chi(\mathbf{u}, \mathbf{y})$ un terme dépendant de la sortie et l'entrée (*i.e* de grandeurs connues), et $\Delta f(\mathbf{x}, t)$ le terme de dynamiques inconnues du système (avec η_1 et η_3 liés à w_f^n et w_r^n , et η_7 équivalent à la fonction variante dans le temps $r(t)$ du système (6.9)). La sortie mesurée est définie par la fonction $\mathbf{h}(\mathbf{x}) = [h_1(\mathbf{x}) \ h_2(\mathbf{x}) \ h_3(\mathbf{x})]^T = [y_1 \ y_2 \ y_3]^T = [x_1 \ c_{22}x_2 + x_4 + c_{27}x_7 \ x_6]^T$, qui correspond à la mesure de la vitesse angulaire de lacet (y_1), la distance latérale mesurée par la caméra (y_2) et l'angle de braquage des roues (y_3).

Afin de tester l'observabilité du système (6.22) à partir du vecteur de sortie \mathbf{y} , on a besoin des expressions analytiques suivantes

$$\begin{aligned} y_1 &= x_1 ; \\ \dot{y}_1 &= a_{11}(t)x_1 + a_{12}x_2 + a_{13}(t)x_3 + a_{16}x_6 ; \\ \ddot{y}_1 &= (\dot{a}_{11}(t) + a_{11}(t)^2 + a_{12} + a_{13}(t)a_{31}(t))x_1 + (a_{11}(t)a_{12} + a_{13}(t)a_{32})x_2 + \\ &\quad + (a_{11}(t)a_{13}(t) + a_{13}(t)a_{33}(t) + \dot{a}_{13}(t))x_3 + a_{16}x_5 + (a_{11}(t)a_{16} + a_{13}(t)a_{36})x_6 + \\ &\quad + (a_{12}a_{27}(t) + a_{13}(t)a_{37})x_7 ; \\ y_2 &= c_{22}x_2 + x_4 + c_{27}x_7 ; \\ \dot{y}_2 &= c_{22}x_1 + x_3 + a_{27}(t)x_7 ; \\ \ddot{y}_2 &= (c_{22}a_{11}(t) + a_{31}(t))x_1 + (c_{22}a_{12}(t) + a_{32}(t))x_2 + (c_{22}a_{13}(t) + a_{33}(t))x_3 + \\ &\quad + (c_{22}a_{16} + a_{36})x_6 + (a_{37}(t) + \dot{a}_{27}(t))x_7 ; \\ y_3 &= x_6 ; \\ \dot{y}_3 &= x_5 ; \\ \ddot{y}_3 &= a_{55}x_5 + a_{56}x_6 + b_5u . \end{aligned} \tag{6.23}$$

Hypothèse 6.6 Notons que la dérivée du terme $a_{27}(t) = -v_x$, $\dot{a}_{27}(t) = -a_x$, apparait dans l'expression analytique de \ddot{y}_2 , v_x étant la vitesse longitudinale et a_x l'accélération longitudinale. Ce terme $\dot{a}_{27}(t)$ sera supposé nul pour la synthèse de l'observateur, ce qui n'est pas une hypothèse forte car il est multiplié par la courbure x_7 laquelle admet, dans les conditions normales de fonctionnement, de faibles valeurs. Néanmoins, ce terme sera pris en compte pour la vérification de l'observabilité du système (6.22). ■

Hypothèse 6.7 La distance longitudinale entre véhicules x_m , laquelle apparaît dans les termes c_{22} et c_{27} , est considérée constante. D'un point de vue applicatif, ce n'est pas gênant car le contrôle longitudinal du véhicule est supposé assurer cette distance constante. ■

6.5.1 Observabilité et condition d'observabilité

Toutes les incertitudes, perturbations et approximations liées aux Hypothèses 6.6 et 6.7 sont supposées contenues dans le terme $\Delta f(\mathbf{x}, t)$ du système (6.22). ■

Hypothèse 6.8 Les dynamiques inconnues du système $\Delta f(\mathbf{x}, t)$ n'affectent pas l'observabilité du système (6.22). ■

L'Hypothèse 6.8 signifie que, par tout $\Delta f(\mathbf{x}, t)$, l'observabilité du système (6.22) ne sera pas modifiée. Par conséquent, par souci de simplicité, l'analyse de l'observabilité est fait en considérant $\Delta f(\mathbf{x}, t)$ nul. Notons, que d'un point de vue pratique, l'Hypothèse 6.8 n'est pas restrictive car η_1 et η_3 sont liés à des bruits bornés et η_7 lié à la courbure, laquelle évolue lentement par rapport aux autres dynamiques de l'état. Définissons l'application $\Gamma(\mathbf{x})$ comme

$$\Gamma(\mathbf{x}) = [y_1 \dot{y}_1 y_2 \dot{y}_2 \ddot{y}_2 y_3 \dot{y}_3]^T \quad (6.24)$$

Le système (6.22) est observable si le rang du jacobien de $\Gamma(\mathbf{x})$ est plein ; de manière équivalente, on peut vérifier que le déterminant du jacobien de $\Gamma(\mathbf{x})$ est toujours différent à 0 dans le domaine de travail. À partir de (6.22) et (6.24) (avec $a_{27}(t) = 0$; voir Hypotèse 6.6), le déterminant du jacobien de $\Gamma(\mathbf{x})$ s'écrit

$$\det \left[\frac{\partial \Gamma}{\partial \mathbf{x}} \right] = \frac{-1}{I_z} (C_f l_f - C_r l_r) (v_x^2 + a_x) \quad (6.25)$$

en désignant par a_x l'accélération longitudinale. Notons que le terme $(C_f l_f - C_r l_r)$ a une valeur constante et non nulle. Aussi, le système ne sera observable que si le déterminant du jacobien est non nul, c'est-à-dire $v_x^2 \neq -a_x$.

La Figure 6.11 représente les contraintes sur l'accélération longitudinale en fonction de la vitesse longitudinale selon la norme ISO 22179 [Organization for Standardization, 2009], les limitation d'usage du TJP en fonction de la vitesse, ainsi que le domaine pour lequel le système (6.22) est inobservable (ligne rouge) ou observable (domaine opérationnel représenté par une zone blanche). Pour tous les tests réalisés dans cette thèse, la relation entre vitesse longitudinale et accélération longitudinale sera évaluée pour vérifier que le système est observable.

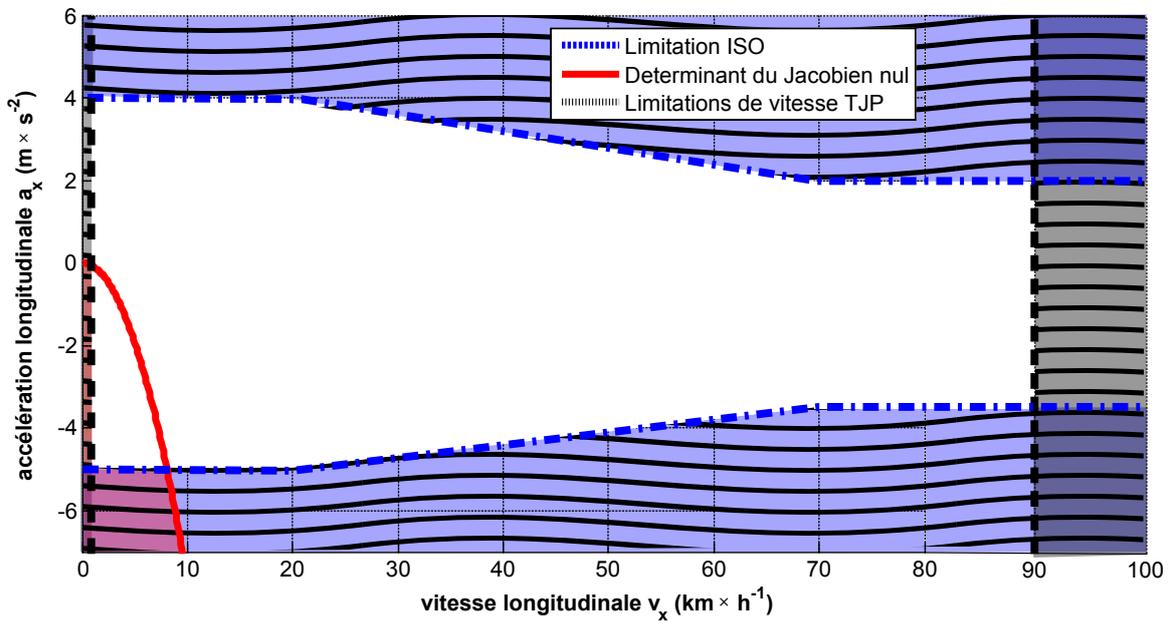


FIGURE 6.11: Problème du Jacobien en utilisant la dérivée des paramètres.

Remarque 6.9 Comme la transformation de coordonnées $\Gamma(\mathbf{x})$ (6.24) est un difféomorphisme du système (6.22) dans le domaine opérationnel, les indices d'observabilité (Remarque 5.7) sont $[k_1 \ k_2 \ k_3] = [2 \ 3 \ 2]$, $k_i (i \in \{1, 2, 3\})$ étant l'indice d'observabilité de la sortie y_i . ■

6.5.2 Forme canonique d'observabilité

Considérons le difféomorphisme $\zeta = \Gamma(\mathbf{x})$ défini par (6.24) : un système localement équivalent à (6.22) (détaillé Section 5.3.1) s'écrit

$$\begin{aligned} \dot{\zeta} &= \underbrace{\begin{bmatrix} 0 & 1 & | & 0 & 0 & 0 & | & 0 & 0 \\ 0 & 0 & | & 0 & 0 & 0 & | & 0 & 0 \\ \hline 0 & 0 & | & 0 & 1 & 0 & | & 0 & 0 \\ 0 & 0 & | & 0 & 0 & 1 & | & 0 & 0 \\ 0 & 0 & | & 0 & 0 & 0 & | & 0 & 0 \\ \hline 0 & 0 & | & 0 & 0 & 0 & | & 0 & 1 \\ 0 & 0 & | & 0 & 0 & 0 & | & 0 & 0 \end{bmatrix}}_{A_\zeta} \zeta + \underbrace{\begin{bmatrix} 0 \\ \Phi_1(\zeta) \\ 0 \\ 0 \\ \Phi_2(\zeta) \\ 0 \\ \Phi_3(\zeta) \end{bmatrix}}_{\Phi_\zeta} \\ \mathbf{y} &= \underbrace{\begin{bmatrix} 1 & 0 & | & 0 & 0 & 0 & | & 0 & 0 \\ 0 & 0 & | & 1 & 0 & 0 & | & 0 & 0 \\ 0 & 0 & | & 0 & 0 & 0 & | & 1 & 0 \end{bmatrix}}_{C_\zeta} \zeta \end{aligned} \quad (6.26)$$

où $\Phi_1(\zeta) = \ddot{y}_1$, $\Phi_2(\zeta) = \ddot{y}_2$, $\Phi_3(\zeta) = \ddot{y}_3$. En raison de la présence de termes incertains, chaque fonction Φ_i ($i \in \{1, 2, 3\}$) est écrite comme la somme d'un terme nominal Φ_i^N et d'un terme incertain $\Delta\Phi_i$

$$\Phi_\zeta = \underbrace{\begin{bmatrix} 0 \\ \Phi_1^N \\ 0 \\ 0 \\ \Phi_2^N \\ 0 \\ \Phi_3^N \end{bmatrix}}_{\Phi_\zeta^N} + \underbrace{\begin{bmatrix} 0 \\ \Delta\Phi_1 \\ 0 \\ 0 \\ \Delta\Phi_2 \\ 0 \\ \Delta\Phi_3 \end{bmatrix}}_{\Delta\Phi_\zeta} \quad (6.27)$$

Supposons qu'un observateur de (6.26) s'écrive

$$\dot{\hat{\zeta}} = A_\zeta \hat{\zeta} + \Phi_\zeta^N(\hat{\zeta}) + \kappa(\mathbf{y}, \hat{\zeta}) \quad (6.28)$$

en désignant par $\kappa(\mathbf{y}, \hat{\zeta})$ le dite *terme correcteur* (Définition 5.10); notons que ce observateur est composé d'une copie du système et du terme correcteur. À partir de la synthèse de l'observateur réalisée Section 5.3.1), un observateur pour le système (6.22) est

$$\dot{\hat{\mathbf{x}}} = f(\hat{\mathbf{x}}, t) + \chi(\mathbf{y}, u) + \left[\frac{\partial \Gamma}{\partial \hat{\mathbf{x}}} \right]^{-1} \kappa(\mathbf{y}, \hat{\mathbf{x}}). \quad (6.29)$$

Un choix adéquat du terme $\kappa(\mathbf{y}, \hat{\mathbf{x}})$ permet de garantir $\hat{\mathbf{x}} \rightarrow \mathbf{x}$ (ou au minimum dans un voisinage) malgré le terme incertain $\Delta f(\mathbf{x}, t)$. Dans la suite, deux types d'observateurs seront appliqués : un observateur à grand gain et un observateur par mode glissant d'ordre supérieur.

6.5.3 Observateur à grand gain [Gauthier et al., 1992]

Comme présenté Section 5.3.2, un observateur à grand gain sous la forme (6.29) a un terme correcteur défini par

$$\kappa(\mathbf{y}, \hat{\mathbf{x}}) = \Lambda^T K(\mathbf{y} - C_\zeta \hat{\mathbf{x}}) \quad (6.30)$$

avec les matrices de gain suivantes

$$K = \begin{bmatrix} K_1 & 0 & 0 \\ K_2 & 0 & 0 \\ 0 & K_3 & 0 \\ 0 & K_4 & 0 \\ 0 & K_5 & 0 \\ 0 & 0 & K_6 \\ 0 & 0 & K_7 \end{bmatrix}; \Lambda = \begin{bmatrix} \tau_1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & \tau_1^2 & 0 & 0 & 0 & 0 & 0 & 0 \\ \hline 0 & 0 & \tau_2 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & \tau_2^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & \tau_2^3 & 0 & 0 & 0 \\ \hline 0 & 0 & 0 & 0 & 0 & \tau_3 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & \tau_3^2 & 0 \end{bmatrix} \quad (6.31)$$

où $A_\zeta - KC_\zeta$ doit être *Hurwitz* (valeurs propres de la matrice à partie réelle strictement négative) et $\tau_1, \tau_2, \tau_3 > 0$.

Remarque 6.10 *L'observateur à grand gain proposé a donc un total de 10 paramètres de réglage :*

$$[\tau_1 \ \tau_2 \ \tau_3 \ K_1 \ K_2 \ K_3 \ K_4 \ K_5 \ K_6 \ K_7]$$

6.5.4 Observateur par mode glissant [Levant, 1993]

Le second type d'observateur utilisé est basé sur la différentiation par mode glissant d'ordre supérieur introduit dans Section 5.3.3.

Hypothèse 6.9 *Dans l'espace opérationnel du système (6.26), les constantes positives connues L_{Φ_1} , L_{Φ_2} et L_{Φ_3} sont définies par*

$$|\Phi_1^N(\zeta)| \leq L_{\Phi_1}, |\Phi_2^N(\zeta)| \leq L_{\Phi_2}, |\Phi_3^N(\zeta)| \leq L_{\Phi_3} \quad (6.32)$$

Alors, l'observateur par mode glissant d'ordre supérieur est défini par

$$\begin{aligned} \dot{\hat{\zeta}}_1 &= \hat{\zeta}_2 - \underbrace{s_1 L_{\Phi_1}^{\frac{1}{2}} |\hat{\zeta}_1 - y_1|^{\frac{1}{2}} \text{sign}(\hat{\zeta}_1 - y_1)}_{\gamma_1} \\ \dot{\hat{\zeta}}_2 &= \Phi_1(\hat{\zeta}) - \underbrace{s_2 L_{\Phi_1} \text{sign}(\gamma_1)}_{\gamma_2} \\ \dot{\hat{\zeta}}_3 &= \hat{\zeta}_4 - \underbrace{s_3 L_{\Phi_2}^{\frac{1}{3}} |\hat{\zeta}_3 - y_2|^{\frac{2}{3}} \text{sign}(\hat{\zeta}_3 - y_2)}_{\gamma_3} \\ \dot{\hat{\zeta}}_4 &= \hat{\zeta}_5 - \underbrace{s_4 L_{\Phi_2}^{\frac{1}{2}} |\gamma_3|^{\frac{1}{2}} \text{sign}(\gamma_3)}_{\gamma_4} \\ \dot{\hat{\zeta}}_5 &= \Phi_2(\hat{\zeta}) - \underbrace{s_5 L_{\Phi_2} \text{sign}(\gamma_4)}_{\gamma_5} \\ \dot{\hat{\zeta}}_6 &= \hat{\zeta}_7 - \underbrace{s_6 L_{\Phi_3}^{\frac{1}{2}} |\hat{\zeta}_6 - y_3| \text{sign}(\hat{\zeta}_6 - y_3)}_{\gamma_6} \\ \dot{\hat{\zeta}}_7 &= \Phi_3(\hat{\zeta}) - \underbrace{s_7 L_{\Phi_3} \text{sign}(\gamma_6)}_{\gamma_7} \end{aligned} \quad (6.33)$$

en désignant par $L_{\Phi_{1,2,3}}$ et $s_{1..7}$ les paramètres de réglage de l'observateur. Finalement, en considérant $\hat{\zeta} = \Gamma(\hat{x})$, le terme correcteur $\kappa(\mathbf{y}, \hat{x})$ (voir Section 5.3.2) est défini par

$$\kappa(\mathbf{y}, \hat{x}) = -[\gamma_1 \ \gamma_2 \ \gamma_3 \ \gamma_4 \ \gamma_5 \ \gamma_6 \ \gamma_7]^T. \quad (6.34)$$

Remarque 6.11 A partir de (6.33), l'observateur par mode glissant a au total 10 paramètres de réglage

$$[L_{\Phi_1} \ L_{\Phi_2} \ L_{\Phi_3} \ s_1 \ s_2 \ s_3 \ s_4 \ s_5 \ s_6 \ s_7].$$

Si les gains $s_{1..7}$ sont fixées en utilisant les valeurs standard proposées par [Levant, 2012] (voir Tableau 5.1), alors il n'y aura que 3 paramètres à régler. ■

6.6 Optimisation du réglage des observateurs non linéaires

Pour assurer la viabilité et la faisabilité des observateurs proposés dans ce chapitre dans un contexte réel et industriel, une approche d'optimisation est introduite pour le réglage de leurs gains en utilisant une *grand base de données* (gBdD). Cette base de données est composée d'un grand nombre de scénarios représentatifs de conditions réelles : configurations du véhicule, type de route, météorologie, style de conduite, type de pneumatiques et charge du véhicule. La procédure de mise au point permet d'optimiser le réglage des gains de l'observateur au regard des performances d'estimation.

Tout d'abord, les critères d'optimisation utilisés pour calculer les performances de l'observateur sont définis; ensuite, la méthode de mise au point permettant de trouver automatiquement la configuration optimale de l'observateur est introduite. Notons que cette procédure de réglage optimale basée sur une gBdD est très originale dans un contexte de mise au point d'observateurs non linéaires, ce qui la rend très intéressante pour son utilisation dans des systèmes et applications industriels.

6.6.1 Critères de performance

Les critères de performance sont basés sur l'estimation de l'état, concrètement sur l'estimation de variables d'état dont la vraie valeur est disponible dans la gBdD grâce à l'utilisation de capteurs spécifiques, ces variables n'étant pas mesurées sur un véhicule standard. Il s'agit par exemple des variables inconnues y_t , ψ_r et ρ . Notons que l'angle relatif de lacet ψ_r a une valeur dépendant directement de la courbure de la route ρ (6.7), ce qui permet de supposer qu'une optimisation de l'estimation de ρ induit une bonne estimation de ψ_r .

Les critères de performance retenus pour l'optimisation des observateurs non linéaires du TJP sont

1. **Estimation de l'Erreur Relative de la Courbure (EERC).** Ce critère est défini par

$$\text{EERC} (\%) = 100 \times \frac{\sum |e_\rho|}{\sum |\rho|}. \quad (6.35)$$

en désignant par $|e_\rho| = |\hat{\rho} - \rho|$ l'erreur absolue d'estimation de la courbure et \sum l'addition de la valeur obtenue à chaque instant d'échantillonnage pendant l'ensemble du scénario. La valeur réelle de la courbure ρ est obtenue en utilisant les mesures du marquage sur chaussée fournies par la caméra (information non disponible dans le contexte de situations difficiles mais disponible sur les nombreux scénarios de la gBdD). De plus, la dynamique de ρ est supposée suffisamment faible pour que la courbure de la trajectoire du véhicule cible et la courbure de la route soient supposées identiques.

2. **Estimation de l'Erreur Relative de la Distance Latérale (EERDL).** Ce critère est défini par

$$\text{EERDL} (\%) = 100 \times \frac{\sum |e_{y_t}|}{\sum |y_t|}. \quad (6.36)$$

en désignant par $|e_{y_t}| = |\hat{y}_t - y_t|$ l'erreur d'estimation absolue de la distance latérale. La valeur réelle de la distance latérale y_t est également obtenue en utilisant les mesures du marquage sur chaussée fournies par la caméra et la position du véhicule cible, ce qui permet d'identifier la trajectoire à suivre et l'écart latéral.

L'utilisation d'autres critères de performance de l'observateur avec les autres variables d'état permettrait d'améliorer la qualité de l'optimisation. Néanmoins, seuls deux objectifs ont été utilisés pour les raisons suivantes

- l'utilisation de critères additionnels augmente la difficulté du problème multi-objectif à résoudre, et par conséquent, le temps total de calcul de l'optimisation ;
- la distance latérale y_t et la courbure ρ sont considérées comme les variables d'état les plus difficiles à estimer par le système TJP. Rappelons que la valeur de l'angle de braquage des roues α et la vitesse angulaire de lacet ψ_r sont des variables d'état mesurées directement par le système (y_1 et y_3).

6.6.2 Optimisation des gains de l'observateur

Le réglage optimal des paramètres des observateurs requiert l'évaluation des performances de toute la gBdD pour l'ensemble des configurations des paramètres à évaluer. Cependant, la gBdD doit être représentative en prenant en compte suffisamment de scénarios, ce qui fait que la taille de la gBdD doit être importante et que chaque évaluation de la performance sera coûteuse en temps de calcul. Le problème est que les constructeurs automobiles ont besoin que le prototypage soit le plus rapide possible. Dans ce contexte, la mise au point des gains des observateurs utilisés pour le système TJP peut être vue comme un problème d'optimisation globale de fonction coûteuse (Parte I de la thèse).

La méthode utilisée pour l'optimisation est l'algorithme KEEP (Chapitre 3), qui permettra de réaliser l'optimisation avec un nombre limité d'évaluations. Cette méthode est une extension des algorithmes d'optimisation globale classiques ParEGO (Section 2.3.3) et EGO (Section 2.2.8). L'idée de base est d'utiliser des modèles de substitution (Section 2.2.4) pour estimer les résultats obtenus de chaque critère par un réglage de paramètres. L'avantage des modèles de substitution est qu'ils sont utilisés par les algorithmes d'optimisation pour proposer rapidement (avec un faible coût de calcul) une configuration de paramètres qui sera simulée en utilisant toute la gBdD. La structure du KEEP adaptée à la mise au point des gains des observateurs du système TJP est représentée par la Figure 6.12.

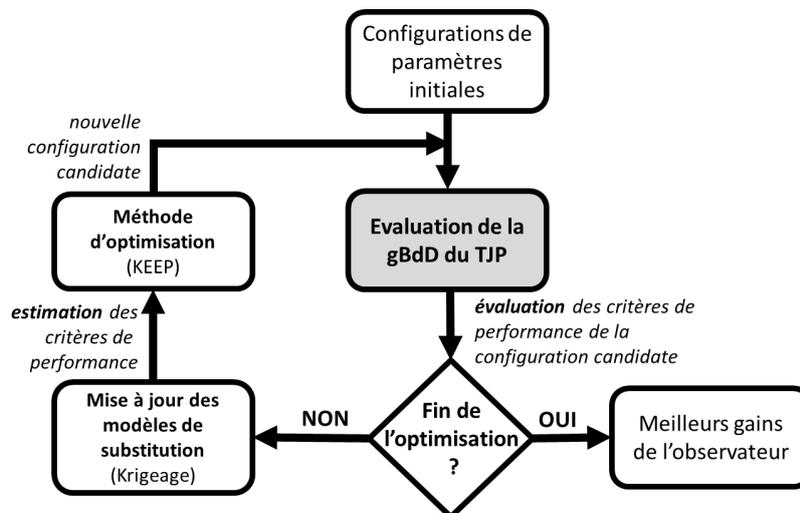


FIGURE 6.12: Structure de la mise au point des observateurs du système TJP en utilisant l'algorithme KEEP.

6.6.3 Résultats de l'optimisation des observateurs

Les deux observateurs à mettre au point, l'observateur à grand gain (6.29)-(6.30) et l'observateur par mode glissant (6.29)-(6.34), ont chacun 10 paramètres à optimiser (voir les Remarques 6.10-6.11). Les critères d'optimisation à minimiser sont l'estimation de l'erreur relative de la courbure EERC (6.35) et de la distance latérale EERDL (6.36).

Avant d'utiliser la nouvelle procédure de mise au point, un **réglage manuel** a été réalisé en utilisant une petite partie de la gBdD; néanmoins, cette tâche est restée très fastidieuse à cause du temps de simulation et de la non-connaissance des corrélations entre paramètres. La configuration de paramètres retenue est celle qui a permis d'avoir un bon compromis d'estimation de toutes les variables d'état. Les configurations de paramètres obtenues grâce à cette mise au point manuelle sont

1. Gains de l'observateur à grand gain (6.31).

$$\begin{aligned} [K_1 \dots K_7] &= [2 \ 0,1 \ 2 \ 0,8 \ 0,05 \ 2 \ 0,1] \\ [\tau_1 \ \tau_2 \ \tau_3] &= [50 \ 0,05 \ 50] \end{aligned} \quad (6.37)$$

2. Gains de l'observateur par mode glissant (6.33-6.34).

$$\begin{aligned} [L_{\Phi_1} \ L_{\Phi_2} \ L_{\Phi_3}] &= [10^{-6} \ 0,8 \ 10^{-6}] \\ [s_1 \dots s_7] &= [1,5 \ 1,1 \ 3 \ 1,5 \ 1,1 \ 1,5 \ 1,1] \end{aligned} \quad (6.38)$$

en utilisant les gains $s_{1\dots 7}$ proposés par [Levant, 2012] (voir Tableau 5.1).

L'optimisation des paramètres des observateurs avec KEEP a la contrainte qu'une évaluation de la fonction objectif (simulation de toute la gBdD) est très coûteuse en temps, sachant que le nombre minimum d'itérations à réaliser pour l'optimisation est de 33 fois le nombre de paramètres à optimiser [Davins-Valldaura et al., 2015b], ce qui donne un total de 330 évaluations. Ainsi, pour le réglage des deux observateurs, 110 itérations initiales (11 fois le nombre de paramètres à optimiser [Davins-Valldaura et al., 2015b]) ont été faites afin de créer les premiers modèles de substitution, plus 250 itérations d'optimisation proposées par la méthode KEEP, ce qui fait un total de 360 évaluations de la gBdD. La simulation de toute la gBdD avec une seule configuration de paramètres est de 3,5 minutes, ce qui fait un total de 21 heures pour finir l'optimisation et pour permettre à KEEP de proposer un ensemble de solutions optimales.

Les résultats finaux de l'optimisation par KEEP sont donnés par la Figure 6.13. Parmi toutes les évaluations faites par l'algorithme KEEP avec la gBdD, les solutions optimales sont sélectionnées à partir du principe du front de Pareto (Section 2.3). L'idée est de choisir arbitrairement une configuration de paramètres de réglage parmi les solutions du front de Pareto choix fait à partir d'un compromis souhaité entre les deux critères (EERC et EERDL). Ce réglage de paramètres sera retenu pour la simulation des observateurs réalisés dans le chapitre. Ces résultats sont comparés avec les résultats obtenus avec le réglage manuel.

Les observateurs retenus à partir des résultats de l'optimisation par l'algorithme KEEP sont

1. Gains de l'observateur à grand gain (6.31)

$$\begin{aligned} [K_1 \dots K_7] &= [18 \ 14 \ 4518 \ 676 \ 27 \ 11 \ 248] \cdot 10^{-3} \\ [\tau_1 \ \tau_2 \ \tau_3] &= [0,173 \ 0,067 \ 15,488] \end{aligned} \quad (6.39)$$

2. Gains de l'observateur par mode glissant (6.33-6.34)

$$\begin{aligned} [L_{\Phi_1} \ L_{\Phi_2} \ L_{\Phi_3}] &= [1,1 \cdot 10^{-7} \ 0,66 \ 10^{-5}] \\ [s_1 \dots s_7] &= [1,56 \ 1,2 \ 3,12 \ 2 \ 0,61 \ 1,56 \ 1,2] \end{aligned} \quad (6.40)$$

Remarque 6.12 Notons que, dans notre cas, les paramètres "s" obtenus par l'optimisation avec KEEP pour l'observateur par mode glissant sont proches des paramètres recommandés par Levant (réglage manuel) à l'exception des paramètres $[s_3 \ s_4 \ s_5]$ qui sont liés à la sortie dont l'indice d'observabilité est le plus grand. ■

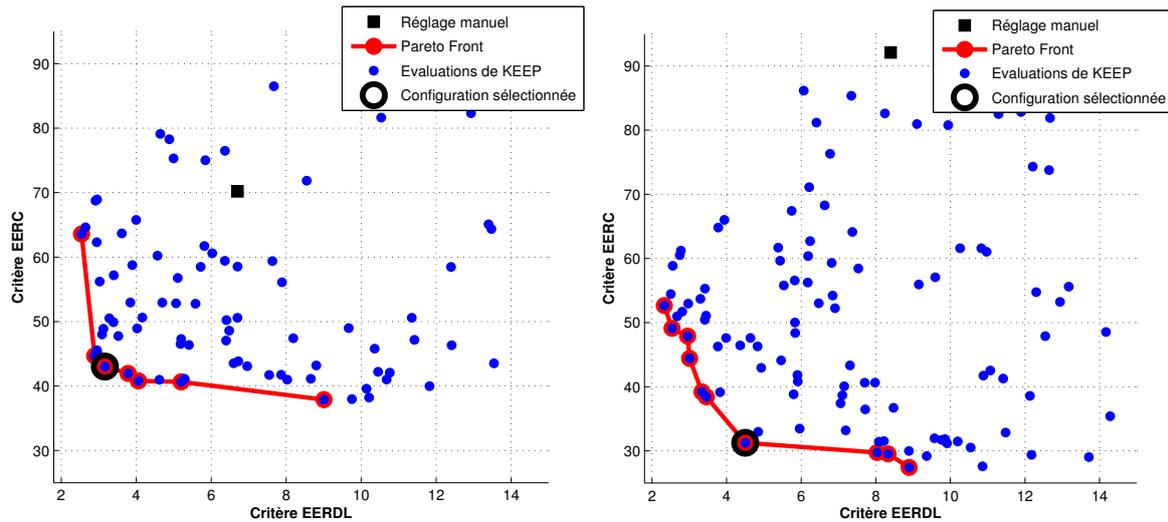


FIGURE 6.13: Résultats obtenus avec l'optimisation de l'observateur à grand gain (à gauche) et l'observateur par mode glissant (à droite) en utilisant les critères EERDL et EERC. Concernant l'optimisation faite par KEEB, les résultats obtenus pour les configurations de paramètres évaluées en utilisant la gBdD sont représentés par les points bleus. Parmi ces résultats, les solutions optimales (*Pareto Front*) sont unies par une ligne rouge. Parmi les solutions optimales, la configuration de paramètres sélectionnée (de manière arbitraire on a choisi la solution la plus proche de l'origine de l'espace de performances) est représentée avec un cercle noir. Concernant le réglage manuel, le résultat obtenu en évaluant la configuration de paramètres avec la gBdD est représenté avec un carré noir.

6.7 Installation expérimentale

Tout les enregistrements ont été obtenus au centre technique d'essais de Renault (Aubevoye, France) avec un véhicule prototype Renault *ESPACE V*.

Toutes les données du véhicule obtenues en plusieurs scénarios ont été stockées afin de construire la gBdD qui a servi pour l'optimisation. En effet, la gBdD est utilisée pour les simulations *off-line*, permettant de mettre au point les gains des observateurs (voir Section 6.6) et de comparer les performances de chaque stratégie.

Remarque 6.13 Afin de vérifier la pertinence du réglage optimal des observateurs, certains scénarios sont volontairement retirés de la gBdD pour n'être utilisés que pour l'évaluation des observateurs (Section 6.9). ■

Pour la réalisation des enregistrements, une *MicroAutoBox-II* a été utilisée pour exécuter le système TJP et pour faire la passerelle entre les différents capteurs et ordinateurs utilisés. Concrètement, l'équipement utilisé est composé des éléments suivants (voir Figure 6.14)

1. Matériels

- une dSpace *MicroAutoBox-II* avec une interface Ethernet (hôte),
- une caméra EPM3 Mobileye,
- un PC pour le traitement d'image,
- un PC pour l'enregistrement des scénarios,
- un PC pour la supervision des données.

2. Logiciels

- MATLAB R2011a/Simulink,
- dSpace Real Time Interface Release 7.4,

- ControlDesk 4,3.

Le réseaux CAN du véhicule opère à un débit de $500 \text{ Kb} \times \text{s}^{-1}$ et les signal ABS a une période d'acquisition de 1 ms . La caméra a une portée de 140 m pour les véhicules et de 120 m pour le marquage sur chaussée. La sortie mesurée y , utilisée par les observateurs, est un signal non filtré. L'angle de braquage des roues mesuré y_3 est obtenu en utilisant un capteur qui mesure l'angle au niveau de la colonne de direction en prenant en compte le gain de l'EPS k_{eps} , qui est une valeur constante et connue. De plus, l'angle de la pente et le devers de la route ne sont pas pris en compte, ni par la caméra, ni par la dynamique du véhicule. Toutes ces contraintes sur les capteurs font que des incertitudes sont introduites dans les modèles de la dynamique du véhicule, ce qui oblige à proposer des solutions robustes.

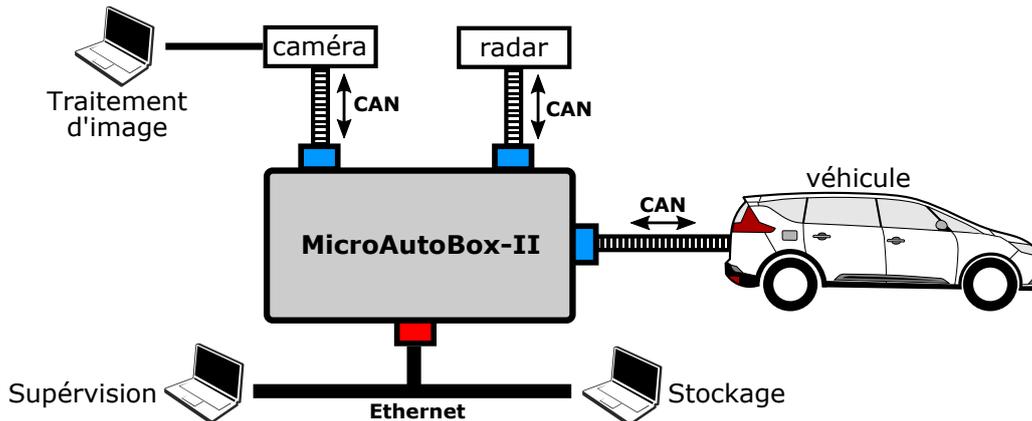


FIGURE 6.14: Schéma d'acquisition sur prototype.

6.8 Résultats par simulation

Dans cette section, les deux observateurs non linéaires, l'observateur à grand gain (6.31) et l'observateur par mode glissant (6.33-6.34), sont testés sur différents scénarios en simulation. Le but est de montrer que ces observateurs peuvent estimer l'état (x_r and ρ) en prenant en compte les aspects suivants :

- la courbure de la trajectoire à suivre ρ n'est pas mesurable ;
- la dynamique de ρ est inconnue ;
- la vitesse longitudinale v_x est supposée constante mais, dans les faits, elle varie dans le temps ;
- la distance longitudinale x_m est supposée constante lors de la synthèse de l'observateur mais, dans les faits, elle varie dans le temps.

Dans un premier temps, un scénario à vitesse et distance longitudinale variables est utilisé pour évaluer la robustesse et la convergence d'estimation des deux observateurs, en utilisant les mises au point des paramètres, d'une part par réglage manuel (6.37,6.38), et d'autre part par réglage issu de KEEP (6.39,6.40). Ensuite, deux scénarios avec différentes valeurs de ρ permettent de comparer l'estimation de l'état réalisé par l'observateur linéaire (Kalman) et les deux observateurs non linéaires.

Les trois scénarios utilisés sont

- **Scénario 1 : scénario mixte.** Combinaison de ligne droite et virage à basse vitesse (voir Figure 6.15) ;
- **Scénario 2 :**
 - **scénario ligne droite.** Route droite avec faibles virages, ce qui permet d'évaluer le comportement de l'estimation de l'état et de la courbure lorsque cette dernière a une valeur faible (voir Figure 6.17) ;

- **scénario route sinueuse.** Route avec forts virages, ce qui permet d'évaluer le comportement de l'estimation de l'état et de la courbure lorsque cette dernière a une valeur élevée (voir Figure 6.18).

Remarque 6.14 Notons que toutes les simulations sont faites avec une courbure ρ et une vitesse longitudinale v_x variant dans le temps. La distance longitudinale est initialisée à 10 mètres et est pratiquement constante (variations faibles dans le temps) en raison du contrôle longitudinal qui a comme objectif de maintenir cette distance constante. ■

Les valeurs initiales de l'état $\mathbf{x} = [\mathbf{x}_r^T \rho]^T$ et de l'état estimé $\hat{\mathbf{x}}$ ont été fixées *arbitrairement*⁸ comme

$$\hat{\mathbf{x}}(0) = [3 \cdot 10^{-2} \ 3,5 \cdot 10^{-3} \ 2 \cdot 10^{-2} \ 1,6 \cdot 10^{-2} \ 8 \cdot 10^{-4} \ 2 \cdot 10^{-2} \ 1,3 \cdot 10^{-3}]^T \quad (6.41)$$

$$\mathbf{x}(0) = [0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0]^T \quad (6.42)$$

Un bruit réaliste, induit par les capteurs, a été pris en compte afin de calculer la sortie mesurée ($\mathbf{y} + \mathbf{y}_{err}$), avec \mathbf{y}_{err} défini comme un bruit blanc avec moyenne nulle et limité par $[\pm 0,006 \ \pm 0,01 \ \pm 0,0001]$ (ces valeurs ont été fixées à partir de données réelles).

Scénario 1.

Le *scénario mixte* utilisé pour la simulation est représenté Figure 6.15. Notons que, d'après la Figure 6.15 *bas-droite*, le système reste toujours dans les conditions d'observabilité (domaine observable décrite par la Figure 6.11).

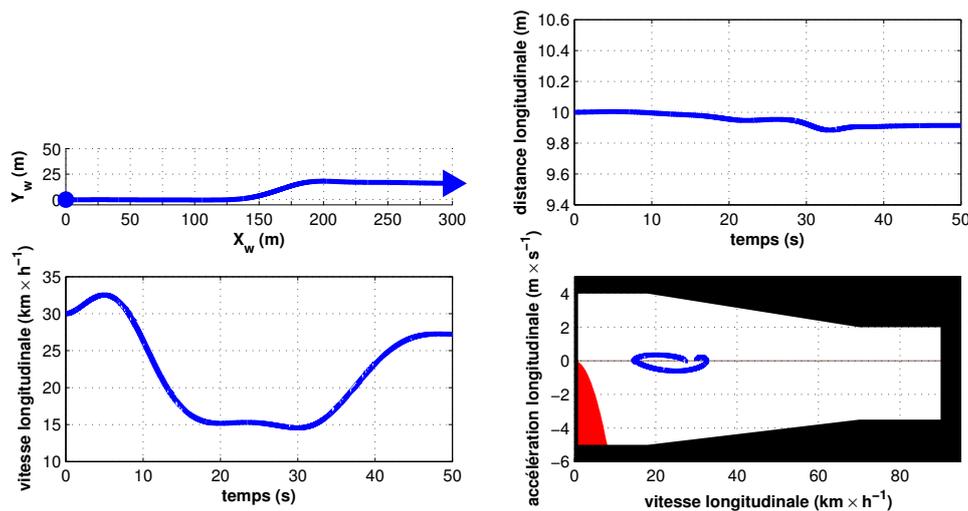


FIGURE 6.15: Caractérisation du **scénario mixte**. (*En haut-gauche*) Trajectoire du CdG du véhicule vue de dessus; (*en haut-droite*) distance longitudinale par rapport au véhicule cible x_m ; (*en bas-gauche*) vitesse longitudinale du véhicule v_x ; (*en bas-droite*) trajectoire du véhicule dans le plan (v_x, a_x) pour l'analyse de l'observabilité.

⁸L'état initial de l'observateur est défini par : $\hat{\mathbf{x}}(0) = 0,2 \cdot \max[\|\mathbf{x}(t)\|]_{t \in [0,40]}$; avec l'état $\mathbf{x}(t)$ correspondant au scénario mixte.

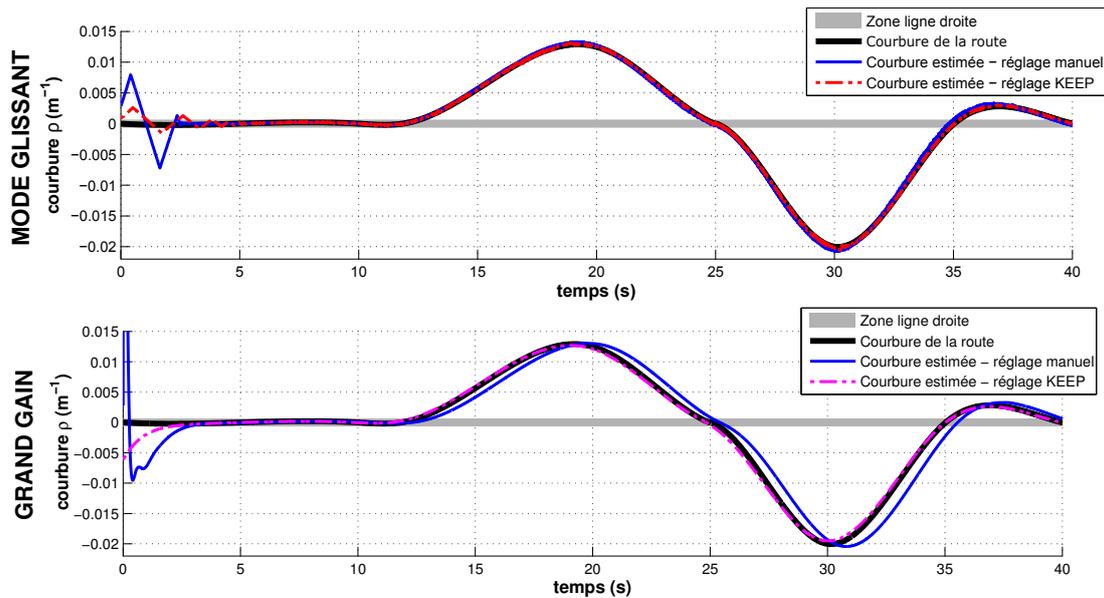


FIGURE 6.16: Résultats du **scénario mixte**. Comparaison des performances obtenues avec les observateurs non linéaires en utilisant le réglage manuel et le réglage proposé par KEEP. (*En haut*) Estimation de la courbure réalisée avec les deux mises au point de l'observateur par mode glissant ; (*en bas*) Estimation de la courbure avec les deux réglages de l'observateur à grand gain.

Les résultats obtenus (voir la Figure 6.16) montrent que les observateurs non linéaires permettent d'obtenir une bonne estimation de la courbure, avec une convergence dans un voisinage de la valeur réelle en moins de 3 s, dans le cas où les gains sont réglés par KEEP. En effet, l'observateur à grand gain, qui a 10 paramètres de mise au point, présente une meilleure estimation si on utilise le réglage proposé par KEEP ; ceci montre que la méthode d'optimisation proposée a permis d'améliorer l'estimation de la courbure. Pour l'observateur par mode glissant, les résultats obtenus en utilisant les deux réglages (manuel et KEEP) sont très similaires. En effet, cet observateur est plus aisé à mettre au point à la main car il n'a que 3 paramètres de réglage. Pour conclure, la solution présentant la meilleure estimation de la courbure est l'observateur par mode glissant avec le réglage proposé par KEEP.

Scénario 2.

Le *scénario ligne droite* et le *scénario route sinueuse* utilisés pour les simulations sont représentés Figures 6.17 et 6.18. Notons que le système TJP reste toujours dans les conditions d'observabilité pendant les deux simulations (voir les Figures 6.17-bas-droite et 6.18-bas-droite).

Hypothèse 6.10 *Les routes en ligne droite ont un rayon de virage supérieur à 1 500 m, c'est-à-dire une courbure de $|\rho| < 0,67 \cdot 10^{-3} m^{-1}$.* ■

Remarque 6.15 *Rappelons que, pendant la sélection des critères de performances (Section 6.6.1), la distance latérale du véhicule par rapport à la trajectoire du véhicule cible y_t et la courbure ρ ont été considérées les variables les plus difficiles à estimer. L'estimation de ces deux variables sera présentée afin d'analyser la performance des observateurs.* ■

Les résultats obtenus par les deux simulations sont représentés Figures 6.19 et 6.20, à savoir l'estimation de y_t et ρ grâce aux différents observateurs. Ces résultats sont complétés par la Tableau 6.3 en utilisant, comme critères de comparaison, la moyenne et l'écart type des valeurs absolues des erreurs d'estimation $|e_\rho| = |\hat{\rho} - \rho|$ et $|e_y| = |\hat{y}_t - y_t|$. Ces erreurs sont calculées lorsque la courbure est quasi constante ($\dot{\rho}$ faible, c'est-à-dire pour $t = [5 \ 15]s$ et $t = [25 \ 35]s$) et lorsque la courbure a des variations plus fortes ($\dot{\rho}$ forte, c'est-à-dire pour $t = [15 \ 25]s$ et $t = [35 \ 40]s$). Le but est de voir l'impact de la dynamique de ρ sur les différents observateurs.

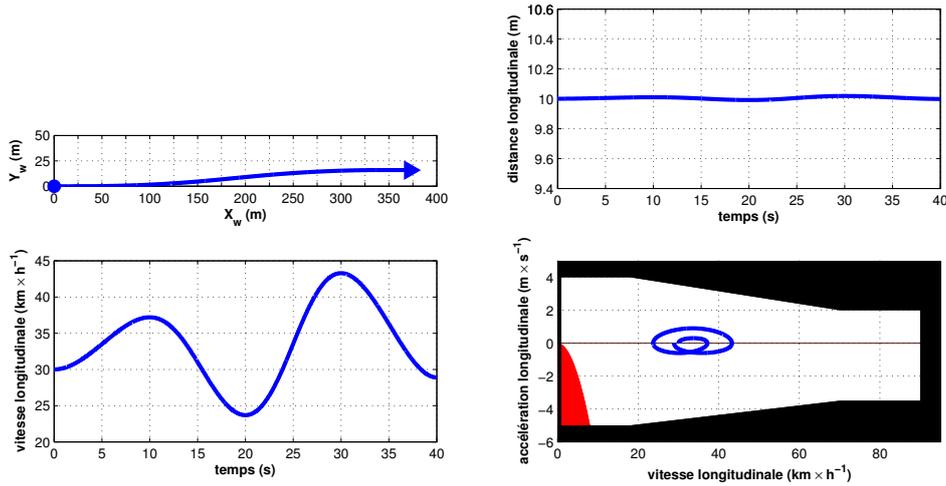


FIGURE 6.17: Caractérisation du **scénario ligne droite**. (*En haut-gauche*) Trajectoire du CdG du véhicule vue de dessus ; (*en haut-droite*) distance longitudinale par rapport au véhicule cible x_m ; (*en bas-gauche*) vitesse longitudinale du véhicule v_x ; (*en bas-droite*) trajectoire du véhicule dans le plan (v_x, a_x) pour l'analyse de l'observabilité.

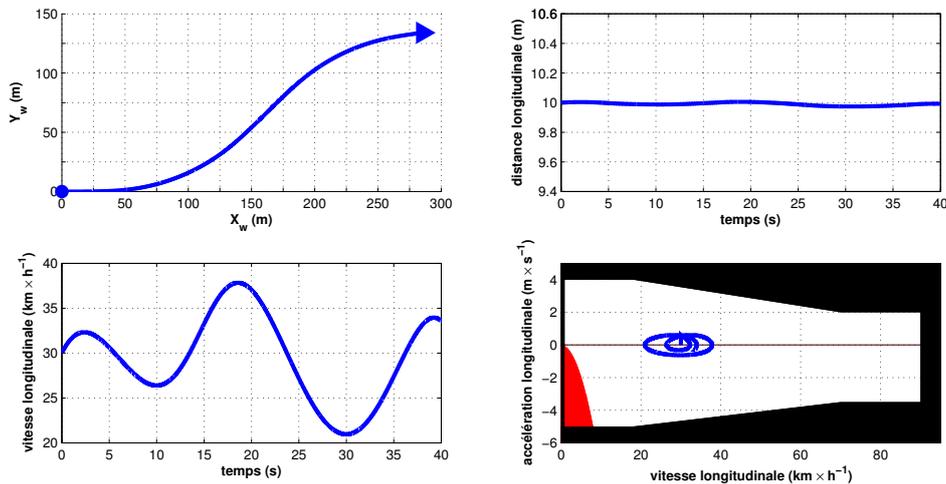


FIGURE 6.18: Caractérisation du **scénario route sinueuse**. (*En haut-gauche*) Trajectoire du CdG du véhicule vue de dessus ; (*en haut-droite*) distance longitudinale par rapport au véhicule cible x_m ; (*en bas-gauche*) vitesse longitudinale du véhicule v_x ; (*en bas-droite*) trajectoire du véhicule dans le plan (v_x, a_x) pour l'analyse de l'observabilité.

Observateur par mode glissant. Les résultats obtenus pour l'estimation de la courbure montrent que l'observateur par mode glissant est la solution donnant la meilleure approximation de ρ , que ce soit pour une route en ligne droite ou pour une route sinueuse. La valeur estimée $\hat{\rho}$ converge en moins de 4 s vers la vraie valeur ρ , ce qui est plus rapide que l'observateur linéaire. La distance latérale y_t a aussi une erreur d'estimation faible en ligne droite ; cependant, dans le cas d'une route sinueuse, lorsqu'il y a une phase avec une forte variation de la courbure, l'estimation de la distance latérale est dégradée (rappelons que la dynamique de la courbure a été incluse dans le terme de dynamiques inconnues $\Delta f(\mathbf{x}, t)$, qui a été supposé nul pendant la synthèse de l'observateur). En effet, dans le pire cas (route sinueuse et forte $\dot{\rho}$), la moyenne de l'erreur de la distance latérale est de 1,7 cm et l'erreur maximal de 5 cm.

Observateur à grand gain. L'estimation de la courbure obtenue par l'observateur à grand gain est en générale bonne mais moins précise que celle obtenue par l'approche type mode glissant. Le temps de convergence est similaire à celui obtenu par l'observateur de Kalman pour la route en ligne droite (environ 7 s) et par l'observateur par mode glissant pour la route sinueuse (moins de 4 s). Concernant

l'estimation de la distance latérale y_t , l'observateur à grand gain a obtenu de meilleurs résultats d'estimation. Dans le cas d'une route sinueuse et forte variation de la courbure, cette solution présente une erreur d'estimation plus faible que les autres observateurs (une moyenne de 0,59 cm). Notons que le réglage choisi pour l'observateur à grand gain est un compromis entre les critères EERC et EERDL différent de celui choisi pour l'observateur par mode glissant (voir Figure 6.13) ; c'est une des raisons pour laquelle le réglage sélectionné pour l'observateur à grand gain permet d'obtenir une erreur d'estimation de la distance latérale plus faible (la configuration de paramètres sélectionnée pour l'observateur à grand gain a un EERDL = 3,2 et pour l'observateur par mode glissant a un EERDL = 4,4).

Observateur de Kalman. Cet observateur linéaire présente clairement quelques limitations par rapport aux observateurs non linéaires. Tout d'abord, cette solution a un temps de convergence élevé, spécialement dans l'estimation de la courbure (plus de 5 s). De plus, il y a un retard dans l'estimation de la courbure, ce qui donne une erreur moyenne importante (en route sinueuse, plus de 10 fois l'erreur obtenue par l'observateur type mode glissant). L'estimation de la distance latérale y_t est aussi affectée (comme l'observateur par mode glissant) par une dynamique forte de ρ , laquelle limite l'utilisation d'une approximation linéaire.

TABLEAU 6.3: Moyenne (**moy**) et écart type (**éc.t**) des erreurs d'estimation $|e_\rho|$ et $|e_{y_t}|$ pour 3 solutions d'observateurs, avec le **scénario 2** (ligne droite, puis route sinueuse).

	$ e_\rho (m^{-1} \cdot 10^{-5})$				$ e_{y_t} (cm)$			
	Ligne droite		Route sinueuse		Ligne droite		Route sinueuse	
	$\dot{\rho}$ faible	$\dot{\rho}$ forte	$\dot{\rho}$ faible	$\dot{\rho}$ forte	$\dot{\rho}$ faible	$\dot{\rho}$ forte	$\dot{\rho}$ faible	$\dot{\rho}$ forte
Mode glissant (moy)	1,01	2,18	3,56	12,91	0,05	0,22	0,32	1,68
Grand gain (moy)	1,54	3,62	9,1	26,7	0,09	0,51	0,31	0,59
Kalman (moy)	1,56	11,4	37,2	186,3	0,04	0,20	0,43	2,12
Mode glissant (éc.t)	0,73	1,55	2,73	7,74	0,04	0,13	0,29	1,61
Grand gain (éc.t)	0,95	2,61	4,4	19,5	0,08	0,32	0,37	0,85
Kalman (éc.t)	0,93	9,11	31,0	154,9	0,01	0,13	0,37	2,03

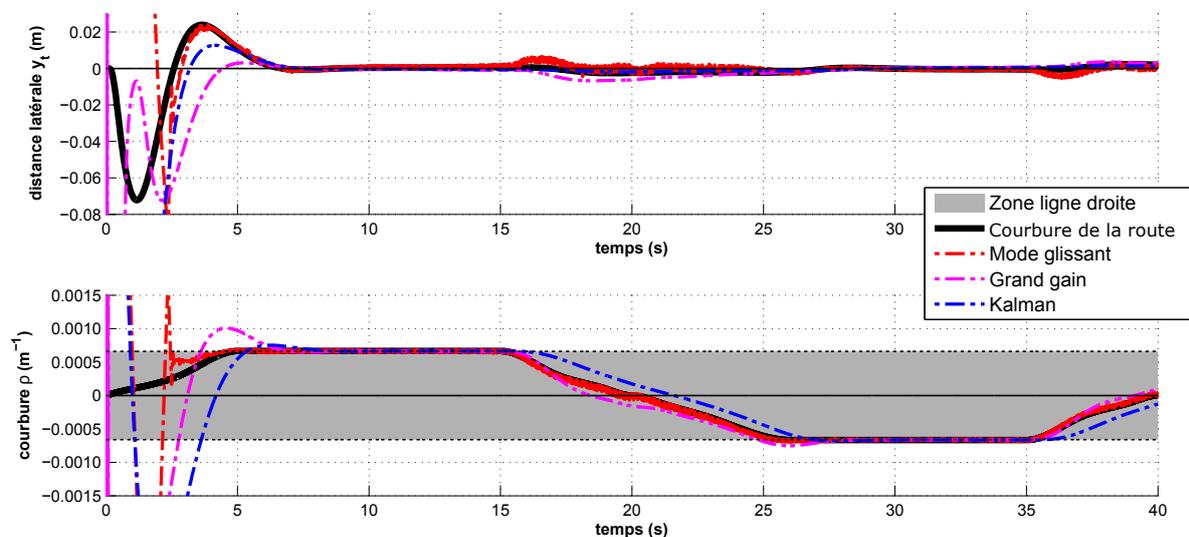


FIGURE 6.19: Résultats du **scénario ligne droite**. Comparaison des performances obtenues avec les observateurs. (*En haut*) Estimation de la distance latérale ; (*en bas*) estimation de la courbure.

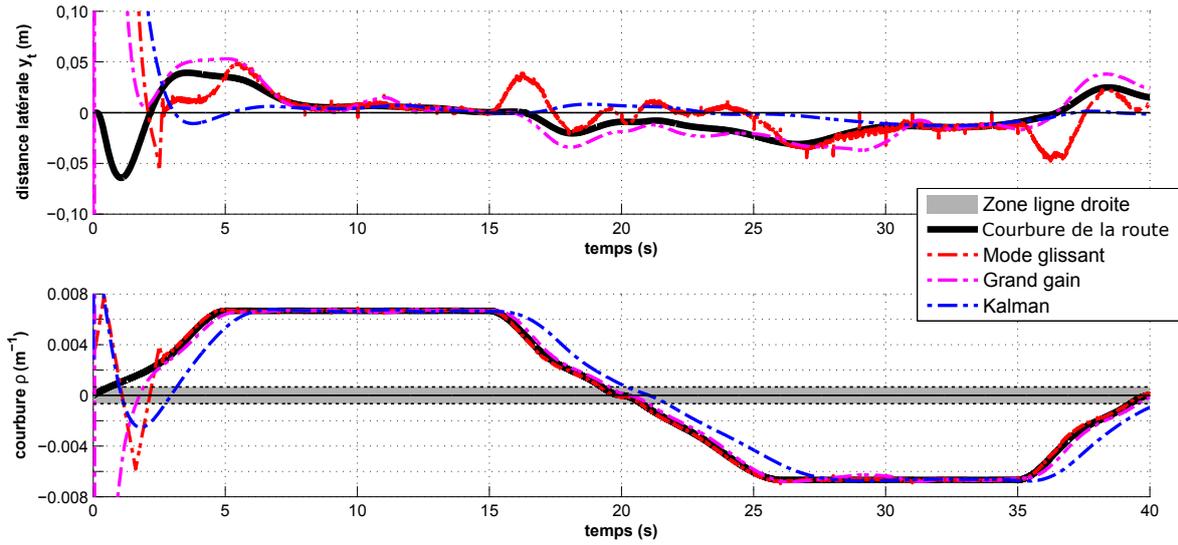


FIGURE 6.20: Résultats du **scénario route sinueuse**. Comparaison des performances obtenues avec les observateurs. (*En haut*) Estimation de la distance latérale ; (*en bas*) estimation de la courbure.

6.9 Résultats sur des données réelles

Comme évoqué la Section 6.6, une base de données de grande dimension d'enregistrements réels a été utilisée pour réaliser l'optimisation des observateurs. Afin de valider les résultats obtenus par l'optimisation et les simulations précédentes (Section 6.8), un enregistrement combinant une route en ligne droite et un virage est utilisé et sera appelé *enregistrement de validation* (voir Figure 6.21).

Remarque 6.16 *L'enregistrement de validation n'appartient pas à la base de données utilisée pour l'optimisation.* ■

Les valeurs initiales des observateurs ont été fixées arbitrairement à

$$\hat{\mathbf{x}}(0) = [y_1(0) \ 0 \ 0 \ 0 \ 0 \ y_3(0) \ 0]^T \quad (6.43)$$

alors que l'état initial de l'enregistrement de validation est

$$\mathbf{x}(0) = [y_1(0) \ 10^{-3} \ -1,3 \ 1,25 \ 0,016 \ y_3(0) \ 4 \cdot 10^{-6}]^T. \quad (6.44)$$

Validation des résultats. Les trois observateurs étudiés dans cette thèse, l'observateur de Kalman (6.18), l'observateur à grand gain (6.31) et l'observateur par mode glissant (6.33-6.34), sont comparés à partir de l'enregistrement de validation, en utilisant les réglages manuels d'une part et les réglages obtenus par KEEP d'autre part (les gains de l'observateur de Kalman sont optimisés à partir d'un outil de mise au point, voir annexe B). Rappelons que l'analyse de performance des observateurs se focalise sur l'estimation de la distance latérale y_t et de la courbure ρ ; en particulier, cette dernière variable ρ a une valeur très faible et sa dynamique est inconnue et plus lente que le reste des variables d'état. Notons que, pendant la validation des observateurs, la performance du système TJP ne sera pas étudiée ici.

Étude de sensibilité. Le modèle complet du véhicule (6.9) utilisé dans ce chapitre et sur lequel est basée la synthèse des observateurs, a plusieurs constantes susceptibles d'évoluer, comme par exemple les coefficients de frottement visqueux des pneumatiques (C_f et C_r) et le moment d'inertie en lacet. Parmi tous ces paramètres, la masse du véhicule est la plus problématique : pour la synthèse des observateurs, elle a été supposée égale à la masse nominale du véhicule (voir Tableau 6.1) ; cependant, elle varie de manière significative en fonction du nombre de passagers et de la charge du coffre du véhicule. Afin de tester leur robustesse par rapport à une forte variation de la masse du véhicule, les observateurs seront testés avec une masse nominale M puis avec une masse maximale M_{400} ($M_{400} = M + 400 \text{ kg}$). Rappelons

également que des erreurs d'estimation sont introduites par des variations de v_x et x_m , ces variables étant supposées constantes pendant la synthèse des observateurs.

Les résultats obtenus sur l'estimation de la courbure et la distance latérale, sont représentés Figure 6.22 (observateurs non linéaires avec le réglage manuel) et Figure 6.23 (observateurs avec le réglage obtenu par KEEP). Ces résultats sont complétés par la Tableau 6.4 afin d'analyser numériquement les résultats en utilisant la moyenne et l'écart type de la valeur absolue des erreurs d'estimation $e_\rho = \hat{\rho} - \rho$ et $e_y = \hat{y}_t - y_t$. Notons que le système TJP est toujours observable pendant l'enregistrement (voir Figure 6.21-bas-droite).

Type de réglage. Concernant le réglage manuel des observateurs non linéaires, lesquels ont été validés par simulation, on remarque une dégradation de la qualité d'estimation en utilisant des données réelles. L'estimation de la courbure présente une erreur deux fois plus importante dans le cas d'un réglage manuel qu'avec le réglage proposé par KEEP. Par conséquent, on peut constater que le réglage obtenu par KEEP permet d'améliorer la qualité de l'estimation des observateurs non linéaires.

Observateurs optimisés. L'observateur par mode glissant permet d'obtenir la meilleure estimation de la courbure (une moyenne de $0,75 \cdot 10^{-4} m^{-1}$) et une bonne estimation de la distance latérale (une moyenne de 3,3 cm). La convergence de la courbure est plus rapide qu'avec les autres observateurs. L'observateur à grand gain a la meilleure estimation de la distance latérale (une moyenne de 2,1 cm). Cependant, il a un pic d'erreur de la courbure important (vers $t = 7$ s), ce qui peut poser un problème dans la boucle de commande du TJP. L'observateur de Kalman présente, quant à lui, une solution plus adoucie mais une précision moindre. Les résultats obtenus par l'observateur de Kalman sont nettement moins bons que ceux obtenus par les observateurs non linéaires.

Masse du véhicule. Globalement, la qualité de la performance d'estimation est moyennement impactée par la variation de masse, notamment l'observateur de Kalman qui est peu sensible aux variations.

Remarque 6.17 Notons que la précision de l'estimation de la courbure pour les trois observateurs est inférieure dans les cas des routes en ligne droite du fait que la courbure a une valeur très faible dans cette situation. D'un point de vue pratique, ce n'est pas un problème car la courbure a un impact presque nul sur la boucle de commande correspondant dans le cas d'une route en ligne droite. ■

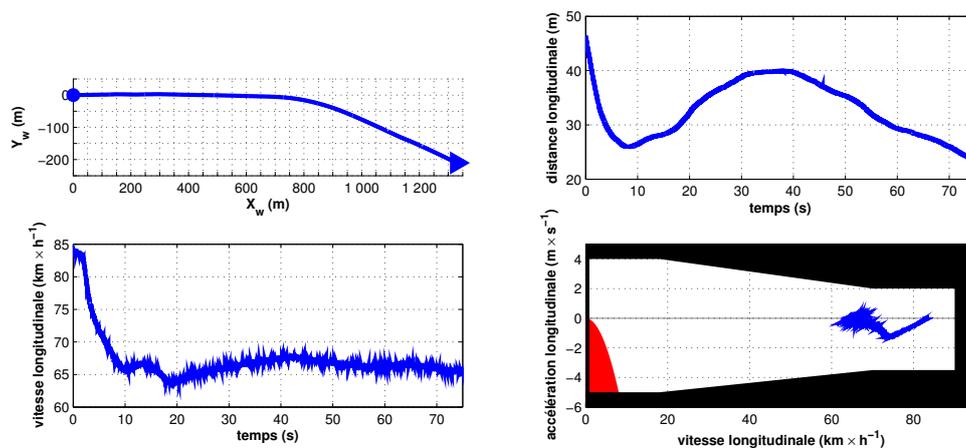


FIGURE 6.21: Caractérisation de l'enregistrement de validation. (En haut-gauche) Trajectoire du CdG du véhicule vu de dessus ; (en haut-droite) distance longitudinale par rapport au véhicule cible x_m ; (en bas-gauche) vitesse longitudinale du véhicule v_x ; (en bas-droite) trajectoire du véhicule dans le plan (v_x, a_x) pour l'analyse de l'observabilité.

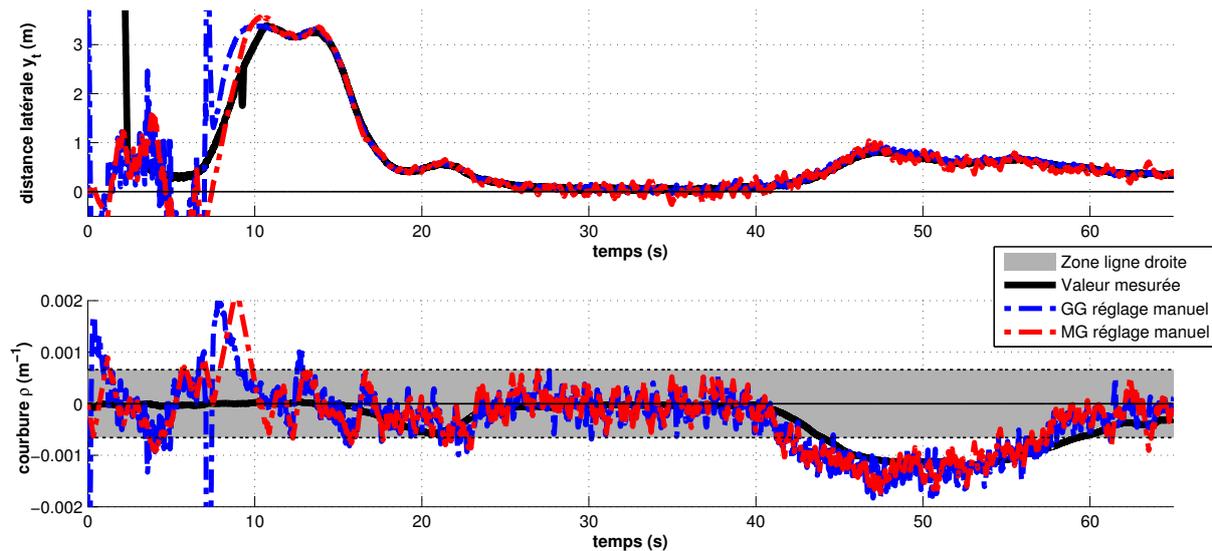


FIGURE 6.22: Résultats de l'enregistrement de validation. Comparaison des performances obtenues avec les observateurs non linéaires en utilisant les réglages manuels. (En haut) Estimation de la distance latérale par les 2 observateurs non linéaires (réglage manuel), GG étant l'observateur à grand gain et MG l'observateur par mode glissant. (En bas) Estimation de la courbure par les 2 observateurs non linéaires (réglage manuel).

TABLEAU 6.4: Moyenne (**moy**) et écart type (**éc.t**) des erreurs d'estimation $|e_\rho|$ et $|e_y|$ obtenues avec les observateurs de Kalman, à grand gain et par mode glissant (calculs réalisés entre $t = 10$ s et $t = 65$ s). Les gains des observateurs sont obtenus par réglage manuel (*man*) et réglage par KEEP (*auto*).

réglage	Grand gain			Mode glissant			Kalman	
	<i>man</i>	<i>auto</i>	M_{400}	<i>man</i>	<i>auto</i>	M_{400}	<i>M</i>	M_{400}
masse du véhicule	M	M	M_{400}	M	M	M_{400}	M	M_{400}
moy ($ e_y $) (cm)	3,48	2,14	3,12	6,82	3,37	4,05	9,01	9,20
éc.t ($ e_y $) (cm)	3,43	2,16	2,65	5,90	2,34	3,06	7,77	7,91
moy ($ e_\rho $) ($m^{-1} \cdot 10^{-4}$)	2,36	1,22	1,31	2,56	0,75	0,78	1,45	1,47
éc.t ($ e_\rho $) ($m^{-1} \cdot 10^{-4}$)	2,76	1,14	1,16	2,75	0,66	0,68	1,31	1,35

6.10 Conclusion

Un des principaux problèmes du contrôle latéral du système TJP est que si on souhaite une estimation performante, les *observateurs linéaires* doivent être réglés sur différentes plages de vitesse, ce qui jusqu'à présent est fait à la main grâce à une mise au point empirique sur les véhicules. Un grand nombre de paramètres de l'observateur doit donc être réglé, ce qui est fastidieux et chronophage. L'utilisation d'*observateurs non linéaires*, de type grand gain ou par mode glissant, permet d'estimer l'état du modèle et la courbure de la route sur l'ensemble de la gamme de vitesses du système, en ne réalisant qu'une seule mise au point, ce qui réduit énormément le nombre paramètres à régler. Une liste des avantages et les inconvénients respectifs des divers observateurs implémentés pour le système TJP sont récapitulés au Tableau 6.5.

Une des contributions du chapitre est l'application de la méthode d'optimisation globale de fonctions coûteuses, proposée dans le Chapitre 3, à la mise au point automatique des gains des observateurs, ce

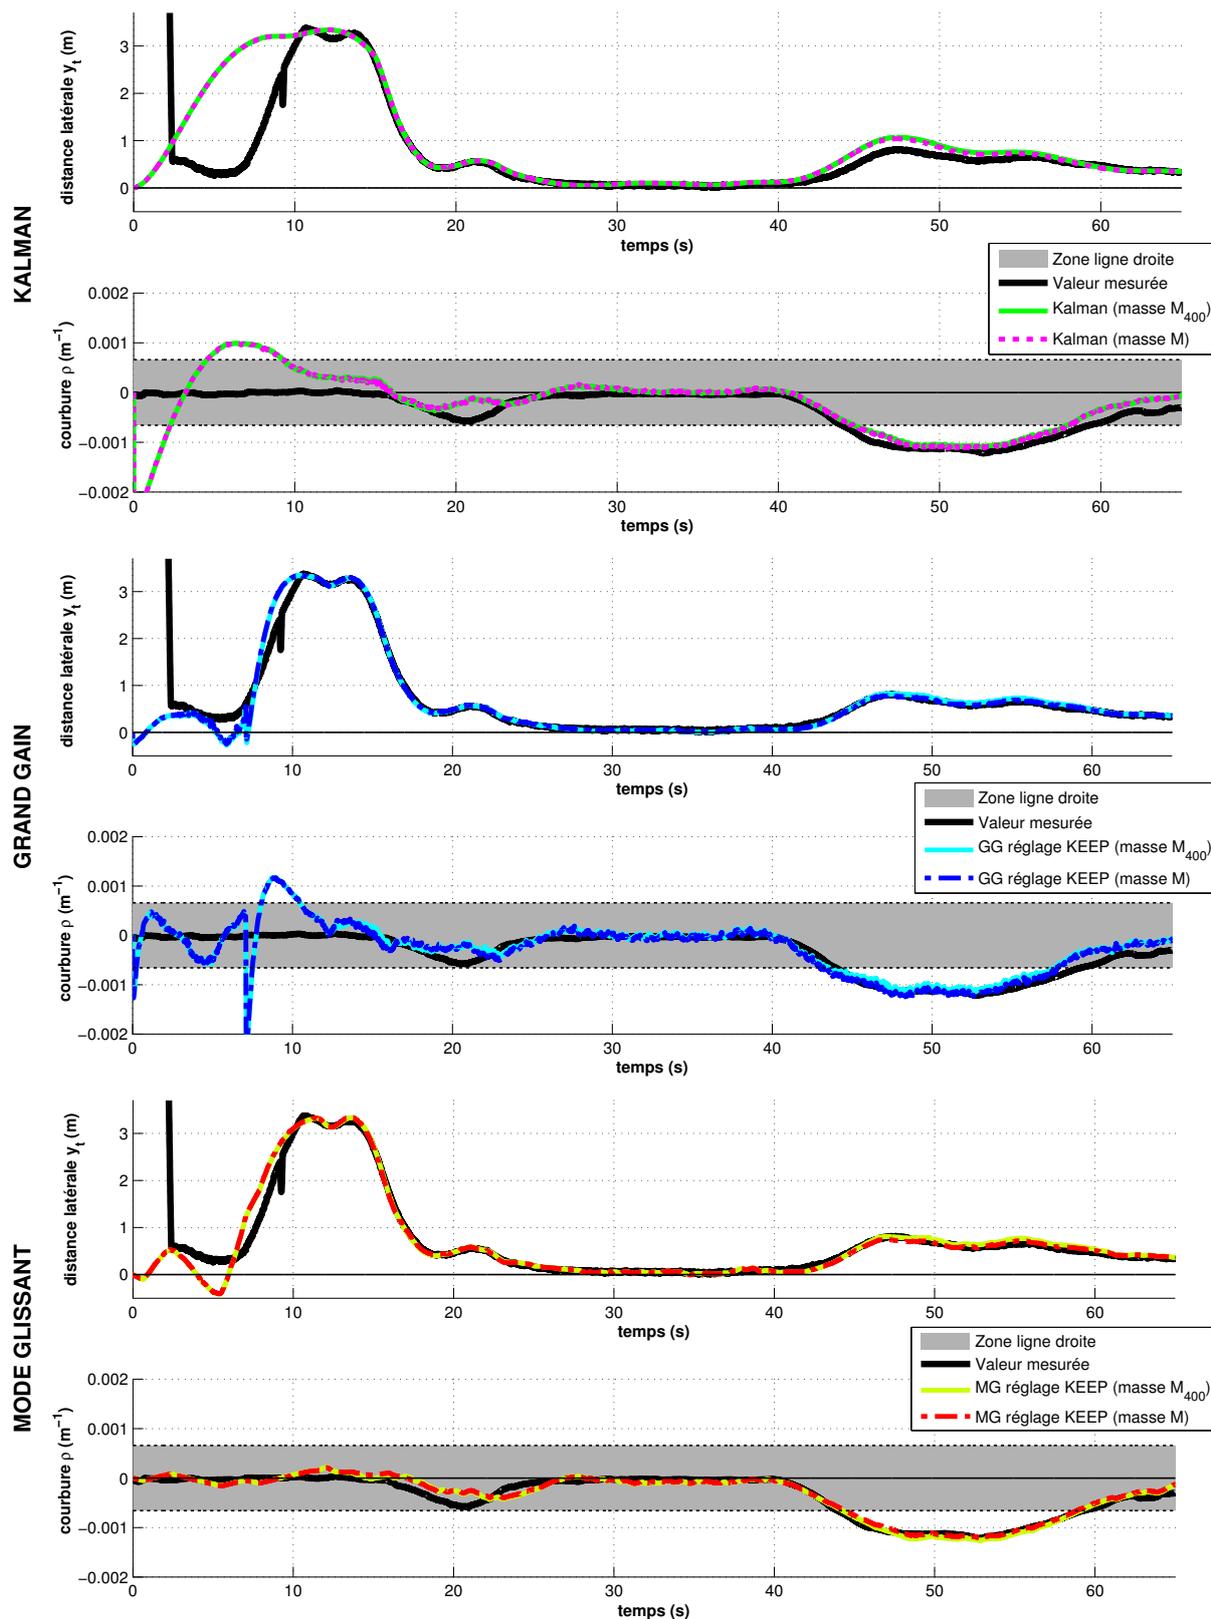


FIGURE 6.23: Résultats de l'enregistrement de validation. Comparaison des performances obtenues avec les observateurs en utilisant les réglages optimaux et différentes charges (une masse nominale M et une masse M_{400}). (En haut, au milieu et en bas) Résultats obtenus par l'observateur de Kalman, à grand gain et par mode glissant, respectivement. Par chaque observateur, l'estimation de la distance latérale (en haut) et de la courbure (en bas).

qui est une nouveauté. En plus de régler les observateurs présentés dans le chapitre, cette méthode a permis aussi de montrer que les constantes proposées de façon standard pour certains coefficients des observateurs par mode glissant d'ordre supérieur sont très proches des valeurs obtenues par le processus d'optimisation (sauf si l'indice d'observabilité de la sortie considérée est supérieur à 2).

Notons que, afin de réaliser la mise au point des observateurs, une grande base de données composée d'un important nombre d'enregistrements de scénarios représentatifs a été utilisée. Dans ce contexte, un réglage manuel est une tâche difficile et fastidieuse ; grâce à la nouvelle méthode de réglage des observateurs, basée sur KEEP, la mise au point a été réalisée automatiquement et fortement simplifiée.

Sur la base de différentes simulations et évaluations sur enregistrements réels, il a été constaté que l'observateur par mode glissant permet d'obtenir une estimation précise de la courbure, qui est une variable fondamentale dans le contexte de situation difficile du système TJP. De plus, l'estimation de l'état, comme par exemple l'écart latéral par rapport à la trajectoire du véhicule cible, présente une faible valeur d'erreur. Ces erreurs d'estimation apparaissent spécialement dans les situations de très fort virage (dynamique de la courbure importante) et sur route très droite (valeur de la courbure très faible). Ceci est dû aux imperfections du modèle, aux imprécisions de mesure des capteurs et au fait que la dynamique de l'état du véhicule est plus rapide que la dynamique de la courbure. Une autre cause réside en les limitations du modèle complet du véhicule utilisé, basé sur le modèle bicyclette classique, qui ne connaît pas la dynamique de la courbure ; ainsi, des hypothèses ont été faites pour la synthèse des observateurs en considérant la distance longitudinale par rapport au véhicule cible, et la vitesse du véhicule constantes.

TABLEAU 6.5: Récapitulatif des résultats et caractéristiques des observateurs implémentés pour le système TJP dans le chapitre.

Observateur	Caractéristiques	Avantages	Inconvénients
Observateur de Kalman (solution standard) [Kalman, 1960]	Utilisation de plusieurs observateurs linéaires (10 observateurs de type Kalman). Au total, 60 paramètres à régler.	<ul style="list-style-type: none"> ● Estimation robuste face aux bruits de mesure et aux perturbations. ● Solution très connue et utilisée par les constructeurs automobiles. 	<ul style="list-style-type: none"> ● Nombre important de paramètres à régler. ● Temps de convergence élevé, spécialement pour l'estimation de la courbure. ● Faible retard pour l'estimation de la courbure.
Observateur de Kalman (réduction du nombre de PdV) [Davins-Valldaura et al., 2015a]	Utilisation de plusieurs observateurs linéaires (4 observateurs de type Kalman). Au total, 24 paramètres à régler.	<ul style="list-style-type: none"> ● Estimation robuste face aux bruits de mesure et aux perturbations. ● Réduction du nombre de paramètres et de la complexité de la mise au point par rapport à la solution standard. 	<ul style="list-style-type: none"> ● Temps de convergence élevé, spécialement pour l'estimation de la courbure. ● Faible retard pour l'estimation de la courbure.
Observateur à grand gain [Gauthier et al., 1992]	Utilisation d'un seul observateur non linéaire. Au total, 10 paramètres à régler.	<ul style="list-style-type: none"> ● Mise au point de l'observateur rapide grâce au nombre réduit de gains à régler. ● Meilleure solution pour l'estimation de la distance latérale. ● Bonne estimation de la courbure. 	<ul style="list-style-type: none"> ● Gain d'observation élevé augmentant la sensibilité au bruit et l'amplitude du transitoire. ● Solution peu robuste face aux erreurs de modélisation et aux perturbations du système.
Observateur par mode glissant [Levant, 1993]	Utilisation d'un seul observateur non linéaire. Au total, 10 paramètres à régler.	<ul style="list-style-type: none"> ● Solution robuste face aux perturbations du système et incertitudes des mesures. ● Certains gains des observateurs (7 sur 10) peuvent être fixés en utilisant les valeurs standard proposées par Levant. ● Mise au point de l'observateur rapide grâce au nombre réduit de gains à régler. ● Meilleure solution pour l'estimation de la courbure. ● Bonne estimation de la distance latérale. 	<ul style="list-style-type: none"> ● Estimation de la distance latérale dégradée pendant les forts virages.

Conclusion générale et perspectives

Conclusion générale

Ce travail de thèse a porté sur une étape très importante dans les phases de conception de systèmes d'aide à la conduite automobile. Il s'agit de la mise au point automatique des dispositifs pour trouver, en un temps limité, un réglage garantissant un bon fonctionnement du système sur des données réelles couvrant plusieurs scénarios. Cette problématique se ramène à la résolution d'un problème d'optimisation multi-objectif de fonctions inconnues et coûteuses. Deux applications ont été considérées : le système de surveillance de la pression des pneumatiques (SSPP) par une approche indirecte et le contrôle latéral dans le système d'aide à la conduite en embouteillage. **La première contribution de la thèse est de proposer un nouvel algorithme d'optimisation globale multi-objectif dans un contexte de fonctions coûteuses.** Cette nouvelle méthode a permis de développer un outil de mise au point automatique qui servira à Renault pour la mise au point de systèmes, au delà des deux systèmes présentés dans cette thèse. **Une deuxième contribution de ce travail a été la proposition d'une stratégie d'estimation optimisée de l'état de la dynamique latérale d'un véhicule automobile et du rayon de courbure de la trajectoire du véhicule suivi, basée sur des observateurs non linéaires,** ces derniers ayant été réglés grâce à l'algorithme d'optimisation proposé. L'utilisation d'une telle approche est aussi novatrice dans le domaine de l'observation et a montré son intérêt pour s'affranchir du réglage manuel des gains des observateurs.

À propos de l'optimisation

Les méthodes d'optimisation globale ont été classifiées afin d'introduire les algorithmes mono-objectif et multi-objectif de référence, en notant les avantages et les inconvénients de chaque algorithme. Concrètement, les algorithmes évolutionnaires et les algorithmes basés sur une stratégie d'utilisation de modèles de substitution ont été introduits avec plus de détails. Comme les travaux de cette thèse sont focalisés sur les fonctions coûteuses avec un budget limité en terme de nombre total d'évaluations de la fonction objectif, il a été noté que les algorithmes actuels ne sont pas suffisamment adaptés à ces contraintes. Pour cette raison, un nouvel algorithme d'optimisation multi-objectif (KEEP) a été proposé [Davins-Valldaura et al., 2015b][Davins-Valldaura et al., 2016b]. Cette solution, s'appuyant sur l'algorithme multi-objectif ParEGO et mono-objectif EGO, propose une amélioration du critère EI en utilisant la définition d'une probabilité d'appartenir à l'ensemble de Pareto (*Pareto Set*), grâce à l'utilisation d'un nouveau modèle de substitution (*krigeage*). À travers une analyse comparative des différents algorithmes multi-objectif (KEEP, ParEGO, NSGA2, MOPSO, SPEA2 et PESA2), ont été testées et comparées les différentes stratégies en montrant que KEEP est le plus performant. En effet, dans un contexte d'optimisation avec un nombre limité d'évaluations de la fonction objectif, l'algorithme KEEP présente plusieurs avantages : une meilleure identification du front de Pareto (*Pareto Front*) avec une meilleure distribution des performances sur ce front, une bonne approximation de la distribution de l'ensemble de Pareto (*Pareto Set*) dans l'espace de recherche, et une vitesse de convergence plus rapide que les autres algorithmes.

L'algorithme KEEP a été utilisé pour le réglage des paramètres du système de surveillance de la pression des pneumatiques (SSPP) par une approche indirecte (c'est-à-dire sans capteur). Cette nouvelle approche, en phase de développement chez Renault, est basée sur deux algorithmes de détection conçus dans le cadre de la thèse [El Tannoury et al., 2013]. Ce système nécessite une mise au point avec plusieurs contraintes : une très grande base de données, un nombre important de paramètres à régler et

un temps global d'optimisation limité. Afin de réaliser cette mise au point, a été proposée une stratégie [Davins-Valldaura et Saint-Loup, 2015] basée sur la division du problème en plusieurs sous-problèmes (de dimension plus petite), chacun étant optimisé séparément en utilisant KEEP. Les résultats obtenus par KEEP ont été comparés par rapport à un réglage manuel réalisé par un ingénieur spécialiste (concernant à la mise au point d'un des algorithmes de détection) et par rapport aux performances obtenues par le système SSPP indirecte de la concurrence (concernant les performances finales du système). Dans les deux cas, les performances obtenues ont été très similaires par les différentes stratégies d'optimisation ; néanmoins, l'optimisation avec KEEP a permis de choisir un compromis entre les critères d'optimisation *a posteriori*, ce qui est de grand intérêt par Renault. En plus, cette solution a permis de substituer le réglage manuel du système par une mise au point automatique, plus rapide et générant plusieurs points de réglage. L'importance de ce résultat est prouvée par le fait que cette stratégie de mise au point sera utilisée désormais en routine pour l'optimisation de tous les futurs véhicules qui utilisent le système SSPP par une approche indirecte. Cependant, il sera toujours possible de réduire le temps de mise au point en cherchant à réduire la taille des bases de données.

À propos de l'observation

Les différentes techniques d'observation classiques pour les systèmes dynamiques linéaires et non linéaires ont été introduites de façon synthétique. Par la suite, le système de conduite autonome (*Traffic Jam Pilot*) est présenté conjointement avec le modèle de dynamique latérale du véhicule (non linéaire) et le système de contrôle latéral au sein du *Traffic Jam Pilot*. Les travaux de cette thèse se sont focalisés sur les situations au cours desquelles l'information du marquage sur la chaussée n'est pas disponible. La version du *Traffic Jam Pilot*, actuellement envisagée par Renault et Nissan, est basée sur l'utilisation de plusieurs observateurs linéaires (Kalman) sur différentes plages de vitesse afin de traiter les non-linéarités de la dynamique. Une première contribution [Davins-Valldaura et al., 2015a] a été la proposition d'une réduction du nombre de plages de vitesse (et du nombre d'observateurs linéaires) afin de simplifier la complexité du système, de réduire le nombre de paramètres à optimiser et de réaliser plus rapidement la mise au point. Une deuxième contribution de la thèse sur ce volet [Davins-Valldaura et al., 2016a] est de proposer une solution alternative basée sur l'utilisation d'un seul observateur non linéaire (observateur à grand gain et observateur par mode glissant), ce qui a réduit de façon très significative le nombre de paramètres de réglage par rapport aux solutions type Kalman. Les différentes simulations et tests réalisés ont montré que l'observateur par mode glissant permet d'obtenir une meilleure estimation de l'état que les autres solutions, en particulier la courbure de la chaussée qui est la variable d'état la plus difficile à estimer dû au fait que sa dynamique est inconnue.

Une autre contribution importante de la thèse est l'application de l'algorithme KEEP pour le réglage des gains des observateurs. Cette mise au point a été faite en utilisant un nombre important d'enregistrements, ce qui a permis de réaliser une mise au point automatique à la place du réglage manuel utilisé actuellement. D'un point de vue conceptuel, ce réglage automatique présente l'autre intérêt de pouvoir comparer objectivement différents observateurs, une fois que ceux-ci ont été optimisés sur la base des mêmes critères. Remarquons aussi qu'un outil d'optimisation pour le système *Traffic Jam Pilot* de Renault et Nissan a également été conçu durant la thèse [Davins-Valldaura et Pita-Gil, 2015], afin de régler les gains du contrôleur et les gains des observateurs linéaires en utilisant l'algorithme KEEP. L'algorithme KEEP pourra aussi être utilisé pour régler de façon optimale le couple commande-observateur.

Pour conclure, ce travail de thèse a montré que les développements théoriques et méthodologiques réalisés dans le domaine de l'optimisation multi-objectif ont une portée qui va au delà du cadre élégant des mathématiques théorique et appliquée. Ils ont un impact très fort et un apport considérable dans le domaine de l'automatique, et dans la recherche et développement dans le contexte automobile.

Perspectives

Une des contraintes principales de cette thèse est que la mise au point des deux applications réelles (le système de surveillance de la pression des pneumatiques (SSPP) indirect et le système de conduite autonome (*Traffic Jam Pilot*)) ont besoin d'un temps important pour finaliser l'optimisation. Pour cette raison, nous n'avons pas eu le temps de réaliser l'optimisation des deux applications réelles en utilisant le reste des algorithmes classiques d'optimisation multi-objectif (ParEGO, NSGA2, MOPSO, SPEA2 et PESA2). L'analyse comparative de performances n'a été fait qu'en utilisant 8 fonctions test de 12 paramètres et 2 objectifs (complexité similaire aux applications réelles). Une première perspective de ce travail est de prouver la viabilité et les performances de l'algorithme KEEP (en comparaison aux autres algorithmes) sur des problèmes réels et analytiques ayant un nombre plus élevé de paramètres (plus de 20) et d'objectifs (plus de 2). Il serait aussi utile d'étudier la possibilité d'utiliser d'autres modèles de fonctions de substitution et de comparer les performances par rapport au *krigeage*, ainsi comme l'utilisation d'autres fonctions de covariance.

Tous les algorithmes présentés dans cette thèse ont été conçus en utilisant Matlab. Une des perspectives est de réaliser une *toolbox* ou un code *open source* de l'algorithme KEEP afin de que la communauté scientifique puisse l'utiliser dans des travaux futurs, soit pour la réalisation d'un analyse comparative de performance soit pour l'utiliser directement.

Concernant la mise au point du SSPP indirect, nous avons constaté des possibles améliorations à faire. La plus importante semble être la réduction de la taille de la base de données. Nous avons montré que l'utilisation d'une partie représentative de la grande base de données était suffisante pour réaliser l'optimisation des algorithmes. Pour les futures mises au point du système, il peut être proposé de faire un étude de la grande base de données (par exemple, identifier les cas d'usage les plus représentatifs en se basant sur une analyse en composantes principales) afin de réduire sa taille (optimisation plus rapide) et le nombre d'enregistrements à faire (moins de roulages à enregistrer). Une autre proposition est que pour la mise au point des futurs véhicules, chaque paramètre du système soit bien identifié (valeurs minimales et maximales) afin de garantir un fonctionnement plus efficace de l'algorithme KEEP.

Par rapport aux observateurs pour le système *Traffic Jam Pilot*, nous avons montré la viabilité des observateurs non linéaires. Pour les prochaines versions du système, nous proposons d'étendre la comparaison avec d'autres observateurs non linéaires, comme par exemple les observateurs adaptatifs. Une autre possible d'amélioration est l'utilisation d'un modèle de la dynamique latérale du véhicule plus réaliste que le modèle bicyclette utilisé, comme par exemple un modèle dynamique du véhicule du type quatre roues.

Pour finir, ce travail de thèse permet d'envisager le potentiel des solutions d'optimisation dans le cadre d'autres systèmes d'aide à la conduite (exemples présentés dans l'Annexe A). Tout d'abord, on peut envisager l'utilisation des observateurs à grand gain ou par mode glissant pour traiter les dynamiques non linéaires et complexes des différents systèmes à la conduite ; afin de simplifier le nombre d'observateurs et le nombre de paramètres à régler. Ensuite, l'utilisation de l'algorithme KEEP doit être envisagé afin de réaliser l'optimisation multi-objectif des systèmes qui utilisent une grande base de données. En effet, l'algorithme KEEP, conçu pour l'optimisation de fonctions coûteuses, permet de converger plus rapidement vers le réglage optimale des paramètres du système. Enfin, il s'agit de travailler sur la mise au point des gains des observateurs. En générale, les observateurs sont réglés manuellement, ce qui est

une tâche difficile et fastidieuse. Grâce à la nouvelle méthode basée sur KEEP, le réglage des gains des observateurs est réalisée automatiquement et est donc fortement simplifiée. Notons que d'autres travaux sont d'ores-et-déjà en cours afin de compléter le travail de cette thèse, notamment dans l'analyse de la stabilité de la loi de commande (contrôleur et observateur) du système *Traffic Jam Pilot*, ce qui est un point-clé quant à l'intégration des nouvelles solutions d'observation et dans la boucle de commande des systèmes d'aide à la conduite.

Annexes



Autres systèmes d'aide à la conduite

Sommaire

A.1	Système de stationnement automatique	137
A.2	Système de <i>parking valet</i> autonome	138
A.3	Système de freinage d'urgence	138
A.4	Système de surveillance de la distraction du conducteur	139

Dans ce chapitre, d'autres ADAS et systèmes de surveillance en développement chez Renault sont présentés. L'idée est d'introduire les contraintes et les difficultés de ces différents systèmes afin de voir que les travaux réalisés dans cette thèse peuvent leur être également appliqués.

A.1 Système de stationnement automatique

Ce système, aussi appelé *AutoPark* a pour but de faciliter les manœuvres de parking en offrant la possibilité de faire un créneau de manière automatisée. Différentes versions du système sont déjà présentes sur le marché sur une large gamme de véhicules. Chez Renault, le système *Stationnement Automatique*, appelé *Easy Park Assist* (actuellement disponible sur la *Renault Espace V*, la *Renault Kadjar* et la *Renault Talisman*) prend le contrôle de la direction pendant la manœuvre en laissant gérer par le conducteur l'accélération, le freinage et le rapport de vitesse. La prochaine évolution du système, en cours de développement, devra contrôler le braquage, l'accélération et le freinage pendant le créneau.

Certains problèmes font que le système n'est pas si aisé à développer. Par exemple, une contrainte importante est que le conducteur doit toujours pouvoir reprendre la main pendant la manœuvre de parking, ce qui est considéré comme une perturbation dans la boucle de commande. Un autre problème est que les capteurs présentent des limites en terme de précision (ultrasons de courte et longue portée) et certaines configurations ne sont pas détectables (orientation des ultrasons), ce qui conduit les constructeurs automobiles à équiper les véhicules de caméras afin d'avoir plus d'informations et de palier ces limitations. Cependant, la fusion de données devient alors plus complexe et la mise au point plus compliquée. (*Il s'agit alors d'un problème complexe avec plusieurs mesures bruitées (comme le TJP) et un nombre important de paramètres pour la fusion d'informations (comme pour le SSPP indirect)*)

Afin de mettre au point ce système d'assistance, un modèle du véhicule est utilisé pour la réalisation de simulations selon une base de données constitué par un nombre important de scénarios et cas d'usage.

(Il s'agit d'une optimisation similaire à celle faite pour le SSPP indirect sous la contrainte d'utilisation d'une grande base de données)

A.2 Système de *parking valet autonome*

L'*Autonomous Valet Parking* [Chirca et al., 2015b] est un système qui contrôle le véhicule dans un environnement sécurisé (par exemple un parking ou une propriété privée) avec le but d'amener le véhicule d'une position de départ jusqu'à une position finale de manière complètement autonome (sans conducteur) (voir Figure A.1). Ce système est divisé en trois fonctions [Chirca et al., 2015a] :

- La *détection* d'obstacles et de zones navigables. Afin d'avoir le maximum d'informations sur l'environnement, plusieurs capteurs (ultrasons, caméras...) sont utilisés, ce qui fait que la fusion de données est complexe et difficile à gérer. Cette information permet de réaliser une carte d'obstacles laquelle est toujours mise à jour en s'adaptant à différents phénomènes comme la météo ou la période de la journée (jour ou nuit). La construction de cette carte est basée sur la méthode de SLAM¹, laquelle présente une optimisation de grande dimension. (Il s'agit d'une optimisation complexe avec un nombre important de paramètres, similaire au problème rencontré avec le SSPP indirect)
- La *localisation* du véhicule. Le bon positionnement du véhicule sur la carte d'obstacles est fondamental afin de bien définir la trajectoire et de mettre à jour la carte. Une fusion de données correcte permettra d'améliorer l'estimation de la position du véhicule sur la carte. (La plupart des mesures, obtenues en utilisant plusieurs capteurs et une caméra, sont généralement très bruitées (similaire au cas du TJP). En plus, plusieurs objectifs sont pris en compte (optimisation multi-objectif) afin de régler les paramètres de l'algorithme de fusion et de vérifier la robustesse par rapport aux bruits et perturbations des mesures.)
- La *navigation*. L'objectif est de définir un parcours optimal entre la position de départ et la position finale. La trajectoire doit éviter les obstacles présents dans la carte, laquelle sera recalculée si de nouveaux obstacles sont rencontrés. Afin de définir une trajectoire réaliste, le véhicule est modélisé en utilisant des dynamiques non linéaires. Comme certaines variables d'état ne sont pas mesurables, des observateurs sont introduits pour les estimer. En pratique, le réglage de ces observateurs est fait manuellement, ce qui est une tâche fastidieuse et chronophage. (Il s'agit d'un problème d'optimisation des gains d'observateur similaire à celui rencontré pendant la mise au point des observateurs du contrôle latérale du TJP)

A.3 Système de freinage d'urgence

L'*Advanced Emergency Breaking System* (AEBS) a pour but de détecter les situations où les vitesses relatives et les distances du véhicule par rapport aux différents obstacles indiquent qu'une collision est imminente. Dans ce cas, un freinage d'urgence est automatiquement appliqué afin d'éviter une collision ou afin de réduire l'impact du choc. Depuis le début 2014, l'AEBS est devenu obligatoire sur tout véhicule de transport (marchandises et voyageurs). Actuellement, le système AEBS est devenu très important pour la définition de sécurité de chaque modèle véhicule à travers des tests *EuroNCAP*².

La principale difficulté rencontrée chez Renault pendant la conception du AEBS a été la fusion de données. Afin d'avoir une information complète de l'environnement du véhicule, le système utilise les mesures réalisées par un radar et une caméra (voir Figure A.2). Si la fusion n'est pas réalisée correctement,

¹*Simultaneous Localization And Mapping*. Il s'agit de la méthode classique utilisée dans le contexte de la robotique ou des véhicules autonomes, pour la reconstruction ou l'amélioration d'une carte et de son environnement.

²Programme d'évaluation européenne des automobiles, spécialisé dans les tests de sécurité passive des véhicules.



FIGURE A.1: Exemple graphique du système *Autonomous Valet Parking*. (A gauche) Situation de départ du domicile, où le véhicule doit sortir du garage, (à droite) situation d'arrivée au domicile, où le véhicule doit se garer dans le garage. Les flèches bleues correspondent à la trajectoire du véhicule faite de manière autonome et les flèches blanches à la trajectoire réalisée par le conducteur. (source de l'image : [Chirca et al., 2015a])

le système peut estimer qu'il y a un obstacle alors qu'il n'existe pas (phénomène connu comme *faux positif*) : cela peut provoquer un fort freinage du véhicule, ce qui est une situation très dangereuse. Pour améliorer la performance du système et réduire le nombre de *faux positifs*, une grande base de donnée a été conçue avec plus de 1 million de *km* de roulage (Il s'agit d'une grande base de données comme celle utilisée pour la mise au point du SSPP indirect). Cette base de données a été indispensable pour la validation du système et sa mise au point car elle a permis d'améliorer le modèle de comportement et la fusion de données. Concrètement, la mise au point final du système a été faite manuellement par un ingénieur expert dans le domaine en cherchant le meilleur compromis entre les performances obtenues aux tests *EuroNCAP* (performance du système) et le taux de faux positifs obtenus. (Il s'agit d'un problème d'optimisation multi-objectif similaire au SSPP indirect, un bon exemple pour utiliser l'algorithme *KEEP*).

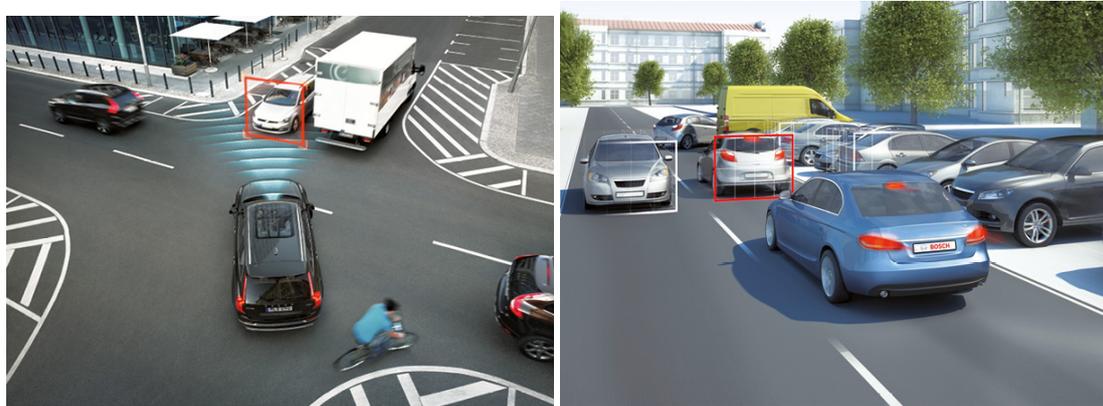


FIGURE A.2: Exemples graphiques de détection d'obstacles du système AEBS. (A gauche) Situation d'un carrefour en ville, (à droite) situation d'une ligne droite en ville. Les carrés rouges correspondent aux obstacles détectés par le radar, les carrés blancs aux obstacles détectés par la caméra. (source de l'image : [Web, 6])

A.4 Système de surveillance de la distraction du conducteur

Plusieurs études statistiques indiquent qu'entre 10 % et 20 % des accidents routiers sont liés à la fatigue et aux fautes d'inattention. Afin de réduire le taux d'accidents, les systèmes de *détection de distraction du conducteur* sont conçus pour alerter le conducteur lorsque ce dernier a une baisse d'attention (endormissement ou distraction).

Une grande partie de ces systèmes utilise des *mesures directes* comme, par exemple, la direction des yeux ; néanmoins, ils ont la contrainte d'avoir besoin d'utiliser des capteurs ou caméras supplémentaires. Afin de réduire le coût global des systèmes, certaines solutions proposent d'utiliser des *mesures indirectes* lesquelles sont déjà disponibles sur le réseau CAN du véhicule, tel l'accélération latérale, l'angle au volant,... *(Il s'agit d'une situation similaire aux SSPP direct et SSPP indirect (solution sans capteurs))*

La problématique principale des systèmes de détection de la distraction du conducteur réside dans la fusion de données, concrètement entre les mesures de l'environnement (mesures relatives à la perception de l'environnement, obtenus par une caméra frontale) et du conducteur (information neuromusculaire). Une solution proposée par [Ameyoe et al., 2015] est d'utiliser un modèle conducteur basé sur les dynamiques latérales du véhicule, afin de prédire le couple et l'angle au volant. À partir d'une comparaison entre les valeurs prédites et réelles, le système sera capable de détecter s'il y a une situation de baisse d'attention. *(Ce système utilise un modèle de la dynamique latérale du véhicule et une solution d'observation comme le système TJP).*

Par rapport à la mise au point du système, plusieurs seuils et paramètres doivent être réglés pour améliorer la performance du système (minimisation du taux de fausses alertes et non détections). Ce réglage a été fait en utilisant une grande base de données réalisée avec un simulateur, laquelle est constituée de plusieurs enregistrements faits avec des conducteurs de différents profils (age, expérience de conduite...). *(Il s'agit d'un problème similaire au SSPP indirect : une grande base de données et un nombre élevé de paramètres à régler, là encore un autre exemple d'application de l'algorithme KEEP)*



Réglage de la boucle du contrôle latéral du *Traffic Jam Pilot*

Sommaire

B.1 Introduction	141
B.2 Outil d'optimisation	142
B.3 Outil de mise au point	144

B.1 Introduction

La boucle de commande du contrôle latéral du système TJP envisagé par Renault et Nissan est composée de deux sous-systèmes différents dont seulement un des deux est utilisé en fonction de la vitesse et de l'information disponible du système. Le premier sous-système est appelé *Auto-Steer*, et est le sous-système étudié dans cette thèse (Chapitre 6). Il est généralement appliqué à des vitesses faibles ou dans des situations difficiles, comme par exemple lorsque l'information du marquage sur chaussée n'est pas disponible. Ce sous-système est contrôlé en prenant comme référence la trajectoire d'un véhicule cible. Le deuxième sous-système, le *Line Centering Assist* (LCA), est généralement utilisé à haute vitesse lorsque toutes les informations du radar et de la caméra sont disponibles. Dans ce cas, le sous-système prend comme référence la trajectoire définie pour les lignes au sol délimitant la voie.

Remarque B.1 *Le système LCA ne sera pas détaillé ici car il ne fait pas partie des travaux réalisés dans cette thèse.* ■

Les deux sous-système précédents modélisent la dynamique du véhicule sous une forme linéaire, pour la synthèse de la commande et de l'observateur (observateur de Kalman). Ces solutions linéaires sont réglées pour différentes *vitesses de référence* (VdR), ce qui est une façon de traiter les non linéarités du système en réduisant le range de la vitesse (pour plus de détails voir la Section 6.4). Concrètement, l'*Auto-Steer* est conçu selon 10 VdR ([5 10 20 30 40 50 60 70 80 90] $km \cdot h^{-1}$, voir Remarque 6.7) et le LCA selon 12 VdR ([5 10 20 30 40 55 70 90 110 130 150 170] $km \cdot h^{-1}$). Afin d'optimiser la boucle de commande du contrôle latéral du système TJP, il faut réaliser un réglage des gains de l'observateur (type Kalman) et de la commande (type LQR¹). Le nombre total de paramètres à optimiser est de **268** (voir Tableau B.1).

¹Régularisation linéaire-quadratique.

TABLEAU B.1: Nombre de paramètres à régler pour la commande et l'observateur de chaque sous-système (*Auto-Steer* et *LCA*) ; à gauche pour une VdR, et à droite pour toutes les VdR (10 VdR pour l'*Auto-Steer* et 12 pour le *LCA*).

1 VdR	Observateur	Commande	Toutes les VdR	Observateur	Commande
Auto-Steer	6	4	Auto-Steer	60	40
LCA	7	7	LCA	84	84

Remarque B.2 En considérant que l'optimisation de la commande et de l'observateur est faite à des vitesses de références constantes, la solution optimal du système à chaque vitesse de référence peut être réalisé indépendamment en se basant sur le principe de séparation présenté Section 5.2.3. ■

Les premières versions du système ont été réglées manuellement par un ingénieur spécialiste dans le domaine pendant quelques semaines, ce qui est fastidieux et chronophage ; de plus, cette opération devra être répétée pour le réglage du TJP par chaque modèle de véhicule. Afin de réaliser une mise au point plus rapide et automatisée, il a été proposée une solution similaire à la procédure de réglage des observateurs non linéaires (voir Section 6.6), laquelle est basée sur la méthode d'optimisation multi-objectif KEEP (voir Chapitre 3).

Une interface graphique créée pour la réalisation du réglage du contrôle latéral du système TJP est présentée ; cette interface permet d'avoir accès à un outil d'optimisation et à un outil de mise au point (voir Figure B.1).

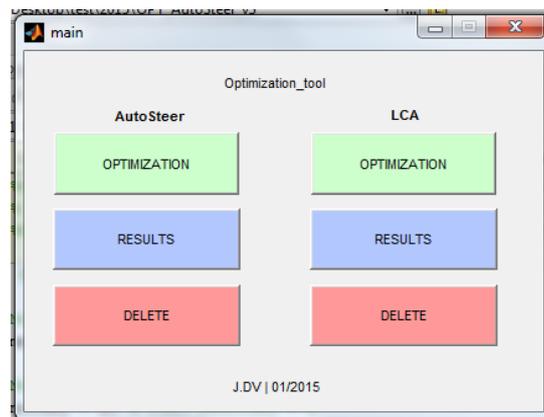


FIGURE B.1: Interface graphique du réglage du contrôle latéral du système TJP : accès à un outil d'optimisation (*optimization*) et à un outil de mise au point (*results*).

Remarque B.3 Les caractéristiques et le fonctionnement de l'outil sont détaillés dans un document technique [Davins-Valldaura et Pita-Gil, 2015] permettant une prise en main rapide. ■

B.2 Outil d'optimisation

L'outil propose d'optimiser indépendamment les observateurs et la commande à travers des résultats obtenus par *simulation*. Un scénario simple dont on connaît parfaitement les vrais valeurs d'état a été utilisé : concrètement, il s'agit d'une trajectoire le long d'un virage de courbure constante, réalisée à vitesse constante.

Les critères de performances utilisés pour l'optimisation des *observateurs* sont :

1. **Erreur d'estimation.** Ce critère est défini à partir de l'erreur relative de la courbure et de la distance latérale, lesquelles sont introduites Section 6.6.1 ;

2. **Stabilité de l'observateur.** Ce critère est basé sur la position des pôles de l'observateur (matrice $A - LC$) sur le plan complexe. Le but est de privilégier les solutions avec pôles à partie réelle négative plus élevée en valeur absolue et les solutions avec pôles à partie complexes qui ont une coordonnée polaire faible par rapport à l'axe réel négative.

Les critères d'optimisation de la *commande* ont été choisis en analysant les problèmes typiques que l'ingénieur avait rencontré lors de la première mise au point manuelle.

1. **Oscillations.** Ce critère correspond au fait que certaines solutions corrigent correctement la position du véhicule mais elles génèrent des oscillations, surtout dans la commande au niveau de l'angle de braquage des roues. Ce phénomène doit être minimisé.
2. **Erreur statique.** Ce critère correspond à l'écart latéral du véhicule par rapport à la *trajectoire de référence*². Une fois que l'estimation de l'observateur a convergé, et que la commande est stabilisée, l'écart latéral doit être minimal.

L'interface graphique (Figure B.2) permet d'optimiser les différentes VdR automatiquement, d'arrêter l'optimisation (en enregistrant les résultats afin de permettre de reprendre l'optimisation à ce point) et de voir la progression de l'optimisation à tout instant.

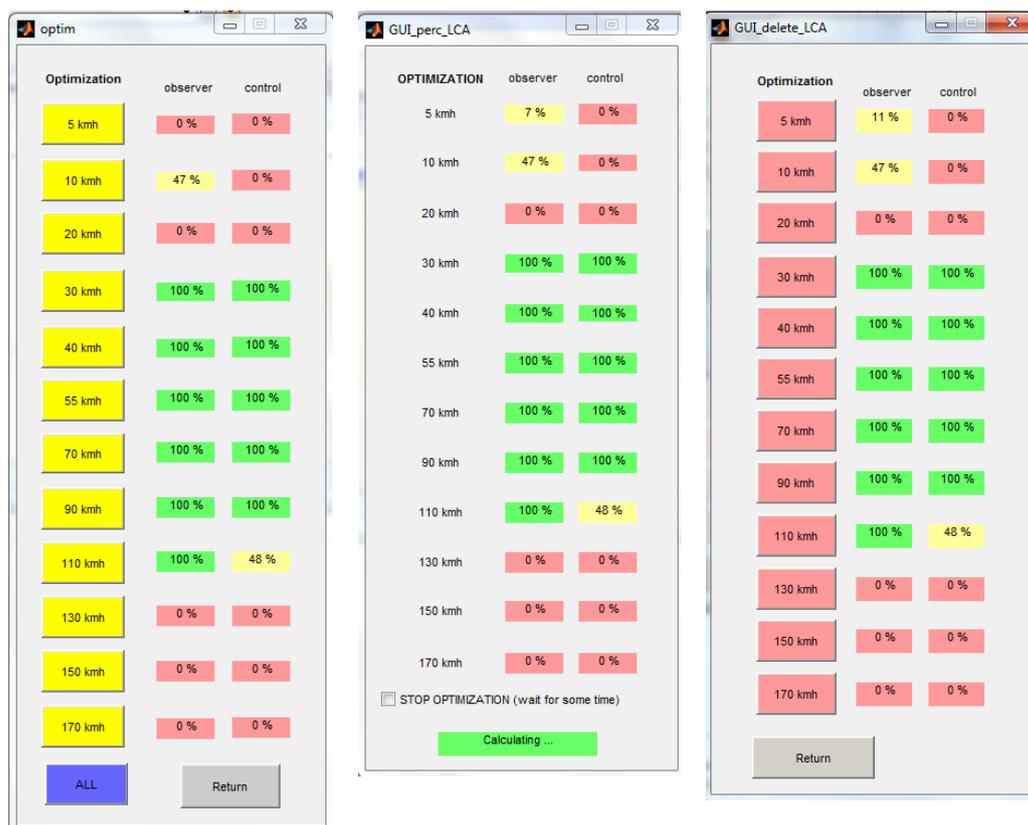


FIGURE B.2: Interface graphique de l'outil d'optimisation. Exemple d'optimisation du LCA. (À gauche) Interface pour lancer l'optimisation, laquelle permet d'optimiser une seule vitesse de référence (carrés jaunes) ou toutes les vitesses ensemble (carré bleu). La progression des optimisations réalisées est aussi affichée. (Au milieu) Interface affichée pendant l'optimisation afin de voir la progression et d'arrêter l'optimisation (stop optimisation) si nécessaire. (À droite) Interface pour éliminer les résultats d'optimisation obtenus par une vitesse de référence (carrés rouges).

²Les trajectoires de référence de l'Auto-Steer et du LCA sont les trajectoires réalisées par le véhicule cible et induits par le marquage sur le sol, respectivement.

B.3 Outil de mise au point

L'objectif de cet outil est de présenter les résultats obtenus par l'optimisation précédente et de permettre de choisir un réglage optimal pour l'observateur et la commande. L'outil de mise au point divise la procédure de réglage en cinq phases. À noter que cette procédure doit être faite par chaque VdR.

1. **Sélection des paramètres.** (Figure B.3) Les résultats obtenus pour l'optimisation de l'observateur et la commande sont représentés. L'outil permet de choisir une configuration de paramètres pour l'observateur et pour la commande en regardant un compromis entre les critères définis à la Section B.2. Les configurations que l'outil permet de sélectionner appartiennent à l'ensemble des solutions optimales ou *non-dominées*³ au sens de Pareto.

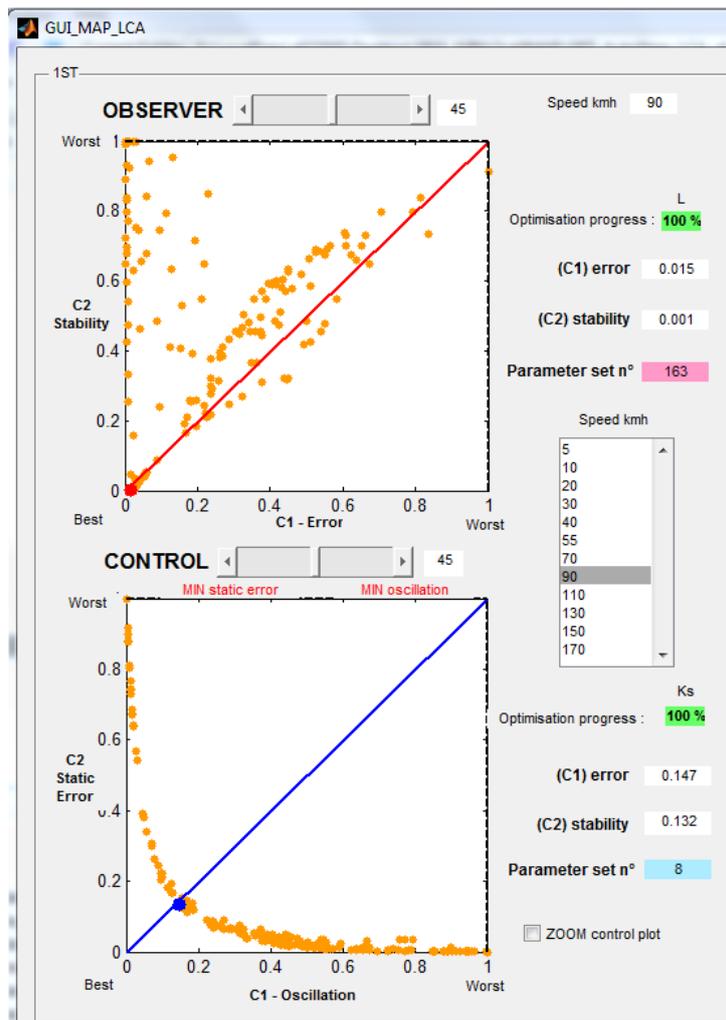


FIGURE B.3: Interface graphique de l'outil de mise au point correspondant à la phase de *sélection des paramètres*.

2. **Calcul des matrices des gains.** (Figure B.4) Une fois les configurations de paramètres fixées, les pôles de la matrice $(A - BK)$ (K étant les gains de la commande) et de la matrice $(A - LC)$ (L étant les gains de l'observateur) sont représentés. L'idée est de vérifier que les deux solutions sont stables et que l'observateur est plus rapide que la commande. Les valeurs finales de L et K (voir Sections 6.3 et 6.4) sont aussi affichées.
3. **Re-simulation dans de conditions différentes.** (Figure B.5) À partir des matrices L et K , l'interface graphique permet de réaliser différents types de tests afin de vérifier les performances.

³Notion introduite à la Section 2.3.

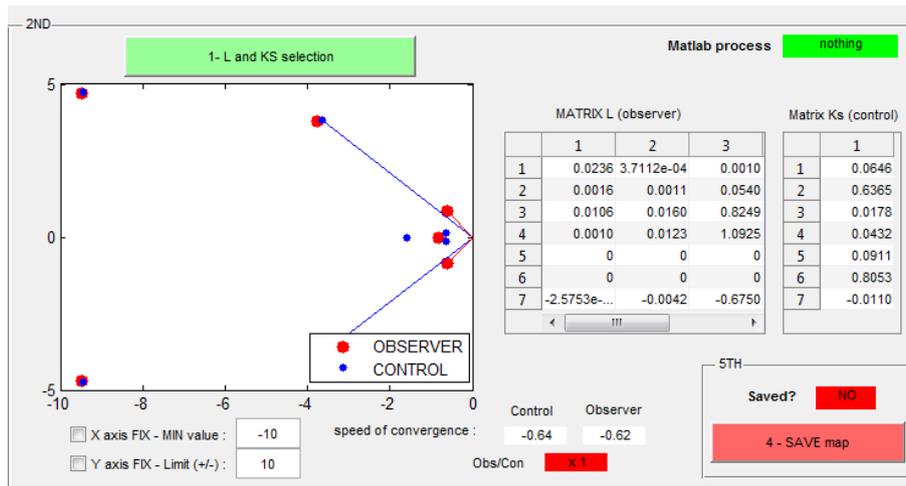


FIGURE B.4: Interface graphique de l’outil de mise au point correspondant aux phases de *calcul des matrices de gains* (2ND) et de *création de fichiers de résultats* (5TH).

Notons qu’une performance de référence, laquelle correspond aux matrices L et K utilisées par Nissan (obtenues par réglage manuel), est aussi représentée afin d’avoir un résultat de référence. Les possibles caractéristiques à modifier sont :

- le rayon de la courbure (entre 5 000 m et 50 m). L’option de réaliser la simulation en ligne droite a été introduite ;
- deux conditions initiales des observateurs (une égale aux vraies valeurs d’état, et une autre très différente). L’idée est de vérifier la convergence de l’estimation de l’observateur ;
- l’introduction d’une erreur dans la valeur du rayon ($\pm 2\%$) et d’une erreur de mesure ($\pm 10\%$).

L’interface graphique permet de représenter et de comparer les valeurs de la commande, de l’angle au volant et de l’écart latéral obtenus avec l’optimisation d’une part et avec l’approche Nissan d’autre part.

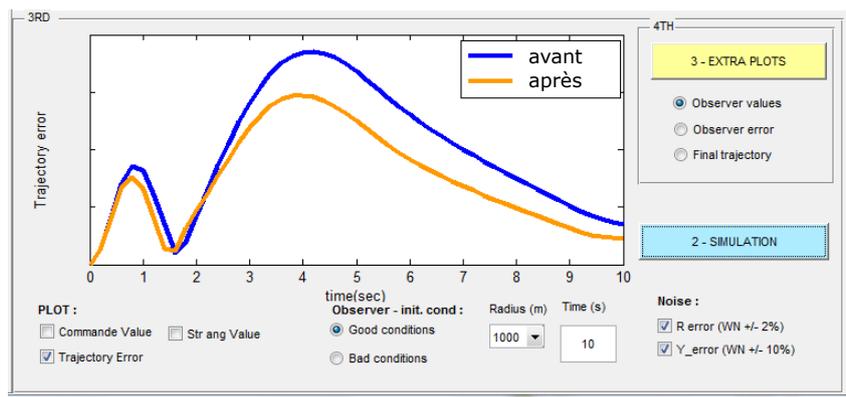


FIGURE B.5: Interface graphique de l’outil de mise au point correspondant aux phases de *re-simulations dans des conditions différentes* (3RD) et de *réalisation de figures supplémentaires* (4TH).

4. **Réalisation de figures supplémentaires.** (Figure B.5) Des figures supplémentaires peuvent être faites afin de vérifier la solution proposée : une pour comparer les valeurs d’état et les valeurs estimées par l’observateur, une pour comparer les erreurs d’estimation et une dernière pour comparer la trajectoire du véhicule réalisée par rapport à la trajectoire de référence.
5. **Création de fichiers de résultats.** (Figure B.4) Une fois les configurations choisies et vérifiées, les matrices L et K sont stockées. Lorsque les gains de toutes les VdR sont enregistrés, l’outil permet

de générer automatiquement un fichier de calibration, lequel est nécessaire pour l'initialisation du système TJP complet.

Conseils pour la réalisation de la mise au point

Pour choisir une bonne combinaison des gains de l'observateur et de la commande, il est proposé de re-simuler (phase 3) la trajectoire du véhicule et l'angle au volant dans des conditions différentes afin de regarder différents aspects (voir Figure B.6) :

- le système doit être toujours stable ;
- l'erreur (une fois le système stabilisé) permettra de vérifier la présence d'erreurs statiques ou d'*offsets* ;
- la vitesse de convergence. La solution finale doit converger rapidement et corriger efficacement la trajectoire du véhicule ;
- les valeurs d'écart latéral et d'angle au volant doivent toujours rester dans une échelle de valeurs raisonnables ;
- les oscillations doivent être minimisées afin d'améliorer le confort des passagers.

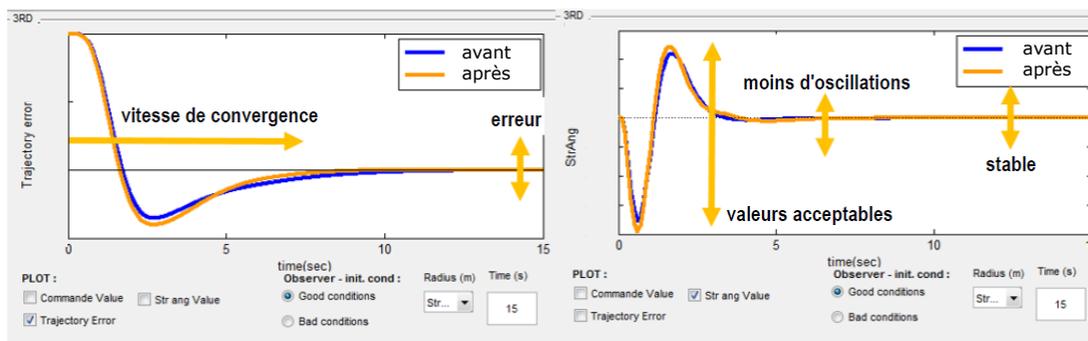


FIGURE B.6: Critères pris en compte pour la sélection finale des paramètres par rapport aux performances obtenues.

Bibliographie

- [**Aldrich, 1997**] Aldrich, J. (1997). R. A. Fisher and the Making of Maximum Likelihood 1912-1922. *Statistical Science*, 12(3), 162–176.
- [**Ameyoe et al., 2015**] Ameyoe, A., Mars, F., Chevrel, P., Le Carpentier, E., et Illy, H. (Septembre 2015). Estimation of Driver Distraction Using the Prediction Error of a Cybernetic Driver Model. In *Driving Simulation Conference and Exhibition* (pp. 13–18). Tübingen, Germany.
- [**Audet et Dennis, 2006**] Audet, C. et Dennis, Jr., J. E. (2006). Mesh adaptive direct search algorithms for constrained optimization. *SIAM Journal on Optimization*, 17(1), 188–217.
- [**Auger et al., 2012**] Auger, A., Bader, J., Brockhoff, D., et Zitzler, E. (2012). Hypervolume-based Multiobjective Optimization : Theoretical Foundations and Practical Implications. *Theoretical Computer Science*, 425, 75–103.
- [**Baffet et al., 2009**] Baffet, G., Charara, A., et Lechner, D. (2009). Estimation of vehicle sideslip, tire force and wheel cornering stiffness. *Control Engineering Practice*, 17(11), 1255–1264.
- [**Berthiau et Siarry, 2001**] Berthiau, G. et Siarry, P. (2001). État de l’art des méthodes d’optimisation globale. *RAIRO-Operations Research*, 35(03), 329–365.
- [**Bettinger, 2009**] Bettinger, R. (Octobre 2009). *Inversion d’un système par krigeage*. Phd thesis, Université Nice Sophia Antipolis.
- [**Bompard, 2011**] Bompard, M. (Décembre 2011). *Modèles de substitution pour l’optimisation globale de forme en aérodynamique et méthode locale sans paramétrisation*. Phd thesis, Université Nice Sophia Antipolis.
- [**Bornard et Hammouri, 1991**] Bornard, G. et Hammouri, H. (1991). A high gain observer for a class of uniformly observable systems. In *IEEE Conference on Decision and Control* (pp. 1494–1496). Brighton, United Kingdom.
- [**Bouibed et al., 2010**] Bouibed, K., Aitouche, A., et Bayart, M. (Juin 2010). Sensor and actuator fault detection and isolation using two model based approaches : Application to an autonomous electric vehicle. In *Conference on Control and Automation* (pp. 1290–1295). Marrakech, Morocco.
- [**Boussaïd et al., 2013**] Boussaïd, I., Lepagnot, J., et Siarry, P. (2013). A survey on optimization meta-heuristics. *Information Sciences*, 237, 82–117.
- [**Box et Draper, 1959**] Box, G. E. P. et Draper, N. R. (1959). A basis for the selection of a response surface design. *Journal of the American Statistical Association*, 54(287), 622–654.
- [**Box et Hill, 1967**] Box, G. E. P. et Hill, W. J. (1967). Discrimination among mechanistic models. *Technometrics*, 9(1), 57–71.
- [**Box et Wilson, 1951**] Box, G. E. P. et Wilson, K. (1951). On the experimental attainment of optimum conditions. *Journal of the Royal Statistical Society. Series B (Methodological)*, 13(1), 1–45.

- [**Boyd et Vandenberghe, 2004**] Boyd, S. et Vandenberghe, L. (2004). *Convex Optimization*. New York, NY, United States : Cambridge University Press.
- [**Bregeault, 2010**] Bregeault, V. (2010). *Quelques contributions à la théorie de la commande par modes glissants*. PhD thesis, Ecole Centrale de Nantes.
- [**Carvalho et al., 2015**] Carvalho, A., Lefèvre, S., Schildbach, G., Kong, J., et Borrelli, F. (2015). Automated driving : The role of forecasts and uncertainty - A control perspective. *European Journal of Control*, 24, 14–32.
- [**Chase et al., 2009**] Chase, N., Rademacher, M., Goodman, E., Averill, R., et Sidhu, R. (2009). *A benchmark study of multi-objective optimization methods*. Technical Report BMK - 3021, Red cedar technology.
- [**Chelouah et Siarry, 2000**] Chelouah, R. et Siarry, P. (2000). A continuous genetic algorithm designed for the global optimization of multimodal functions. *Journal of Heuristics*, 6(2), 191–213.
- [**Chirca et al., 2015a**] Chirca, M., Chapuis, R., Martin, G., Debain, C., et Lenain, R. (Septembre 2015a). Autonomous valet parking system architecture. In *IEEE Conference on Intelligent Transportation Systems* (pp. 2619–2624). Las Palmas, Spain.
- [**Chirca et al., 2015b**] Chirca, M., Martin, G., Minoiu-Enache, N., Vorobieva, H., et Guegan, S. (2015b). Dispositif et procédé de stationnement automatique d'un véhicule automobile. FR Patent App. 15-51-027, Renault.
- [**Cody, 1976**] Cody, W. (1976). An overview of software development for special functions. In *Numerical Analysis* (pp. 38–48). Springer Verlag Berlin.
- [**Coello et al., 2004**] Coello, C. A. C., Pulido, G. T., et Lechuga, M. S. (2004). Handling multiple objectives with particle swarm optimization. *IEEE Transactions on Evolutionary Computation*, 8(3), 256–279.
- [**Coello et al., 2007**] Coello, C. C., Lamont, G. B., et Van Veldhuizen, D. A. (2007). *Evolutionary algorithms for solving multi-objective problems*. Springer.
- [**Collette et Siarry, 2003**] Collette, Y. et Siarry, P. (2003). *Multiobjective optimization : principles and case studies*. Springer.
- [**Conn et al., 2009**] Conn, A. R., Scheinberg, K., et Vicente, L. N. (2009). *Introduction to derivative-free optimization*, volume 8. SIAM.
- [**Corne et al., 2001**] Corne, D. W., Jerram, N. R., Knowles, J. D., et Oates, M. J. (Juillet 2001). PESA-II : Region-based Selection in Evolutionary Multiobjective Optimization. In *Genetic and Evolutionary Computation Conference* (pp. 283–290). San Francisco, CA, United States.
- [**Corne et al., 2000**] Corne, D. W., Knowles, J. D., et Oates, M. J. (2000). The Pareto envelope-based selection algorithm for multiobjective optimization. In *Parallel Problem Solving from Nature VI* (pp. 839–848). Springer.
- [**Cox et John, 1997**] Cox, D. D. et John, S. (1997). SDO : A statistical method for global optimization. In *Multidisciplinary Design Optimization : State-of-the-Art* (pp. 315–329).
- [**Cressie, 2015**] Cressie, N. (2015). *Statistics for spatial data*. John Wiley & Sons.
- [**Dabladji et al., 2014**] Dabladji, M. E.-H., Ichalal, D., Arioui, H., et Mammar, S. (Août 2014). Estimation of lateral dynamics and road curvature for two-wheeled vehicles : A hoshm observer approach. In *International Federation of Automatic Control* (pp. 2806–2811). Cape Town, South Africa.

- [**Dahmani et al., 2015**] Dahmani, H., Chadli, M., Rabhi, A., et El Hajjaji, A. (2015). Vehicle dynamics and road curvature estimation for lane departure warning system using robust fuzzy observers : experimental validation. *Vehicle System Dynamics*, 53, 1–15.
- [**Dahmani et al., 2011**] Dahmani, H., Mohammed, C., Rabhi, A., et El Hajjaji, A. (Juin 2011). Vehicle dynamics and road geometry estimation using a takagi-sugeno fuzzy observer with unknown inputs. In *IEEE Intelligent Vehicles Symposium* (pp. 272–277). Kongresshaus Baden-Baden, Germany.
- [**Davins-Valldaura, 2012**] Davins-Valldaura, J. (2012). Algorithme de décision avec la logique floue. Universitat Politècnica de Catalunya and ENSTA ParisTech.
- [**Davins-Valldaura et al., 2015a**] Davins-Valldaura, J., Ballesteros-Tolosana, I., Plestan, F., Moussaoui, S., et Vignaud, J. (2015a). Control latéral du TJP à plages des vitesses variables. Brevet en cours de dépôt : PJ-15-0686 , Renault.
- [**Davins-Valldaura et al., 2016a**] Davins-Valldaura, J., Franck, P., Moussaoui, S., et Pita Gil, G. (Juin 2016a). Sliding mode observer design for the road curvature estimation in Traffic Jam Pilot system. In *14th International Workshop on Variable Structure Systems* Nanjing, China.
- [**Davins-Valldaura et al., 2016b**] Davins-Valldaura, J., Moussaoui, S., Pita-Gil, G., et Plestan, F. (2016b). ParEGO extensions for multi-objective optimization of expensive evaluation functions. *Journal of Global Optimization*, (pp. 1–18).
- [**Davins-Valldaura et al., 2015b**] Davins-Valldaura, J., Moussaoui, S., Plestan, F., et Pita Gil, G. (Février 2015b). ParEGO Extensions for Multi-objective Optimization of Expensive Evaluation Function. In *World Congress on Global Optimization* (pp. 15–16). Gainesville, FL, United States.
- [**Davins-Valldaura et Pita-Gil, 2015**] Davins-Valldaura, J. et Pita-Gil, G. (2015). *Project AD1 – Low Level Identification and Tuning*. Functional Specification 65616-2015-06, pages 13–20, Renault.
- [**Davins-Valldaura et Saint-Loup, 2015**] Davins-Valldaura, J. et Saint-Loup, P. (2015). *Project ATPMS – Tuning Algorithm*. Functional Specification 65616-2015-05, Renault. 1–39.
- [**De-Rinaldis et al., 2012**] De-Rinaldis, A., Pothin, R., Cayoln, O., et Lorimier, L. (2012). *Synthèse des informations sur le système de détection de crevaison des pneus*. Technical report, Renault.
- [**De Wit et Slotine, 1991**] De Wit, C. C. et Slotine, J.-J. (1991). Sliding observers for robot manipulators. *Automatica*, 27(5), 859–864.
- [**Deb et al., 2000**] Deb, K., Pratap, A., Agarwal, S., et Meyarivan, T. (2000). A fast elitist multi-objective genetic algorithm : NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6, 182–197.
- [**Dixon, 1996**] Dixon, J. C. (1996). *Tires, Suspension and Handling*. Society of Automotive Engineers.
- [**Doraiswami et al., 2014**] Doraiswami, R., Stevenson, M., et Diduch, C. (2014). *Identification of Physical Systems : Applications to Condition Monitoring, Fault Diagnosis, Soft Sensor and Controller Design*. John Wiley & Sons.
- [**Dorigo et al., 1996**] Dorigo, M., Maniezzo, V., et Colorni, A. (1996). Ant system : optimization by a colony of cooperating agents. *IEEE Transactions on Systems, Man, and Cybernetics*, 26(1), 29–41.
- [**Doumiati, 2009**] Doumiati, M. (Octobre 2009). *Estimation embarquée des efforts verticaux et latéraux d'un véhicule pour le diagnostic du comportement sur route*. PhD thesis, Université de Technologie de Compiègne.
- [**Drakunov, 1992**] Drakunov, S. V. (Décembre 1992). Sliding-mode observers based on equivalent control method. In *IEEE Conference on Decision and Control* (pp. 2368–2369). Tucson, AZ, United States.

- [**Dréo et al., 2003**] Dréo, J., Siarry, P., Pérowski, A., et Taillard, E. (2003). *Metaheuristics for hard optimization : methods and case studies*. Springer.
- [**Droesbeke et al., 1997**] Droesbeke, J.-J., Saporta, G., et Fine, J. (1997). *Plans d'expériences : applications à l'entreprise*. Editions Technip.
- [**Dugard et al., 2012**] Dugard, L., Sename, O., Aubouet, S., et Talon, B. (2012). Full vertical car observer design methodology for suspension control applications. *Control Engineering Practice*, 20(9), 832–845.
- [**Durrande, 2011**] Durrande, N. (Novembre 2011). *Étude de classes de noyaux adaptées à la simplification et à l'interprétation des modèles d'approximation. Une approche fonctionnelle et probabiliste*. Phd thesis, École Nationale Supérieure des Mines, Saint-Étienne.
- [**Economic Commission for Europe, 2009**] Economic Commission for Europe, I. (2009). *Note of Evolution of Regulation N° 64610-2010-001N*. Technical report, World Forum for Harmonization of Vehicle Regulations, Geneva, Switzerland.
- [**Edling et al., 2012**] Edling, F., Gootjes, L., Köbe, A., Griesser, M., Koukes, V., Cunz, J., Irth, M., Hofmann, M., Blank, F., Duchow, A., et al. (2012). Method for recognition of a pressure loss in motor vehicle tires. US Patent 2012/8180523.
- [**El-Beltagy et Keane, 1999**] El-Beltagy, M. A. et Keane, A. J. (1999). A comparison of genetic algorithms with various optimization methods for multi-level problems. *Engineering Applications of Artificial Intelligence*, 12, 639–654.
- [**El-Tannoury, 2012**] El-Tannoury, C. (Mars 2012). *Development of vehicle tire pressure monitoring tools using methods based on spectral analysis and observers synthesis*. PhD thesis, Ecole Centrale de Nantes.
- [**El Tannoury et al., 2013**] El Tannoury, C., Moussaoui, S., Plestan, F., Romani, N., et Pita Gil, G. (2013). Synthesis and application of nonlinear observers for the estimation of tire effective radius and rolling resistance of an automotive vehicle. *IEEE Transactions on Control Systems Technology*, 21(6), 2408–2416.
- [**Esfandiari et Khalil, 1992**] Esfandiari, F. et Khalil, H. K. (1992). Output feedback stabilization of fully linearizable systems. *International Journal of control*, 56(5), 1007–1037.
- [**Farrelly et Wellstead, 1996**] Farrelly, J. et Wellstead, P. (1996). Estimation of vehicle lateral velocity. *IEEE International Conference on Control Applications*.
- [**Filipescu et al., 2003**] Filipescu, A., Dugard, L., et Dion, J.-M. (Décembre 2003). Adaptive gain sliding observer based sliding controller for uncertain parameters nonlinear systems. application to flexible joint robots. In *IEEE Conference on Decision and Control* (pp. 3537–3542). Maui, HI, United States.
- [**Fridman et al., 2007**] Fridman, L., Levant, A., et Davila, J. (2007). Observation of linear systems with unknown inputs via high-order sliding-modes. *International Journal of Systems Science*, 38(10), 773–791.
- [**Friedman, 1991**] Friedman, J. H. (1991). Multivariate Adaptive Regression Splines. *The Annals of Statistics*, 19(1), 1–67.
- [**Fujimoto et al., 2004**] Fujimoto, H., Saito, T., et Noguchi, T. (Mars 2004). Motion stabilization control of electric vehicle under snowy conditions based on yaw-moment observer. In *International Workshop on Advanced Motion Control* (pp. 35–40). Kawasaki, Japan.
- [**Fukatani, 1997**] Fukatani, K. (1997). Vehicle state observer system. Patent US 5/652.379, Toyota.

- [**Gandin et Hardin, 1965**] Gandin, L. S. et Hardin, R. (1965). *Objective analysis of meteorological fields*, volume 242. Israel program for scientific translations Jerusalem.
- [**Gao et al., 2010**] Gao, Y., Lin, T., Borrelli, F., Tseng, E., et Hrovat, D. (Janvier 2010). Predictive control of autonomous ground vehicles with obstacle avoidance on slippery roads. In *Dynamic Systems and Control Conference* (pp. 265–272). Cambridge, MA, United States.
- [**Gauthier et Bornard, 1981**] Gauthier, J. et Bornard, G. (1981). Observability for any $u(t)$ of a class of nonlinear systems. *IEEE Transactions on Automatic Control*, 26(4), 922–926.
- [**Gauthier et al., 1992**] Gauthier, J. P., Hammouri, H., et Othman, S. (1992). A simple observer for nonlinear systems applications to bioreactors. *IEEE Transactions on Automatic Control*, 37(6), 875–880.
- [**Geng et al., 2009**] Geng, C., Mostefai, L., Denai, M., et Hori, Y. (2009). Direct yaw-moment control of an in-wheel-motored electric vehicle based on body slip angle fuzzy observer. *IEEE Transactions on Industrial Electronics*, 56(5), 1411–1419.
- [**Gillespie, 1992**] Gillespie, T. D. (1992). *Fundamentals of vehicle dynamics*. Technical report, SAE Technical Paper.
- [**Gilmore et Kelley, 1995**] Gilmore, P. et Kelley, C. T. (1995). An implicit filtering algorithm for optimization of functions with many local minima. *SIAM Journal on Optimization*, 5(2), 269–285.
- [**Gorp et al., 2015**] Gorp, J. V., Defoort, M., Djemai, M., et Veluvolu, K. C. (2015). Fault detection based on higher-order sliding mode observer for a class of switched linear systems. *IET Control Theory Applications*, 9(15), 2249–2256.
- [**Guldner et al., 1994**] Guldner, J., Utkin, V., et Ackermann, J. (Juin 1994). A sliding mode control approach to automatic car steering. In *American Control Conference* (pp. 1969–1973). Baltimore, MD, United States.
- [**Gutmann, 1999**] Gutmann, H.-M. (1999). A radial basis function method for global optimization. *Journal of Global Optimization*, 19.
- [**Hall et Gustavsson, 2013**] Hall, P. et Gustavsson, T. (2013). Tire pressure classification based tire pressure monitoring. US Patent 2013/8494704.
- [**Haouari et al., 2013**] Haouari, F., Cherki, B., et Djemai, M. (Octobre 2013). Sliding mode observers for takagi-sugeno fuzzy models. In *IEEE International Conference on Systems and Control* (pp. 1061–1065). Algiers, Algeria.
- [**Hermann et Krener, 1977**] Hermann, R. et Krener, A. J. (1977). Nonlinear controllability and observability. *IEEE Transactions On Automatic Control*, 5(22).
- [**Hernandez, 1994**] Hernandez, J. (Mars 1994). *Sur la synthese de lois de commande non lineaires avec observateur : applications a la robotique et a l'electrotechnique*. PhD thesis, Université de Paris-Sud, Orsay.
- [**Holland, 1992**] Holland, J. H. (1992). *Adaptation in natural and artificial systems : an introductory analysis with applications to biology, control, and artificial intelligence*. U. Michigan Press.
- [**Hooke et Jeeves, 1961**] Hooke, R. et Jeeves, T. A. (1961). "Direct Search" solution of numerical and statistical problems. *Journal of the ACM*, 8(2), 212–229.
- [**Huband et al., 2006**] Huband, S., Hingston, P., Barone, L., et While, L. (2006). A review of multiobjective test problems and a scalable test problem toolkit. *IEEE Transactions on Evolutionary Computation*, 10(5), 477–506.

- [**Huyer et Neumaier, 1999**] Huyer, W. et Neumaier, A. (1999). Global optimization by multilevel coordinate search. *Journal of Global Optimization*, 14(4), 331–355.
- [**Imine et Dolcemascolo, 2008**] Imine, H. et Dolcemascolo, V. (2008). Sliding mode observers to heavy vehicle vertical forces estimation. *International Journal of Heavy Vehicle Systems*, 15(1), 53–64.
- [**Imine et al., 2011**] Imine, H., Fridman, L., Shraim, H., et Djemai, M. (2011). *Sliding mode based analysis and identification of vehicle dynamics*. Springer.
- [**Jin et al., 2000**] Jin, R., Chen, W., et Simpson, T. W. (2000). Comparative studies of metamodeling techniques under multiple modeling criteria. *Structural and Multidisciplinary Optimization*, 23, 1–13.
- [**Johnson et al., 1990**] Johnson, M. E., Moore, L. M., et Ylvisaker, D. (1990). Minimax and maximin distance designs. *Journal of statistical planning and inference*, 26(2), 131–148.
- [**Jones, 2001**] Jones, D. R. (2001). A taxonomy of global optimization methods based on response surfaces. *Journal of Global Optimization*, 21, 345–383.
- [**Jones et al., 1993**] Jones, D. R., Perttunen, C. D., et Stuckman, B. E. (1993). Lipschitzian optimization without the lipschitz constant. *Journal of Optimization Theory and Applications*, 79(1), 157–181.
- [**Jones et al., 1998**] Jones, D. R., Schonlau, M., et Welch, W. J. (1998). Efficient global optimization of expensive black-box functions. *Journal of Global Optimization*, 13(4), 455–492.
- [**Journel et Huijbregts, 1978**] Journel, A. G. et Huijbregts, C. J. (1978). *Mining geostatistics*. Academic press.
- [**Kalman, 1960**] Kalman, R. (1960). A new approach to linear filtering and prediction problems. *Journal of Basic Engineering*, 82(1), 35–45.
- [**Kalman, 1963**] Kalman, R. (1963). Mathematical description of linear dynamical systems. *SIAM Journal of the Society for Industrial and Applied Mathematics*, 1(2), 152–192.
- [**Kang et al., 2013**] Kang, C. M., Kim, B.-A., Lee, S.-H., et Chung, C. C. (Octobre 2013). Sliding mode observer for vehicle states estimation. In *International Conference on Control, Automation and Systems* (pp. 747–750). Gwangju, Korea.
- [**Kelley, 1999**] Kelley, C. (1999). Detection and remediation of stagnation in the nelder–mead algorithm using a sufficient decrease condition. *SIAM Journal on Optimization*, 10(1), 43–55.
- [**Kennedy et Eberhart, 1995**] Kennedy, J. et Eberhart, R. (Novembre 1995). Particle swarm optimization. In *IEEE International Conference on Neural Networks*, volume 4 (pp. 1942–1948). Perth, Western Australia.
- [**Khemoudj et al., 2010**] Khemoudj, O., Imine, H., et Djemai, M. (Juin 2010). Variable gain sliding mode observer for heavy duty vehicle tyre forces estimation. In *International Workshop on Variable Structure Systems* (pp. 522–527). Mexico City, Mexico.
- [**Kiencke et Daiß, 1997**] Kiencke, U. et Daiß, A. (1997). Observation of lateral vehicle dynamics. *Control Engineering Practice*, 5(8), 1145 – 1150.
- [**Kim, 2009**] Kim, J. (2009). Identification of lateral tyre force dynamics using an extended kalman filter from experimental road test data. *Control Engineering Practice*, 17(3), 357–367.
- [**Knowles, 2005**] Knowles, J. (2005). ParEGO : A hybrid algorithm with on-line landscape approximation for expensive multiobjective optimization problems. *IEEE Transactions on Evolutionary Computation*, 10(1), 50–66.

- [**Knowles et Hughes, 2005**] Knowles, J. et Hughes, E. J. (2005). Multiobjective optimization on a budget of 250 evaluations. In *Evolutionary Multi-Criterion Optimization* : Springer-Verlag.
- [**Kokotovic, 1992**] Kokotovic, P. (1992). Bode lecture : The joy of feedback. *IEEE Control Systems Magazine*, 3, 7–17.
- [**Kolmogorov, 1950**] Kolmogorov, A. (1950). Foundations of the theory of probability.
- [**Kong et al., 2015**] Kong, J., Pfeiffer, M., Schildbach, G., et Borrelli, F. (2015). Kinematic and dynamic vehicle models for autonomous driving control design. In *IEEE Intelligent Vehicles Symposium* (pp. 1094–1099).
- [**Koo et al., 2004**] Koo, S.-L., Tan, H.-S., et Tomizuka, M. (Juin 2004). Nonlinear tire lateral force versus slip angle curve identification. In *American Control Conference* (pp. 2128 – 2133). Boston, MA, United States.
- [**Krener et Respondek, 1985**] Krener, A. et Respondek, W. (1985). Nonlinear observers with linearizable error dynamics. *SIAM J. Control Optim.*, 23(2), 197–216.
- [**Krige, 1951**] Krige, D. (1951). A statistical approach to some basic mine valuation problems on the witwatersrand. *Journal of the Chemical, Metallurgical and Mining Society*, 52, 119–139.
- [**Kushner, 1964**] Kushner, H. J. (1964). A New Method of Locating the Maximum Point of an Arbitrary Multipeak Curve in the Presence of Noise. *Journal of Basic Engineering*, 86(1).
- [**Lebastard et al., 2011**] Lebastard, V., Aoustin, Y., et Plestan, F. (2011). Estimation of absolute orientation for a bipedal robot : Experimental results. *IEEE Transactions on Robotics*, 27(1), 170–174.
- [**Lee et Khalil, 1997**] Lee, K. W. et Khalil, H. K. (1997). Adaptive output feedback control of robot manipulators using high-gain observer. *International Journal of Control*, 67(6), 869–886.
- [**Lescarret et al., 2015**] Lescarret, S., Saint-Loup, P., Pita-Gil, G., et Davins-Valldaura, J. (2015). Stratégie de détection indirecte de sous-gonflage par identification d'un écart de fréquence inter essieu. Brevet en cours de dépôt : PJ-15-0063, Acsystème et Renault.
- [**Levant, 1993**] Levant, A. (1993). Sliding order and sliding accuracy in sliding mode control. *International Journal of Control*, 58(6), 1247–1263.
- [**Levant, 2003**] Levant, A. (2003). Higher-order sliding modes, differentiation and output-feedback control. *International Journal of Control*, 76(9-10), 924–941.
- [**Levant, 2012**] Levant, A. (2012). Finite-time stability and high relative degrees in sliding-mode control. In *Sliding Modes after the First Decade of the 21st Century* (pp. 59–92). Springer Berlin Heidelberg.
- [**Lou et al., 2002**] Lou, Y., Dilger, F. P.-E., et Musson, J. T. (2002). Online frequency analysis for resource optimized systems. US Patent 2002/6374163.
- [**Luenberger, 1964**] Luenberger, D. G. (1964). Observing the state of a linear system. *IEEE Transactions on Military Electronics*, 8(2), 74–80.
- [**Luenberger, 1966**] Luenberger, D. G. (1966). Observers for multivariable systems. *IEEE Transactions on Automatic Control*, 11(2), 190–197.
- [**Marques, 1993**] Marques, J.-C. (Novembre 1993). *Sur la stabilisation de systèmes non linéaires à l'aide d'observateurs*. PhD thesis, Université Claude Bernard-Lyon.
- [**Matheron, 1962**] Matheron, G. (1962). *Traité de géostatistique appliquée*, volume 14. Paris : Editions Technip.

- [**Mayer, 1994**] Mayer, H. (Août 1994). Comparative diagnosis of tyre pressures. In *IEEE Conference on Control Applications* (pp. 627–632). Glasgow, United Kingdom.
- [**McCullagh et Nelder, 1989**] McCullagh, P. et Nelder, J. A. (1989). *Generalized Linear Models*. London : Chapman and Hall.
- [**McKay et al., 1979**] McKay, M. D., Beckman, R. J., et Conover, W. J. (1979). 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.
- [**Menhour et al., 2011**] Menhour, L., Lechner, D., et Charara, A. (2011). Commande et observation d'un véhicule automobile pour le diagnostic de rupture d'un itinéraire. *Actes de l'Institut National de Recherche sur les Transports et leur Sécurité*.
- [**Milliken, 2003**] Milliken, D. (2003). *Race Car Vehicle Dynamics : Problems. Answers and Experiments*. SAE International.
- [**Minoux, 1983**] Minoux, M. (1983). *Programmation mathématique : théorie et algorithmes*, volume 1. Dunod Paris.
- [**M'Sirdi et al., 2008**] M'Sirdi, N., Rabhi, A., Fridman, L., Davila, J., et Delanne, Y. (2008). Second order sliding-mode observer for estimation of vehicle dynamic parameters. *International Journal of Vehicle Design*, 48(3), 190–207.
- [**Müller, 2007**] Müller, W. (2007). *Collecting spatial data : optimum design of experiments for random fields*. Springer.
- [**Myung, 2008**] Myung, I. J. (2008). Tutorial on maximum likelihood estimation. *Journal of Mathematical Psychology*, (pp. 90–100).
- [**Nardi et al., 2010**] Nardi, F., Ryu, J., Moshchuk, N., et O'Dea, K. (2010). Dynamic observer for the estimation of vehicle lateral velocity. Patent US 12/276965, Gm Global Technology Operations Inc.
- [**Nelder et Mead, 1965**] Nelder, J. A. et Mead, R. (1965). A simplex method for function minimization. *The Computer Journal*, 7(4), 308–313.
- [**Neyrat et Crosnier, 1992**] Neyrat, P. et Crosnier, S. (1992). Procédé de détection du sous-gonflage d'un pneumatique. FR Patent 1992/2664536.
- [**Noh et Han, 2014**] Noh, S. et Han, W.-Y. (Octobre 2014). Collision avoidance in on-road environment for autonomous driving. In *Conference on Control, Automation and Systems* (pp. 884–889). Kintex, Korea.
- [**Organization for Standardization, 2009**] Organization for Standardization, I. (2009). *Intelligent transport systems - Full speed range adaptive cruise control (FSRA) systems - Performance requirements and test procedures*. Technical Report 22179, ISO, Geneva, Switzerland.
- [**Orr, 1996**] Orr, M. J. L. (1996). Introduction to radial basis function networks. Technical Report, Center for Cognitive Science, University of Edinburgh.
- [**Pacejka, 2002**] Pacejka, H. (2002). *Tyre and Vehicle Dynamics*. Butterworth Heinemann.
- [**Patterson et Thompson, 1971**] Patterson, H. D. et Thompson, R. (1971). Recovery of inter-block information when block sizes are unequal. *Biometrika*, 58(3), 545–554.
- [**Peng et Tomizuka, 1990**] Peng, H. et Tomizuka, M. (1990). *Lateral Control of Front-Wheel-Steering Rubber-Tire Vehicles*. Technical report, California Partners for Advanced Transportation Technology.

- [**Perruquetti et Barbot, 2002**] Perruquetti, W. et Barbot, J.-P. (2002). *Sliding mode control in engineering*. CRC Press.
- [**Persson et al., 2002**] Persson, N., Gustafsson, F., et Drevo, M. (Octobre 2002). Indirect tire pressure monitoring using sensor fusion. In *SAE World Congress and Exhibition* (pp. 1250–1258). Detroit, MI, United States.
- [**Pintér, 2013**] Pintér, J. D. (2013). *Global optimization in action : continuous and Lipschitz optimization : algorithms, implementations and applications*. Springer.
- [**Plestan, 1997**] Plestan, F. Glumineau, A. (1997). Linearization by generalized input-output injection. *Systems and Control Letters*, 31, 115–128.
- [**Poli et al., 2007**] Poli, R., Kennedy, J., et Blackwell, T. (2007). Particle swarm optimization. *Swarm Intelligence*, 1(1), 33–57.
- [**Powell, 1994**] Powell, M. J. (1994). A direct search optimization method that models the objective and constraint functions by linear interpolation. In *Advances in optimization and numerical analysis* (pp. 51–67). Springer.
- [**Praveen et Duvigneau, 2009**] Praveen, C. et Duvigneau, R. (2009). *Study of some strategies for global optimization using Gaussian process models with application to aerodynamic design*. Technical report, INRIA.
- [**Qin-man et al., 2010**] Qin-man, F., Yong-hai, W., Kun, L., et Feng, W. (Juin 2010). Multi-objective optimization design of automobile suspension helical spring. In *International Conference on Information and Computing*, volume 1 (pp. 219–222). Amsterdam, Netherlands.
- [**Rajamani, 2006**] Rajamani, R. (2006). *Vehicle Dynamics and Control*. Springer US.
- [**Rasmussen et Williams, 2006**] Rasmussen, C. E. et Williams, C. K. I. (2006). *Gaussian Processes for Machine Learning*. the MIT Press.
- [**Ratle, 1998**] Ratle, A. (1998). Accelerating the convergence of evolutionary algorithms by fitness landscape approximation. *Parallel Problem Solving from Nature*, (pp. 87–96).
- [**Ray, 1997**] Ray, L. R. (1997). Nonlinear tire force estimation and road friction identification : Simulation and experiments. *Automatica*, 33(10), 1819–1833.
- [**Reimpell et al., 2001**] Reimpell, J., Stoll, H., et Betzler, J. (2001). *The automotive chassis : engineering principles*. Butterworth-Heinemann.
- [**Reza, 2008**] Reza, N. (2008). *Vehicle Dynamics Theory and Application*. Springer.
- [**Rios et Sahinidis, 2013**] Rios, L. et Sahinidis, N. (2013). Derivative-free optimization : a review of algorithms and comparison of software implementations. *Journal of Global Optimization*, 56(3), 1247–1293.
- [**Robinson et Keane, 1999**] Robinson, G. et Keane, A. (1999). A case for multi-level optimisation in aeronautical design. *Aeronautical Journal*, 103(1028), 481–485.
- [**Sacks et al., 1989**] Sacks, J., Welch, W., Mitchell, T., et Wynn, H. (1989). Design and analysis of computer experiments. *Statistical science*, 4(4), 409–423.
- [**Sacks et Ylvisaker, 1970**] Sacks, J. et Ylvisaker, D. (August 1970). Statistical designs and integral approximation. In *12th Biennial Seminar of the Canadian Math Congress* (pp. 115–136). Montreal, Canada.

- [**Said et al., 2011**] Said, S. H., Mimouni, M., M'Sahli, F., et Farza, M. (2011). High gain observer based on-line rotor and stator resistances estimation for imms. *Simulation Modelling Practice and Theory*, 19(7), 1518–1529.
- [**Saliou et al., 2015**] Saliou, S., Saint-Loup, P., Pita-Gil, G., et Davins-Valldaura, J. (2015). Système d'aide à l'identification de sous-gonflage pneumatique indirect par analyse multicritère des vitesses angulaires. Brevet en cours de dépôt : PJ-15-0064, Acsystème et Renault.
- [**Sasaki et Nishimaki, 2000**] Sasaki, H. et Nishimaki, T. (2000). *A Side-Slip Angle Estimation Using Neural Network for a Wheeled Vehicle*. Technical report, SAE Technical Paper 2000-01-0695.
- [**Sasena, 2002**] Sasena, M. J. (April 2002). *Flexibility and efficiency enhancements for constrained global design optimization with kriging approximations*. PhD thesis, University of Michigan.
- [**Schimetta et al., 2000**] Schimetta, G., Dollinger, F., et Weigel, R. (2000). A wireless pressure-measurement system using a saw hybrid sensor. *IEEE Transactions on Microwave Theory and Techniques*, 48(12), 2730–2735.
- [**Schoofs, 1988**] Schoofs, A. (1988). *Experimental design and structural optimization*. Springer Netherlands.
- [**Sebsadji et al., 2008**] Sebsadji, Y., Glaser, S., Mammar, S., et Dakhlallah, J. (June 2008). Road slope and vehicle dynamics estimation. In *American Control Conference* (pp. 4603–4608). Seattle, WA, United States.
- [**Senger et Kortum, 1989**] Senger, K. et Kortum, W. (1989). Investigations on state observers for the lateral dynamics of four wheel steered vehicles. *Vehicle System Dynamics*, 18, 515–527.
- [**Senger et Schwartz, 1988**] Senger, K. et Schwartz, W. (1988). The influence of a four wheel steering system on the stability behaviour of a vehicle-driver system. *Vehicle System Dynamics*, 17(1), 388–402.
- [**Shen et al., 2014**] Shen, J., Dusmez, S., et Khaligh, A. (2014). Optimization of sizing and battery cycle life in battery/ultracapacitor hybrid energy storage systems for electric vehicle applications. *IEEE Transactions on Industrial Informatics*, 10(4), 2112–2121.
- [**Shubert, 1972**] Shubert, B. O. (1972). A sequential method seeking the global maximum of a function. *SIAM Journal on Numerical Analysis*, 9(3), 379–388.
- [**Shuming et Gao, 2005**] Shuming, T. et Gao, H. (2005). A traffic incident detection algorithm based on nonparametric regression. *IEEE Transactions on Intelligent Transportation System*, 6(1), 38–42.
- [**Siarry, 1995**] Siarry, P. (1995). La méthode du recuit simulé : théorie et applications. *Automatique-productique informatique industrielle*, 29(4-5), 535–561.
- [**Siarry, 2014**] Siarry, P. (2014). *Métaheuristiques recuit simulé, recherche avec tabous, recherche à voisinages variables, méthode GRASP, algorithmes évolutionnaires, fourmis artificielles, essais particuliers et autres méthodes d'optimisation*. Paris : Eyrolles.
- [**Siarry et Berthiau, 1997**] Siarry, P. et Berthiau, G. (1997). Fitting of tabu search to optimize functions of continuous variables. *International journal for numerical methods in engineering*, 40(13), 2449–2457.
- [**Slotine et Li, 1991**] Slotine, J.-J. E. et Li, W. (1991). *Applied nonlinear control*. Prentice-Hall Englewood Cliffs, NJ.
- [**Smola et Schölkopf, 2004**] Smola, A. J. et Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, 14(3), 199–222.

- [**Stein, 1999**] Stein, M. (1999). *Interpolation of Spatial Data : Some Theory for Kriging*. Springer New York.
- [**Stephan, 2004**] Stephan, J. (2004). Virtual sensor : Application to vehicle sideslip angle and transversal forces. *IEEE Transactions on Industrial Electronics*, 51, 278–289.
- [**Stephant et al., 2007**] Stephant, J., Charara, A., et Meizel, D. (2007). Evaluation of a sliding mode observer for vehicle sideslip angle. *Control Engineering Practice*, 15(7), 803–812.
- [**Stotsky et Hu, 1997**] Stotsky, A. et Hu, X. (Décembre 1997). Control of car-like robots using sliding observers for steering angle estimation. In *Conference on Decision and Control* (pp. 3648–3653). San Diego, California, USA.
- [**Takagi et Sugeno, 1985**] Takagi, T. et Sugeno, M. (1985). Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man and Cybernetics*, 15(1), 116–132.
- [**Torczon, 1997**] Torczon, V. (1997). On the convergence of pattern search algorithms. *SIAM Journal on Optimization*, 7(1), 1–25.
- [**Tseng et al., 2005**] Tseng, H., Asgari, J., Hrovat, D., Van der Jagt, P., Cherry, A., et Neads, S. (2005). Evasive manoeuvres with a steering robot. *Vehicle System Dynamics*, 43(3), 199–216.
- [**Tudon-Martinez et al., 2014**] Tudon-Martinez, J. C., Fergani, S., Sename, O., Morales-Menendez, R., et Dugard, L. (June 2014). Online road profile estimation in automotive vehicles. In *European Control Conference* (pp. 2370–2375). Strasbourg, France.
- [**Utkin, 1993**] Utkin, V. (1993). Sliding mode control design principles and applications to electric drives. *IEEE Transactions on Industrial Electronics*, 40(1), 23–36.
- [**Utkin, 2013**] Utkin, V. (2013). *Sliding modes in control and optimization*. Springer Science & Business Media.
- [**Velupillai et Guveng, 2007**] Velupillai, S. et Guveng, L. (2007). Tire pressure monitoring. *IEEE Transactions on Control Systems Magazine*, 27(6), 22–25.
- [**Villemonteix, 2009**] Villemonteix, J. (Janvier 2009). *Optimisation de fonctions coûteuses*. PhD thesis, Université Paris-Sud XI, Faculté des sciences d’Orsay.
- [**Villemonteix et al., 2009**] Villemonteix, J., Vázquez, E., et Walter, E. (2009). An informational approach to the global optimization of expensive-to-evaluate functions. *Journal of Global Optimization*, 44(4), 509–534.
- [**Voutchkov et Keane, 2010**] Voutchkov, I. et Keane, A. (2010). Multi-objective optimization using surrogates. In *Computational Intelligence in Optimization*, volume 7 of *Adaptation, Learning, and Optimization* (pp. 155–175). Springer.
- [**Wahba, 1999**] Wahba, G. (1999). Advances in kernel methods. In *Support Vector Machines, Reproducing Kernel Hilbert Spaces, and Randomized GACV* (pp. 69–88). MIT Press.
- [**Wang et al., 2013**] Wang, B., Charara, A., et Corrêa Victorino, A. (Novembre 2013). State observers applied to vehicle lateral dynamics estimation : a comparison between extended kalman filter and particle filter. In *IEEE Conference of the Industrial Electronics Society* Vienna, Austria.
- [**Web, 1**] Web (1). Systèmes d’aide à la conduite de la nouvelle *Renault Espace V*. <https://group.renault.com/passion/innovation/renault-laudace-dans-les-genes/adas-des-technologies-au-service-de-la-facilite-de-conduite-et-de-la-securite/> ; Avril 2016.

- [Web, 2] Web (2). Google car. <https://www.wired.com/2015/10/googles-lame-demo-shows-us-far-robo-car-come/>; Mai 2015.
- [Web, 3] Web (3). Volkswagen passat Junior. http://www.wikiwand.com/en/Autonomous_car; Février 2016.
- [Web, 4] Web (4). Volvo xc90 IntelliSafe. <http://www.volvocars.com/intl/about/our-innovation-brands/intellisafe>; Novembre 2015.
- [Web, 5] Web (5). Bmw i3. <http://www.bmwblog.com/2015/01/06/bmw-i3-parks-multistorey-parking-garage/>; Janvier 2015.
- [Web, 6] Web (6). Détection des véhicules. <http://www.digitaltrends.com/cars/self-driving-car-moral-decisions/#:frk9rQoTYBjBqA>; Octobre 2015.
- [Wilson, 1989] Wilson, T. G. (1989). On the use of marginal likelihood in time series model estimation. *Journal of the Royal Statistical Society*, 51(1), 15–27.
- [Yacine et al., 2013] Yacine, Z., Ichalal, D., Oufroukh, N., Mammar, S., et Djennoune, S. (Avril 2013). New nonlinear takagi-sugeno vehicle model for state and road curvature estimation via nonlinear pmi observer. In *IEEE International Conference on Networking, Sensing and Control* (pp. 843 – 848). Evry, France.
- [Zhang et al., 2009] Zhang, Q., Liu, B., et Liu, G. (Juillet 2009). Design of tire pressure monitoring system based on resonance frequency method. In *IEEE/ASME International Conference on Advanced Intelligent Mechatronics* (pp. 781–785). Singapore.
- [Zinober, 1991] Zinober, A. (May 1991). Deterministic control of uncertain systems. In *IEEE Colloquium on Real Control Problems* (pp. 41–43). London, United Kingdom.
- [Zitzler et al., 2001] Zitzler, E., Laumanns, M., et Thiele, L. (2001). *SPEA2 : Improving the Strength Pareto Evolutionary Algorithm*. Technical report, Institut für Technische Informatik und Kommunikationsnetze (TIK) Zürich, Switzerland.
- [Zitzler et Thiele, 1998] Zitzler, E. et Thiele, L. (1998). Multiobjective optimization using evolutionary algorithms - a comparative case study. In *Parallel problem solving from nature* (pp. 292–301). : Springer.
- [Zitzler et al., 2002] Zitzler, E., Thiele, L., Laumanns, M., Fonseca, C. M., et da Fonseca, V. G. (2002). Performance assessment of multiobjective optimizers : An analysis and review. *IEEE Transactions on Evolutionary Computation*, 7, 117–132.

Thèse de Doctorat

Joan DAVINS-VALLDAURA

Surveillance et estimation de l'état de véhicules automobiles : un champ d'applications pour l'optimisation multi-objectif

Monitoring and state estimation for automotive vehicles: a range of applications for multi-objective optimization

Résumé

Cette thèse est dédiée à l'optimisation globale multi-objectif de fonctions coûteuses, avec des applications de mise au point de systèmes de surveillance et d'aide à la conduite automobile. Après avoir présenté un état de l'art du domaine, un nouvel algorithme basé sur une stratégie de double *krigeage* est proposé afin de réduire le nombre d'évaluations de la fonction objectif. La première application de l'algorithme concerne l'optimisation des paramètres de mise en œuvre d'un système de surveillance de la pression des pneumatiques sans capteur de pression. En plus du nombre important de paramètres à optimiser, cette mise au point est soumise à des contraintes de test sur une très grande base de données de roulage, dans différents scénarios et à un temps de calcul limité. La seconde application concerne un système de conduite automatique dans une situation d'embouteillage. Le travail est focalisé sur l'utilisation d'observateurs pour le contrôle latéral. La solution actuellement utilisée par Renault/Nissan est fondée sur un filtre de Kalman. Afin de réduire le nombre de paramètres de réglage, des solutions basées sur des approches non linéaires (grand gain et mode glissant) ont été proposées. Les gains de ces observateurs ont été réglés en utilisant le nouvel algorithme d'optimisation et en tenant compte d'essais sur route dont les mesures ont généré une grande base de données.

Mots clés

Optimisation multi-objectif, Fonctions coûteuses, Modèles de substitution, Observateurs non linéaires, Applications automobiles.

Abstract

This thesis deals with multi-objective optimization for expensive evaluation functions and its application for the tuning of vehicle monitoring and driver assistance systems in the context of automotive engineering. After the presentation of a state of the art on multi-objective optimization methods, a new algorithm based on a double kriging strategy is proposed in order to reduce the number of objective function evaluations. The first application of the optimization algorithm concerns the tuning of an indirect tire-pressure monitoring system (without sensor). In addition to the tuning of high number of parameters, the optimization is constrained by the use of a large database, containing measurements obtained in real driving situations, and has to provide an optimal tuning in a limited processing time. The second application falls within lateral control of an autonomous driving system in a traffic jam situation. The current solution used by Renault/Nissan is based on a Kalman filter. In order to reduce the number of tuning parameters, solutions based on nonlinear approaches (high gain and sliding mode) are proposed. The tuning of the gains appearing in all these observers has been performed by using the proposed optimization algorithm, and by taking into account real driving data with measurements contained in a large database.

Key Words

Multi-objective optimization, Expensive evaluation functions, Surrogate models, Nonlinear observers, Automotive applications.