

Optimisation des paramètres d'un système de surveillance de la pression des pneumatiques d'un véhicule automobile

Joan DAVINS-VALLDAURA^{1,2}, Saïd MOUSSAOUI², Guillermo PITA-GIL¹, Franck PLESTAN²

¹Renault, Technocentre, 1 avenue du Golf, 78288 Guyancourt, France
prenom.nom@renault.com

²Ecole Centrale de Nantes, IRCCyN, CNRS UMR 6597, 1 rue de la Noë, 44321 Nantes Cedex 3, France
prenom.nom@irccyn.ec-nantes.fr

Résumé – Cette communication 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 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. Nous proposons une nouvelle méthode d'optimisation multi-objectif de fonctions coûteuses pour le réglage des paramètres de ce système. L'avantage principal de cette méthode est la possibilité d'obtenir le front de Pareto tout en minimisant le nombre d'évaluations des fonctions qui sont inconnues et très coûteuses. Les résultats de la mise au point automatique et manuelle seront comparés et un exemple d'une simulation réelle sera présenté pour illustrer l'apport de notre proposition.

Abstract – This paper concerns the automatic tuning of an indirect tire pressure monitoring system where the pressure deflation detection is done without physical pressure sensors. To detect any deflation, two algorithms have been created to alert the driver if there is a tire deflation or a puncture. The complexity of the system and the huge database used for the tuning make the manual tuning a very hard task. A new method for the multi-objective optimization, called KEEP, is used to find the best parameter configuration of the system. Its advantage is the possibility to optimize several parameters of a black-box expensive function. The final results of the automatic and the manual tunings are compared and an example of a real simulation is presented to illustrate the relevance of our solution.

1 Introduction

Depuis 2014, la réglementation européenne impose à ce qui 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). Ce système a comme objectif de réduire l'émission de CO₂, d'allonger la durée de vie des pneumatiques et d'augmenter la sécurité des passagers en réduisant le risque d'accidents.

La première solution adoptée actuellement par Renault est le SSPP *direct*. Ce système est basé sur l'installation d'un capteur de pression sur chaque valve des quatre roues du véhicule. Les valeurs de pression sont ainsi obtenues en temps-réel. Ce système n'est pas trop complexe d'un point de vue instrumentation et il est relativement facile à mettre au point. Néanmoins, les SSPP directs ont quelques inconvénients [1]. 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 de non détection. Le dernier inconvénient est que les capteurs de pression ont des coûts de

fabrication et d'entretien non négligeables.

Une deuxième solution, en phase de développement, est le système SSPP *indirect*. Ce système est capable d'estimer un dégonflage à partir de l'analyse des signaux présents dans le bus CAN (angle volant, vitesses angulaires, régime moteur et accélérations) et qui sont déjà utilisés par d'autres systèmes (comme l'ESP : sécurité active d'anti-dérapiage destiné à l'amélioration du contrôle de la trajectoire du véhicule). L'avantage de ce système est qu'il ne nécessite pas de capteurs de pression [2]. Cependant, ce système étant assez complexe il est difficile à mettre au point.

Une grande *base de données* (BdD), de plus de 1.380.000 km de roulage, a été construite avec des enregistrements de tous les signaux du véhicule. Pour obtenir une BdD représentative, différents types de conducteurs, profils de routes et de conditions de roulage ont été testés. Cette BdD sera utilisée pour la *mise au point* (MAP) du premier véhicule équipé du système SSPP indirect.

L'objectif de ce papier est de présenter un algorithme de mise au point automatique du SSPP indirect. La technique proposée se fonde sur une méthode d'optimisation multi-objectifs de fonctions inconnues et dont l'évaluation est très coûteuse.

2 Mise au point du SSPP indirect

Le système SSPP indirect qui fait l'objet de cette étude a été développé dans [3]. 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 vitesse angulaires. En effet, une baisse du rayon dynamique a comme conséquence directe une augmentation de la vitesse angulaire de la roue [4]. Cet algorithme *temporel* permet de détecter efficacement toute baisse de pression dans une seule roue. Le deuxième algorithme est basé sur l'analyse spectrale des signaux de vitesses angulaires. Il est a été constaté que la baisse de la pression engendre une diminution des fréquences caractéristiques des vibrations du véhicule et de la roue, qui apparaissent dans le signal de vitesse angulaire [5]. Cet algorithme *fréquentiel* est capable de détecter un dégonflage de plusieurs roues et il est très utile pour détecter les petites pertes de pression accumulées après une longue période de roulage. L'algorithme de décision [2] fusionne les résultats des deux algorithmes temporel et fréquentiel pour calculer la probabilité d'avoir une crevaison ou une diffusion pour ensuite alerter le conducteur en cas de probabilité suffisamment élevée.

La mise au point du SSPP indirect requiert la spécification des valeurs d'un ensemble de 36 paramètres de réglage : 12 paramètres pour l'algorithme temporel, 18 paramètres pour l'algorithme fréquentiel et 6 paramètres pour l'algorithme de fusion. L'objectif du réglage de paramètres est de réaliser le meilleur compromis entre taux de fausses alarmes (% FA) et le taux de non-détections (% ND). Par ailleurs, la simulation du système complet sur toute la BdD pour une configuration donnée des paramètres de réglage du système nécessite un temps de calcul de 21 jours.

Plutôt que de réaliser une optimisation directe portant sur tous les paramètres du système, et afin de réduire le temps de mise au point, la solution adoptée consiste en une optimisation séparée des deux algorithmes temporel et fréquentiel. Le module de fusion est ensuite optimisée en ayant fixé les paramètres optimaux des deux algorithmes de détection. Cette option est bien évidemment sous-optimale mais elle présente l'avantage de scinder le problème initial (dimension 36) en trois problèmes de taille réduite (dimensions 12, 18 et 6 respectivement). De plus, l'algorithme fréquentiel présente deux ensembles de paramètres indépendants et il est par conséquent scindé en deux sous-problèmes de dimension 9 chacun. Finalement, la mise au point du SSPP indirect nécessite de résoudre quatre problèmes d'optimisation multi-objectifs de fonctions coûteuses et qui ne sont pas connues analytiquement.

3 Optimisation multi-objectif

L'optimisation multi-objectif est définie comme un problème de minimisation conjointe de n fonctions objectifs (performances)

$f(\mathbf{x}) = \{f_1(\mathbf{x}), \dots, f_n(\mathbf{x})\}^T$ avec $\mathbf{x} = \{x_1, \dots, x_m\}^T$ le vecteur de m paramètres ($f(\mathbf{x}) : \mathbb{R}^m \rightarrow \mathbb{R}^n$). Ce problème n'admet pas une solution unique mais plutôt un ensemble de solutions optimales admissibles qui peuvent être comparée à l'aide du concept de dominance de Pareto : une configuration de paramètres domine une autre configuration si celle-ci est meilleure au moins dans un objectif sans être moins bonne dans les autres objectifs. L'ensemble des configurations optimales (non-dominées) est appelée *Ensemble de Pareto ou Pareto Set* (PS), et son image selon la fonction à optimiser est appelée *Front de Pareto ou Pareto front* (PF).

Dans le contexte de fonctions inconnues et dont l'évaluation est coûteuse, la plupart des méthodes d'optimisation s'appuient sur un modèle de substitution (Mds). Ces méthodes d'optimisation ont une structure itérative : à chaque itération j , toutes les configurations de paramètres $\mathbf{X}^j = \{\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(j)}\}$ et leurs performances $\mathbf{F}^j = \{f(\mathbf{x}^{(1)}), \dots, f(\mathbf{x}^{(j)})\}$ sont utilisées pour estimer un Mds qui permettra de calculer un nouveau candidat $\mathbf{x}^{(j+1)}$ à évaluer sur la fonction réelle.

3.1 Approche classique

La méthode d'optimisation multi-objectif de référence basée sur un Mds est la méthode ParEGO [6]. Celle-ci est une extension de la méthode d'optimisation globale mono-objectif (EGO pour *Efficient Global Optimization*) [7], qui est basée sur le principe d'utilisation d'un Mds $F(\mathbf{x})$ construit par krigeage : $F(\mathbf{x}) \sim \mathcal{N}(\hat{f}(\mathbf{x}), \hat{\sigma}(\mathbf{x}))$.

Le critère utilisé dans l'algorithme EGO pour la sélection d'un nouveau candidat est appelé *Expected Improvement* (EI) défini par :

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

où $\hat{\sigma}^2(\mathbf{x})$ est la variance de $f(\mathbf{x})$, Φ et ϕ sont respectivement la fonction de répartition et la fonction de densité de probabilité d'une loi normale. L'avantage du critère EI est de réaliser un compromis entre la réduction de l'erreur d'approximation de la fonction objectif par le Mds et sa minimisation.

Entrées : $\mathbf{X}^j, \mathbf{F}^j$ et j
Tant que ($j < J$) **faire**
 Mds : $(\hat{f}^j, \hat{\sigma}^j) \leftarrow \text{Kriging} \{\mathbf{X}^j, \mathbf{F}^j\}$
 Candidat : $\mathbf{x}^{j+1} \leftarrow \arg \max_{\mathbf{x}} EI(\hat{f}^j, \hat{\sigma}^j)$
 Fonction réelle : $f^{j+1} \leftarrow f(\mathbf{x}^{j+1})$
Fait
Sorites : \mathbf{X}^J et \mathbf{F}^J

Algorithme 1: Etapes de la méthode EGO

Pour le cas de fonction multi-objectifs, la méthode ParEGO (Algorithme 2) utilise le principe d'EGO mais en introduisant

une étape préliminaire consistent à combiner linéairement les différentes fonctions objectifs pour obtenir un problème mono-objectif. La fonction utilisée pour la fusion est la fonction de *Chebycheff* [6] :

$$f_\lambda(\mathbf{x}) = \max_{j=1}^k (\lambda_j f_j(\mathbf{x})) + \rho \sum_{j=1}^k \lambda_j f_j(\mathbf{x}) \quad (1)$$

où ρ est une constante fixée à 0.05 et λ le vecteur de poids définis aléatoirement ($\lambda = \{\lambda_1, \dots, \lambda_m\} \mid \lambda_j \in [0, 1] \forall j = \{1, \dots, m\}$ et $\sum_{i=1}^m \lambda_i = 1$). Le fait d'utiliser une valeur de λ différente à chaque itération permet à la méthode de ParEGO d'optimiser dans toute les directions du FP. A la fin de l'optimisation, le front de Pareto (PF) et l'ensemble de Pareto (PS) sont obtenus par tests de dominance entre les différentes valeurs des paramètres testés durant l'optimisation.

Entrées : $\mathbf{X}^j, \mathbf{F}^j$ et j
Tant que ($j < J$) **faire**
 Poids : $\lambda^j \leftarrow \text{rand}(n)$ avec $\sum_{i=1}^n \lambda_i^j = 1$
 Combinaison : $\mathbf{F}_\lambda^j \leftarrow \text{Chebycheff}(\mathbf{F}^j, \lambda^j)$
 MdS : $(\hat{f}_\lambda^j, \hat{\sigma}_\lambda^j) \leftarrow \text{Krigage}\{\mathbf{X}^j, \mathbf{F}_\lambda^j\}$
 Candidat : $\mathbf{x}^{j+1} \leftarrow \arg \max_{\mathbf{x}} \text{EI}(\hat{f}_\lambda^j, \hat{\sigma}_\lambda^j)$
 Evaluation : $\mathbf{f}^{j+1} \leftarrow \mathbf{f}(\mathbf{x}^{j+1})$
Fait
Sorties : $\mathbf{X}^J, \mathbf{F}^J$ et PF^J

Algorithme 2: Etapes de la méthode ParEGO

3.2 Méthode proposée

On peut constater que la méthode ParEGO consiste à réaliser plusieurs optimisations du critère issu de la combinaison linéaire des objectifs sans prendre en compte l'objectif initial qui est de retrouver le PS et le PF. Ainsi, plusieurs évaluations des fonctions objectifs seront nécessaires pour obtenir de bonnes approximations du front de Pareto. Cette méthode est donc inadaptée pour des fonctions très coûteuses.

L'idée proposée consiste à utiliser le même principe que la méthode ParEGO pour la construction des MdS des fonctions objectifs et de construire un MdS supplémentaire dans l'espace des paramètres pour favoriser le choix d'un candidat susceptible d'appartenir à l'ensemble de Pareto. Cette méthode est appelée KEEP (Kriging for Expensive Evaluation Pareto) [8]. Le MdS dans l'espace des paramètres permet d'estimer la probabilité que chaque paramètre appartienne au PS :

$$p_\lambda^j(\mathbf{x}^j) = \begin{cases} 1 & \text{si } \mathbf{x}^j \in \text{PS} \\ 0 & \text{sinon} \end{cases} \quad (2)$$

Les valeurs $\mathbf{P}_\lambda^j = \{p_\lambda^j(\mathbf{x}^{(1)}), \dots, p_\lambda^j(\mathbf{x}^{(j)})\}$ sont utilisées pour créer le MdS par Krigage \hat{p}_λ^j . Finalement, KEEP utilisera un nouveau critère, appelé *Pareto Expected Improvement*

(PEI), obtenu à partir de la fusion des deux critères issus des MdS :

$$\text{PEI}(\mathbf{x}) = \hat{p}_\lambda^j(\mathbf{x}) \cdot \text{EI}_\lambda^j(\mathbf{x}) \quad (3)$$

où $\text{EI}_\lambda(\mathbf{x})$ est la valeur du *expected improvement* utilisé pour la méthode ParEGO. La maximisation du PEI est réalisée à l'aide d'un algorithme génétique (adapté à l'utilisation de deux MdS [8]) permettant de proposer un nouveau candidat à évaluer pour la fonction réelle. Les étapes principales de la méthode KEEP sont résumées dans Algorithm 3.

Entrées : $\mathbf{X}^j, \mathbf{F}^j$ et j
Tant que ($j < J$) **faire**
 Poids : $\lambda^j \leftarrow \text{rand}(n)$ avec $\sum_{i=1}^n \lambda_i^j = 1$
 Combinaison : $\mathbf{F}_\lambda^j \leftarrow \text{Chebycheff}(\mathbf{F}^j, \lambda^j)$
 1ère MdS : $(\hat{f}_\lambda^j, \hat{\sigma}_\lambda^j) \leftarrow \text{Krigage}\{\mathbf{X}^j, \mathbf{F}_\lambda^j\}$
 Pareto Set probabilité : $\mathbf{P}_\lambda^j \leftarrow \text{ParetoSet}\{\mathbf{X}^j, \mathbf{F}^j\}$
 2ème MdS : $(\hat{p}_\lambda^j, \cdot) \leftarrow \text{Krigage}\{\mathbf{X}^j, \mathbf{P}_\lambda^j\}$
 Candidat : $\mathbf{x}^{j+1} \leftarrow \arg \max_{\mathbf{x}} \text{PEI}(\hat{f}_\lambda^j, \hat{\sigma}_\lambda^j, \hat{p}_\lambda^j)$
 Evaluation : $\mathbf{f}^{j+1} \leftarrow \mathbf{f}(\mathbf{x}^{j+1})$
Fait
Sorties : $\mathbf{X}^J, \mathbf{F}^J, \text{PF}^J$ et PS^J

Algorithme 3: Etapes principales de la méthode KEEP

4 Résultats

La méthode proposée a été comparée avec la méthode ParEGO dans [8] sur des fonctions issues de benchmarks de problèmes d'optimisation multi-objectif. Il a été montré que l'approche proposée permet d'obtenir une meilleure estimation du front de Pareto avec une réduction significative du nombre d'évaluations des fonctions. Dans cette section, nous présentons les résultats de l'application de la méthode à la mise au point du SSPP indirect.

4.1 Résultats de l'optimisation

Les deux critères de performance %FA et le %ND résultant du système optimisé sont représentés dans la FIGURE 1. L'optimisation automatique permet d'obtenir un ensemble de solutions optimales non-dominantes meilleures que la proposition issue de la mise au point manuelle. Un autre avantage est la possibilité de choisir un autre compromis (%FA vs %ND) *a-posteriori* sans avoir à relancer le processus d'optimisation. Signalons que le temps de calcul nécessaire à la résolution de ce problème est de 6 mois sur une machine standard.

4.2 Simulation réelle du système optimisé

Deux simulations réelles réalisées avec la meilleure configuration des paramètres obtenue par la méthode KEEP sont présentées. La simulation commence par une phase d'apprentissage (temps négatif) et une phase de détection (temps po-

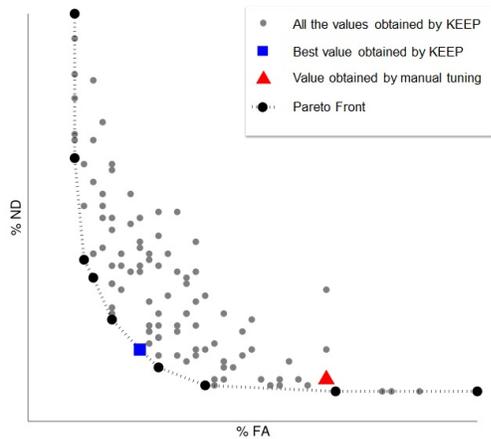


FIGURE 1 – Résultats de l’optimisation. Pour des raisons de confidentialité, les valeurs des axes ne sont pas données.

sitif). Les probabilités de dégonflage de chaque roue sont représentées avec une couleur différente. L’objectif est de détecter l’existence d’un problème de dégonflage le plus rapidement possible (moins de 10 minutes après le dégonflage d’une seule roue ou 60 minutes si le dégonflage concerne plusieurs roues simultanément).

- **Cas 1** : 1 roue dégonflée (FIGURE 2). L’algorithme temporel est capable de détecter le problème correctement et dans le temps réglementaire ; par contre, l’algorithme fréquentiel le détecte trop tardivement. La fusion des deux permet une détection correcte.

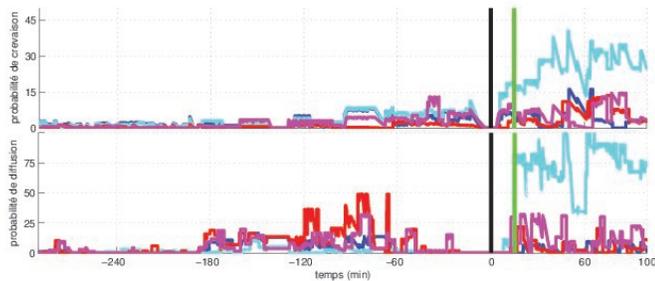


FIGURE 2 – Simulation réelle : 1W

- **Cas 2** : 4 roues dégonflées (FIGURE 3). L’algorithme temporel n’arrive pas à détecter la baisse de pression ; par contre, l’algorithme fréquentiel fournit une bonne détection et dans le temps réglementaire.

Ces simulations illustrent que la configuration obtenue lors de la mise au point du SSPP indirect en utilisant la méthode KEEP permet d’atteindre les performances souhaitées pour le projet du SSPP indirect.

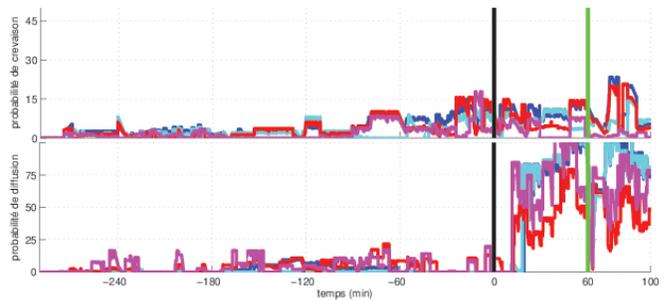


FIGURE 3 – Simulation réelle : 4W

5 Conclusion

Nous avons présenté dans cette communication une méthode d’optimisation multi-objectifs dans le cas de fonctions coûteuses. Cette méthode est capable de fournir le front de Pareto en un nombre minimisé d’évaluations des fonctions. Un tel problème d’optimisation apparaît dans plusieurs phases de conception de produits industriels. Nous avons présenté une application réelle consistant en la mise au point d’un système d’aide à la conduite par la surveillance des pressions des pneumatiques d’un véhicule automobile.

Références

- [1] S. Velupillai et L. Guveng. *Tire pressure monitoring*. IEEE Control Systems Magazine, **27**(6), 22–25, 2007.
- [2] N. Persson, F. Gustafsson et M. Drevo. *Indirect tire pressure monitoring using sensor fusion*. In Proceedings of 2002 SAE World Congress and Exhibition, Detroit, MI, USA, Mars 2002.
- [3] C. El Tannoury, F. Plestan, S. Moussaoui, G. Pita-Gil et N. Romani. *Estimation du rayon dynamique d’une roue et de la vitesse d’un véhicule automobile*. Patent num : FR2973115 ; WO-2012127139. France, 2012.
- [4] H. Mayer. *Comparative diagnosis of tyre pressures*. In Proceedings of 3rd IEEE conference on Control Applications, 627–632, Glasgow, UK, Août 1994.
- [5] Q. Zhang, B. Liu, et G. Liu. *Design of tire pressure monitoring system based on resonance frequency method*. In Proceedings of IEEE/ASME International Conference on Advanced Intelligent Mechatronics, Singapore, Juillet 2009.
- [6] J. Knowles. *ParEGO : A hybrid algorithm with on-line landscape approximation for expensive multiobjective optimization problems*. IEEE Transactions on Evolutionary Computation, **10**(1), 50–66, Février 2005.
- [7] D.R. Jones, M. Schonlau, W.J. Welch. *Efficient Global Optimization of Expensive Black-Box Functions*. Journal of Global Optimization **13**(4), 455–492, Décembre 1998.
- [8] J. Davins-Valldaura, S. Moussaoui, F. Plestan et G. Pita-Gil. *ParEGO Extensions for Multi-objective Optimization of Expensive Evaluation Function*. World congress on global optimization, Gainesville, FL, USA, Février 2015.