



HAL
open science

Optimisation par Algorithme Génétique d'une Commande LPV de Suspension Semi-active

Anh Lam Do, Olivier Sename, Luc Dugard

► **To cite this version:**

Anh Lam Do, Olivier Sename, Luc Dugard. Optimisation par Algorithme Génétique d'une Commande LPV de Suspension Semi-active. JD-JN-MACS 2011 - 4èmes Journées Doctorales/Journées Nationales MACS, Jun 2011, Marseille, France. pp.s/n. hal-00606442

HAL Id: hal-00606442

<https://hal.science/hal-00606442>

Submitted on 6 Jul 2011

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.

Optimisation par Algorithme Génétique d'une Commande LPV de Suspension Semi-active

Anh-Lam DO, Olivier SENAME, Luc DUGARD

GIPSA-Lab, Département Automatique,
CNRS-Grenoble INP
ENSE3, BP 46, F-38402 St Martin d'Hères cedex, France.

{anh-lam.do, olivier.sename, luc.dugard}@gipsa-lab.grenoble-inp.fr

Résumé— Cet article concerne le problème d'optimisation multi-objectif pour la commande de suspension semi-active. Dans [1], les auteurs ont proposé une formulation LPV pour la commande de suspension semi-active d'un modèle non-linéaire de suspension où les non-linéarités (c.à.d la biviscosité et l'hystérésis) ont été prises en compte; une commande H_∞ /LPV pour gérer le confort et la tenue de route a également été conçue. Dans ce travail, on présente une nouvelle méthode pour la synthèse LPV de suspension semi-active en utilisant l'algorithme génétique SPEA2 (Strength Pareto Evolutionary Algorithm 2). Les résultats des simulations effectuées sur un modèle non-linéaire de véhicule soulignent l'efficacité de la méthode par rapport à celle développée dans [1].

Mots-clés— suspension semi-active, système LPV, algorithmes génétiques.

I. INTRODUCTION

L'approche de commande H_∞ est un outil efficace pour améliorer les performances d'un système en boucle fermée dans les gammes de fréquence prédéfinies. L'étape clé de la conception du contrôleur H_∞ repose sur la sélection de fonctions de pondération qui dépend de la compétence et de l'expérience des ingénieurs. Cependant, ce n'est pas toujours une tâche facile même pour de bons ingénieurs. Dans beaucoup d'applications, la difficulté dans le choix des fonctions de pondération augmente encore parce que la spécification de performance n'est pas définie avec précision et il est tout simplement impossible d'atteindre les meilleures performances (conception optimale) ou d'améliorer en même temps plus d'un objectif (conception multi-objectif). Ainsi, l'optimisation des fonctions de pondération pour satisfaire les performances souhaitées est encore un problème ouvert.

Dans la littérature, quelques travaux orientés vers cet objectif ([2], [3]...) proposent de considérer chaque système, si complexe soit-il, comme une combinaison de sous-systèmes du premier et second ordre, pour lesquels il est facile de trouver les fonctions de pondération. Cependant, il n'y a aucune méthode explicite pour retrouver ces fonctions dans le cas général. Une manière de faire est de procéder par essai/erreur. Une solution au problème est de faire appel à un outil d'optimisation, c'est ce qui est proposé pour le système LTI dans [4]. Nous allons voir ici que le choix des Algorithmes Génétiques (GAs) semble naturel, leur formulation étant bien adaptée pour ce type de problématique.

Dans cette communication, nous cherchons les meilleures

fonctions de pondération pour obtenir un contrôleur stabilisant un système de type LPV et garantissant un performance prédéfinie du système en boucle fermée. Il est important de noter que ce problème est plus général que le problème H_∞ où le contrôleur ne garantit que la stabilité et la performance H_∞ . Pour illustrer cette idée, le cas particulier de commande de suspensions semi-actives est étudié. Tout d'abord, à partir de critères de performance industriels des systèmes de suspension tels que ceux définis dans [5], une fonction objectif appropriée est formulée. Cette fonction se compose de deux objectifs antagonistes : le confort et la tenue de route. Deuxièmement, les fonctions de pondération sont ensuite réglées par l'algorithme génétique SPEA2 [6] de façon à minimiser la fonction objectif. Enfin, les meilleures fonctions de pondération sont choisies pour la synthèse de contrôleur LPV. Il est important de noter que cette méthode fournit un nouvel outil efficace et générique pour la conception de commande de suspension, où les objectifs de performance industrielle sont inclus directement dans la procédure de conception, et non pas dans l'objectif de performance H_∞ comme dans les études précédentes [5], [7].

La section 2 est consacrée à l'introduction de l'algorithme génétique et le SPEA2. Dans la 3^{ème} section, on présente la formulation du modèle LPV pour l'étude de la dynamique verticale de véhicule. Dans la section 4, la nouvelle méthode de synthèse du contrôleur LPV avec l'aide de SPEA2 est détaillée. Les simulations et les résultats obtenus sont donnés dans la section 5. Quelques conclusions et perspectives terminent cette communication.

II. ALGORITHMES GÉNÉTIQUES

A. Introduction

Les algorithmes génétiques ont connu un fort développement depuis la première étude de Holland [8], l'ouvrage orienté pour la théorie de Goldberg [9] et l'ouvrage orienté pour l'application de Davis [10]. Les algorithmes sont basés sur le mécanisme de la sélection naturelle et se sont révélés très efficaces dans l'optimisation avec beaucoup d'applications réelles comme dans les stratégies de financement et d'investissement, la robotique, l'ingénierie de conception, les télécommunications... Ils peuvent conduire à des techniques d'optimisation globale (malgré le coût élevé de calcul) (voir [11]) en utilisant l'approche probabiliste, la re-

cherche de multi-points, la combinaison aléatoire (croisement, mutation) et de l'information de l'itération précédente pour évaluer et améliorer la population. Un grand avantage des GAs par rapport à d'autres méthodes de recherche (les méthodes de gradient par exemple), est qu'ils cherchent sans considérer la nature des fonctions d'objectif et des contraintes.

Les GAs sont initialisés avec une population aléatoire. Par les opérations génétiques : la *sélection*, le *croisement* et la *mutation*, une nouvelle population est obtenue. En utilisant le processus de sélection, les individus les plus "convenables" qui sont basés sur la valeur de la *fonction d'adaptation* sont choisis ; le croisement et la mutation s'appliquent alors pour créer la nouvelle population. L'opération génétique sur les individus de population continue jusqu'à ce que le critère d'optimisation soit satisfait ou qu'un certain nombre de générations soit atteint.

B. Optimisation multi-objectif

Une application bien connue des GAs est de trouver la solution optimale pour le problème d'optimisation multi-objectif comportant des objectifs multiples et conflictuels. C'est un problème très populaire dans la pratique et peut être décrit comme suit :

$$\min_{x \in C} F(x) = \begin{bmatrix} f_1(x) \\ f_2(x) \\ \vdots \\ f_{n_{obj}}(x) \end{bmatrix}, \quad n_{obj} \geq 2, \quad (1)$$

où x est le vecteur de décision, C l'ensemble des vecteurs de décision (ou l'espace de recherche), et $F(x)$ le vecteur des objectifs.

L'existence d'une solution idéale x^* qui permet de minimiser simultanément toutes les fonctions objectif $f_1, f_2 \dots f_{n_{obj}}$ est en fait rarement possible. Ainsi, dans ce cas, le concept de *Pareto-optimal* est habituellement utilisée pour décrire la solution du problème d'optimisation multi-objectif et elle est définie comme suit :

Considérons deux vecteurs de décision $a, b \in C$. Le vecteur a domine b si et seulement si :

$$\begin{cases} \forall i \in \{1, 2, \dots, n_{obj}\} : f_i(a) \leq f_i(b) \\ \exists j \in \{1, 2, \dots, n_{obj}\} : f_j(a) < f_j(b) \end{cases} \quad (2)$$

Tous les vecteurs de décision qui ne sont pas dominés par un vecteur de décision sont appelés *non-dominés* ou *Pareto-optimal*. La famille de vecteurs non-dominés est notée par *Ensemble-Pareto*. Dans l'Ensemble-Pareto, on ne peut pas améliorer l'un des objectifs sans dégrader au moins un autre.

C. SPEA2 - Strength Pareto Evolutionary Algorithm 2

Comme mentionné dans [12], deux problèmes majeurs doivent être abordés quand un algorithme génétique est appliqué à l'optimisation multi-objectif :

- Comment faire pour choisir la "meilleure" fonction d'adaptation et de sélection, respectivement, afin d'orienter la recherche vers l'Ensemble-Pareto ?
- Comment maintenir une population diversifiée, afin d'éviter la convergence prématurée et réaliser un Ensemble-Pareto bien réparti ?

Il est prouvé que les algorithmes élitistes (par exemple PESA [13], SPEA2 [6], NSGA-II [14]) contribuent à améliorer la convergence du problème MOEAs-*Multi-Objective Evolutionary Algorithms* [12]. Les points communs de ces MOEAs élitistes sont les suivants : (1) la valeur de la fonction d'adaptation de chacun de membres de la population est calculée grâce au tri non-dominé et (2) la diversité de la solution est conservée (parce que la distance des individus est maximisée dans le processus d'optimisation).

Dans cet article, le SPEA2 est utilisé parce qu'il est très efficace pour l'optimisation multi-objectif [15], [16]. Les idées principales du SPEA2 sont :

- Parallèlement à l'ensemble de population P , à chaque génération, une archive ensemble \bar{P} de taille fixe est utilisée pour stocker des solutions non dominées.
- La fonction d'adaptation de chaque solution est définie par la valeur "strength" (basée sur la relation de Pareto-dominance) et l'estimation de la densité (fonction de la distance au k -ème point le plus proche). La solution non-dominée a une valeur de fonction d'adaptation inférieure à 1.
- La sélection de l'environnement (*environmental selection*) est appliquée pour les deux ensembles de la population et d'archive $P + \bar{P}$. Les solutions non-dominées sont choisies et sont copiées vers l'archive \bar{P} . Si le nombre de solutions non-dominées s'adapte à la taille de l'archive, l'étape de sélection de l'environnement est terminée. S'il est plus petit, un nombre approprié d'individus les mieux dominés dans $P + \bar{P}$ est ajouté à P . Sinon, une procédure de troncature de l'archive est utilisée, c.à.d, la solution qui a la distance minimale aux autres solutions est éliminée.
- La sélection par tournoi binaire (*binary tournament selection*) est appliquée sur P pour créer une génération intermédiaire (mating pool). Ensuite, les opérateurs de recombinaison et de mutation sont appliqués à la génération intermédiaire, afin de créer la nouvelle population de P .

III. FORMULATION LPV DU MODÈLE DE SUSPENSION SEMI-ACTIVE

A. Description du système

Considérons un modèle simple 1/4 de véhicule se composant d'une masse suspendue (m_s) et d'une masse non-suspendue (m_{us}), reliées par un ressort de raideur k_s et un amortisseur semi-actif. La roue est représentée par un ressort de raideur k_t . Dans ce modèle, z_s (z_{us} , respectivement) est le déplacement vertical de m_s (m_{us} , respectivement) autour de sa position statique, z_r représente le profil vertical du sol. Le contact roue-route est supposé permanent.

Les dynamiques du quart de véhicule sont données par :

$$\begin{cases} m_s \ddot{z}_s = -F_{spring} - F_{mr} \\ m_{us} \ddot{z}_{us} = F_{spring} + F_{mr} - k_t (z_{us} - z_r) \end{cases} \quad (3)$$

Les efforts (F_{spring}, F_{mr}) dans les équations dynamiques ci-dessus sont les parties dynamiques des efforts réels. $F_{spring} = k_s z_{def}$ et F_{mr} est donnée par

$$F_{mr} = a_2 (\dot{z}_{def} + \frac{v_0}{x_0} z_{def}) + a_1(I) \tanh(a_3 (\dot{z}_{def} + \frac{v_0}{x_0} z_{def})) \quad (4)$$

où $z_{def} = z_s - z_{us}$ et $\dot{z}_{def} = \dot{z}_s - \dot{z}_{us}$ et où a_2, a_3, v_0 et x_0 sont des paramètres constants et a_1 dépend du courant électrique ($0 < a_{1min} \leq a_1 \leq a_{1max}$). Le quart de véhicule

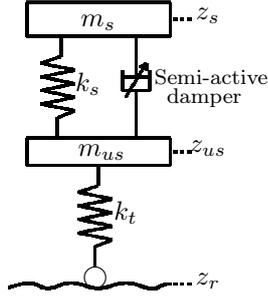


Fig. 1. Modèle 1/4 de véhicule avec un amortisseur MR semi-actif.

étudié dans cet article correspond à la "Renault Mégane Coupé" (voir [17]). Les paramètres sont $m_s = 315$ kg, $m_{us} = 37.5$ kg, $k_s = 29500$ N/m, $k_t = 210000$ N/m.

Les paramètres du modèle de l'amortisseur ont été choisis comme ceux de [18] : $a_2 = 1500$ Ns/m, $a_3 = 129$ s/m, $v_0 = 0.788 \times 10^{-3}$ m/s, $x_0 = 1.195 \times 10^{-3}$ m, $a_{1min} = 0$ N, $a_{1max} = 400$ N. Deux paramètres pour la conception du contrôleur (voir [1]) sont $F_0 = (a_{1max} + a_{1min})/2 = 200$ N, $F_1 = (a_{1max} - a_{1min})/2 = 200$ N.

En définissant $\rho_1 = \tanh(a_3(\dot{z}_{def} + \frac{v_0}{x_0} z_{def}))$, la représentation d'état du modèle 1/4 de véhicule peut être écrite comme suit :

$$\begin{cases} \dot{x}_s = A_s x_s + B_s \rho_1 I + B_{s1} w \\ y = C_s x_s \end{cases} \quad (5)$$

où

$$\begin{aligned} x_s &= (z_s, \dot{z}_s, z_{us}, \dot{z}_{us})^T, w = z_r, y = z_s - z_{us}. \\ A_s &= \begin{pmatrix} 0 & 1 & 0 & 0 \\ -\frac{k_s+k_v}{m_s} & -\frac{c_v}{m_s} & \frac{k_s+k_v}{m_s} & \frac{c_v}{m_s} \\ 0 & 0 & 0 & 1 \\ \frac{k_s+k_v}{m_{us}} & \frac{c_v}{m_{us}} & -\frac{k_s+k_v+k_t}{m_{us}} & -\frac{c_{mr}}{m_{us}} \end{pmatrix} \\ B_s &= \begin{pmatrix} 0 \\ -\frac{y_{mr}}{m_s} \\ 0 \\ \frac{y_{mr}}{m_{us}} \end{pmatrix}, B_{s1} = \begin{pmatrix} 0 \\ 0 \\ 0 \\ \frac{k_t}{m_{us}} \end{pmatrix}, C_s = \begin{pmatrix} 1 \\ 0 \\ -1 \\ 0 \end{pmatrix}^T \end{aligned}$$

B. Formulation de modèle LPV

La formulation LPV du modèle de suspension semi-active est présentée en détail dans [1]. Ici, on ne donne que le résultat final.

Le modèle non-linéaire (5) se ré-écrit dans le cadre de l'approche LPV

$$\begin{cases} \dot{x} = A(\rho_1^*, \rho_2^*) x + B u_c + B_1 w \\ y = C x \end{cases} \quad (6)$$

où

$$\begin{aligned} x &= (x_s^T \quad x_f^T)^T \\ A(\rho_1^*, \rho_2^*) &= \begin{pmatrix} A_s + \rho_2^* B_{s2} C_{s2} & \rho_1^* B_s C_f \\ 0 & A_f \end{pmatrix}, \\ B &= \begin{pmatrix} 0 \\ B_f \end{pmatrix}, B_1 = \begin{pmatrix} B_{s1} \\ 0 \end{pmatrix}, C = \begin{pmatrix} C_s \\ 0 \end{pmatrix}^T \\ B_{s2} &= \left(0; -\frac{F_0}{m_s}; 0; \frac{F_0}{m_{us}} \right)^T, \end{aligned}$$

$$C_{s2} = \left(\frac{a_3 v_0}{x_0}; a_3; -\frac{a_3 v_0}{x_0}; -a_3 \right)^T,$$

x_f est le vecteur d'état d'un filtre strictement propre F_f défini par

$$F_f : \begin{pmatrix} \dot{x}_f \\ u \end{pmatrix} = \begin{pmatrix} A_f & B_f \\ C_f & 0 \end{pmatrix} \begin{pmatrix} x_f \\ u_c \end{pmatrix} \quad (7)$$

où A_f, B_f, C_f sont les matrices constantes.

Deux paramètres variants sont définis par

$$\rho_1^* = \tanh(C_{s2} x_s) \tanh\left(\frac{C_f x_f}{F_1}\right) \frac{F_1}{C_f x_f} \quad (8)$$

$$\rho_2^* = \frac{\tanh(C_{s2} x_s)}{C_{s2} x_s} \quad (9)$$

On note également que ρ_1^* et ρ_2^* ne sont pas indépendants (voir Fig. 2).

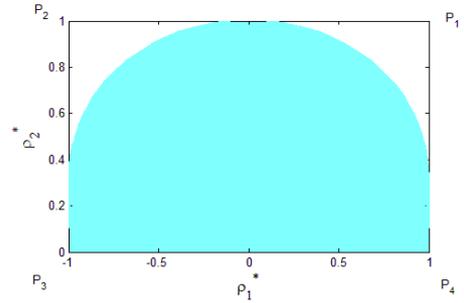


Fig. 2. Ensemble de (ρ_1^*, ρ_2^*) (zone grisée).

C. Objectifs de performance pour la suspension

Les objectifs de performance pour le confort et la tenue de route sont issus des idées de [5].

- Confort dans les hautes fréquences ([3 – 10] Hz) : $\min \int_3^{10} \ddot{z}_s/z_r(f) df$.
- Confort dans les basses fréquences ([0 – 4] Hz) : $\min \bar{\sigma}(z_s/z_r)(f)$.
- La tenue de route ([0 – 20] Hz) : $\min \bar{\sigma}(z_{us}/z_r)(f)$ (rebond de la roue) et de $\int_0^{20} (z_{us} - z_r)/z_r(f) df$ (Force de contact).

IV. OPTIMISATION DE CONTRÔLEUR LPV UTILISANT SPEA2

La structure de commande proposée dans [1] se retrouve dans la Fig. 3.

Les filtres utilisés pour la synthèse sont définis comme suit :

$$F_f = \frac{\Omega_f}{s + \Omega_f} \quad (10)$$

$$W_{\ddot{z}_s} = k_{\ddot{z}_s} \frac{s^2 + 2\xi_{11}\Omega_{11}s + \Omega_{11}^2}{s^2 + 2\xi_{12}\Omega_{12}s + \Omega_{12}^2} \quad (11)$$

$$W_{z_{us}} = k_{z_{us}} \frac{s^2 + 2\xi_{21}\Omega_{21}s + \Omega_{21}^2}{s^2 + 2\xi_{22}\Omega_{22}s + \Omega_{22}^2} \quad (12)$$

Définissons

$$\nu = [\Omega_f \quad \Omega_{11,12} \quad \xi_{11,12} \quad k_{\ddot{z}_s} \quad \Omega_{21,22} \quad \xi_{21,22} \quad k_{z_{us}}]^T \quad (13)$$

le vecteur de décision qui est optimisé par le SPEA2.

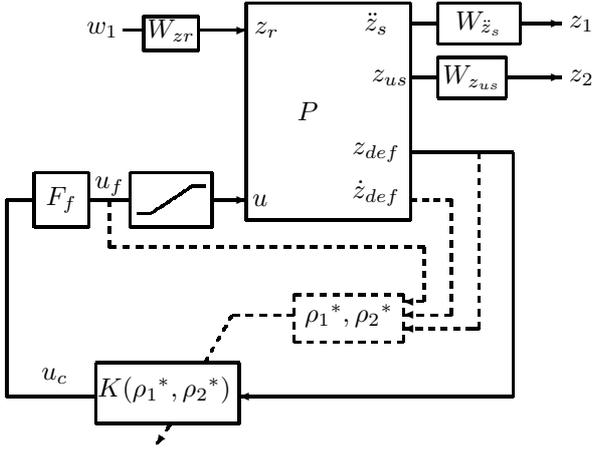


Fig. 3. Schéma bloc pour la commande de suspension semi-active .

Le système augmenté du système en boucle ouverte (5) avec les filtres (10)-(12) est représenté par

$$\begin{aligned} \dot{\xi} &= \mathcal{A}(\rho^*, \nu)\xi + \mathcal{B}_1(\rho^*, \nu)w + \mathcal{B}_2 u_c \\ z &= \mathcal{C}_1(\rho^*, \nu)\xi + \mathcal{D}_{11}(\rho^*, \nu)w + \mathcal{D}_{12} u_c \\ y &= \mathcal{C}\xi \end{aligned} \quad (14)$$

où ξ se compose des états des systèmes (5),(10)-(12), $z = [z_1 \ z_2]^T$ et $\rho^* = [\rho_1^* \ \rho_2^*]^T$.

Objectif - Chercher un contrôleur *LPV* qui stabilise le système (6) et qui satisfait les objectifs de performance de suspension spécifiés dans III-C.

A. Synthèse du contrôleur stabilisant

Considérons un contrôleur *LPV* associé au système (14) et décrit par les équations d'état

$$K_c(\rho^*) : \begin{pmatrix} \dot{x}_c \\ u_c \end{pmatrix} = \begin{pmatrix} A_c(\rho^*) & B_c(\rho^*) \\ C_c(\rho^*) & D_c(\rho^*) \end{pmatrix} \begin{pmatrix} x_c \\ y \end{pmatrix} \quad (15)$$

où x_c , y et u sont l'état, l'entrée et la sortie du contrôleur, respectivement.

Selon [19] et [20], s'il existe \hat{A} , \hat{B} , \hat{C} , \hat{D} , X , Y satisfaisant les LMIs suivantes

$$\begin{bmatrix} M_{11}(\rho_i^*, \nu) & M_{12}(\rho_i^*, \nu) \\ M_{12}^T(\rho_i^*, \nu) & M_{22}(\rho_i^*, \nu) \end{bmatrix} \prec 0 \quad (16)$$

pour $i = 1 : 4$

où

$$\begin{aligned} M_{11}(\rho_i^*, \nu) &= \mathcal{A}(\rho_i^*, \nu)X + X\mathcal{A}(\rho_i^*, \nu)^T + \mathcal{B}_2\hat{C}(\rho_i^*, \nu) + \hat{C}(\rho_i^*, \nu)^T\mathcal{B}_2^T \\ M_{12}(\rho_i^*, \nu) &= \hat{A}(\rho_i^*, \nu) + \mathcal{A}(\rho_i^*, \nu)^T + \mathcal{C}^T\hat{D}(\rho_i^*, \nu)^T\mathcal{B}_2^T \\ M_{22}(\rho_i^*, \nu) &= Y\mathcal{A}(\rho_i^*, \nu) + \mathcal{A}(\rho_i^*, \nu)^TY + \hat{B}(\rho_i^*, \nu)\mathcal{C} + \mathcal{C}^T\hat{B}(\rho_i^*, \nu)^T \end{aligned}$$

alors le contrôleur *LPV* (15) qui stabilise le système (14) est donné par :

$$K_c(\rho^*) = \text{Co}\left\{ \begin{pmatrix} A_c(\rho_i^*) & B_c(\rho_i^*) \\ C_c(\rho_i^*) & D_c(\rho_i^*) \end{pmatrix} \right\} \quad (17)$$

avec

$$\begin{aligned} D_c(\rho_i^*) &= \hat{D}(\rho_i^*) \\ C_c(\rho_i^*) &= (\hat{C}(\rho_i^*) - D_c(\rho_i^*)\mathcal{C}_2X)M^{-T} \\ B_c(\rho_i^*) &= N^{-1}(\hat{B}(\rho_i^*) - Y\mathcal{B}_2D_c(\rho_i^*)) \\ A_c(\rho_i^*) &= N^{-1}(\hat{A}(\rho_i^*) - Y\mathcal{A}(\rho_i^*)X - Y\mathcal{B}_2D_c(\rho_i^*)\mathcal{C}_2X)M^{-T} \\ &\quad - B_c(\rho_i^*)\mathcal{C}_2XM^{-T} - N^{-1}Y\mathcal{B}_2C_c(\rho_i^*) \end{aligned} \quad (18)$$

$i = 1 : 4$ correspond aux 4 sommets du polytope (P_1, P_2, P_3, P_4) (voir fig. 2). M et N sont définies telles que $MN^T = I_n - XY$ soit résolue par une décomposition en valeurs singulières et une factorisation de Cholesky.

Jusqu'ici, une question peut être posée : comme le but original est de synthétiser un contrôleur qui stabilise le système (6), quelle est l'utilité des filtres (10)-(12) ?

En fait, chaque valeur possible des filtres pourra donner un contrôleur qui stabilise le système (6). L'algorithme génétique SPEA2 va choisir les meilleurs parmi ces contrôleurs. Alors, les filtres sont des outils utilisés par l'algorithme génétique SPEA2 pour la recherche de meilleurs contrôleurs, satisfaisant les objectifs de performance décrit dans III-C.

B. Optimisation du contrôleur

On n'utilise pas la méthode conventionnelle H_∞ /*LPV* proposée dans [19] et [20] où le niveau d'atténuation de perturbation γ est l'objectif à minimiser ; ici l'objectif de performance est celui de la suspension, défini par

$$J = \begin{pmatrix} J_{\text{Confort}} \\ J_{\text{Tenué de route}} \end{pmatrix} \quad (19)$$

où J_{Confort} et $J_{\text{Tenué de route}}$ sont des indices de performance correspondant au sommet P_3 (Remarquons que les solutions à P_3 et P_4 sont identiques en raison de la propriété symétrique du polytope (P_1, P_2, P_3, P_4)). Il est important de noter qu'en basses fréquences l'amélioration (réduction de gain) de \ddot{z}_s/z_r implique une amélioration de z_s/z_r . Avec cette remarque et la définition de critère de performance dans la section III-C, J_{Confort} et $J_{\text{Tenué de route}}$ sont définis par

$$J_{\text{Confort}} = \int_1^{10} \ddot{z}_s/z_r(f)df \quad (20)$$

$$J_{\text{Tenué de route}} = \bar{\sigma}_{f \in [10-20]}(z_{us}/z_r(f)) \quad (21)$$

Remarque 1 : Pour le système de suspension semi-active étudiée, il y a des parties non-linéaires (saturation d'entrée a_1 , la partie non-linéaire hyperbolique tangente de la suspension semi-active), et les contrôleurs *LPV* stables sont préférés. La solution théorique de l'existence d'un contrôleur *LPV* stable n'est pas donnée ici. Pour garantir un contrôleur *LPV* stable, il suffit que tous les contrôleurs locaux à chaque sommet du polytope soient stables. Par algorithme génétique, on peut obtenir ce type de contrôleurs en éliminant les "solutions instables" correspondant à au moins un contrôleur local instable lors de la synthèse. Ceci peut être obtenu simplement en choisissant $J = \infty$ pour les "solutions instables". Alors, la fonction objectif est choisie comme suit.

Algorithme 1 : Affectation de valeur de fonction d'objectif

si (16) est faisable **alors**

tous les contrôleurs locaux K_{c_i} sont stables **alors**

Calculer J en utilisant les Eq. (19) - (21)

sinon

$J = \infty$

fin

sinon

$J = \infty$

fin.

Méthode proposée pour optimiser la commande LPV de suspension semi-active

- Etape 1 : Initialiser la première génération avec des valeurs positives aléatoires des paramètres des filtres (10)-(12).
- Etape 2 : Résoudre les LMI (16) pour obtenir un contrôleur LPV $K_c(\rho^*)$. Calculer la fonction d'objectif J en utilisant l'Algorithme 1 pour chaque individu.
- Etape 3 : Utiliser le SPEA2 pour sélectionner les meilleurs individus qui peuvent entrer dans la prochaine génération.
- Etape 4 : Si le nombre de génération est inférieur à une valeur maximale, revenir à l'étape 2 avec la nouvelle génération obtenue dans l'étape 3. Sinon, arrêter le programme et sauvegarder les individus de la dernière génération. Ces individus correspondent à une approximation de l'ensemble de Pareto.

V. RÉSULTATS

Pour la simulation, la force du ressort k_s (Fig. 1) est une fonction non-linéaire de z_{def} (voir [17]) et la force de l'amortisseur est donné par (4). Dans la suite, les différents cas sont considérés pour l'évaluation de la performance de la méthodologie proposée :

- "Soft MRD" = Renault Mégane Car avec un amortisseur MR passif avec $a_1 = a_{1min} = 0 N$.
- "Hard MRD" = Renault Mégane Car avec un amortisseur MR passif avec $a_1 = a_{1max} = 400 N$.
- " H_∞/LPV (ACC 2010)" = Renault Mégane Car avec un amortisseur MR dont le coefficient d'amortissement est piloté par l'algorithme H_∞/LPV proposé dans [1].
- "LPV/SPEA2" = Renault Mégane Car avec un amortisseur contrôlé par la méthodologie proposée.

Les paramètres des filtres utilisés pour la synthèse de H_∞/LPV dans [1] et les paramètres obtenus par la méthode proposée $LPV/SPEA2$ sont donnés dans le Tableau I. Notons que pour les deux méthodes, la même structure de filtre a été choisie.

Dans les Fig. 4-8, globalement, la méthode proposée offre le meilleur compromis : une très bonne performance pour le confort en hautes fréquences et la force de contact (tenue de route) ; une bonne performance pour le confort en basses fréquences et le rebond de la roue (tenue de route).

VI. CONCLUSION

Nous avons proposé une nouvelle méthode de type LPV avec l'aide de l'algorithme génétique SPEA2 pour la commande de suspensions semi-actives (plus généralement, cette méthode peut être étendue pour la commande de systèmes représentés par des modèles LPV). Les simulations ont été faites avec un modèle vertical, non-linéaire, simplifié. Les résultats fréquentiels montrent l'efficacité de la méthode pour obtenir un contrôleur "optimal". Dans les travaux futurs, la réduction du conservatisme de la solution concernant la synthèse de contrôleur LPV stable ou "stabilisation forte" sera étudiée.

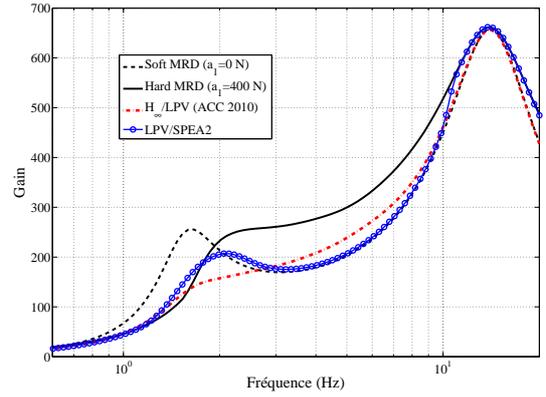


Fig. 4. Accélération \ddot{z}_s/z_r .

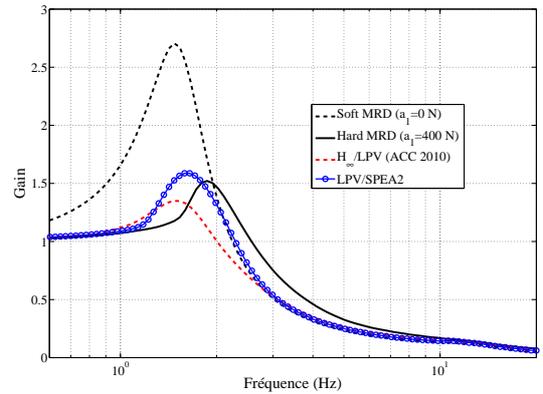


Fig. 5. Déplacement du châssis z_s/z_r .

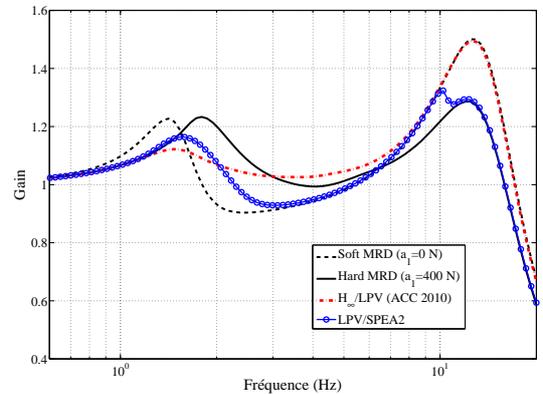


Fig. 6. Rebond du pneu z_{us}/z_r .

RÉFÉRENCES

- [1] A. L. DO, O. SENAME et L. DUGARD : An LPV control approach for semi-active suspension control with actuator constraints. In *Proceedings of the IEEE American Control Conference (ACC)*, Baltimore, Maryland, USA, June 2010.
- [2] R. W. BEAVEN, M. T. WRIGHT et D. R. SEAWARD : Weighting function selection in the \mathcal{H}_∞ design process. *Control Engineering Practice*, 4(5):625–633, 1996.
- [3] J. HU, C. BOHN et H. R. WU : Systematic \mathcal{H}_∞ weighting function selection and its application to the real-time control of a vertical take-off aircraft. *Control Engineering Practice*, 8:241–252, 2000.
- [4] E. ALFARO-CID, E. W. MCGOOKIN et D. J. MURRAY-SMITH : Optimisation of the weighting functions of an \mathcal{H}_∞ controller

Contrôleurs	Filtre Ω_f	W_{z_s}					$W_{z_{us}}$				
		Ω_{11}	Ω_{12}	ξ_{11}	ξ_{12}	k_{z_s}	Ω_{21}	Ω_{22}	ξ_{21}	ξ_{22}	$k_{z_{us}}$
H_∞ /LPV (ACC 2010)	50	125.7	125.7	20	1	1	69.1	69.1	20	1	1
LPV/SPEA2 (proposée)	9.3	50.71	0.012	55.39	78.4	68.96	94.39	28.23	81.52	48.21	21

TABLE I

PARAMÈTRES DES FILTRES POUR LA SYNTHÈSE LPV.

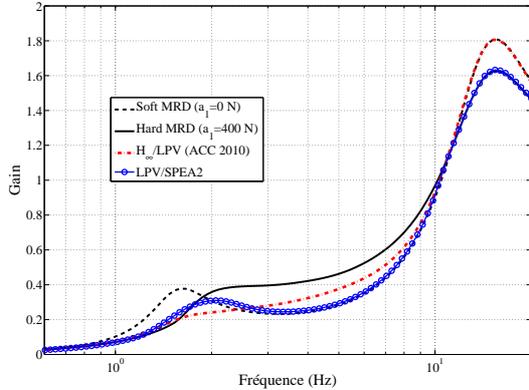
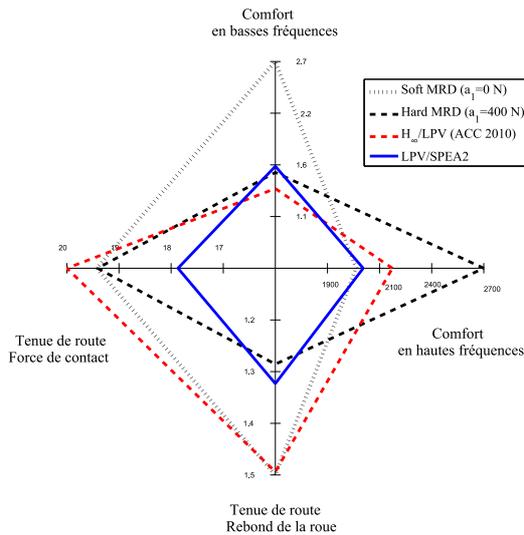
Fig. 7. Force de contact $(z_s - z_r)/z_r$.

Fig. 8. Comparaison des performances.

using genetic algorithms and structured genetic algorithms. *International Journal of Systems Science*, 39 :4:335–347, 2008.

- [5] D. SAMMIER, O. SENAME et L. DUGARD : Skyhook and \mathcal{H}_∞ control of active vehicle suspensions : some practical aspects. *Vehicle System Dynamics*, 39(4):279–308, avril 2003.
- [6] E. ZITZLER, M. LAUMANN et L. THIELE : SPEA2 : Improving the strength pareto evolutionary algorithm. Rapport technique, 2001.
- [7] C. POUSSOT-VASSAL, O. SENAME, L. DUGARD, P. GÁSPÁR, Z. SZABÓ et J. BOKOR : New semi-active suspension control strategy through LPV technique. *Control Engineering Practice*, 16(12):1519–1534, December 2008.
- [8] H. J. HOLLAND : Adaptation in natural and artificial systems, an introductory analysis with application to biology, control and artificial intelligence. *Ann Arbor, The university of Michigan Press*, 1975.
- [9] D. GOLDBERG : *Genetic Algorithms in Searching Optimisation and Machine Learning*. Addison-Wesley Longman, 1989.
- [10] L. D. DAVIS : Handbook of genetic algorithms. *Van Nostrand Reinhold*, 1991.
- [11] R. T. MARLER et J. S. ARORA : Survey of multi-objective optimization methods for engineering. *Struct Multidisc Optim*, 26:369–395, 2004.
- [12] E. ZITZLER, K. DEB et L. THIELE : Comparison of multiobjective evolutionary algorithms : Empirical results. *Evol. Comput.*, 8(2): 173–195, 2000.
- [13] D. W. CORNE, J. D. KNOWLES et M. J. OATES : The pareto envelope-based selection algorithm for multiobjective optimization. In *Proceedings of the Parallel Problem Solving from Nature VI Conference*, pages 839–848. Springer, 2000.
- [14] K. DEB, A. PRATAP, S. AGARWAL et T. MEYARIVAN : A fast elitist multi-objective genetic algorithm : NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2):182–197, 2002.
- [15] S. BLEULER, M. BRACK, L. THIELE et E. ZITZLER : Multiobjective genetic programming : Reducing bloat using SPEA2. In *Proceedings of the 2001 Congress on Evolutionary Computation CEC2001*, pages 536–543. Press, 2001.
- [16] H. LI et Q. ZHANG : Multiobjective optimization problems with complicated pareto sets, MOEA/D and NSGA-II. *IEEE Transactions on Evolutionary Computation*, 13(2):284–302, 2009.
- [17] A. ZIN, O. SENAME, M. BASSET, L. DUGARD et G. GISSINGER : A nonlinear vehicle bicycle model for suspension and handling control studies. In *Proceedings of the IFAC Conference on Advances in Vehicle Control and Safety (AVCS)*, pages 638–643, Genova, Italy, october 2004.
- [18] E. NINO-JUAREZ, R. MORALES-MENENDEZ, R. RAMIREZ-MENDOZA et L. DUGARD : Minimizing the frequency in a black box model of a MR damper. In *11th Mini Conf on Vehicle Sys. Dyn., Ident. and Anomalies*, Budapest, Hungary, 2008.
- [19] C. SCHERER, P. GAHINET et M. CHILALI : Multiobjective output-feedback control via LMI optimization. *IEEE Transaction on Automatic Control*, 42(7):896–911, july 1997.
- [20] P. APKARIAN et P. GAHINET : A convex characterization of gain scheduled \mathcal{H}_∞ controllers. *IEEE Transaction on Automatic Control*, 40(5):853–864, may 1995.