
Une méthodologie de conception robuste en dynamique des structures

Boubker Ait brik — Nouredine Bouhaddi — Scott Cogan

Institut FEMTO ST UMR 6174

Laboratoire de Mécanique Appliquée R. Chaléat

24 chemin de l'Épitaphe, F-25000 Besançon

{boubker.ait_brik ;nouredine.bouhaddi}@univ-fcomte.fr,

scott.cogan@univ-fcomte.fr

RÉSUMÉ. Les outils de modélisation et d'optimisation multiobjectif les plus utilisés en dynamique des structures reposent sur la méthode des éléments finis et les algorithmes génétiques. Bien que les avancées dans le domaine informatique permettent de traiter des modèles éléments finis comportant plusieurs millions de degrés de liberté, les coûts de calculs demeurent encore un obstacle important dans le cadre de l'optimisation de structures complexes surtout en présence des incertitudes (géométriques, matérielles...) sur les paramètres de conception. Dans cet article, nous proposons une méthode qui permet de réduire la taille des modèles éléments finis associés à ces structures en utilisant une approche de condensation ou de sous-structuration dynamique. Cette approche qui exploite une base de Ritz robuste vis-à-vis des incertitudes et des modifications structurales est couplée à un algorithme génétique dans une procédure d'optimisation multiobjectif stochastique.

ABSTRACT. The tools of modelling and multicriterion optimization the most employed in the structural dynamics rests on the finite element methods and the genetic algorithms. Although the progress in the data-processing field make it possible to treat models comprising several million degrees of freedom, the costs of calculations especially remain a significant obstacle within the framework of the optimization of complex structures in the presence of uncertainties (geometrical, material) on the parameters of design. It then becomes necessary to reduce the size of the models by using a robust base of Ritz. In this article, we propose a new method which makes it possible to reduce the size of the finite elements models by using a condensation approach. This approach which exploits a robust Ritz base with respect to uncertainties and structural modifications is coupled with a genetic algorithm in a stochastic of multiobjective optimization procedure.

MOTS-CLÉS : condensation robuste, incertitudes, optimisation multiobjectif, robustesse.

KEYWORDS: robust condensation, uncertainties, multiobjective optimisation, robustness.

1. Introduction

Les méthodes d'optimisation multiobjectif basées sur les approches déterministes ou heuristiques sont aujourd'hui appliquées à différents domaines pour réduire les coûts et les délais de conception des produits. Elles tiennent une place importante pour résoudre les problèmes d'ingénierie multiphysique et multiobjectif compte tenu de leur robustesse numérique et de leur facilité de mise en œuvre.

Ces méthodes peuvent être classées en deux grandes catégories : les approches déterministes qui considèrent seulement des valeurs nominales des variables de conception et les approches robustes qui prennent en compte les incertitudes sur les variables de conception (Balling, 1986 ; Bennett, 1990). En ingénierie mécanique, ces incertitudes sont inhérentes aux défauts de modélisation, aux propriétés mécaniques des matériaux (module d'Young, masse volumique...), aux processus de fabrication et d'assemblage (épaisseurs de tôles et d'autres variables géométriques...). Dans une phase de conception en avant-projet, ces incertitudes sont introduites pour prendre en compte la méconnaissance de certaines variables de conception. Cette méthode est dédiée à la conception robuste de structures mécaniques en avant-projet : des variations paramétriques importantes, des incertitudes sur ces paramètres et éventuellement un nombre important de paramètres de conception.

L'utilisation des algorithmes génétiques comme le NSGA (Srivinas, 1993) pour résoudre des problèmes d'optimisation multiobjectif en dynamique des structures et de modèles éléments finis associés de grande taille conduit à des coûts de calcul prohibitifs. Pour résoudre ce problème, nous proposons dans cet article, une méthodologie de conception robuste basée sur le couplage de l'optimisation multiobjectif stochastique avec une méthode de condensation robuste vis-à-vis des modifications structurales.

Pour cela, avant d'entamer la procédure d'optimisation, la structure est préalablement divisée en sous-structures. La première étape consiste à utiliser une base de réduction de type Craig-Bampton standard (Craig, 1968), qui est ensuite enrichie par des résidus statiques afin que la condensation finale soit robuste par rapport aux modifications et aux incertitudes sur les paramètres de conception (Balmès, 1997 ; Masson, 2003). Ainsi, au cours de l'optimisation, les évaluations des fonctions coûts par l'algorithme génétique de type NSGA d'une part, et de la robustesse des solutions optimales vis-à-vis des incertitudes d'autre part, sont effectuées sur le modèle condensé robuste, ce qui évite une réactualisation coûteuse de la base de condensation.

2. Optimisation multiobjectif robuste

2.1. Algorithme évolutionnaire

L'algorithme évolutionnaire utilisé dans cet article est l'algorithme NSGA (*Non Dominated Sorting Genetic Algorithm*), proposé par Srinivas (1993). Il est basé sur le concept de dominance de Pareto. Les solutions sont classées en rang. Les individus qui ne sont pas dominés, sont affectés au front n° 1, puis ils sont éliminés de la population. L'ensemble suivant d'individus non dominés est identifié et affecté au rang 2, etc. Cette procédure est répétée jusqu'à ce que tous les individus de la population aient un rang. Les solutions situées dans les premiers fronts ont une probabilité plus forte pour être sélectionnés.

Après le classement de chaque population en rang, on attribue à chaque individu x_i une valeur f_i appelée performance ou « fitness » telle que : $f_i = 1/r_i$ avec r_i égal au rang de l'individu x_i .

Généralement, la résolution d'un problème multiobjectif n'est pas seulement de trouver l'ensemble Pareto optimal, mais aussi que les solutions soient uniformément réparties dans cet ensemble. Pour cela, il est nécessaire d'introduire dans un algorithme génétique la technique de formation des niches (Srinivas, 1993). Les valeurs de la fonction fitness sont ainsi divisées par une fonction m_i :

$$m_i = \sum_{j=1}^N sh(d(x_i, x_j)) \quad [1]$$

où : x_i et x_j sont des individus et N le nombre d'individus dans la population.

sh est la fonction de niche (sharing) donnée par l'expression :

$$sh(d(x_i, x_j)) = \begin{cases} 1 - d(x_i, x_j) / \sigma_{shar} & \text{si } d(x_i, x_j) < \sigma_{shar} \\ 0 & \text{si } d(x_i, x_j) \geq \sigma_{shar} \end{cases} \quad [2]$$

avec σ_{shar} est une constante fixée par le décideur afin de définir l'intervalle des niches, et $d(x_i, x_j)$ est la distance euclidienne entre les deux individus x_i et x_j .

Après la définition de la nouvelle fonction de fitness, on utilise ensuite les trois opérations standard d'un algorithme génétique : sélection, croisement et mutation (Goldberg 1989).

2.2. Robustesse des solutions optimales

Classiquement, la robustesse d'une solution optimale est évaluée à la fin de la procédure d'optimisation déterministe. Cette idée suppose que l'espace de

conception déterministe contienne les solutions robustes que l'on doit ensuite sélectionner en introduisant des critères de robustesse.

L'idée proposée dans cet article est différente, car on suppose que la solution à la fois optimale et robuste n'est pas forcément une solution de l'espace déterministe qui doit être enrichi. Pour cela, la robustesse est introduite comme fonction objective supplémentaire à maximiser. Cette fonction de robustesse caractérise la dispersion de chaque fonction coût originale. Ainsi, au cours de l'optimisation, la fonction robustesse f^R d'une fonction coût f est définie par :

$$f^R = (\sigma_f / \mu_f)^{-1} \quad [3]$$

Le rapport σ_f / μ_f désigne la dispersion ou la fonction vulnérabilité $f^V = (1/f^R)$ de f .

où : $\mu_f = E(f)$ et $\sigma_f = E((E(f) - f)^2)$ sont respectivement la moyenne et l'écart type calculés sur un ensemble N d'échantillons $(f_i)_{1 \leq i \leq N}$ de la fonction coût f .

Le calcul de la fonction de robustesse, fait appel à un tirage de type Monte Carlo (Latin Hypercube (Mckay, 1997)) avec 200 échantillons. Pour des modèles complexes, il est bien connu que la simulation de Monte Carlo conduit généralement à des coûts de calcul prohibitifs ou simplement incompatibles avec des délais de conception réalistes. Pour réduire ces temps de calcul, d'autres alternatives d'évaluation de la robustesse peuvent être utilisées. On peut citer les méthodes basées sur les éléments finis stochastiques comme la méthode des perturbations (Klieber, 1992), le chaos polynomial (Ghanem, 1991), les approches d'approximation par les métamodèles basés sur les surfaces de réponses stochastiques (Isukapalli, 1999), les réseaux de neurones artificiels (Ait Brik, 2004) et enfin la réduction de modèles par une approche non paramétrique (Soize, 2000). Par une de ces alternatives, il est alors possible de calculer de manière efficace et précise les deux premiers moments (moyenne et écart type) de la fonction robustesse.

Le problème d'optimisation multiobjectif (m fonctions coûts) initial défini sous la forme :

$$\begin{cases} \text{Min}_x F(x) = (f_1(x), f_2(x), \dots, f_m(x)) \\ \text{avec } x \in C \end{cases} \quad [4]$$

est transformé en un problème d'optimisation multiobjectif robuste posé de la manière suivante :

$$\begin{cases} \text{Min}_x F(x) = (f_1(x), f_1^V(x), f_2(x), f_2^V(x), \dots, f_m(x), f_m^V(x)) \\ \text{avec } x \text{ variable aléatoire } \in C \end{cases} \quad [5]$$

Une solution robuste vis-à-vis des incertitudes est celle qui permet de minimiser simultanément les fonctions coûts initiales $F(x) = (f_1(x), f_2(x), \dots, f_m(x))$ et de maximiser leurs robustesses ou de minimiser leurs vulnérabilités $F^V(x) = (f_1^V(x), f_2^V(x), \dots, f_m^V(x))$.

2.3. Condensation robuste vis-à-vis des incertitudes et des modifications paramétriques

On aborde dans cette partie la notion de robustesse des bases de réduction d'un modèle vis-à-vis de modifications sur des paramètres de conception, la description géométrique du modèle et sa connectivité étant supposées figées. En effet, disposer d'une base de réduction capable de représenter le mouvement d'un modèle perturbé ou modifié est primordial dans des procédures itératives de recalage ou d'optimisation : une telle base autorise des réanalyses approchées rapides et économiques en termes de calculs.

L'objectif est de compléter le plus efficacement la base modale tronquée par des vecteurs susceptibles d'augmenter la qualité de représentation du comportement dynamique du système soumis à des modifications structurales qui résultent de variations de paramètres de conception (masse volumique, module d'Young, épaisseurs, raideurs de jonctions...). La stratégie proposée s'inspire de méthodes développées dans le cadre de la condensation directe (Bouazzouni, 1997) et la sous-structuration dynamique (Masson, 2003). L'idée est d'enrichir la base de condensation standard par des vecteurs résiduels statiques bien choisis qui dépendent des zones de modifications. Cela permet d'améliorer considérablement la prédictivité des méthodes de sous-structuration standard en prenant en compte une information a priori concernant les modifications structurales éventuelles. La même transformation est alors utilisée tout au long de la procédure d'optimisation. Le calcul requiert la résolution d'un problème statique afin d'avoir des déplacements approchés sur tous les degrés de liberté de la structure. Puis en soustrayant la contribution dynamique des modes connus, on obtient une approximation de l'effet des modes inconnus sous une forme résiduelle.

Le modèle modifié s'écrit sous la forme :

$$(Z_{o(\omega)} + \Delta Z)U_{(\omega)} = f_e \quad [6]$$

$Z_{o(\omega)} = K_o - \omega^2 M_o$ est la matrice de raideur dynamique du modèle nominal

$\Delta Z_{o(\omega)} = \Delta K_o - \omega^2 \Delta M_o$ est la matrice de modifications globales ou par zones

Le modèle modifié condensé par une base de réduction T_o , ($U^c = T_o U$) du modèle nominal s'écrit, sous la forme :

$$Z_{o(\omega)}^c U_{(\omega)}^c = f_{\Delta}^c(\omega) + f_e^c(\omega) \quad [7]$$

$Z_o^c = T_o^T Z_{o(\omega)}^c T_o = (K_o^c - \omega^2 M_o^c)$ est la matrice moyenne de raideur dynamique condensée; $f_{\Delta(\omega)}^c = -\Delta Z_{o(\omega)}^c U_{(\omega)}^c$ est le vecteur condensé des forces de modification, $f_e^c(\omega)$ est le vecteur condensé des forces appliquées.

La base de réduction T commune au système initial et modifié est construite à l'aide de la base de condensation T_o et des résidus statiques R_{Δ} associés à une suite de chargements statiques F_{Δ} représentatifs des modifications $\Delta Z_{o(\omega)}$:

$$T = [T_o \ R_{\Delta}]; \quad R_{\Delta} = R f_{\Delta} \quad [8]$$

$R = K_o^{-1} - Y \Lambda^{-1} Y^T$ la matrice des résidus statiques du modèle nominal. La base T_o peut être par exemple une base de condensation de type interfaces bloquées de Craig-Bampton ou tout simplement une base modale tronquée dans le cadre d'une condensation directe.

Sous cette forme, la base de condensation enrichie T permet d'éviter la réactualisation du modèle nominal dans le processus d'optimisation.

La « robustesse » est définie ici relativement à l'aptitude de la transformation enrichie à prédire correctement le comportement de la structure modifiée au cours de la procédure d'optimisation.

2.4. Couplage algorithme génétique-condensation robuste en optimisation

Le mécanisme de recherche des solutions optimales et robustes par la stratégie couplant l'algorithme génétique (NSGA) et la méthode de condensation enrichie (par exemple, méthode de Craig-Bampton enrichie CBE) peut être brièvement décrit comme suit :

- à partir du modèle nominal, on construit la matrice de transformation enrichie par des résidus statiques, et le modèle condensé « robuste » associé ;
- l'algorithme génétique est ensuite utilisé pour explorer les solutions optimales dans l'espace de décision ;
- chaque fois que l'algorithme génétique produit une nouvelle solution, la transformation de Craig-Bampton enrichie (CBE) réduisant le modèle dynamique est exploitée afin de calculer les fonctions coûts et d'évaluer la robustesse des

solutions. Un tirage aléatoire de type Monte Carlo (Latin hypercube) est utilisé pour évaluer les fonctions de robustesse, avec 200 tirages ;

– l’algorithme génétique suit son processus de recherche jusqu’à ce que le critère d’arrêt soit satisfait.

3. Simulation numérique

3.1. Exemple 1

La structure proposée est une équerre (figure 1) constituée d’un assemblage de 2 plaques renforcées. La structure est divisée en deux sous-structures. Le modèle éléments finis complet contient 4 140 ddls. Le modèle de la sous-structure 1 contient 1 944 ddls et celui de la sous-structure 2 contient 2 340 ddls. La jonction entre les 2 sous-structures comporte 144 ddls. Par la méthode de Craig-Bampton (CB), le modèle initial est ramené à un modèle condensé à 224 ddls.

Les caractéristiques nominales de la structure sont : $t = 1 \times 10^{-3}$ m (épaisseur) ; $E = 2,1 \times 10^{11}$ N/m² ; $\rho = 7800$ kg/m³.

Six zones de modifications sont définies pour les deux sous-structures. Les modifications appliquées aux zones portent sur l’épaisseur et le module d’Young qui sont considérés comme des paramètres de conception pour le problème d’optimisation (figure 1). Ainsi, l’extension de la base de transformation est effectuée par 190 résidus statiques (85 pour SS1 et 105 pour SS2). Par conséquent, la base de transformation de Craig-Bampton enrichie (CBE) contient 414 vecteurs. Il en résulte alors un modèle condensé robuste à 414 ddls qui sera exploité dans la procédure d’optimisation.

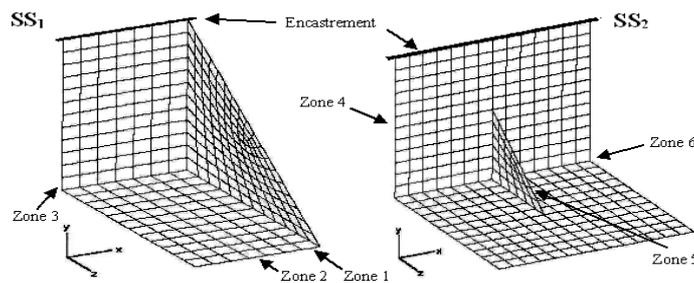


Figure 1. MEF de l’équerre – Définition des sous-structures

Dans une première étape, nous proposons d’illustrer la capacité de la méthode de condensation robuste à prédire le comportement de la structure en introduisant des modifications structurales arbitraires (tableau 1, qualité de la condensation) dans le

modèle nominal (par exemple : E zone 1 est multiplié par 2). Cela reflète l'aptitude de la base de condensation enrichie à fournir un modèle réduit de bonne prédictivité qui sera exploité plus loin au cours de l'optimisation.

Paramètres de conception	Sous-structure 1			Sous-structure 2		
	E _{zone 1}	t _{zone 2}	E _{zone 3}	E _{zone 4}	t _{zone 5}	E _{zone 6}
Qualité de la condensation						
Coefficient de modification	2	0.5	2	2	0.5	2
Optimisation						
Intervalles de variation	± 80%	± 40%	± 80%	± 80%	± 40%	± 80%
Niveaux de tolérance	± 10%	± 10%	± 10%	± 10%	± 10%	± 10%

Tableau 1. Définition des paramètres de conception et des tolérances

La figure 2 groupe les dix premières fréquences propres du modèle nominal et du modèle modifié ainsi que la matrice de Mac entre les modèles nominal et modifié. Trois méthodes de réanalyse approchée sont comparées entre elles :

- 1°) Méthode de Craig-Bampton classique dont la base de Ritz contient 204 ddls dénommée CB204,
- 2°) Méthode de Craig-Bampton classique dont la base contient 284 ddls dénommée CB284,
- 3°) Méthode de Craig-Bampton enrichie dont la base contient 284 ddl dénommée CBE284.

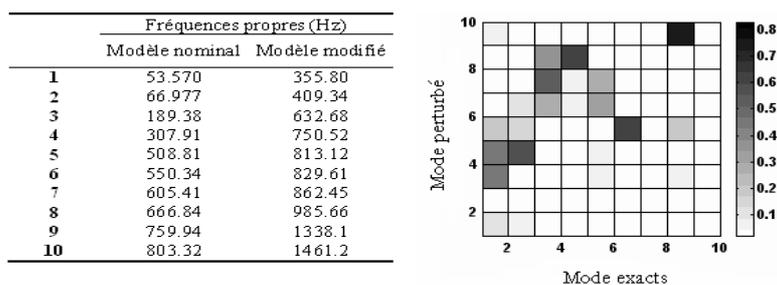


Figure 2. Ecart en fréquence modèle nominal – modèle modifié

La méthode CB fournit de moins bons résultats que la méthode CBE. Le fait de rajouter des modes normaux issus du modèle initial dans la base de condensation n'a aucune influence sur la qualité de prédiction du modèle réduit. A taille identique, la

condensation enrichie CBE améliore de façon significative la précision et donne les meilleurs résultats pour les dix premiers modes analysés, avec des coûts de calculs comparables (figure 3).

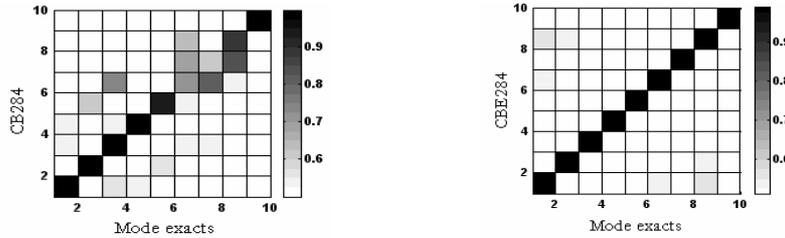


Figure 3. Niveau de prédiction des bases de réduction sur le modèle modifié

La deuxième étape consiste à effectuer l'optimisation robuste multiobjectif. Pour cela, les paramètres de conception (tableau 1, Optimisation) sont définis avec leurs intervalles de variations au cours de l'optimisation $[x_{i\min}; x_{i\max}]$ ($i=1,2,\dots,6$) (pour le paramètre E des zones 1, 3, 4 et 6 : $[x_{i\min} = 4.2 \times 10^{10}, x_{i\max} = 3.78 \times 10^{11}]$ qui correspond à une variation de $\pm 80\%$ de la valeur nominale $E = 2.1 \times 10^{11}$, pour le paramètre t : $[x_{i\min} = 0.6 \times 10^{-3}, x_{i\max} = 1.4 \times 10^{-3}]$ qui correspond à une variation de $\pm 40\%$ de la valeur nominale $t = 1 \times 10^{-3}$). Pour l'évaluation de la robustesse, on définit généralement les incertitudes sur les paramètres de conception grâce à un niveau de tolérance donné. Dans cet exemple, la variation de chaque paramètre est supposée gaussienne et son intervalle de tolérance est de ± 3 fois l'écart type ($\pm 3\sigma$). Cette variation correspond à $\pm 10\%$ pour les six paramètres. Dans le cas général, la non-positivité de la loi normale peut conduire à des valeurs négatives pour des paramètres tels que le module d'Young, épaisseur... Mais ce risque est évité dans cette étude par le choix de l'intervalle de tolérance maximum ($\pm 3\sigma$), qui correspond à des faibles incertitudes et conduit à des valeurs positives des paramètres. A noter également que d'autres lois (loi uniforme par exemple) peuvent être exploitées dans l'approche proposée.

Le problème d'optimisation multiobjectif consiste à minimiser la première fréquence propre et à maximiser la deuxième (*i.e.* maximiser l'écart entre les deux). Les paramètres de conception choisis sont définis dans le tableau 1. L'algorithme NSGA est utilisé avec les caractéristiques suivantes : Probabilité de sélection = 0.5, probabilité de croisement = 0.2, probabilité de mutation = 0.02, nombre d'individus par génération = 30, nombre de générations = 100. Ainsi, le problème d'optimisation robuste est composé de quatre fonctions objectif dont deux fonctions de vulnérabilité. La figure 4 illustre les fronts de Pareto du modèle complet et du modèle condensé, qui contiennent respectivement 47 et 53 solutions.

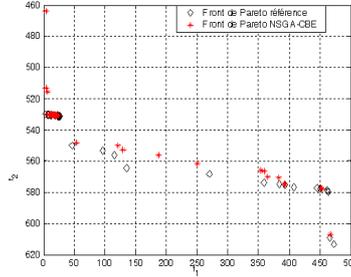


Figure 4. Comparaison des solutions optimales

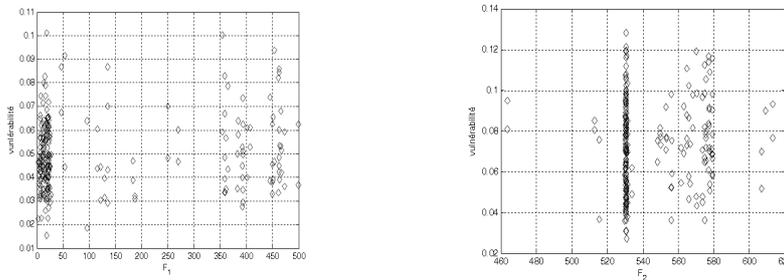


Figure 5. Front de Pareto de l'espace robuste

La figure 5 illustre les deux fonctions coûts en fonction de leurs vulnérabilités respectives. On peut remarquer que les solutions optimales présentent des faibles variations dues aux incertitudes sur les paramètres de conception. Une comparaison des temps de calcul est nécessaire pour mettre en évidence les performances de la méthode proposée. Le tableau 2 illustre le gain en termes de temps de calcul de la méthode NSGA-CBE par rapport à un calcul exact. Ce gain est d'autant plus significatif que la taille du modèle élément fini est très importante.

	NSGA	NSGA-CBE
1 génération	6 min	<2 min
100 générations	10 h	1h30 mn

Tableau 2. CPU des deux méthodes

La réanalyse approchée par la méthode de condensation de Craig-Bampton enrichie fournit des solutions comparables aux solutions issues de l'optimisation sur le modèle de référence avec une réduction très significative des temps de calcul.

3.2. Exemple 2

Le deuxième exemple (figure 6) est représenté par une plaque courbée renforcée par 5 raidisseurs. La structure est discrétisée par des éléments finis coques ; le modèle éléments finis comporte 12 000 ddls. Les dimensions géométriques de la plaque sont : rayon interne $R = 300$ (mm), largeur $l = 310$ (mm), longueur = 740 (mm). La hauteur de chaque raidisseur $h = 60$ (mm), $E = 2,1 \times 10^{11}$ (N/m²), $\rho = 7800$ (kg/m³). L'analyse dynamique est réalisée dans la bande fréquentielle [0-1000 Hz] comportant les 10 premiers modes globaux. On considère 2 zones de la structure complète avec 2 paramètres de conception incertains par zones (E et ρ (figure 6)).

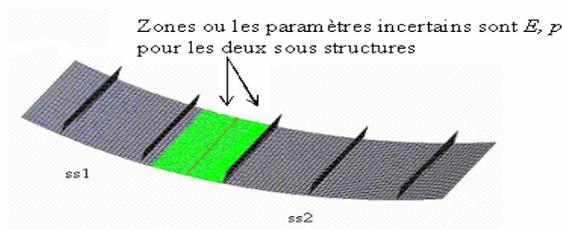


Figure 6. Structure globale divisée en 2 sous-structures. Zones des paramètres incertains

Par la méthode de condensation de Craig-Bampton enrichie (notée CBE), le modèle initial à 12 000 ddls est ramené à un modèle condensé robuste à 600 ddls.

Pour résoudre le problème d'optimisation multiobjectif robuste, les paramètres de conception (tableau 3, Optimisation) sont définis avec leurs intervalles de variations au cours de l'optimisation et les incertitudes sur les paramètres de conception sont définis grâce à un niveau de tolérance donné. Comme dans l'exemple 1, la variation de chaque paramètre est supposée gaussienne et son intervalle de tolérance est de ± 3 fois l'écart type. Ce niveau de tolérance correspond à ± 10 %.

Paramètres de conception	Sous-structure 1		Sous-structure 2	
	E	ρ	E	ρ
Optimisation				
Intervalles de variation	$\pm 70\%$	$\pm 60\%$	$\pm 70\%$	$\pm 60\%$
Niveaux de tolérance	$\pm 10\%$	$\pm 10\%$	$\pm 10\%$	$\pm 10\%$

Tableau 3. Paramètres de conception incertains (paramètres d'optimisation)

Le problème d'optimisation multiobjectif robuste consiste à optimiser deux fonctions coûts : minimiser la masse totale, maximiser la première fréquence propre. Les paramètres d'optimisation sont définis dans le tableau 3. Pour valider la méthode proposée, nous comparons les solutions optimales (Front de Pareto) issues d'un calcul exact sans condensation de modèle et les solutions optimales issues de l'optimisation utilisant la condensation enrichie.

Les paramètres de l'algorithme génétique sont : la taille de la population (50), le nombre total de générations (100), la probabilité de croisement (0.8), la probabilité de mutation (0.15). Après convergence, les fronts de Pareto optimal (sans condensation : 111 solutions, condensation de Craig-Bampton classique : 34 solutions et condensation de Craig-Bampton enrichie 110 solutions) sont présentés dans la figure 7. L'utilisation de la condensation de Craig-Bampton enrichie permet de trouver de bons résultats. Par contre, le manque d'information dû aux modifications structurales au cours de l'optimisation dans la base de Ritz classique ne permet pas de générer les bonnes solutions. Une deuxième comparaison en termes de performance est enfin effectuée (pour 100 générations, les CPU de l'optimisation exacte et de l'optimisation approchée sont respectivement : 72 heures ; 6 heures).

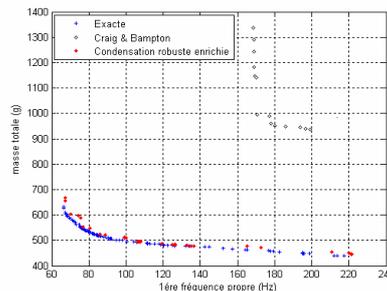


Figure 7. Fronts de Pareto optimal issus de différentes approches d'optimisation

4. Conclusions

Dans cet article nous proposons une méthodologie de conception robuste qui consiste à intégrer un modèle condensé enrichi dans un processus d'optimisation multiobjectif stochastique. Cette méthodologie permet de prendre en compte les incertitudes sur les paramètres de conception et de réduire efficacement la taille du modèle sans dégradation des solutions optimales. Cette méthode constitue une alternative intéressante pour optimiser efficacement des structures mécaniques complexes dont les modèles sont de grande taille et dont le nombre de paramètres de conception est important. Cette méthode est adaptée à la conception robuste de structure et en particulier à la conception de nouvelles architectures dans une phase d'avant-projet. Une alternative en cours d'étude consiste à coupler les méthodes de condensation et les méthodes d'approximations de réponse utilisant les surfaces de

réponse ou les réseaux de neurones. L'objectif est la réduction des temps de calcul, tout en conservant la qualité de prédiction dans la procédure d'optimisation.

5. Bibliographie

- Ait Brik B., Bouhaddi N., Cogan S., « Neural Networks and Evolutionary Algorithms For Solving Multi Objective Optimisation Problems », *Proceeding of The Fourth Int. Conf. on the Comput. Structures Eng., Civil-Comp Press*, Stirling, Scotland., 7-9 Sept. 2004.
- Balling R. J., Free J. C., « A.R Parkinson, Consideration of worst-case manufacturing tolerances in design optimization », *ASME*, 1986.
- Balmès E., Modèles expérimentaux complets et modèles analytiques réduits en dynamique des structures, Mémoire de HDR, Université P&M Curie, Paris VI, 1997.
- Bennett J. A., Lust R. V., « Conservative methods for structural optimization », *AIAA Journal* 1990.
- Bouazzouni A., Lallement G., Cogan S., « Selecting a Ritz basis for reanalysis of frequency response functions of modified structures », *Journal of sound and Vibration*, vol. 199, n° 2, 1997, p. 309-322.
- Craig RR. Jr., « A review of time-domain and frequency domain component mode synthesis method », *Int J Anal Exp Modal Anal*, 2, 1968, p. 59-72.
- Ghanem R. G., Spanos P. D., *Stochastic finite elements- A spectral approach*, Springer Verlag, 1991.
- Goldberg D. E., *Genetic Algorithms in Search, Optimization and Machine learning*, Addison Wesley, Reading, MA 1989.
- Isukapalli S. S., Uncertainty analysis of transport-transformation models, PhD dissertation, The State University of New Jersey, New Brunswick, 1999.
- Klieber M., Hien T. D., *The Stochastic Finite Element Method, Basic Perturbation Technique and Computer Implementation*, John Wiley & Sons, New York, 1992.
- Masson G., Synthèse modale robuste adaptée à l'optimisation de modèles de grande taille, Thèse de doctorat, Université de Besançon 2003.
- McKay M. D., Bechman R. J. and Conover W. J., « A Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output from a Computer Code », *Technometrics*, vol. 21, n° 2, p. 239-245, 1979.
- Soize C., « A nonparametric Model of random uncertainties for reduced matrix models in structural dynamics », *Probabilistic Engineering Mechanics*, vol. 15, (3), p. 277-294, 2000.
- Srivinas N., Deb K., Multiobjective Optimization using Non-dominated Sorting in Genetic Algorithms, Technical Report, Department of Mechanical Engineering, Institute of Technology, India, 1993.

