



HAL
open science

Élicitation Incrémentale combinée à la Recherche Heuristique pour l'Optimisation Combinatoire Multi-objectifs

Nawal Benabbou, Cassandre Leroy, Thibaut Lust

► **To cite this version:**

Nawal Benabbou, Cassandre Leroy, Thibaut Lust. Élicitation Incrémentale combinée à la Recherche Heuristique pour l'Optimisation Combinatoire Multi-objectifs. 21ème congrès annuel de la société française de recherche opérationnelle et d'aide à la décision, Feb 2020, Montpellier, France. hal-02986705

HAL Id: hal-02986705

<https://hal.science/hal-02986705>

Submitted on 3 Nov 2020

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

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

Élicitation Incrémentale combinée à la Recherche Heuristique pour l'Optimisation Combinatoire Multi-objectifs

Nawal Benabbou, Cassandre Leroy, Thibaut Lust

Sorbonne Université, CNRS, LIP6, F-75005 Paris, France, email : prénom.nom@lip6.fr

Mots-clés : *Elicitation incrémentale, recherche locale, algorithmes génétiques, voyageur de commerce.*

1 Introduction

Dans ce travail, on s'intéresse à l'élicitation de préférences sur domaine combinatoire en décision multicritère. Dans ce contexte, les solutions sont représentées par des vecteurs réels à plusieurs dimensions. Pour déterminer la valeur d'une solution il existe une riche littérature qui propose différents agrégateurs (comme la somme pondérée, la moyenne pondérée ordonnée dit OWA, ou encore l'intégrale de Choquet) selon le type de comportement que l'on veut traduire. La plupart de ces fonctions d'agrégation sont paramétrables, ce qui permet d'adapter le modèle aux préférences du décideur. On suppose ici que les paramètres permettant de représenter au mieux ses préférences ne sont pas connus. À la place, il s'agit pour nous de collecter des informations sur ses préférences pour apprendre ces paramètres, ou du moins en apprendre suffisamment pour pouvoir faire une recommandation pertinente.

L'approche classique en élicitation des préférences est d'apprendre les meilleurs paramètres possibles à l'aide d'un historique, autrement dit une base de données contenant des informations sur les préférences du décideur. Après avoir déterminé les paramètres, on résout le problème considéré à l'aide d'un algorithme de résolution avec préférences connues. Cependant, deux difficultés se posent. Tout d'abord, on sait que les agrégateurs ont une grande sensibilité à leur paramètre. C'est un problème si les bases de données ne sont pas assez grandes, ou si elles sont trop anciennes. De plus, cette approche est difficilement applicable dans le cadre de problèmes sans historique. La deuxième difficulté est que les paramètres sont très difficiles à déterminer avec précision. On poserait beaucoup de questions et, en fin de procédure, elles deviendraient délicates pour le décideur avec des solutions difficiles à comparer.

Ainsi, dans ce travail, nous ne souhaitons pas apprendre précisément les paramètres mais nous cherchons à la place à réduire suffisamment l'espace des paramètres admissibles jusqu'à trouver la meilleure solution pour le décideur (approche incrémentale [2]). L'intérêt est de poser moins de questions dans un temps d'exécution inférieur à la méthode classique. Effectivement, l'intégration de la résolution à l'apprentissage permet d'apprendre uniquement la part d'information sur les paramètres qui est utile pour résoudre le problème donné. Des travaux utilisant cette approche ont déjà été réalisés sur des problèmes combinatoires pour lesquels il existe des algorithmes de résolution efficaces dans les cas où les paramètres sont connus [1]. L'approche nouvelle que nous développons ici est l'intégration de l'apprentissage actif des paramètres à la résolution du problème par une recherche heuristique. L'approche heuristique que nous faisons nous permet de considérer des problèmes combinatoires difficiles qui n'ont pas forcément d'algorithme de résolution efficace, comme le problème du voyageur de commerce, sur lequel nous appliquons nos différentes méthodes.

2 Recherche locale et algorithmes génétiques

Ainsi, nous présentons deux algorithmes heuristiques permettant de résoudre tout problème d'optimisation combinatoire multi-objectifs, sous les conditions suivantes : la fonction de scalarisation doit être linéaire en ses paramètres (comme une somme pondérée, un OWA ou une intégrale de Choquet), et une solution (quasi-)optimale doit pouvoir être déterminée efficacement lorsque les paramètres sont connus avec précision. Nous proposons dans un premier temps une approche générale fondée sur la recherche locale et l'élicitation incrémentale de préférences, nommée ILS (Interactive Local Search). Une phase d'initialisation est utilisée pour générer rapidement une solution de départ prometteuse. Dans une deuxième phase, nous posons des questions entre les solutions voisines, générées par une fonction de voisinage. Cette méthode ne comporte aucune garantie sur le nombre de questions, la qualité de la solution ou le temps d'exécution mais devant ces résultats encourageants, nous proposons une autre méthode heuristique interactive, utilisant cette fois-ci l'approche génétique, nommée IGA (Interactive Genetic Algorithm). En effet, l'approche génétique permet de bénéficier du voisinage de plusieurs solutions contrairement à la recherche locale où nous ne travaillons qu'avec le voisinage d'une seule solution. On commence par évaluer et sélectionner les meilleures solutions d'une population initiale générée aléatoirement. Puis, à partir de ces dernières solutions, on crée de nouvelles solutions par croisements et mutations. On obtient ensuite une nouvelle population par sélection, en posant des questions au décideur. Puis, on itère ces étapes dans le but de simuler le principe de l'évolution. On peut interrompre le processus après un nombre arbitraire d'itérations, après l'identification d'une solution de qualité satisfaisante, ou encore après un temps imparti. Cette approche nous permet d'avoir une garantie polynomiale sur le temps de calcul et le nombre de questions.

3 Résultats obtenus

Dans le but de démontrer l'efficacité de nos algorithmes, nous les avons testés sur des instances du voyageur de commerce multi-objectifs, avec une somme pondérée et un OWA. Les instances sont de 50 ou 300 villes et varient entre 3 et 7 critères. Nos algorithmes sont évalués selon leur temps d'exécution, le nombre de questions posées et l'écart à l'optimum. Ces tests nous ont permis d'observer qu'IGA possède de meilleures performances globales qu'ILS. Par exemple, pour 50 villes et 6 critères, la recherche locale pose 32.2 questions en 36.2s avec une précision de 1.8% contre 18.7 questions en 21.2s avec 0.9% de précision pour notre algorithme génétique. Ainsi, IGA nous permet d'étendre nos tests sur 300 villes pour obtenir, par exemple pour 6 critères, 20.0 questions en 181.8s avec un pourcentage d'erreur à l'optimal de 2.0%.

Remerciements

Ces travaux ont bénéficié du soutien du programme PGM0 de la FMJH et du soutien de EDF, Thales, Orange.

Références

- [1] N. Benabbou. *Procédures de décision par élicitation incrémentale de préférences en optimisation multicritère, multi-agents et dans l'incertain*. PhD thesis, 2017.
- [2] C. Boutilier, R. Patrascu, P. Poupart, and D. Schuurmans. Constraint-based optimization and utility elicitation using the minimax decision criterion. *Artificial Intelligence*, 170(8-9) :686–713, 2006.