

Exploration de l'espace de conception des processeurs par optimisation bayésienne

Vincent Fu¹, Lilia Zaourar¹, Alix Munier-Kordon²

¹ *Université Paris-Saclay, CEA, List, F-91120, Palaiseau, France*
{vincent.fu, lilia.zaourar}@cea.fr

² *Sorbonne Université, CNRS, LIP6, F-75005, Paris, France*
alix.munier@lip6.fr

Mots-clés : *conception de processeurs, optimisation de fonctions objectifs sous boîtes noires, optimisation bayésienne, surrogate models.*

1 Optimisation matérielle pour les systèmes computationnels

Le développement grandissant des processeurs de Calcul Haute Performance (HPC) et des accélérateurs d'Intelligence Artificielle (IA) répond à un enjeu majeur dans les décennies à venir. Afin de satisfaire les besoins de calculs importants, les architectures matérielles deviennent de plus en plus complexes. Leur optimisation mène à des problèmes d'explosion combinatoire à large échelle. Le concepteur doit fixer les valeurs des paramètres matériels tels que le nombre de coeurs, de clusters, les tailles mémoires ou encore le type de réseau d'interconnexion. La difficulté réside dans la recherche d'architectures présentant les meilleures performances en terme de temps d'exécution, de consommation énergétique et de surface.

En pratique, l'évaluation de ces métriques pour une architecture et un *benchmark* fixés est obtenue par une simulation coûteuse en temps. Une énumération exhaustive de l'espace des solutions n'est pas envisageable en raison de l'explosion combinatoire du nombre d'architectures et de son évaluation. L'exploration de l'espace de conception des architectures se résume alors à un problème d'optimisation multiobjectif avec un nombre très limité d'évaluations de fonctions objectifs sous boîtes noires. Notre objectif est de proposer des stratégies d'exploration pour la conception des architectures à large échelle.

2 Automatisation de l'exploration de l'espace de conception

Plusieurs algorithmes d'exploration [5] ont été proposés dans l'état de l'art. Ces derniers peuvent être classés en deux familles : les approches *model-free* et *model-based*. Les méthodes *model-free* dont la recherche locale et les algorithmes génétiques, sont scalables en grande dimension mais souffrent d'un nombre d'évaluations de fonctions objectifs élevé. Ce défaut rend ces approches inefficaces pour la conception des architectures matérielles à combinatoire élevée. Une unique simulation peut durer jusqu'à quatorze heures [1].

À l'inverse, les méthodes *model-based* se basent sur des modèles d'interpolation (*surrogate models*) capables de décrire la structure de l'espace des objectifs. Les modèles d'interpolation sont utiles pour guider efficacement la recherche et sont remis à jour à chaque évaluation de fonction objectif sous un processus d'apprentissage active.

2.1 Optimisation bayésienne : une approche efficace d'apprentissage active

L'optimisation bayésienne [2, 1] est une approche *model-based* qui a fait ses preuves dans l'optimisation d'hyperparamètres (pour le *machine learning*) et des fonctions coûteuses sous boîtes noires. Ses performances s'expliquent autour de la résolution de trois sous-problèmes :

- a) **Les solutions initiales pour l'initialisation du modèle d'interpolation** : le choix des solutions initiales dans une approche classique est généralement un choix aléatoire. Des méthodes d'échantillonnage [2] d'optimisation de couverture d'espace ou de variance prédictive ont cependant été proposées parmi les meilleurs variantes de l'optimisation bayésienne. Ces méthodes d'échantillonnage améliorent l'algorithme en captant des informations diversifiées dans l'espace de recherche.
- b) **Le choix du modèle d'interpolation** : la qualité d'approximation du modèle d'interpolation est centrale à la performance de l'optimisation bayésienne. Or, il n'existe pas de modèle adapté pour résoudre tous les problèmes. Certains modèles [3] tels que les processus gaussiens sont efficaces pour caractériser la non-linéarité en faible dimension. En revanche, les fonctions à base radiale le sont moins mais sont plus scalables en large dimension. Ainsi, Les performances des modèles diffèrent selon le problème étudié.
- c) **La définition du fonction d'acquisition** : la solution à évaluer à l'itération suivante est déterminée par l'optimum de la fonction d'acquisition. Cette fonction est définie par l'espérance et la variance du modèle d'interpolation. Elle permet de caractériser une mesure de compromis entre l'exploitation et l'exploration. *Expected Improvement (EI)*, *Probability of Improvement (PI)* et *Upper Confidence Bound (UCB)* sont des exemples de fonctions d'acquisitions monobjectifs [2].

3 Solution proposée et perspectives

Une première implémentation d'exploration automatisée pour la conception des processeurs a été effectuée à partir d'un solveur existant [4]. Ce dernier utilise un modèle d'interpolation à forêt aléatoire et une scalarisation randomisée à norme de Tchebyshev pour une optimisation bayésienne multiojectif. Nous avons observé que l'optimisation bayésienne retourne un front de Pareto aussi performant qu'un algorithme génétique [6] en utilisant deux à cinq fois moins d'évaluations.

Des travaux sont en cours pour proposer notre propre algorithme à optimisation bayésienne et visent trois perspectives de recherche : une hybridation des méthodes d'échantillonnage, un modèle d'interpolation pondéré adaptatif ainsi qu'une fonction d'acquisition multiple à hypervolume.

Références

- [1] Chen BAI et al. "BOOM-Explorer : RISC-V BOOM Microarchitecture Design Space Exploration Framework". In : *2021 IEEE/ACM International Conference On Computer Aided Design (ICCAD)*. 2021.
- [2] Sourav DAS et Solomon TEFAMARIAM. *State-of-the-Art Review of Design of Experiments for Physics-Informed Deep Learning*. 2022.
- [3] Ping JIANG, Qi ZHOU et Xinyu SHAO. *Surrogate Model-Based Engineering Design and Optimization*. Springer Tracts in Mechanical Engineering. 2020.
- [4] Luigi NARDI et al. "HyperMapper : a Practical Design Space Exploration Framework". In : *2019 IEEE 27th International Symposium on Modeling, Analysis, and Simulation of Computer and Telecommunication Systems (MASCOTS)*. 2019.
- [5] Jacopo PANERATI, Donatella SCIUTO et Giovanni BELTRAME. "Optimization Strategies in Design Space Exploration". In : *Handbook of Hardware/Software Codesign*. 2017.
- [6] Lilia ZAOURAR, Alice CHILLET et Jean-Marc PHILIPPE. "A-DECA : an Automated Design space Exploration approach for Computing Architectures to develop efficient high-performance many core processors". In : 2023.