



HAL
open science

Évaluation de la consommation d'énergie nécessaire à l'exécution d'un workload dans un datacenter vert

Louis-Claude Canon, Damien Landré, Laurent Philippe, Jean-Marc Pierson

► To cite this version:

Louis-Claude Canon, Damien Landré, Laurent Philippe, Jean-Marc Pierson. Évaluation de la consommation d'énergie nécessaire à l'exécution d'un workload dans un datacenter vert. 24ème Congrès annuel de l'association française de Recherche Opérationnelle et d'Aide à la Décision (ROADEF 2023), Association Française de Recherche Opérationnelle et d'Aide à la Décision, Feb 2023, Rennes, France. hal-04257320

HAL Id: hal-04257320

<https://hal.science/hal-04257320>

Submitted on 25 Oct 2023

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.

Evaluation de la consommation d'énergie nécessaire à l'exécution d'un workload dans un datacenter vert

Louis-Claude Canon¹, Damien Landré^{1,2}, Laurent Philippe¹, Jean-Marc Pierson²

¹ Institut FEMTO-ST, département DISC, France

{lccanon,lphilipp,damien.landre}@femto-st.fr

² Institut de Recherche en Informatique de Toulouse, France

{damien.landre,jean-marc.pierson}@irit.fr

Mots-clés : *datacenter, énergies renouvelables, workload, prévision, programme linéaire*

1 Introduction

Les datacenters représentaient, en 2018, 1% de la consommation énergétique globale, soit 6% de plus qu'en 2010 selon Masanet et al. [2], et on estime que ce chiffre est en augmentation [1]. Pour cette raison, l'objectif des projets ANR DATAZERO [3] (2015-2019) puis DATAZERO 2 (2020-2024) est de concevoir un datacenter autonome fonctionnant uniquement aux énergies renouvelables. La production d'énergie étant variable et locale, celle-ci est couplée à des sources de stockage. Le stockage permet d'anticiper les variations de demande en énergie nécessaire au traitement de la charge IT. Une négociation sur la prévision de la gestion de l'énergie est mise en place afin de concilier la prévision d'offre et de demande en énergie du datacenter. Elle se fait au moyen d'échanges de profils de puissance entre la gestion de la partie électrique du datacenter et celle de la partie IT. Ce travail s'intéresse au calcul d'un profil de puissance pour la demande en énergie, à venir et à négocier, des serveurs de la partie IT. Cette demande est basée sur une prévision de workload. Le but est de minimiser la demande électrique en vue de traiter un workload à venir sous la contrainte d'une qualité de service.

2 Objectif

Nous supposons que la prévision de workload et les caractéristiques des serveurs sont connus. Le workload est composé de différentes parts, soumises à des deadlines. La contrainte de qualité de service impose de limiter le nombre de deadlines violées. Le workload est considéré comme flexible : le traitement des parts du workload peut être repoussé selon leur deadline. Pour traiter ces parts de workload, il est nécessaire de les ordonnancer sur des serveurs. Dans un environnement hétérogène, la difficulté du problème réside dans le choix des serveurs à allumer et de leur état DVFS (Dynamic voltage and frequency scaling). La configuration des serveurs est le résultat de ces choix. Elle définit la puissance de calcul totale des serveurs et leur consommation électrique. Nous cherchons une configuration qui minimise cette consommation tout en traitant le workload et en respectant la contrainte du nombre de deadline violées.

La figure (1) donne un exemple de workload flexible (dont certaines parts du workload ont été repoussées selon leur deadline) que l'on souhaite traiter, en allumant des serveurs hétérogènes, ayant une puissance de calcul suffisante et qui consomme le moins possible. Plusieurs configurations de serveurs sont possibles mais toutes consomment différemment et ne respectent pas nécessairement la contrainte de qualité de service. Une configuration de serveurs ne respectant pas la qualité de service peut consommer plus qu'une configuration la respectant si les serveurs ont été mal choisis.

L'objectif est de proposer une valeur de puissance minimisant la demande en énergie, sur une fenêtre de temps, en vue de proposer un profil de puissance (composé de plusieurs valeurs de puissance) à la négociation.




FIG. 1 – Prévision de workload en fonction du temps. Différentes configurations de serveurs sont montrées pour traiter le workload. Toutes produisent et consomment différemment. Seules certaines (vertes) respectent la contrainte de qualité de service après utilisation de la flexibilité du workload. Parmi elles, il est préférable de retenir la configuration la moins énergivore.

3 Résultats

Nous proposons un algorithme dichotomique cherchant une puissance optimale. Celle-ci permet d'allumer des serveurs disposant d'une puissance de calcul suffisante pour traiter un workload flexible en respectant la qualité de service. Ainsi, à chaque itération, une puissance est fixée, puis l'algorithme maximise la puissance de calcul en cherchant la configuration des serveurs optimale ne dépassant pas la puissance fixée. Il ordonnance ensuite la charge sur les serveurs. Si la contrainte de qualité de service est respectée, alors la puissance est diminuée, afin de trouver une configuration des serveurs moins puissante mais moins énergivore. Elle est augmentée sinon. La maximisation de la puissance de calcul pour une puissance électrique donnée peut être faite par un programme linéaire, mais avec un temps de calcul important. Nous proposons également des heuristiques, moins précises, mais beaucoup plus rapides car l'objectif est de pouvoir négocier un profil de puissance rapidement. La politique d'ordonnancement utilisée est un Earliest Deadline First. Quatre heuristiques sont proposées afin de répondre au problème de maximisation de la puissance de calcul. Une heuristique triviale consiste à allumer aléatoirement les serveurs, mais l'écart moyen α à la solution optimale est de 33.6%. Une deuxième heuristique est de classer les serveurs selon deux métriques et d'allumer les plus performants (α de 0.2%). Deux autres heuristiques allument les serveurs dans l'état DVFS ayant les meilleures performances. S'il reste de la puissance, alors elle est réattribuer aux serveurs allumés. La différence entre ces deux heuristiques est que la suivante examine des configurations avec moins de serveurs (α de 2.3% et 0.2% respectivement).

Références

- [1] F. Bordage. The environmental footprint of the digital world. *GreenIT*, page 20, 2019.
- [2] E. Masanet, A. Shehabi, N. Lei, S. Smith, and J. Koomey. Recalibrating global data center energy-use estimates. *Science*, 367(6481) :984–986, 2020.
- [3] J.-M. Pierson, G. Baudic, S. Caux, B. Celik, G. Da Costa, L. Grange, M. Haddad, J. Le-cuivre, J.-M. Nicod, L. Philippe, V. Rehn-Sonigo, R. Roche, G. Rostirolla, A. Sayah, P. Stolf, M.-T. Thi, and C. Varnier. Datazero : Datacenter with zero emission and robust management using renewable energy. *IEEE Access*, 7 :103209–103230, 2019.