



HAL
open science

Négociation multiobjectif de profils de puissance de centre de données alimenté par énergies renouvelables sur site

Léo Grange, Patricia Stolf, Georges da Costa, Paul Renaud-Goud

► To cite this version:

Léo Grange, Patricia Stolf, Georges da Costa, Paul Renaud-Goud. Négociation multiobjectif de profils de puissance de centre de données alimenté par énergies renouvelables sur site. Conférence d'informatique en Parallélisme, Architecture et Système, Jul 2018, Toulouse, France. hal-01809188

HAL Id: hal-01809188

<https://hal.science/hal-01809188v1>

Submitted on 6 Jun 2018

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.

Négociation multiobjectif de profils de puissance de centre de données alimenté par énergies renouvelables sur site

Léo Grange, Patricia Stolf, Georges Da Costa, Paul Renaud-Goud

IRIT, Université de Toulouse, 118 Route de Narbonne, 31062 Toulouse Cedex 9, France
{leo.grange, stolf, dacosta, paul.renaud.goud}@irit.fr

Résumé

Afin de réduire leur impact écologique et permettre leur construction dans des zones ayant un réseau électrique peu fiable, la conception de centres de données alimentés par des sources d'énergies renouvelables (EnR) sur site est étudiée depuis quelques années. Le principal obstacle est lié au caractère intermittent des EnR, nécessitant le stockage de l'excès de production et la planification de la consommation pour optimiser l'utilisation de cette énergie. Nous proposons l'abstraction d'un tel centre de données en deux systèmes indépendants : un producteur gère l'infrastructure électrique et un consommateur est lié à l'utilisation des serveurs. Un module de négociation coordonne ces deux systèmes. Les objectifs de chaque système étant différents, nous proposons une approche multiobjectif, basée sur l'algorithme génétique SPEA2. Les calculs de planification des infrastructures électriques et informatiques étant coûteux, nous avons mis en place et évalué un système d'estimation de la qualité des planifications.

Mots-clés : centre de données, négociation, multiobjectif, énergies renouvelables

1. Introduction

L'impact écologique est au cœur des préoccupations actuelles concernant les technologies informatiques. Les centres de données prenant de l'ampleur via l'utilisation toujours plus importante de plateformes en ligne et l'usage croissant du *cloud computing* font l'objet depuis plusieurs années de travaux visant à réduire leur consommation énergétique. Le risque d'augmentation du prix des énergies fossiles et la réduction du coût des sources d'énergies renouvelables (EnR) ces dernières années [9] participent également à l'intérêt scientifique et industriel de l'utilisation d'EnR dans les infrastructures informatiques [13, 18].

Tous les travaux étudiant l'intégration d'EnR dans les centres de données cherchent à répondre au caractère intermittent des EnR. Une partie exploite l'idée de distribution géographique de centres de données, afin de faire varier la charge de chaque emplacement suivant la production locale [15, 17]. D'autres approches, se focalisant sur un seul centre de données disposant d'EnR sur site, cherchent à rapprocher la consommation au cours du temps de la production renouvelable [11, 19, 20].

Dans la continuité de nos travaux précédents [12], l'approche proposée correspond à la seconde catégorie et se distingue des approches existantes en séparant la gestion de l'infrastructure électrique de celle des ressources informatiques, chacune étant perçue comme une *boîte noire*. Le but est d'obtenir, avec un minimum de sollicitations des systèmes de décision des infrastructures électrique et informatique, un ensemble de solutions représentant les meilleurs compromis entre la qualité de service et l'impact environnemental au cours d'une période de temps à venir.

Une description de l'infrastructure considérée et du problème sont présentés en section 2. Le cœur de notre approche est décrit en section 3, la méthodologie utilisée pour valider notre approche en section 4, les résultats en section 5. Enfin, conclusion et perspectives sont en section 6.

2. Négociation de profils de puissance

Le modèle de centre de données considéré au long article est composé de trois entités :

- **PDM** (Power Decision Module) : la boîte noire de gestion de l'infrastructure électrique (sources renouvelables, éléments de stockage, connexion au réseau électrique)
- **ITDM** (IT Decision Module) : la boîte noire de gestion de l'infrastructure informatique (contrôle de l'état d'alimentation des serveurs, placement des tâches)
- le module de négociation, servant d'intermédiaire entre les deux modules de décision en cherchant des compromis de production et de consommation

À partir de ses informations internes (prévision météorologiques ou état des batteries pour le PDM), le module est capable d'évaluer des scénarios de production (PDM) ou de consommation (ITDM) d'électricité au cours d'une prochaine fenêtre temporelle. Ces scénarios sont représentés sous forme de *profils de puissance* (série temporelle représentant la puissance électrique moyenne à chaque pas de temps). Un module de décision est modélisé comme une fonction associant une utilité à un profil de puissance, $f : \mathbb{R}^T \rightarrow \mathbb{R}$, avec T le nombre de pas de temps de la fenêtre.

L'évaluation d'un profil de puissance par un module de décision permet à ce dernier d'y associer une valeur d'*utilité* représentant son intérêt propre pour le profil donné indépendamment des considérations de l'autre module de décision. La méthode de calcul de cette valeur d'utilité est inconnue pour les autres entités. La complexité des infrastructures électriques et informatiques, ainsi que des techniques d'optimisations telles que l'ordonnancement de tâches rend cependant coûteux en temps et en puissance de calcul l'évaluation de l'utilité d'un profil par les modules de décision. Le problème du choix d'un profil de puissance à suivre durant la prochaine fenêtre temporelle est un problème multiobjectif. La plupart des travaux étudient sa réduction en un problème mono-objectif (somme pondérée d'objectifs, optimisation d'un objectif sous contrainte...). Au contraire, l'approche présentée ici se focalise sur l'obtention d'un ensemble de compromis possibles, au sens d'approximation du *front de Pareto* et conserve ainsi la dimension multiobjectif.

Le module de négociation fait le lien entre les deux boîtes noires (ITDM et PDM) pour trouver des profils de puissance électrique ayant de bonnes utilités des deux cotés. Son but est d'être en mesure d'obtenir une approximation du front de Pareto de bonne qualité en limitant les évaluations coûteuses. SPEA2 [25], un algorithme génétique multiobjectif connu de la littérature [8, 24] a été choisi comme base du module de négociation. L'obtention des objectifs d'un individu est effectuée en demandant aux modules de décision d'évaluer l'utilité du profil de puissance qu'il encode.

3. Approximation des fonctions d'utilité

3.1. Approximation par transformée de Haar multirésolution

L'évaluation coûteuse des individus est un problème commun des algorithmes évolutionnistes appliqués à des problèmes réels. L'une des stratégies étudiées pour réduire le coût total est l'utilisation d'une approximation rapide [4, 16] de la fonction objectif cible, qui peut être obtenue via une régression de la fonction réelle par exemple. Cette dernière n'est alors utilisée que lorsque l'approximation d'un individu permet d'espérer un bon résultat.

Dans le cadre du problème présenté ici, on cherche une approximation d'une fonction *boîte noire* inconnue a priori. L'approximation doit donc être faite en ligne, au fur et à mesure que

des profils de puissance sont évalués. Un profil de puissance est défini dans un espace à grande dimension (\mathbb{R}^T), mais est aussi une *série temporelle*. Bien que certains travaux se concentrent sur l'approximation de fonctions définies dans des espaces à grande dimensions [21], aucun à notre connaissance n'adresse le cas particulier de fonctions définies pour des séries temporelles.

Nous proposons une nouvelle méthode d'approximation adaptée au cas de l'évaluation de série temporelles, basée sur la transformation en ondelettes de Haar [22]. Les transformations en ondelettes sont utilisées dans l'analyse de séries temporelles, pour du calcul de similarité, de partitionnement ou d'indexation [2, 5].

La transformation d'une série de $N = 2^k$ valeurs en ondelettes de Haar permet d'obtenir une nouvelle série de même taille représentant les coefficients de l'ondelette pour différentes fréquences et décalages. Ces coefficients peuvent également être groupés par *séquence* [22], chaque séquence contenant les coefficients pour une fréquence donnée. On obtient alors $k + 1$ groupes H_0, \dots, H_k . Le premier, H_0 , contient un seul élément donnant une information sur la moyenne de la série d'origine. La taille des autres séquences H_i (avec $i \in [1, k]$) est donnée par $|H_i| = 2^{i-1}$. Chaque séquence H_i contient des informations sur la série d'origine avec une précision temporelle deux fois plus importante que la séquence H_{i-1} .

Soit X, Y deux profils de taille $N = 2^k$. On note $HC_i(X)$ la concaténation des séquences H_0, \dots, H_i de la transformée de Haar de X et $hdist_i(X, Y)$ la distance euclidienne entre $HC_i(X)$ et $HC_i(Y)$. La transformation conserve les distances euclidiennes ($dist(X, Y) = hdist_k(X, Y)$) [6], et une distance partielle donne une borne inférieure de la distance réelle ($dist(X, Y) \geq hdist_i(X, Y)$).

L'approche que nous proposons utilise ces propriétés pour approximer l'utilité d'un nouveau profil à partir des profils les plus proches dont l'utilité est connue (l'ensemble des solutions évaluées via les modules de décision depuis le début de l'optimisation). Les profils connus sont progressivement filtrés en fonction de leur distance $hdist_i$ avec le profil cible, en incrémentant i . Seuls ceux dont la distance est inférieure à une valeur r fixée sont conservés pour l'itération suivante. Le processus s'arrête pour la dernière valeur de i pour laquelle plus de θ profils sont conservés. L'utilité du profil cible est approximée via la moyenne des utilités associées aux profils proches, pondérée par leur proximité avec la cible ($r - hdist_i(target, p)$). Si aucun profil n'est proche, l'approximation est considérée comme impossible à effectuer avec les données connues et aucune valeur n'est retournée.

Le raffinement de l'ensemble des profils connus pris en compte est effectué d'abord à partir des caractéristiques liées aux fréquences les plus basses, avant de considérer les variations de fréquences de plus en plus élevées. Ainsi, cette approche fournit une approximation grossière avec très peu de profils connus et améliore la précision des approximations avec de nombreux profils similaires connus.

3.2. Adaptation de SPEA2 pour l'approximation

L'intégration initiale de l'approximation d'utilité dans l'algorithme génétique SPEA2 a été réalisée de manière naïve, en utilisant une notion de *durée de vie* d'une approximation. Lorsqu'un nouvel individu doit être évalué pour chacun des objectifs, l'évaluation est substituée par la fonction d'approximation. Dans ce cas, la durée de vie de l'approximation est fixée à une valeur initiale lf_{init} . Si la fonction d'approximation échoue, la valeur réelle est obtenue par interrogation directe du module de décision (évaluation). À chaque fois qu'une évaluation est effectuée, le profil évalué est ajouté aux solutions connues de la fonction d'approximation, associé à sa valeur d'utilité réelle. Au début de chaque génération, la durée de vie est décrémentée pour tous les individus. Si cette dernière atteint 0, les valeurs des objectifs sont évaluées par les modules de décision.

Bien que fonctionnelle, cette intégration initiale introduit deux nouvelles faiblesses dans SPEA2

tel que présenté par Zitzler et al. [25] : 1) certaines solutions de bonnes qualités et dont les utilités ont été évaluées peuvent être éliminées par des solutions approximées semblant meilleures mais en réalité mauvaises; 2) lorsque la condition d'arrêt est atteinte, l'algorithme ne peut pas garantir le nombre de solutions obtenues après retrait des solutions approximées. Ainsi, nous proposons une version modifiée de l'algorithme génétique nommée USPEA2 (pour *Uncertain Strength Pareto Evolutionary Algorithm*) utilisant une seconde archive d'individus, de taille identique à celle de l'algorithme original. Cette *archive certaine* ne peut contenir que des solutions évaluées. À la fin de chaque génération, les solutions certaines de la nouvelle descendance et des deux archives sont évalués par l'algorithme de sélection de SPEA2 et le résultat est assigné à l'archive certaine pour la prochaine génération. Les individus des deux archives sont utilisées à la fois dans le processus de sélection de l'archive standard et dans le processus de création de la descendance (après suppression d'éventuels individus dupliqués).

4. Méthodologie et validation

4.1. Modèle simplifié

La validation de la méthode d'approximation et les modifications apportées à SPEA2 est réalisée grâce à un modèle simplifié de centre de données alimenté avec des EnR visant à reproduire les caractéristiques principales d'un modèle plus complexe de centre de données et permettre le calcul des solutions optimales en un temps raisonnable afin de s'y comparer.

L'ensemble du modèle décrit le centre de données et ses sources électriques pour une fenêtre de T pas de temps d'une durée δ chacun. Les modules de décision sont implémentés en calculant, pour un profil de puissance donné, une répartition des ressources informatiques (ITDM) ou électriques (PDM) respectant ce profil et maximisant leurs utilités respectives.

L'**infrastructure informatique** est modélisée par un ensemble de M machines identiques, consommant $p_{machine}$ chacune en activité et considérées éteintes si inutilisées. La charge de travail est une charge *fluide*, pouvant être répartie au long de la fenêtre temporelle. L'unité minimale d'exécution consiste en une machine entière durant un pas de temps. Sa masse totale W est exprimée en temps nécessaire pour son exécution sur une unique machine. En plus de ces tâches, un nombre arbitraire de tâches supplémentaires de faible priorité peuvent être exécutées sans bénéfice, afin d'absorber un pic de production.

Pour un placement de tâches donné, l'utilité, correspondant à une mesure de qualité de service, dépend principalement de la masse de la charge principale exécutée dans la fenêtre. Un supplément est attribué pour l'exécution précoce de tâches. En notant w_t le nombre de tâches exécutées durant le pas t , l'utilité de l'ITDM est donnée par : $u_{itdm} = \sum_{t=0}^{T-1} qos_{done} \delta \cdot w_t + qos_{early} \frac{(T-1-t)w_t}{(T-1)\delta}$

L'**infrastructure électrique** est composée de sources renouvelables, de batteries et d'une connexion au réseau électrique permettant l'achat et la vente d'énergie. L'utilité de la partie électrique correspond à l'émission de gaz à effet de serre (GES) nécessaire pour fournir un profil de puissance donné, calculée en équivalent CO_2 . La prédiction de production de l'ensemble des sources renouvelables pour un moment t dans la fenêtre est donnée par r_t . L'infrastructure étant supposée déjà construite, l'utilisation de tout ou partie de l'énergie renouvelable disponible ne cause pas l'émission supplémentaire de GES et n'impacte donc pas l'utilité d'un profil.

Les batteries sont caractérisées par une capacité maximale bat_{max} et une charge initiale bat_{init} . Leur charge, à tout temps t est donné par c_t . L'utilisation des batteries provoque un vieillissement prématuré, nécessitant un remplacement à terme et donc une émission de GES pour la fabrication de nouvelles batteries. Un coût de vieillissement, ghg_{aging} , est pris en compte à chaque utilisation (charge ou décharge). Au contraire, toute énergie stockée dans la batterie en

fin de fenêtre est considérée comme un gain potentiel, correspondant à l'émission de GES qui résulterait de son achat une fois le vieillissement lié à la décharge nécessaire pris en compte.

L'utilisation du réseau électrique à chaque pas de temps est noté gs_t pour la vente et gb_t pour l'achat. L'achat d'énergie sur le réseau engendre également une émission de GES dépendant de l'origine de l'énergie. Dans ce modèle, seul une moyenne d'émission de GES par kilowatt-heure est considérée, notée ghg_{buy} . La revente sur le réseau permet, à condition d'être consommée par un autre acteur, de réduire d'autant l'émission de GES. Afin de prendre en compte les pertes et l'éventuelle non-consommation de l'énergie vendue, un gain moindre sera considéré par rapport à l'achat, et noté ghg_{sell} .

Pour une utilisation des sources d'énergie données, l'utilité du PDM est finalement donnée par : $u_{pdm} = \sum_{t=0}^{T-1} \delta(ghg_{sell} \cdot gs_t - ghg_{buy} \cdot gb_t) - ghg_{aging} |c_{t+1} - c_t| + (ghg_{buy} - ghg_{aging})c_T$

4.2. Protocole expérimental

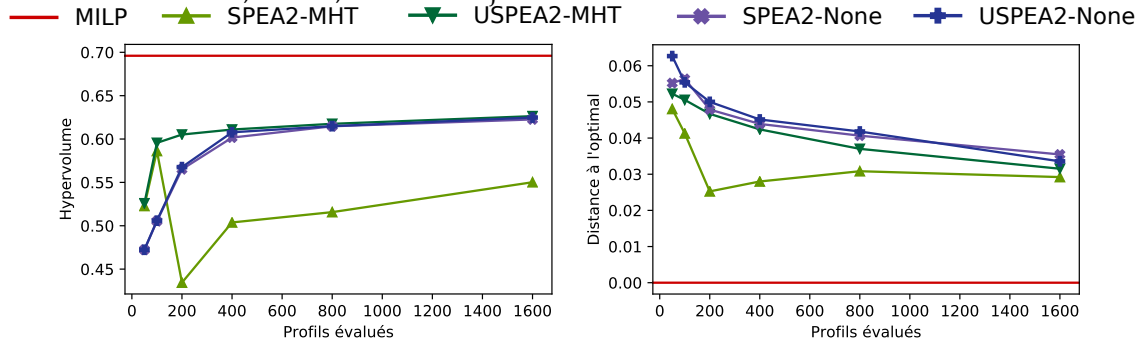
L'approche est évaluée avec 3 scénarios différents, chacun couvrant une fenêtre de 72 heures commençant à minuit. Chaque scénario correspond à une production renouvelable et un niveau de batterie initial différent. Plusieurs nombres de pas de temps (T), ont été étudiés. La durée d'un pas de temps est $\delta = 72/T$. La production renouvelable est issue des données fournies par le NREL pour des panneaux photovoltaïques installés en Californie, dimensionnés pour fournir en moyenne sur l'année 75% de la puissance maximale du centre de données. Le premier scénario, *ExcessRenew*, correspond à la production pour 3 jours de beau temps en Juin, avec des batteries chargées initialement à 50% de leur capacité maximale. Le second, *Normal*, correspond à des jours de mi-Juin moins favorables et le même niveau de batteries. Le dernier, *FewRenew* couvre 2 jours de quasi-absence de soleil suivis d'un jour nuageux de Janvier, avec des batteries chargées seulement à 25% de leur capacité.

Quelque soit le scénario, la charge de travail nécessite 75% de la capacité de calcul dans la fenêtre. La capacité maximale de la batterie bat_{max} permet l'alimentation complète des machines pendant 12 heures. Le calcul de l'émission de GES pour la consommation sur le réseau électrique se base sur les chiffres fournis par l'agence de protection de l'environnement de Californie pour l'année 2014 [1], soit $ghg_{buy} = 0.3$ kg CO₂-eq/kWh. Le gain de revente est fixé à la moitié, $ghg_{sell} = 0.15$ kg CO₂-eq/kWh. Le coût de vieillissement des batteries est obtenu en se basant sur l'étude de Hao et al. [14] pour une technologie LMO. Avec une durée de vie de 1000 cycles charge/décharge [7, 10, 23], on obtient un coût de $ghg_{aging} = 0.0483$ kg CO₂-eq/kWh.

L'infrastructure informatique est composée de $M = 6$ machines, consommant $p_{machine} = 1$ kW h. La mesure de qualité de service est paramétrée par $qos_{done} = 1$ et $qos_{early} = 0.2$.

La méthode d'approximation décrite en section 3.1 est paramétrée avec une valeur de proximité $r = 1$ et un nombre minimal de solutions proches $\theta = 4$. L'algorithme USPEA2 est configuré pour utiliser une durée de vie des approximations $lf_{init} = 4$. Pour SPEA2 et USPEA2, la taille des archives est fixée à 20 individus et la probabilité de mutation à 50%. Les algorithmes génétiques ont pour condition d'arrêt l'atteinte d'un nombre n_{eval} fixé d'évaluation de profils cumulé par les modules de décision. Enfin, la population est initialisée avec un profil maximisant l'utilité de chaque module de décision, complétée par 18 individus aléatoires (distribution uniforme pour chaque pas de temps).

Pour chacun des scénarios, les algorithmes SPEA2 et USPEA2 ont été évalués, soit sans approximation (variantes *None*) soit avec la méthode par transformée de Haar multirésolution (variante *MHT*). Trois valeurs de T sont étudiées : 20, 80 et 320 pas de temps. Le nombre d'évaluations à atteindre est fixé successivement à 50, 100, 200, 400, 800 et 1600 évaluations. Chaque valeur produite dans la section 5 est la moyenne de 10 exécutions.



(a) Hypervolume normalisé.

(b) Distance moyenne au front de Pareto.


FIGURE 1 – Résultats des heuristiques en fonction du nombre d'évaluations autorisées.

En plus des différentes heuristiques, une formulation MILP de l'ensemble du modèle est utilisée pour obtenir une construction précise du front de Pareto réel.

La comparaison des différentes méthodes est effectuée via deux métriques : l'hypervolume et la distance moyenne des solutions au front de Pareto obtenu par MILP. L'hypervolume représente, dans le cas d'un problème de maximisation à 2 dimensions, la surface entre les solutions Pareto-optimales obtenues et un point de référence arbitraire considéré comme une borne inférieure [3]. Le point de référence utilisé ici consiste, pour chaque objectif, en la valeur minimale obtenue par l'ensemble des méthodes pour un scénario et un nombre de pas de temps donnés. Enfin, pour faciliter la comparaison de différents scénarios, l'hypervolume et la distance au front de Pareto sont calculés après normalisation de chaque objectif entre 0 (point de référence) et 1 (valeur maximale obtenue).

5. Résultats

Les résultats obtenus par les différentes méthodes, pour 80 pas de temps et avec le scénario *Normal* sont donnés dans la figure 1. La variante USPEA2-MHT donne de bons résultats en terme d'hypervolume pour un nombre faible d'évaluations (moins de 400) comparé à SPEA2 ou USPEA2 sans approximation. On constate que, à l'exception de SPEA2-None, toutes les heuristiques convergent rapidement vers une même valeur d'hypervolume, sensiblement distante de l'optimal. La variante SPEA2-MHT subit les problèmes indiqués en section 3.2, engendrant un hypervolume dégradé à partir de 200 évaluations, probablement à cause de la perte de bonnes solutions. Au contraire, la distance au front de Pareto, détaillée par la figure 1b, est nettement meilleure. Une explication possible est que les solutions perdues de cette manière tendent à être dans des espaces plus difficiles à améliorer, tendant donc à conserver uniquement quelques très bonnes solutions évaluées. Les autres heuristiques donnent des résultats



(a) T = 20 pas de temps

(b) T = 80 pas de temps.

(c) T = 320 pas de temps.

FIGURE 2 – Comparaison de l'hypervolume obtenu après 100 évaluations.

sensiblement identiques, s'améliorant lentement avec le nombre d'évaluations.

Les résultats présentés en figure 2 se focalisent sur un faible nombre d'évaluations (100) afin d'évaluer les performances des heuristiques suivant le scénario utilisé et la valeur de T (nombre de pas de temps dans la fenêtre). Le nombre de pas de temps semble impacter directement la difficulté des heuristiques à obtenir une bonne approximation du front de Pareto. Cependant, l'utilisation de l'approche d'approximation proposée permet d'atténuer cet effet, et d'obtenir rapidement de meilleures solutions malgré l'explosion de l'espace de recherche. On remarque également via les écart-types que, pour un faible nombre d'évaluations, notre approche donne des résultats plus stables qu'en l'absence de fonction d'approximation.

6. Conclusion

Dans cet article, nous avons présenté une nouvelle méthode pour l'optimisation multiobjectif de la planification d'utilisation de la puissance électrique, adaptée à un centre de données équipé de sources renouvelables. Une méthode d'approximation de fonctions *boîtes noires* appliquées à des séries temporelle a été détaillée, utilisant une transformation en ondelettes de Haar. Une variante de l'algorithme génétique SPEA2, nommée USPEA2, a été proposée afin d'exploiter efficacement l'approximation des objectifs. Les résultats montrent une approximation du front de Pareto du problème plus stable et de meilleure qualité avec un nombre limité d'évaluations de solutions. Dans un tel problème multiobjectif, une approximation rapide du front de Pareto est indispensable pour choisir, parmi les solutions possibles, un compromis souhaitable. Nous souhaitons, dans de futurs travaux, étudier les méthodes possibles pour effectuer le choix de ce compromis parmi les solutions finales.

7. Remerciements

Les expériences présentées dans cet article ont été effectuées en utilisant la plateforme Grid'5000 (<https://grid5000.fr>) dans le cadre du projet DATAZERO, ANR-15-CE25-0012.

Bibliographie

1. California GHG Emission Inventory Edition 2016, 2016.
2. Aghabozorgi (S.), Seyed Shirkorshidi (A.) et Ying Wah (T.). – Time-series clustering – A decade review. *Information Systems*, vol. 53, octobre 2015, pp. 16–38.
3. Auger (A.), Bader (J.), Brockhoff (D.) et Zitzler (E.). – Theory of the Hypervolume Indicator : Optimal μ -distributions and the Choice of the Reference Point. – In *Proceedings of the Tenth ACM SIGEVO Workshop on Foundations of Genetic Algorithms, FOGA '09*, FOGA '09, pp. 87–102, New York, NY, USA, 2009. ACM.
4. Brownlee (A. E.), Woodward (J. R.) et Swan (J.). – Metaheuristic Design Pattern : Surrogate Fitness Functions. – In *Proceedings of the Companion Publication of the 2015 Annual Conference on Genetic and Evolutionary Computation, GECCO Companion '15*, GECCO Companion '15, pp. 1261–1264, New York, NY, USA, 2015. ACM.
5. Chan (F. K. P.), Fu (A. W. C.) et Yu (C.). – Haar wavelets for efficient similarity search of time-series : With and without time warping. *IEEE Transactions on Knowledge and Data Engineering*, vol. 15, n3, mai 2003, pp. 686–705.
6. Chan (K.-P.) et Fu (A. W.-C.). – Efficient time series matching by wavelets. – In *Data Engineering, 1999. Proceedings., 15th International Conference On*, pp. 126–133. IEEE, 1999.
7. Chen (K. H.) et Ding (Z. D.). – Lithium-ion battery lifespan estimation for hybrid electric vehicle. – In *The 27th Chinese Control and Decision Conference (2015 CCDC)*, pp. 5602–5605, mai 2015.

8. Deb (K.). – Multi-objective optimization. *In : Search Methodologies*, pp. 403–449. – Springer, 2014.
9. Devabhaktuni (V.), Alam (M.), Shekara Sreenadh Reddy Depuru (S.), Green (R. C.), Nims (D.) et Near (C.). – Solar energy : Trends and enabling technologies. *Renewable and Sustainable Energy Reviews*, vol. 19, mars 2013, pp. 555–564.
10. Dunn (B.), Kamath (H.) et Tarascon (J.-M.). – Electrical Energy Storage for the Grid : A Battery of Choices. *Science*, vol. 334, n6058, novembre 2011, pp. 928–935.
11. Goiri (Í.), Katsak (W.), Le (K.), Nguyen (T. D.) et Bianchini (R.). – Parasol and GreenSwitch : Managing Datacenters Powered by Renewable Energy. – *In Proceedings of the Eighteenth International Conference on Architectural Support for Programming Languages and Operating Systems, ASPLOS '13, ASPLOS '13*, pp. 51–64, New York, NY, USA, 2013. ACM.
12. Grange (L.), Da Costa (G.) et Stolf (P.). – Green IT scheduling for data center powered with renewable energy. *Future Generation Computer Systems*, vol. 86, septembre 2018, pp. 99–120.
13. Greenpeace. – Clicking Clean : Who is winning the race to build a green internet?, janvier 2017.
14. Hao (H.), Mu (Z.), Jiang (S.), Liu (Z.) et Zhao (F.). – GHG Emissions from the Production of Lithium-Ion Batteries for Electric Vehicles in China. *Sustainability*, vol. 9, n4, avril 2017, p. 504.
15. Hatzopoulos (D.), Koutsopoulos (I.), Koutitas (G.) et Heddeghem (W. V.). – Dynamic virtual machine allocation in cloud server facility systems with renewable energy sources. – *In 2013 IEEE International Conference on Communications (ICC)*, pp. 4217–4221, juin 2013.
16. Jin (Y.). – A comprehensive survey of fitness approximation in evolutionary computation. *Soft Computing*, vol. 9, n1, janvier 2005, pp. 3–12.
17. Khosravi (A.), Nadjaran Toosi (A.) et Buyya (R.). – Online virtual machine migration for renewable energy usage maximization in geographically distributed cloud data centers. *Concurrency and Computation : Practice and Experience*, mai 2017, p. 0.
18. Kong (F.) et Liu (X.). – A Survey on Green-Energy-Aware Power Management for Datacenters. *ACM Computing Surveys*, vol. 47, n2, novembre 2014, pp. 1–38.
19. Li (Y.), Orgerie (A. C.) et Menaud (J. M.). – Balancing the Use of Batteries and Opportunistic Scheduling Policies for Maximizing Renewable Energy Consumption in a Cloud Data Center. – *In 2017 25th Euromicro International Conference on Parallel, Distributed and Network-Based Processing (PDP)*, pp. 408–415, mars 2017.
20. Pahlevan (A.), Rossi (M.), Valle (P. G. D.), Brunelli (D.) et Atienza (D.). – Joint Computing and Electric Systems Optimization for Green Datacenters. *In : Handbook of Hardware/Software Codesign*, pp. 1163–1183. – Springer, Dordrecht, 2017.
21. Shan (S.) et Wang (G. G.). – Survey of modeling and optimization strategies to solve high-dimensional design problems with computationally-expensive black-box functions. *Structural and Multidisciplinary Optimization*, vol. 41, n2, mars 2010, pp. 219–241.
22. Stanković (R. S.) et Falkowski (B. J.). – The Haar wavelet transform : Its status and achievements. *Computers & Electrical Engineering*, vol. 29, n1, janvier 2003, pp. 25–44.
23. Van den Bossche (P.), Vergels (F.), Van Mierlo (J.), Matheys (J.) et Van Autenboer (W.). – SUBAT : An assessment of sustainable battery technology. *Journal of Power Sources*, vol. 162, n2, novembre 2006, pp. 913–919.
24. Zhou (A.), Qu (B.-Y.), Li (H.), Zhao (S.-Z.), Suganthan (P. N.) et Zhang (Q.). – Multiobjective evolutionary algorithms : A survey of the state of the art. *Swarm and Evolutionary Computation*, vol. 1, n1, 2011, pp. 32–49.
25. Zitzler (E.), Laumanns (M.), Thiele (L.) et others. – *SPEA2 : Improving the Strength Pareto Evolutionary Algorithm*. – TIK-report, 2001.