

# Dimensionnement d'un centre de données autonome alimenté 100 % par des énergies renouvelables

Manal Benaïssa<sup>♦♦</sup>, Georges Da Costa<sup>♦</sup> et Jean-Marc Nicod<sup>♦</sup>

♦Institut IRIT, Univ. de Toulouse 3, Toulouse, France

♦Institut FEMTO-ST, Univ. de Bourgogne Franche-Comté, ENSMM, CNRS, Besançon, France

---

## Résumé

Au cours des deux dernières décennies, la résilience des infrastructures informatiques telles que les centres de données est devenue une préoccupation majeure pour les géants de l'informatique comme Google ou Amazon. Des centres de données alimentés par des énergies renouvelables ont été proposés. Mais en raison de l'intermittence de ces alternatives énergétiques, ces plate-formes restent connectées au réseau électrique classique. La structure informatique et les contraintes électriques ont souvent été questionnées séparément, conduisant à un système global non efficace. Dans cet article, un centre de données décarboné auto-suffisant en énergie est modélisé et conçu, en proposant une infrastructure électriquement autonome comprenant des éoliennes, des panneaux solaires et des dispositifs de stockage à court (batteries) et à long terme (systèmes à hydrogène). Le dimensionnement d'une telle infrastructure est l'une des principales questions du projet DATAZERO2. Cet article montre comment réduire et combattre le surdimensionnement en questionnant l'impact de la réduction d'éléments de calcul ou de stockage (serveurs et batteries) sur la qualité de service.

**Mots-clés :** Datacenter, Énergie Renouvelable, Ordonnancement, Efficacité énergétique, Dimensionnement, Stockage d'énergie, Emprunte carbone

---

## 1. Introduction

Les deux tiers de la population mondiale auront accès à Internet d'ici 2023 [2]. Cela représente près de 5,3 milliards de personnes utilisant les différents services existants sur Internet. Les datacenters rendant accessibles ces services sont particulièrement énergivores [10] du fait notamment du nombre de leur serveurs. La capacité à gérer les pics de charges pour rendre transparent l'accès aux informations conduisent nécessairement à un fort surdimensionnement. En effet, les serveurs fonctionnent souvent entre 10 et 50 % de leur capacité maximale [1].

Les rapports du GIEC de 2022 annoncent que le seuil d'1,5°C de réchauffement climatique pourrait être atteint dès 2030 [5]. Or en 2012, le secteur de l'informatique consommait déjà 4,6% de la production mondiale d'électricité avec 1,4 % pour les seuls datacenters [9]. Une piste à explorer serait alors d'utiliser de l'énergie décarbonée comme les énergies renouvelables [7]. Ces dernières fournissent une énergie plus propre. Le vent et le soleil sont des énergies très souvent choisies car elles sont renouvelables par nature et présentes en abondance partout moyennant un coût d'installation compétitif [11]. Par contre comme elles sont intermittentes, elles doivent




FIGURE 1 –  $(q, Apvq)$  est une configuration avec  $q$  éoliennes et  $Apvq$   $m^2$  de panneaux solaires pour la charge prévue sur  $m$  serveurs.  $(0, maxApv)$  et  $(maxWT, 0)$  sont valides.

être adossées à un système de stockage. C'est dans ce contexte que des projets ANR DATA-ZERO [8] et DATAZERO2 proposent de dimensionner et piloter un datacenter alimenté grâce aux énergies renouvelables (solaires et éoliennes), avec des batteries et un système hydrogène pour le stockage respectivement à court et à long terme. Dans la suite de cet article, nous nous intéresseront au dimensionnement d'un seul datacenter. D'autres études[4] s'intéressent à la coopération de plusieurs sites, partageant autant leur capacité de production que de stockage d'énergie.

## 2. Dimensionnement initial du datacenter

Le schéma de principe du dimensionnement du datacenter est donné à la figure 1. Il s'agit d'un processus en deux étapes : (1) le dimensionnement du datacenter d'abord en terme de nombre de serveurs utiles au traitement d'une charge de travail donnée, puis (2) le dimensionnement électrique des sources primaires (éoliennes, panneaux solaires) et secondaires (batteries, système hydrogène) pour son alimentation électrique. Différentes configurations, en nombre fini, sont à tester en fonction du nombre d'éoliennes pour mesurer l'impact de la réponse à la demande électrique des serveurs de calcul compte tenu de la météo. À chaque configuration est associée un ensemble de métriques, comme le coût de l'infrastructure ou l'emprunte carbone, afin d'aider un décideur à choisir la géométrie de son datacenter. Ce dimensionnement s'effectue en analysant la charge possible du datacenter et la météo sur un horizon  $\mathcal{H}$ , afin de proposer une infrastructure utilisable sur trente ans, avec possibles réajustements sur la période. Le défi est alors d'éviter de surdimensionner sans raison le datacenter. Nous parlons dans cet article de dimensionnement initial, par conséquent homogène par hypothèse.

### 2.1. Dimensionnement des salles serveurs (IT)

Le dimensionnement IT s'appuie sur une estimation de la quantité de travail  $\mathcal{W}$  qui pourrait être adressée au datacenter. Cette estimation est basée sur des données réelles collectées sur

la plateforme Cloud expérimentale à grande échelle Chameleon [6], conçue pour soutenir la recherche sur les systèmes informatiques, basée à Chicago et au Texas.  $\mathcal{W}$  est un ensemble de travaux soumis à chaque intervalle indivisible de temps  $\Delta t$ , sur un horizon  $\mathcal{H} = K\Delta t$ . Par hypothèse,  $\Delta t$  est une unité de temps ( $\Delta t = 1$  u.t.) qui subdivise l'horizon  $\mathcal{H}$  en  $K$  intervalles d'une heure. Ces travaux sont soit des services  $S_i \in \mathcal{S} = \{S_1, \dots, S_r\}$  soumis par un utilisateur, soit des tâches  $T_i \in \mathcal{T} = \{T_1, \dots, T_n\}$ . Ils sont défini par une date de soumission  $rs_i$  (pour les services) ou  $rt_i$  (pour les tâches), un nombre d'instructions  $ws_{i,k}$  (resp.  $wt_{i,k}$  pour les tâches) à exécuter, et une flexibilité  $\delta_i$ . Cette flexibilité, exprimée en unités de temps  $\Delta t$ , est le retard maximum accordé pour exécuter une tâche, les services (e.g., flux vidéo, etc.) ne pouvant être retardés. De cette flexibilité, une date de fin  $d_i$  peut être déduite. Si la flexibilité d'un service est nulle, la flexibilité  $\delta_i$  est différente d'une tâche à l'autre. Cependant, sans perte de généralité, la flexibilité choisie ici est constante par hypothèse dans la suite,  $\delta_i = \delta, \forall i < n$ .

Le dimensionnement s'appuie également sur les caractéristiques des serveurs, ici homogènes. Un serveur  $M_j$  est défini par le nombre d'instructions  $nbI$  qu'il peut exécuter pendant  $\Delta t$ . Comme  $nbI$  est le même d'un serveur à l'autre, la consommation électrique  $p_j = p$  est aussi la même. Ainsi, les bornes  $\min M$  et  $\max M$ , respectivement le nombre minimal et maximal de serveurs nécessaires pour satisfaire la charge de travail  $\mathcal{W}$  sur la période  $\mathcal{H}$ , peuvent être calculées quelque soit l'ordonnancement des tâches. Le but est alors de trouver  $mOPT$ , le nombre minimal de serveurs utiles pour supporter la charge  $\mathcal{W}$ , après réelle planification des tâches. La figure 2a illustre l'état de la charge de travail avant tout ordonnancement.

### 2.1.1. Algorithme d'ordonnancement

Afin de trouver  $mOPT$ , l'algorithme d'ordonnancement EDF (Earliest Deadline First) a été choisi. Le principe repose sur l'utilisation d'une liste  $\mathcal{A}_k$  contenant toutes les tâches  $T_i$  dans le système à l'heure  $k$ , et triée par ordre croissant des dates de fin, puis des tailles. Pour un nombre de serveurs  $m$  donné, toutes les tâches de  $\mathcal{A}_k$  sont ordonnancées à l'heure  $k$  jusqu'à atteindre la limite  $\max W = m \times nbI$ . Si une tâche  $T_i \in \mathcal{A}_k$  ne peut pas être ordonnancée sans dépasser  $\max W$ , alors deux options sont possibles : (1) la tâche  $T_i$  n'a pas encore atteint sa date de fin  $d_i$ , une fraction de son travail est effectué si possible pendant l'heure  $k$ , le reste est alors placé dans la liste  $\mathcal{A}_{k+1}$  pour l'heure  $k + 1$  suivante; (2) si  $T_i$  a atteint sa date limite  $d_i$ , l'ordonnancement échoue.

Si l'ordonnancement échoue, le nombre de serveurs est insuffisant et s'il réussit, il est au contraire sans doute trop grand. Ainsi,  $mOPT$  est trouvé optimalement par dichotomie, entre  $\min M$  et  $\max M$ , et où la méthode de décision repose sur l'algorithme EDF, optimal avec nos hypothèses. La figure 2 montre un exemple de dimensionnement des serveurs.

## 2.2. Dimensionnement des sources renouvelables et du stockage d'énergie

Connaissant  $m = mOPT$  et la charge de travail  $\mathcal{W}$ , la consommation électrique  $\mathcal{D}^m$  de la partie serveurs du datacenter est calculée heure par heure en prenant en compte le facteur multiplicateur PUE (Power Usage Effectiveness). Il est alors possible de définir le dimensionnement électrique nécessaire à cette demande. On procède en deux étapes : le dimensionnement des énergies primaires (éolienne et solaire) et des énergies secondaires (batteries et système hydrogène). On se base sur des données météo réelles fournies par la NASA [3] connaissant la position géographique choisie pour leur installation, ainsi que sur les caractéristiques des infrastructures électriques concernées.




FIGURE 2 – Exemple de l’ordonnancement d’une charge  $\mathcal{W}$  en utilisant l’algorithme EDF, avec une flexibilité  $\delta = 2$  La ligne rouge représente la capacité de calcul de ce datacenter.

### 2.2.1. Dimensionnement des énergies primaires

Dans une première étape,  $\max Ap_v$ , l’aire maximale des panneaux solaires nécessaire pour satisfaire la demande  $\mathcal{D}^m$  sans éolienne sans stockage est calculée. Il s’agit de l’intégrale des demandes  $D_k$  sur le temps divisées par la production d’un mètre carré de panneaux solaires en fonction de l’irradiation donnée pour chaque heure  $k$ . Puis toutes les configurations possibles pouvant satisfaire  $D_k$  avec chaque nombre  $q$  d’éoliennes (compris entre zéro et  $\max WT$ ), l’aire minimale  $Ap_{v_q}$  de panneaux solaires utile pour compléter la production des éoliennes est calculée par dichotomie. La recherche s’arrête lorsque pour  $q = \max WT$ , valeur pour laquelle plus aucun panneau solaire n’est nécessaire. Ainsi, un certain nombre de configurations  $(q, Ap_v)$  est possible, de  $(0, \max Ap_v)$  à  $(\max WT, 0)$  : cet ensemble est nommé  $Q$ . Pour chaque configuration de  $Q$ , un profil énergétique  $Pre$  (courbe en vert sur la figure 1) est donné, heure par heure. Cette production directe en énergie renouvelable est nécessaire pour déterminer la production journalière.

### 2.2.2. Dimensionnement des énergies secondaires

Afin de palier à l’intermittence des sources renouvelables, l’infrastructure est aussi dotée d’un système de stockage d’énergie. Les batteries au lithium sont utilisées pour compenser l’intermittence jour/nuit, et l’hydrogène compense l’intermittence saisonnière (moins de renouvelables en hiver qu’en été). Ce choix est influencé par le rapport rendement/prix de ces types de stockage : la batterie au lithium a un rendement électrique de 80% (20% de cette énergie est perdue lors de chaque charge comme décharge) mais coûte cher, aussi bien pour l’environnement que du point de vue économique. Réciproquement, le système hydrogène a rendement plus faible (40%) mais est plus économique et écologique. Le dimensionnement des sources secondaires est défini par la quantité d’énergie maximale à stocker  $BC_{\max}$  dans les batteries sur l’ensemble de l’horizon  $\mathcal{H}$ , et par la quantité d’hydrogène à stocker  $LOH_{\max}$ , sur cette même période. Par extension,  $BC_k$  (resp.  $LOH_k$ ) est la quantité d’énergie stockée dans les batteries (reps. stockée sous forme d’hydrogène) à chaque heure  $k$ . Afin de gérer au mieux ce dimensionnement, deux contraintes sont posées : (1) la quantité d’énergie de la batterie est la même à chaque début de journée ; (2) la quantité de  $H_2$  disponible est la même à chaque début d’année. C’est cette dernière contrainte qui décide si l’aire  $Ap_v$  des panneaux solaires, associée à un nombre  $q$  d’éoliennes, est suffisante pour compenser la demande du datacenter lors de la recherche dichotomique. En effet, si trop d’hydrogène a été stocké en fin d’année, la configuration est surdimensionnée et réciproquement.

Chaque jour  $d$ , le comportement de la batterie n’est pas le même suivant que  $d$  est un jour

de surproduction ou de sous-production. Lorsque l'énergie produite dépasse la demande du datacenter, la batterie compense toutes les heures de sous-production et se recharge pendant les heures de surproduction afin de revenir à son niveau initial. Le reste de la surproduction est transformée en hydrogène par les électrolyseurs. Lorsque  $d$  est un jour de sous-production les rôles sont inversés. La batterie compense les heures de sous-production à hauteur de ce qu'elle pourra se recharger pendant des heures de surproduction et les piles à combustibles complètent la production électrique si nécessaire. Dans les deux cas, l'efficacité des composants est prise en compte. La capacité utile de la batterie  $BC_{max,d}$  au jour  $d$  est l'amplitude utile pour jouer son rôle. Ainsi  $BC_{max}$ , la capacité de la batterie, est la plus grande des amplitudes sur  $\mathcal{H}$ .

A l'issue de ce dimensionnement, l'ensemble  $Q$  des configurations est alors un ensemble de 4-uplets  $(q, Apv, bc, loh)$  qui sont respectivement, le nombre d'éoliennes, la surface des panneaux solaires, la capacité des batteries et des réservoirs d'hydrogène.

### 3. Étude du surdimensionnement

À l'issue des deux étapes de dimensionnement IT et électrique, un ensemble de configurations  $Q$  est proposé, où chaque configuration devient un 5-uplets  $(mOPT, q, Apv, bc, loh)$ . Le but de ce dimensionnement est de minimiser l'impact écologique et économique de l'infrastructure totale, en évitant le surdimensionnement et en puisant dans des sources électriques renouvelables, tout en assurant une qualité de service donnée. Mais dans ce premier modèle de dimensionnement, les incertitudes liées à la charge de travail, à la météo, ou même aux possibles pannes du système, n'ont pas été prises en compte. Une première étape consiste donc à analyser la sensibilité du système aux facteurs internes (paramètres du dimensionnement, le dimensionnement lui-même) et externes (charge de travail, météo). Seule une des analyses déjà faites sera présentée ici, afin d'illustrer la problématique.

#### 3.1. Influence du nombre de serveurs sur la QoS

L'étude consiste dans un premier temps à analyser l'impact d'une modification du dimensionnement sur la qualité de service. Le nombre de serveurs minimal  $mOPT$  est volontairement réduit jusqu'à atteindre  $minM$ , afin de constater l'évolution de la qualité de service par rapport à ce critère. Cette qualité de service est donnée en fonction du nombre de tâches rejetées durant l'ordonnancement EDF effectué lors du dimensionnement. Une tâche est rejetée si sa date limite  $d_i$  est atteinte et qu'il n'est pas possible (faute de ressources) d'ordonner celle-ci. Ainsi, une qualité de service atteint 100% si aucune tâche n'est rejetée, et décroît progressivement à chaque serveur supprimé. La figure 3 montre l'évolution de la qualité de service en fonction du nombre de serveurs. Cette étude a été effectuée sur une simulation de charge de travail, produite selon une loi uniforme.

Ce premier résultat montre peu de conséquences sur la qualité de service, si le nombre de serveurs est réduit d'environ 10%. Cela permet notamment de réduire le coût de l'infrastructure total. En effet, il arrive que le dimensionnement ne soit déterminé que par quelques épiphénomènes (Black Friday, évènements commerciaux ponctuels, etc.), et qu'écarter ces exceptions réduisent considérablement le nombre de serveurs, sans impacter trop la qualité de service.

#### 3.2. Dimensionnement de la batterie

Nous observons ici l'amplitude utile de la batterie, jour par jour et nous trions ces amplitudes par ordre croissant. La figure 4 montre le tri des amplitudes utiles ainsi que la production d'énergie renouvelable associée pour l'année 2019 à Lille (surproduction en vert et sous-production en bleu) avec une configuration comptant 2 éoliennes à 4 MW et 1596 m<sup>2</sup> de




FIGURE 3 – Évolution du nombre de tâches rejetées, en fonction du nombre de serveurs supprimés.  $m$  varie de  $m_{OPT}$  à  $minM$ .




FIGURE 4 – Évolution de la production électrique (différence entre la demande  $D$  du datacenter et la production  $P_{re}$  des sources primaires), et de la capacité des batteries, au cours de l'année.

panneaux solaires. Nous constatons que la batterie n'est pas utilisée la moitié de l'année, jours pendant lesquels chaque heure est une heure de surproduction ou de sous-production. On remarque que les dix jours nécessitant la plus grande amplitude utile pour la batterie influencent fortement sa capacité. Ainsi diminuer sa capacité peut avoir une grande influence sur le budget et l'impact carbone de l'infrastructure totale sans pour autant impacter le fonctionnement.

#### 4. Conclusion

Le dimensionnement d'un datacenter alimenté en énergie solaire et éolien repose, d'une part, sur le dimensionnement de l'infrastructure IT (le nombre de serveurs nécessaires pour satisfaire une charge de travail donnée), et sur le dimensionnement électrique (le nombre d'éoliennes, de panneaux solaires et la capacité de stockage). Cependant, ce dimensionnement initial ne prend pas en compte les incertitudes liées aux facteurs externes (météo et utilisation des datacenters), ni les pannes. Une première étape est donc d'analyser la résilience de ce modèle face à ces différents paramètres, afin de proposer un modèle plus robuste aux changements impré-

vus. Les résultats présentés ici ne sont qu'un échantillon des études déjà menées et des études prévues par la suite, afin de tenir compte le mieux possible l'ensemble des incertitudes associées à cette infrastructure. Ces explorations sont permises par notre approche modulaire. En effet, il est possible de changer les différents modules (par exemple le gestionnaire de tâches, le gestionnaire de la batterie, ...) et donc d'évaluer l'impact de modèles différents sur le dimensionnement, ou la résilience du dimensionnement à l'utilisation de modèles différents.

## Remerciement

Les travaux présentés ici sont financées par le projet ANR DATAZERO2 (contract "ANR-19-CE25-0016") et par la Graduate school EIPHI (contract "ANR-17-EURE-0002").

## Bibliographie

1. Barroso (L. A.) et Hölzle (U.). – The case for energy-proportional computing. *Computer*, vol. 40, n12, 2007, pp. 33–37.
2. Cisco (U.). – Cisco annual internet report (2018–2023) white paper, 2020.
3. Dataset (N. W.). – <https://power.larc.nasa.gov/data-access-viewer/>.
4. Gamatié (A.), Sassatelli (G.) et Mikučionis (M.). – Modeling and analysis for energy-driven computing using statistical model-checking. – In *2021 Design, Automation & Test in Europe Conference & Exhibition (DATE)*, pp. 980–985. IEEE, 2021.
5. GIEC. – <https://www.ipcc.ch/reports/>.
6. Keahey (K.), Anderson (J.), Zhen (Z.), Riteau (P.), Ruth (P.), Stanzione (D.), Cevik (M.), Colleran (J.), Gunawi (H. S.), Hammock (C.), Mambretti (J.), Barnes (A.), Halbach (F.), Rocha (A.) et Stubbs (J.). – Lessons learned from the chameleon testbed. In : *USENIX Annual Technical Conference (USENIX ATC '20)*. – USENIX Association, July 2020.
7. Masanet (E.), Shehabi (A.), Lei (N.), Smith (S.) et Koomey (J.). – Recalibrating global data center energy-use estimates. *Science*, vol. 367, n6481, 2020, pp. 984–986.
8. Pierson (J.-M.), Baudic (G.), Caux (S.), Celik (B.), Da Costa (G.), Grange (L.), Haddad (M.), Lecuire (J.), Nicod (J.-M.), Philippe (L.), Rehn-Sonigo (V.), Roche (R.), Rostirolla (G.), Sayah (A.), Stolf (P.), Thi (M.-T.) et Varnier (C.). – DATAZERO : DATAcenter with Zero Emission and RObust management using renewable energy. *IEEE Access*, vol. 7, juillet 2019.
9. Van Heddeghem (W.), Lambert (S.), Lannoo (B.), Colle (D.), Pickavet (M.) et Demeester (P.). – Trends in worldwide ict electricity consumption from 2007 to 2012. *Computer Communications*, vol. 50, 2014, pp. 64–76.
10. Xia (W.), Zhao (P.), Wen (Y.) et Xie (H.). – A survey on data center networking (dcn) : Infrastructure and operations. *IEEE communications surveys & tutorials*, vol. 19, n1, 2016, pp. 640–656.
11. Yao (Y.), Xu (J.-H.) et Sun (D.-Q.). – Untangling global levelised cost of electricity based on multi-factor learning curve for renewable energy : Wind, solar, geothermal, hydropower and bioenergy. *Journal of Cleaner Production*, vol. 285, 2021, p. 124827.