

Rapport MesoNET - GT GES

Co-rédacteurs : Gaël Guennebaud, Françoise Berthoud, David Benaben, Pierre-Emmanuel Guérin, Marco Leoni, Marc Odunlami

1 Contexte et objectifs

Financé par l'ANR dans le cadre du PIA3, le projet [MesoNET](#) regroupe 21 mésocentres régionaux et l'IR* [GENCI](#) en tant que partenaire coordinateur. MesoNET visant à créer une Infrastructure de Recherche nationale distribuée de type mésocentre, l'impact environnemental des investissements et activités de ce projet soulève plusieurs questions. Comment estimer l'empreinte carbone d'une infrastructure de calcul ou de stockage ? Comment permettre aux utilisateurs d'évaluer l'empreinte de leur activité calculatoire ? Afin d'y apporter des éléments de réponse, le GT GES de MesoNET s'est intéressé à une méthode d'évaluation de l'empreinte carbone globale d'un centre de calcul, résultant de travaux menés par des membres de [Labos 1point5](#), d'[EcoInfo](#), du [GRICAD](#) et de GENCI. La méthodologie proposée permet d'estimer le coût carbone d'une heure de calcul sur un cœur CPU ou sur un GPU [1] et le coût équivalent carbone pour stocker 1 Go de données / an. Cette méthodologie a ainsi été appliquée à des mésocentres régionaux du réseau MesoNET : nous en décrivons les résultats obtenus et les limites observées. Nous mettrons également en lumière quelques indicateurs clés de la méthode. Enfin, nous proposerons des recommandations pour mettre en œuvre les pratiques, outils et réflexions nécessaires à la réduction des impacts environnementaux des activités des mésocentres. Les résultats obtenus dans le cadre de MesoNET pourront alimenter l'application [GES 1point5](#) afin de permettre aux utilisateurs d'évaluer l'empreinte carbone de leurs calculs.

2 Méthodologie

La méthodologie appliquée dans le cadre de MesoNET suit celle éprouvée sur les centres de calculs nationaux et présentée dans ce rapport [1] de Labos1point5. Nous y avons apporté quelques ajustements pour s'adapter au contexte légèrement différent de MesoNET. L'étape principale consiste à estimer l'empreinte carbone du centre considéré sur une année complète d'exploitation. Dans le cadre de MesoNET, nous nous sommes limités au périmètre dit "obligatoire" de la méthodologie d'origine, qui comprend les émissions de GES liées aux phases de fabrication et d'usage (principalement la consommation électrique) des équipements suivants : l'ensemble des serveurs nécessaires au service (calcul, frontends, stockage temporaire, etc.), les équipements réseaux, les unités d'alimentation (onduleurs, batteries, génératrices de secours avec la consommation de Gasoil Non Routier), ainsi que les unités de refroidissement (avec les éventuelles fuites de réfrigérant).

Facteurs de fabrication

Les émissions liées à la fabrication sont réparties de manière uniforme sur la durée de vie présumée des équipements. Le choix de cette durée de vie est laissé à la discrétion de chacun des centres. En revanche, afin de garantir une certaine cohérence entre les différentes estimations, les émissions de fabrication des serveurs ont été estimées à partir de la méthodologie et de l'outil ouvert de Boavizta [[boavizta/serversimpact](#)], lui-même complété avec des facteurs estimés dans le cadre des études des centres du GENCI, notamment pour les GPUs. L'outil de Boavizta donnant des estimations nettement inférieures aux fiches

d’empreinte carbone et ACV de DELL et autres référentiels utilisés par les études précédentes (GRICAD, CINES, IDRIS), nous avons choisi de majorer les estimations de Boavizta de +45% de manière à fournir des résultats cohérents entre eux.

Extrapolation des facteurs de fabrication de l’infrastructure

Pour certains centres, la collecte d’informations précises sur l’infrastructure matérielle environnante (alimentation et refroidissement) s’est avérée trop difficile. Pour pallier cette absence d’information, nous avons mis en place une méthode d’extrapolation des émissions de ces postes à partir des données collectées pour les autres centres. A l’image du PUE (“Power Usage Efficiency”) pour la consommation électrique, nous avons estimé le ratio entre les émissions de fabrication annualisées totales (serveurs + infrastructures) sur les émissions de fabrication des serveurs. Pour les centres étudiés de manière exhaustive, nous avons trouvé un ratio allant de l’ordre de 1.06 à 1.11. Ce ratio dépend de nombreux paramètres dont le niveau de garantie de service attendu (redondance, surdimensionnement, volume de batteries, etc.). Aussi, nous avons retenu le ratio de 1.1, qui nous semble être un compromis raisonnable.


Allocation

Une fois le bilan annuel réalisé, l’empreinte globale est divisée par le volume d’heure-coeur CPU (resp. d’heure-GPU) réalisé sur l’infrastructure sur la même année pour en déduire un facteur en gCO₂e/h.coeur (resp. gCO₂e/h.GPU) qui peut être utilisé par les centres pour répartir l’empreinte entre les utilisateurs, projets, ou laboratoires. Contrairement à la méthodologie initiale, ici nous avons choisi de garder chaque centre indépendant et de ne pas passer par un coefficient moyen unifié et la notion d’*heure-équivalente* (ou *heure-normalisée* dans le jargon GENCI). En effet, les différents mésocentres ne s’adressent pas aux mêmes utilisateurs, et ils ont été jugés trop hétérogènes pour que cette vision de service unifié ait un sens ici.

Stockage

Finalement, cette méthodologie a également été appliquée à deux services de stockage. Pour ceux-ci, la méthodologie de l’estimation de l’empreinte globale annuelle reste inchangée. En revanche, le calcul d’un facteur d’allocation entre les usagers passe par une normalisation de l’empreinte par le volume de données stockées. Pour les services de calcul, nous observons un taux de charge moyen qui est plutôt stable sur la durée de vie des serveurs. Au contraire, les services de stockage que nous avons considérés sont volontairement surdimensionnés de manière à répondre à un besoin de volume croissant pendant la durée de vie du service (une meilleure stratégie consisterait à prévoir des achats et déploiements incrémentaux pour coller au plus juste aux besoins réels, mais ce n’est pas ce qui est observé). Dans ces conditions, et si l’on s’intéresse au volume de données stockées au cours d’une année précise, alors le facteur en gCO₂e/Go.an sera très différent selon que l’on réalise l’estimation en début, milieu ou fin de vie des serveurs. Une telle approche comptable conduirait à un coût carbone très important des premiers Go stockés. Aussi, nous avons jugé préférable d’amortir l’empreinte globale du service sur la totalité du volume de données qui sera stocké (en Go.an) au cours de la durée de vie totale des serveurs, et d’utiliser ce volume pour en déduire un facteur moyen et stable au cours du temps. Cette stratégie présente aussi l’avantage de communiquer une information plus claire et simple aux utilisateurs. Bien sur, ce volume de données total doit être estimé de manière anticipée, car il ne sera réellement connu qu’au démantèlement des serveurs.

Concrètement, le graphique ci-dessous montre l'évolution du taux de remplissage pour quatre modèles différents : quadratique, linéaire, diffusif, exponentiel inversé. Ce taux varie de 0% à 70% sur les 7 années de vie considérées pour l'exemple suivant :



Les taux de remplissage moyens sont respectivement de 23%, 35%, 46% et 56%. Au regard de ces hypothèses et modèles théorique, et faute de données permettant d'affiner les choix, nous avons retenu pour cette étude un taux moyen de 46% (ce qui correspond à un taux de remplissage de type diffusif, courbe verte).

3 Résultats

Trois partitions CPU ont été finalisées. Il s'agit du MCIA (Nouvelle-Aquitaine), de Pyrene (UPPA, site de Pau) et de GLiCID (Pays de la Loire). Le tableau suivant inclut aussi les résultats de l'étude du GRICAD [3] actualisés à l'intensité carbone du mix électrique français de 2022 (source ADEME) et pour un périmètre proche (la fabrication des équipements de refroidissement est exclue de l'étude GRICAD). Trois d'entre eux datent d'environ 2018 avec des configurations très similaires. Pour le MCIA et Pyrene, bien qu'ils soient toujours utilisés, nous avons retenu la durée de garantie de 5 ans. Le mésocentre GLiCID est en revanche beaucoup plus récent et n'a commencé à être réellement exploité qu'en 2024. Pour ce dernier, faute de relevés de consommation réelle, la consommation énergétique a du être estimée à partir d'hypothèses et de mesures de puissance instantanée des noeuds, du taux d'usage et d'une hypothèse du ratio entre la puissance statique et la puissance crête (0.3).

	Année de mise en service	Caractéristiques principales	Durée de vie	PUE	Taux de charge	gCO2e /h.coeur	% Usage	Wh /h.coeur
GRICAD/ Dahu	2016	Skylake 2x16 coeurs, RAM: 192 Go	7 ans	1.4	72%	~2.7	43%	~22.4
MCIA	2019	Skylake 2x16 coeurs, RAM: 96 Go	5 ans	1.53	80%	~2.0	42%	~17.4
Pyrene	2019	Skylake 2x16 coeurs, RAM: 96 Go	5 ans	1.5	74%	~3.0	38%	~21.9
GLiCID	2023	Genoa/Sapphire 2x48	6 ans	1.2	52%	~1.3	38%	~9.3

Année de mise en service	Caractéristiques principales	Durée de vie	PUE	Taux de charge	gCO2e /h.coeur	% Usage	Wh /h.coeur
	coeurs, RAM: 415 Go						

La colonne “% Usage” reporte le pourcentage des émissions liées à la consommation électrique en phase d’usage. La différence notable sur le résultat normalisé entre le MCIA et Pyrene qui présentent les mêmes caractéristiques s’explique principalement par 1) le taux de charge, mais surtout, 2) par le fait que la proportion de noeuds de services plus noeuds spéciaux (ayant énormément de RAM et donc un impact de fabrication très important) est nettement plus importante dans le cas de Pyrene (7 pour 36 noeuds *standards*) que dans le cas du MCIA (11 pour 315 noeuds *standards*).

Deux services de stockage ont également été étudiés. Pour le site de Saclay, les émissions de fabrication des équipements de l’infrastructure ont été extrapolées :

	Année de mise en service	Caractéristiques principales	Durée de vie	PUE	Taux de réplication	gCO2e /Go.an	% use	Wh /Go.an
GRICAD/Summer	-	Hétérogène avec en moyenne 30 HDD de 5.6To / noeud	7 ans	1.4	3	~41	28%	~216
MCIA - iRODS	2021	12 HDD de 12To / noeud	6 ans	1.53	2	~18.5	34%	~122
Saclay	2023	24 HDD de 18To / noeud	7 ans	1.5	3	~11.0	29%	~61.4

On peut remarquer que malgré un taux de réplication plus important, le troisième, plus récent, affiche une meilleure efficacité théorique (anticipée) qui s’explique par une plus grande densité de To par noeud.

4 Limites

Limites liées à la métrique utilisée (émissions de Gaz à Effet de Serre)

L’indicateur de l’empreinte carbone (CO2e) des infrastructures de calcul, mono-critère, renseigne sur l’impact sur le changement climatique, mais n’informe pas sur l’épuisement des ressources (eau, métaux, minéraux, etc.), les pollutions ou la perte de biodiversité. De même, les aspects sociaux (la santé, les conflits, la compétition sur les ressources, la violation des droits humains, les tensions géopolitiques, etc.) ou les enjeux du calcul (bénéfices scientifiques, développement économique, gouvernance, etc.) n’y sont pas traités. De plus, des transferts d’impacts non souhaitables pourraient survenir. Il est par exemple possible d’utiliser moins d’électricité mais plus d’eau via un refroidissement par évaporation d’eau. L’indicateur doit donc être repositionné dans ces impacts plus globaux.

Limites liées aux effets rebonds

Par ailleurs, l’empreinte carbone d’une heure de calcul est un indicateur d’efficacité. Il ne donne pas d’informations sur l’empreinte carbone totale du calcul scientifique. Un centre de calcul peut être plus efficace (taux d’usage plus important, plus de cœurs de calcul par CPU, etc.), donc réduire l’empreinte d’une heure de calcul, sans pour autant baisser son empreinte totale. Il ne prend pas non plus en compte les effets rebonds : quand l’efficacité accrue mène

à une augmentation du nombre de calculs, annulant les gains en réductions d'émissions. Ainsi la connaissance de l'empreinte carbone d'une heure de calcul n'est pas suffisante pour jauger de la réduction globale des émissions du calcul scientifique.

Limites liées au périmètre considéré pour le calcul

La donnée correspondant aux émissions de GES pour une heure de calcul ne dit pas le périmètre qui a été défini pour l'obtenir : nature des équipements considérés (IT, alimentation, refroidissement), caractéristiques du bâtiment, activités du personnel. Concernant les équipements, différentes phases du cycle de vie peuvent être prises en compte : extraction des matières premières, fabrication, transport, usage, fin de vie.

Il est important que le lecteur connaisse précisément le périmètre utilisé pour la détermination de l'indicateur. Le détail de la décomposition de ce dernier et la connaissance des impacts relatifs à chaque poste mis en jeu dans son obtention permettra à chacun d'ajuster au mieux ses actions.

Autres limites

Par ailleurs, il y a des limites intrinsèques à un tel exercice provenant à la fois de la collecte des données, des inévitables hypothèses sur le futur, de la méthodologie de calcul elle-même, ainsi que des bases de données nécessaires à l'évaluation des impacts. Par exemple :

- Les données sont incertaines, partielles ou manquantes (données constructeurs, phase de fin de vie, maintenance, données parfois anciennes, etc.).
- Les impacts indirects ou connexes ne sont pas pris en compte (conception, marketing, etc).
- Certaines données sont parfois estimées a priori (durée de vie des équipements, taux d'usage, consommations, etc.).
- Les tranches additionnelles d'infrastructures de calcul ou de stockage obligent à refaire les estimations.

Indicateurs

Globaux

Les indicateurs globaux visent à vérifier au fil du temps la réduction absolue des impacts environnementaux. Ils se calculent pour une année N donnée.

- kWh : Consommation d'électricité sur l'année N.
- GES (kg CO₂ équivalent) : quantité totale de GES émis par l'infrastructure de calcul et son environnement pour l'année N.
- MasseIT (kg) et MasseDEEE : masse en kg du matériel IT acquis année N, DEEE générés année N.
- Destinataires DEEE (préciser si reconditionnement ou recyclage matière).

Efficacité

Comme leur nom l'indique, les indicateurs d'efficacité permettent de rendre compte des niveaux de performance des infrastructures matérielles et/ou logicielles. Ils sont relatifs.

- Le Power Usage Effectiveness (PUE, sans unité) est un nombre toujours supérieur à 1 qui permet d'avoir une idée du surcoût de consommation d'électricité à cause de l'environnement électrique et du refroidissement de l'IT.
- Le Water Usage Effectiveness (WUE, l/kWh) est le rapport entre la quantité d'eau utilisée par le datacenter et l'électricité fournie au matériel informatique.
- Le Taux d'usage (%) est le rapport entre le nombre d'heure de calcul réellement réalisé sur une période donnée (typiquement 1 an) et le nombre théorique d'heures dans l'année.
- Les indicateurs GES/heure de calcul ou Wh/heure de calcul permettent de fournir aux utilisateurs la quantité d'électricité ou les émissions de GES générées par heure de calcul sur la plateforme. Rappelons que la diminution de ces indicateurs d'efficacité n'atteste pas de réductions globales d'électricité, d'eau ou d'émissions de GES.

Autres indicateurs

- Il peut être très pertinent d'afficher la distribution des utilisateurs actifs (combien d'utilisateurs ont fait combien d'heures sur l'année) et d'observer l'évolution au cours du temps.
- Idéalement, il serait intéressant d'avoir une estimation qualitative des résultats produits par les calculs effectués sur la plateforme, mais cela paraît difficile, voire impossible.

5 Leviers de réductions

D'une façon générale, les leviers suivants constituent des pistes à explorer pour réduire les impacts environnementaux liés aux calculs. Le Code de Conduite des Datacenters Européens liste un ensemble de bonnes pratiques qui peuvent être consultées ici : <https://ecoinfo.cnrs.fr/wp-content/uploads/2020/05/guide-de-bonnes-pratiques-datacenter-2019.pdf>.

Ci dessous quelques éléments qui nous paraissent particulièrement importants :

Au niveau des plateformes de calcul

- Éviter/retarder l'achat.
 - Ex. : les besoins ne peuvent-ils pas déjà être couverts par d'autres plateformes existantes ?
- Inclure les utilisateurs pour la spécification des besoins pour que la plateforme réponde au plus près aux types de besoins des utilisateurs, au niveau matériel comme au niveau logiciel.
- Mutualiser le plus possible sur chaque territoire pour limiter le gaspillage de ressources (bâtiments, serveurs sous-utilisés, etc.).
- Introduire des critères environnementaux et des critères sélectifs dans le cahier des charges d'achat des plateformes de calcul (efficacité de l'alimentation électrique, garantie de 7 ans, caractéristiques de plages de température/humidité, efficacité du système de refroidissement, etc..)
- En cas d'un déploiement conjoint des baies et des systèmes de refroidissement et d'alimentation, passer par un prestataire unique de manière à aboutir à une solution la plus cohérente et efficace possible.

Au niveau des plateformes de stockage

- Prévoir des achats et déploiements incrémentaux pour coller au plus juste aux besoins réels.

Au niveau de l'hébergement des plateformes de calcul

- Choisir un environnement qui minimise la consommation d'eau et d'électricité pour le refroidissement des serveurs.
- Questionner les besoins (ou non) de redondance des systèmes électrique et de refroidissement (est ce que ces calculs sont critiques ?).

A la fin de vie des équipements

- Préférer un prestataire qui propose un reconditionnement des serveurs plutôt qu'un recyclage matière et interroger précisément le prestataire sur le devenir des déchets ultimes (lieu et type de traitements).

Au niveau de la gestion de la plateforme

- Choisir une solution (gestionnaire) qui maximise le taux d'occupation des serveurs tout en minimisant les temps d'occupation des noeuds par des jobs inactifs.
- Penser à éteindre les noeuds de calcul non utilisés pendant les périodes très creuses de l'année (il existe des solutions logicielles pour cela).

En direction des utilisateurs

- Les sensibiliser aux impacts environnementaux du numérique et leur communiquer l'ordre de grandeur des impacts liés à leurs propres calculs. À défaut de calcul précis de l'empreinte carbone d'une heure de calcul sur le centre, nous suggérons d'utiliser l'ordre de grandeur de 2.5 gCO₂e/h.coeur.
- Les inviter à se questionner sur leurs réels besoins, notamment à l'occasion des renouvellements des plateformes.
- Appliquer des bonnes pratiques, comme :
 - Tester sur des petits jeux de données.
 - Vérifier que les ressources demandées et allouées sont réellement utilisées.

6 Conclusion

Les décisions basées uniquement sur ce type d'indicateur (empreinte carbone d'une heure de calcul) peuvent mener à des paradoxes où la réduction de l'indicateur ne mène pas à une réduction globale.

L'intérêt principal de ces indicateurs est avant tout de permettre aux utilisateurs d'évaluer l'empreinte des heures de calcul de leur activité ou de leurs projets, rendant ainsi visibles des émissions qui autrement seraient totalement occultées par l'éloignement de ces infrastructures matérielles.

En revanche, il est important de bien remarquer qu'une part très importante des émissions sont issues de la phase de fabrication des serveurs et autres équipements. Contrairement à ce que laissent penser ces indicateurs, la majeure partie des émissions ont donc déjà eu lieu avant même que la première heure de calcul ne soit réalisée. En d'autres termes, il n'y a donc pas de lien de cause à effet direct et parfaitement proportionnel entre le choix de réaliser ou d'éviter

de réaliser un calcul. Cette observation amène à au moins deux implications majeures. Premièrement, cela signifie que ces indicateurs ne devraient pas être utilisés seuls pour comparer différentes plateformes entre elles. En effet, de part la miniaturisation des procédés de fabrication et des gains d'efficacité en ressources et énergie qui en découle, il est attendu qu'une partition plus récente qu'une autre soit associée à un indicateur d'émission plus faible (toute chose égale par ailleurs). Une comparaison directe pourrait donc amener à une migration systématique des utilisateurs vers la dernière plateforme déployée et ainsi créer un phénomène d'obsolescence accélérée qui serait contre productif (et qui fausserait les estimations précédentes). Deuxièmement, cela signifie aussi qu'une composante importante de toute stratégie de réduction ou maîtrise des émissions absolues des heures de calcul se joue au moment des prises de décision du renouvellement ou d'ajout de nouveaux moyens. Pour des prises de décision éclairées, il convient donc d'inclure l'ensemble des utilisateurs tout en prenant en compte le panorama complet des plateformes disponibles et en cours de déploiement.

À noter également que la comparaison d'empreintes carbone ramenées à une heure de calcul est un exercice périlleux au regard des éventuelles différences de méthodologies ou de périmètres, ainsi que des écarts très importants qui existent au niveau des sources et bases de données disponibles pour estimer les impacts de fabrication. Ajoutons à cela une dépendance importante de ces indicateurs à des paramètres extrinsèques tels que la durée de vie ou le taux d'usage, et nous pouvons arriver à des situations où deux plateformes parfaitement identiques sur le plan technique afficheraient des indicateurs très différents.

Ces limites montrent que les indicateurs doivent être utilisés avec précaution et en complément d'une réflexion globale et collective pour réduire les impacts environnementaux et sociaux des solutions numériques.

7 Références

- [1] David Benaben, Françoise Berthoud, Gaël Guennebaud, Anne-Laure Ligozat, Sophie Valcke. 2024. Estimation de l'empreinte carbone d'une heure de calcul sur un cœur CPU ou sur un GPU. Labos1point5. <https://labos1point5.org/les-rapports/estimation-empreinte-calcul>
- [2] Gaël Guennebaud. 2022. Empreinte carbone des heures de calculs : limites et paradoxes. Présenté à Journée scientifique 2022 du Mésocentre de Calcul Intensif Aquitain (MCIA), <https://jsmcia2022.sciencesconf.org/>, Talence (France), 21 octobre 2022. https://jsmcia2022.sciencesconf.org/data/program/Pres_MCIA_2022_carbone_calcul.pdf.
- [3] Françoise Berthoud, Bruno Bzeznik, Nicolas Gibelin, Myriam Laurens, Cyrille Bonamy, et al. Estimation de l'empreinte carbone d'une heure.coeur de calcul. [Rapport de recherche] UGA - Université Grenoble Alpes; CNRS; INP Grenoble; INRIA. 2020. <[hal-02549565v5](https://hal.archives-ouvertes.fr/hal-02549565v5)>
- [4] Guillaume Charret, Alexis Arnaud, Françoise Berthoud, Bruno Bzeznik, Anthony Defize, et al. Estimation de l'empreinte carbone du stockage de données. [Rapport de recherche] CNRS - GRICAD. 2020. <https://hal.science/hal-03573790/>