

# Techniques de limitation de la consommation énergétique d'un nœud de calcul

Green Days 2024


Vladimir Ostapenco <sup>1</sup>  
Laurent Lefevre <sup>1</sup>  
Anne-Cécile Orgerie <sup>2</sup>  
Benjamin Fichel <sup>3</sup>

FrugalCloud (Défi Inria/OVHcloud)

<sup>1</sup> Univ Lyon, EnsL, UCBL, CNRS, Inria, LIP, Avalon  
<sup>2</sup> Univ Rennes, Inria, CNRS, IRISA, Magellan  
<sup>3</sup> OVHcloud

# Contexte

- Augmentation considérable de l'utilisation des technologies de l'information et de la communication
- Centres de données et services cloud
  - Sont au centre de cette croissance
  - Leur nombre et leurs impacts sont en constante augmentation
- **De 2021 à 2022 en France**, les opérateurs de centres de données <sup>1</sup>
  - **+14 %** d'émissions de GES
  - **+15 %** de consommation électrique
    - **Plus de 90 % des émissions** globales de GES



<sup>1</sup> ARCEP (2024). "Pour un numérique soutenable"

# Contexte

- Dans ce contexte, l'efficacité énergétique des datacenters et des services cloud est une préoccupation croissante
- Nœuds de calcul représentent une part importante de la consommation totale des datacenters
- Nous devons avoir les moyens de
  - Mesurer la consommation d'énergie
    - Comprendre les impacts
  - **Limiter la consommation énergétique**
    - Réduire les impacts
    - Améliorer l'efficacité énergétique




# Consommation d'un nœud de calcul

## - Partie Statique

- Consommation quand aucune charge de travail n'est exécutée
- Représente une partie non négligeable de la consommation d'un nœud de calcul

## - Partie Dynamique

- Augmentation de la consommation due à l'exécution de la charge de travail



Profil de puissance avant et pendant l'exécution du benchmark MG NAS

# Techniques de limitation de la consommation énergétique

- **Shutdown policies** (agit sur la consommation statique)
  - Arrêt et allumage des noeuds de calcul
- **Sleep states** (agit sur la consommation statique)
  - Mise en veille ou allumage/extinction des ressources
- **DVFS** (agit sur la consommation dynamique)
  - Modulation de tension et de fréquence du CPU
  - Disponible sur la majorité des nœuds de calcul
- **Intel RAPL** (agit sur la consommation dynamique)
  - Limitation de puissance des composants du nœud de calcul (package CPU et DRAM)


**Application de chaque technique** engendre des coûts en termes de temps et d'énergie non négligeables car la transition d'état nécessite du temps et implique une consommation d'énergie. <sup>1,2</sup>

<sup>1</sup> Rais et al. (2018). Quantifying the impact of shutdown techniques for energy-efficient data centers

<sup>2</sup> Kim et al. (2008). System level analysis of fast, per-core DVFS using on-chip switching regulators

# Intel RAPL - Running Average Power Limit

- Introduit dans l'architecture Intel Sandy Bridge (2011)
- Bien que la plupart des travaux étudient le RAPL pour la mesure <sup>1,4</sup>, **conçu à l'origine à des fins de limitation de puissance**
- Permet **la spécification de la puissance moyenne sur une période de temps** sur les domaines de puissance
- Assez précis et stable pour la majorité des applications de longue durée <sup>2</sup>
- A des temps de transition d'état courts et est assez efficace <sup>2</sup>
- Tend à remplacer DVFS <sup>3</sup>
- **Pouvons-nous utiliser RAPL pour un plafonnement strict de la puissance** afin de répondre aux contraintes énergétiques ?



Domaines de puissance disponibles dans RAPL <sup>3</sup>

<sup>1</sup>Jay et al. "An experimental comparison of software-based power meters: focus on CPU and GPU."

<sup>2</sup>Zhang et al. (2015). A quantitative evaluation of the RAPL power control system

<sup>3</sup>Imes et al. (2019). CoPPer: Soft Real-Time Application Performance Using Hardware Power Capping

<sup>4</sup>Khan et al. (2018). RAPL in Action: Experiences in Using RAPL for Power Measurements

# Intel RAPL - Comment RAPL fonctionne ?

- Il n'existe que **peu d'information officielle publiquement accessible** sur la mise en œuvre interne du RAPL
  - Travail relativement ancien décrivant un mécanisme d'estimation et de limitation de la puissance de la mémoire vive <sup>1</sup>
  - Seule l'interface de configuration et d'utilisation est documentée
- **Aucune information officielle** sur
  - Propriétés telles que la précision, le temps de stabilisation et les impacts sur les performances des applications
  - Différences d'implémentation entre les architectures de processeur
  - Comment la réduction de puissance est obtenue
- Informations **trouvées dans la littérature**
  - RAPL utilise le DVFS et d'autres techniques qui forcent les composants du processeur à rester inactifs à de faibles niveaux de puissance <sup>2</sup>
  - UFS (Uncore Frequency Scaling) semble être utilisé par le mécanisme de contrôle de puissance Intel RAPL<sup>3</sup>



<sup>1</sup> David et al. (2010). RAPL: memory power estimation and capping

<sup>2</sup> Zhang et al. (2016). Maximizing Performance Under a Power Cap: A Comparison of Hardware, Software, and Hybrid Techniques

<sup>3</sup> Riha et al. (2020). Evaluation of DVFS and Uncore Frequency Tuning Under Power Capping on Intel Broadwell Architecture

# Intel RAPL - Analyse de la technologie RAPL

- **Validation du mécanisme de limitation de la puissance**
  - En utilisant un wattmètre externe de haute précision
  - Pour les charges de travail hétérogènes
- **Étude des caractéristiques**
  - Valeurs de limitation de puissance prises en charge
  - Précision
  - Granularité minimale de limitation
  - Temps de stabilisation
- **Étude des mécanismes utilisés** pour ajuster la puissance
- **Étude des impacts sur les performances** des applications
  - FLOPS et bande passante mémoire

Pour les benchmarks

- **NAS** (EP, MG, LU)
- **Stream**



Sur **4 clusters de Grid'5000**

- **Taurus** (Sandy Bridge - 2011 - **RAPL v1**)
- **Orion** (Sandy Bridge - 2011 - **RAPL v1**)
- **Gemini** (Broadwell - 2014 - **RAPL v2**)
- **Troll** (Cascade Lake - 2019 - **RAPL v2**)

# Intel RAPL - Validation du mécanisme RAPL

## Quelques observations

- RAPL est capable de faire respecter les limites de puissance avec **un bon niveau de précision**
- **Puissance** du noeud de calcul **est effectivement réduite**
- **Dépassements** de la limite de puissance **sont possibles** et sont fréquentes pour les charges de travail instables (profil de consommation instable)

# Intel RAPL - Étude des caractéristiques

## - **Précision**

- Calcul de MAPE (Mean Average Percentage Error) entre la limite imposé et la puissance donnée par Intel RAPL
- Valeurs **MAPE** sont presque toujours **inférieures à 2 %**
- MAPE inférieur à 0.1 % pour les benchmarks NAS EP et Stream sur les noeuds avec Intel RAPL v2

## - **Granularité minimale de limitation**

- Limitation de puissance est exprimée en "Power Units" (par défaut 0.125 Watts)
- Vérifier si le pas minimum est de 0,125 Watts et si la puissance peut réellement être affectée par ces pas
- Puissance **peut être influencée par des incréments de 0,125 Watts** pour chaque cluster étudié

## - **Temps de stabilisation**

- Temps nécessaire pour appliquer une limite de puissance et stabiliser la consommation
- Resultats: *RAPL v1* - **plus de 5 secondes**, *RAPL v2* - **entre 0.5 et 1 seconde**

# Intel RAPL - Étude des mécanismes utilisés

**Comment Intel RAPL gère la fréquence CPU core et uncore pour limiter la puissance ?**

- **Fréquence core est significativement affecté** par les limitations de puissance (de la manière équivalente à la puissance)
  - Corrélation entre la fréquence core et les limitations de puissance est très élevé
- **Fréquence uncore est également impacté** par les limitations, mais la dépendance avec la puissance est moindre
- Gestion des fréquences dépend de la nature de la workload exécuté
  - Différente pour les workloads CPU et RAM-intensives

# Intel RAPL - Étude des impacts sur les performances

**Quel est l'impact** de la limitation avec Intel RAPL sur les performances des applications en termes de **FLOPS** et de **bande passante mémoire** ?

- **Valeur FLOPS diminue** de la même manière que la fréquence core du CPU pour le benchmark NAS EP (CPU-intensive)
- **Bande passante mémoire est moins impacté** par l'application de limitation de puissance
- Existence de la plage de limites de puissance où **la puissance peut être réduite sans modifier la bande passante mémoire** pour les benchmarks Memory-intensive
  - RAPL est donc capable de réduire la puissance sans dégrader les performances

# Intel RAPL - Conclusions

- **Nous avons validé que RAPL**
  - Capable de faire respecter les limites de puissance avec un bon niveau de précision, en particulier pour les charges de travail intrinsèquement stables (profil de consommation stable)
  - Est assez précis et a des faibles temps de stabilisation
  - Capable influencer la puissance par les incréments de **0.125 Watts**
  - Utilise **DVFS, UFS** et impose l'**état inactif de certains composants** internes du processeur à de faibles niveaux de puissance pour limiter la consommation d'énergie
- **Nous avons découvert que**
  - Disponibilité des domaines de puissance RAPL utilisables pour la limitation dépend non seulement de l'architecture du processeur, mais également du BIOS et de son firmware
  - **Ne doit pas être considéré comme un levier de plafonnement strict de la puissance**, car la limite de puissance spécifiée peut être dépassée
  - Est capable dans certains cas de réduire la consommation sans dégrader les performances
  - Modulation des fréquences core/uncore effectuée dépend de la nature du workload
- **Future Works**
  - Publier les travaux sur Intel RAPL (le travail est tout frais, ne le dévoilez pas)

# Merci pour votre attention!

Avez-vous des questions ?