CentraleSupélec

Big Data : Informatique pour les données et calculs massifs

3 – Métriques de performance et de passage à l'échelle

Stéphane Vialle

CentraleSupélec université PARIS-SACLAY — ÉCOLE DOCTORALE Sciences et technologies de l'information et de la communication (STIC) — RISEGrid — Grand Est ALSACE CHAMPAGNE-ARDENNE LORRAINE

Stephane.Vialle@centralesupelec.fr
http://www.metz.supelec.fr/~vialle

CentraleSupélec

Que faire avec plus de resources informatiques ?

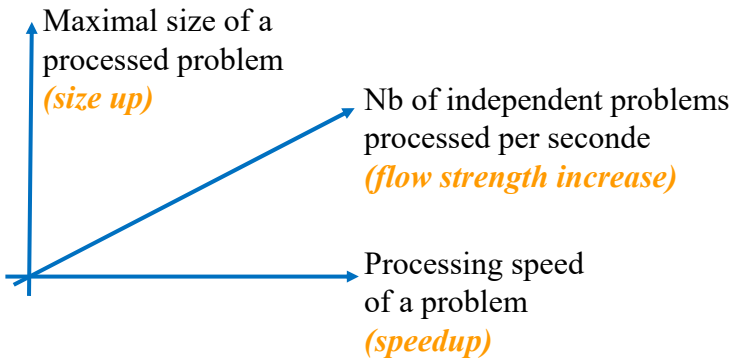

« **Passage à l'échelle** » : size up + speedup + maîtrise des coûts

Accélération d'un traitement

Difficultés pour accélérer une application (sur plusieurs rsrcs de calcul) **:**

1. *Les parties de son code les plus gourmandes en temps doivent être décomposables en sous-tâches pouvant s'exécuter en parallèle*

   Certains algorithmes sont intrinsèquement séquentiels !
   → chercher une nouvelle modélisation du problème !!

2. *L'algorithme parallèle doit avoir une complexité identique ou pas beaucoup plus grande que le meilleur algorithme séquentiel*

   Sinon le gain peut être faible !

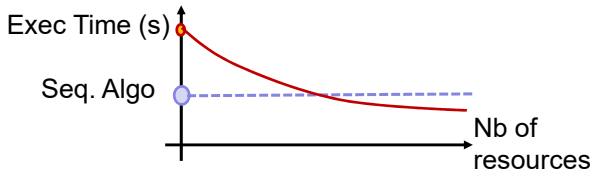

Accélération d'un traitement

Difficultés pour accélérer une application (sur plusieurs rsrcs de calcul) **:**

3. *Le surcoût de gestion de la décomposition en sous-tâches ne doit pas être trop important*

   Coût de gestion du parallélisme : temps de synchronisation et temps de communications

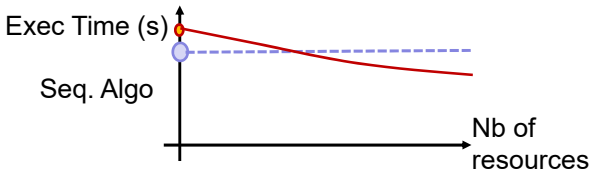

Il y a plein de raisons d'échouer dans une parallélisation !

Accélération d'un traitement

Métrique d'accélération : *Speedup* sur P ressources

$$S(P) = \frac{T(1)}{T(P)}$$

- S(P) < 1 : on ralentit ! mauvaise parallélisation
- 1 < S(P) < P : "normal"
- P < S(P) : hyper-accélération analyser & justifier

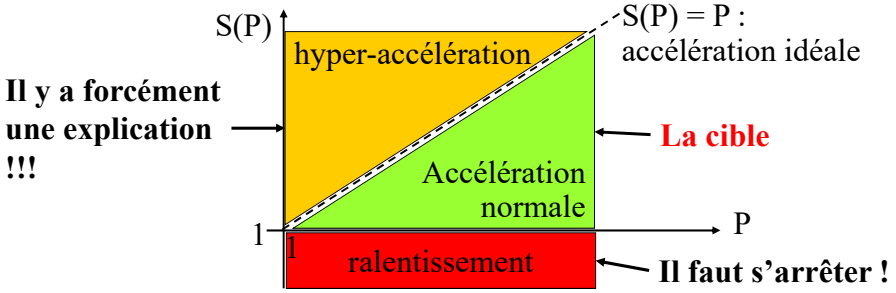

Accélération d'un traitement

Métrique d'accélération : *Speedup* sur P ressources

$$S(P) = \frac{T(1)}{T(P)}$$

- S(P) < 1 : on ralentit ! mauvaise parallélisation
- 1 < S(P) < P : "normal"
- P < S(P) : hyper-accélération analyser & justifier

Habituellement….

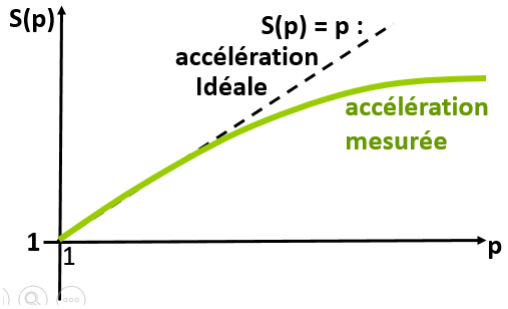

Accélération d'un traitement

Efficacité :

$$e(P) = \frac{S(P)}{P}$$

Taux d'utilisation des ressources, ou fraction obtenue de l'accélération idéale

- $e(P) \in [0;1], \in [0\%;100\%]$
- $e(P) > 100\% \Leftrightarrow$ hyper – accélération

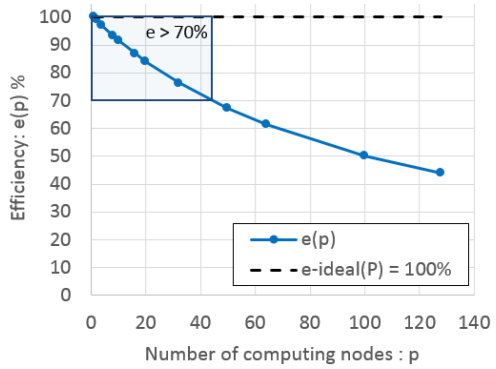

L'utilisateur s'intéresse à l'accélération obtenue

L'acheteur de la machine s'intéresse à l'efficacité des applications exécutées

Le **développeur** s'intéresse aux **deux**

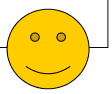

Traitement de plus gros pbs

Difficultés à traiter de plus gros problèmes (origine HPC)

Un code qui **réplique** la plupart de ses données sur toutes les machines sera toujours limité par la taille mémoire d'une machine…
…et ne sera **pas apte au *size up***

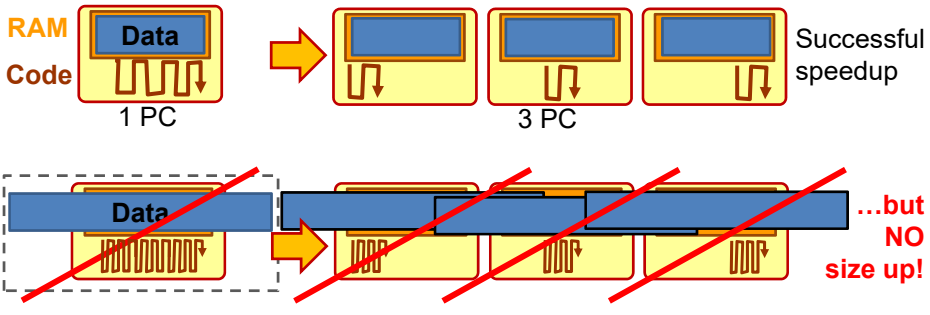

Traitement de plus gros pbs

Difficultés à traiter de plus gros problèmes (origine HPC)

Un code qui **répartit** la plupart de ses données sur toutes les machines pourra stocker plus de données sur plus de machines…
… et sera **apte au *size up***

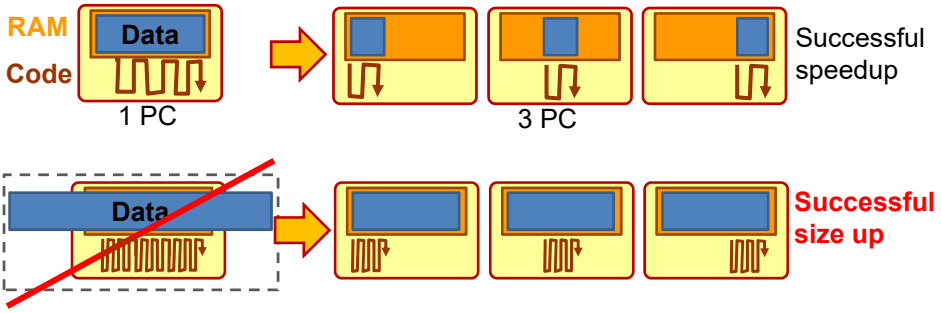

Traitement de plus gros pbs

Difficultés à traiter de plus gros problèmes (origine HPC)

Un algorithme distribué avec répartition des données est souvent complexe :

- ***Besoin de faire circuler les données initiales entre les nœuds de calcul*** : pour qu'un nœud puisse poursuivre ses calculs sur d'autres données que les siennes
- ***Besoin de faire circuler les résultats intermédiaires entre les nœuds*** : pour qu'un nœud puisse poursuivre les calculs d'un autre, avec ses données

→ Conception d'une répartition initiale des données, et d'un schéma de communication (à volume minimal…) : **nécessite un expert** !

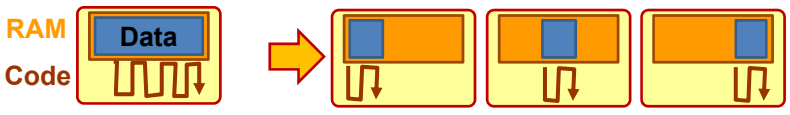

Traitement de plus gros pbs

Métrique de *size up* (extensibilité) : courbe de temps

1 - Maintenir constant le temps d'exécution

$T(1\times n_1,p_1) = T(2\times n_1,p_2) = T(k\times n_1,p_k) = C^{te}$

avec : T(taille pb, nb rsrc)

→ **Objectif pas toujours atteignable !**

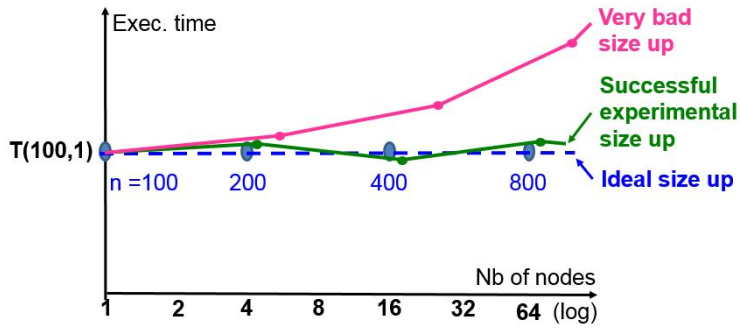

Traitement de plus gros pbs

Métrique de *size up* (extensibilité) : courbe de temps

2 - Maintenir constant le temps d'exéc. avec le bon nombre de rsrc

$T(1\times n_1,p_1) = T(2\times n_1,p_2) = T(k\times n_1,p_k) = C^{te}$

avec : T(taille pb, nb rsrc)

Avec $O(p_k) = O(calcul(n))$

→ **Objectif pas toujours atteignable !**

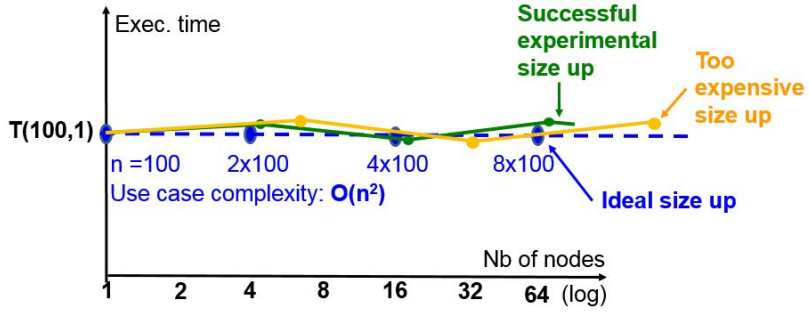

Traitement de plus gros pbs

Métrique de *size up* (extensibilité) : courbe de coût en rsrc

2 - Maintenir constant le temps d'exéc. avec le bon nombre de rsrc

$T(1\times n_1,p_1) = T(2\times n_1,p_2) = T(k\times n_1,p_k) = C^{te}$

avec : T(taille pb, nb rsrc)

Avec $O(p_k) = O(calcul(n))$

→ **Objectif pas toujours atteignable !**

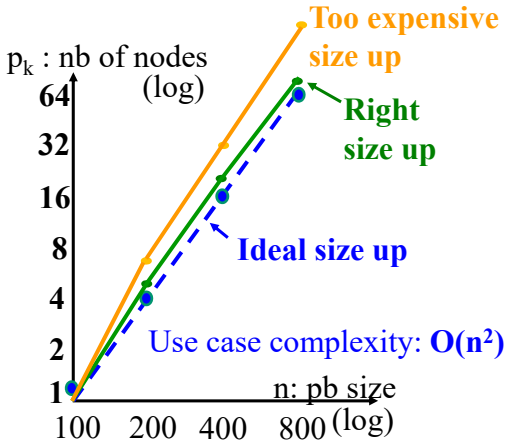

Traitement de plus gros pbs

Métrique de *size up* (extensibilité) :

2 - Maintenir constant le temps d'exéc. avec le bon nombre de rsrc

→ **Exemple expérimental de courbes de temps**

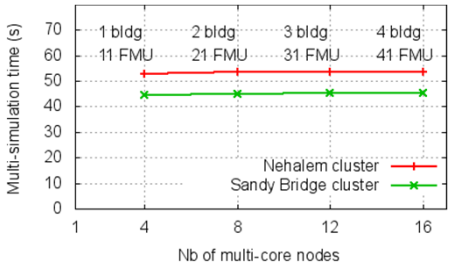

Un problème avec bcp de calculs et peu de communications
→ Size up avec 1Gb/s

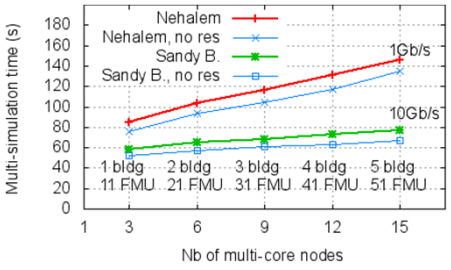

Un problème avec peu de calculs et peu de communications
→ Presque un size up avec 10Gb/s

Traitement de flux de requêtes plus intenses

(origine HTC)

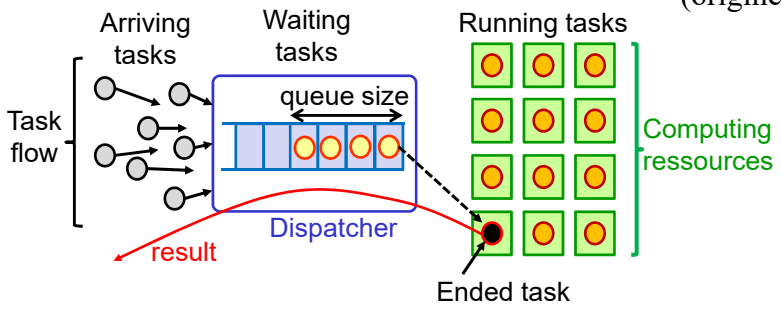

Système de base:

- Tâches identiques (mêmes calculs, données différentes)
- Tâches séquentielles

Systèmes plus complexe :

- Tâches différentes (hétérogènes)
- Taches séquentielles ou *multithreads*

Traitement de flux de requêtes plus intenses

(origine HTC)

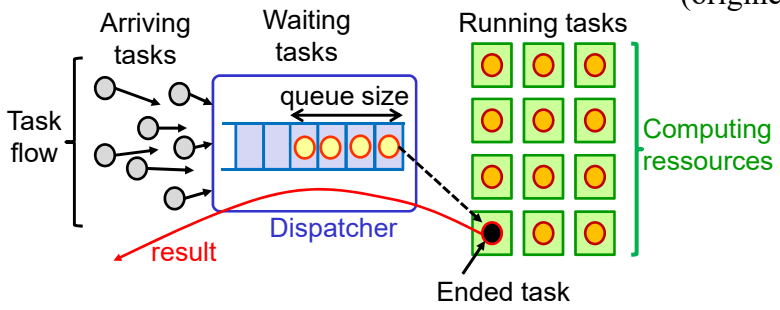

Métriques *size up* :

1. Vitesse de traitement des tâches (tâches/s, tâches/min…)
2. Temps de traitement d'une tâche (T_{max}, T_{moy} …)

→ Maintenir $T < T_{max}$, et $V > V_{flow}$

Traitement de flux de requêtes plus intenses

(origine HTC)

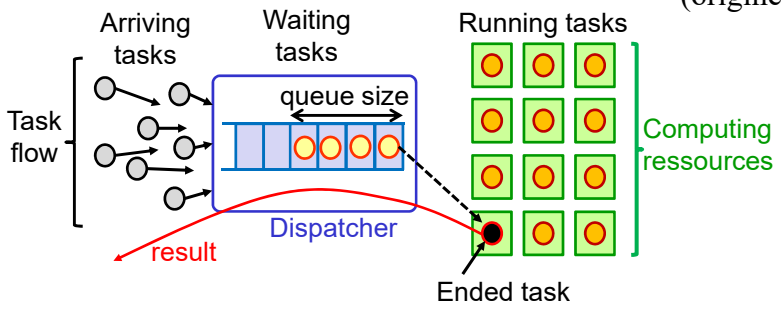

Métriques de *size up* :

3. Taille de la file d'attente (en nbr de tâches)
4. Temps de latence d'une tâche ($t_{démarrage} - t_{soumission}$)

→ Si *Taille de file* ou *Temps de latence* augmente
Alors augmenter le nombre de ressources de calcul
(ou améliorer le *dispatcher*…si pb)

Traitement de flux de requêtes plus intenses

(origine HTC)

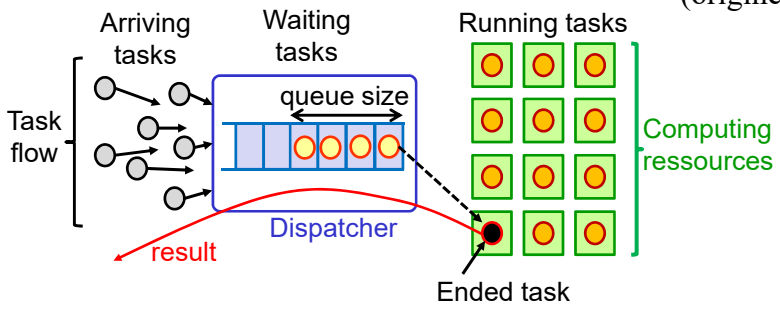

Analyse des pics de charge :

Métrique de moyenne ⇨ Métrique instantannée

- V → V(t)
- T_{max} → $T_{max}(t)$
- Taille → Taille(t)
- $T_{latence}$ → $T_{latence}(t)$

Architecture de *size up*

(support de l'extensibilité)

Approche HPC pour un size up en taille de problème

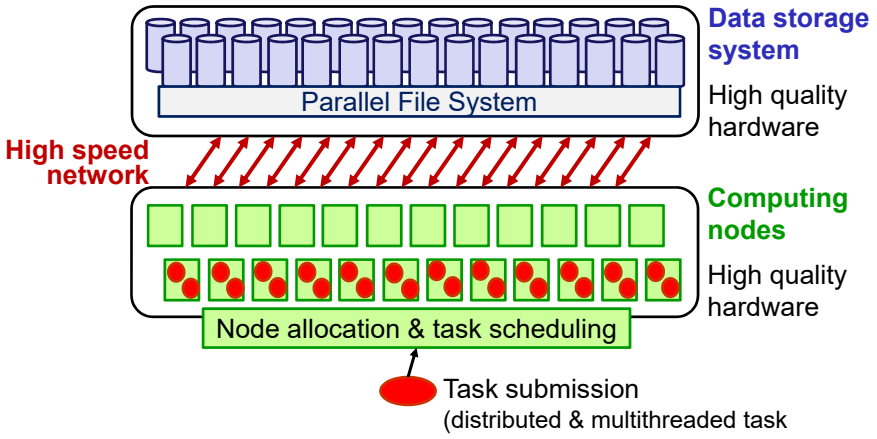

- Architecture de grande taille, matériel fiable et cher
- Chargement des données depuis la baie disque

Architecture de *size up*

(support de l'extensibilité)

Approche HPC pour un size up en taille de problème

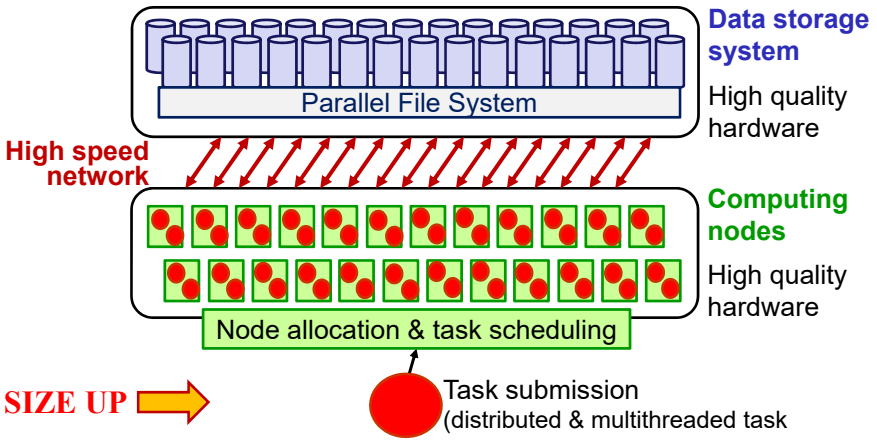

- Architecture de grande taille, matériel fiable et cher
- Chargement des données depuis la baie disque

Architecture de *size up*

(support de l'extensibilité)

Approche HTC pour un size up sur un flux de requêtes

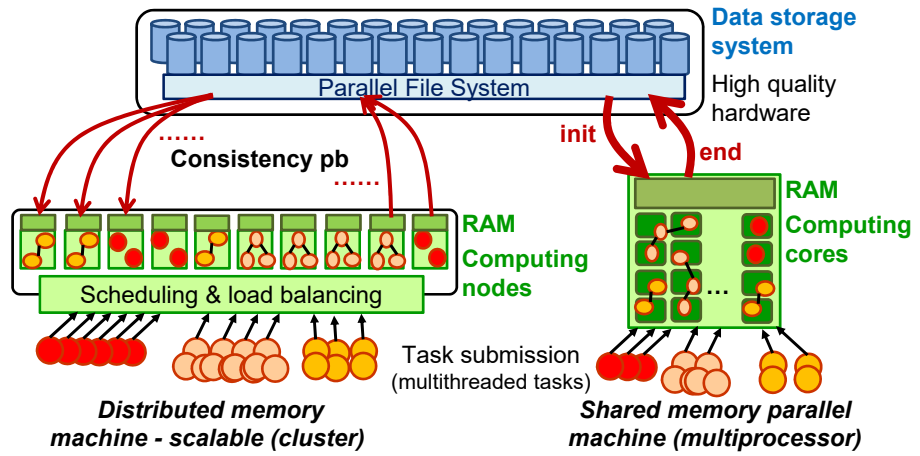

Chaque nœud charge le nécessaire
Possible pb de cohérence…

Charge toute la base en RAM
puis travaille en RAM

Architecture de *size up*

(support de l'extensibilité)

Architecture Big Data pour un size up en taille de données à traiter

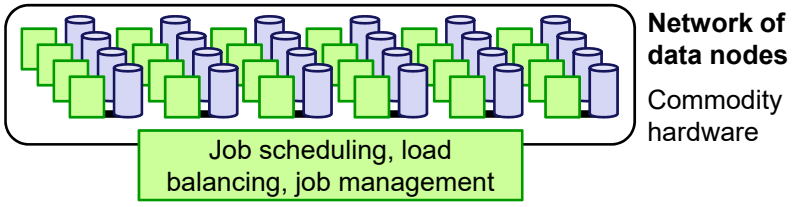

- Architecture très extensible
- Matériel standard (pas trop cher), moyennement fiable
- Tolérance aux pannes par redondance matérielle et logicielles…

Architecture de *size up*

(support de l'extensibilité)

Architecture Big Data pour un size up en taille de données à traiter

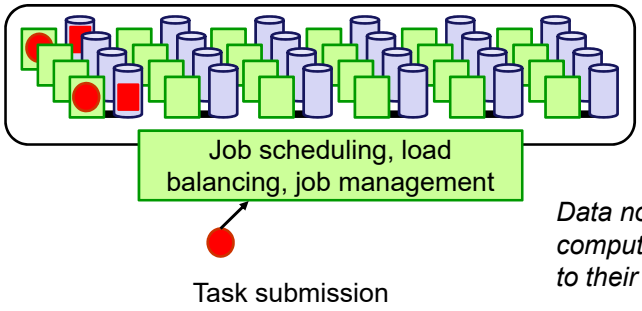

- Architecture très extensible
- Matériel standard (pas trop cher), moyennement fiable
- Tolérance aux pannes par redondance matérielle et logicielles…
- On amène les calculs sur les nœuds possédant les bonnes données

Architecture de *size up*

(support de l'extensibilité)

Architecture Big Data pour un size up en taille de données à traiter

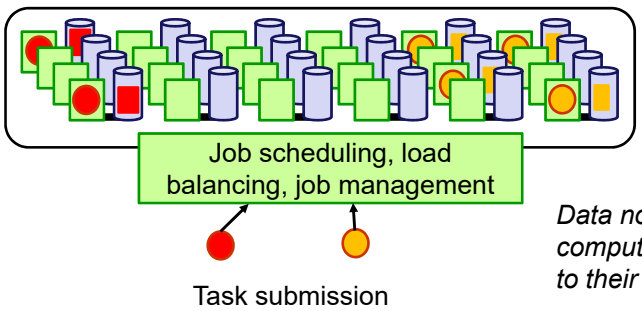

- Architecture très extensible
- Matériel standard (pas trop cher), moyennement fiable
- Tolérance aux pannes par redondance matérielle et logicielles…
- On amène les calculs sur les nœuds possédant les bonnes données

Architecture de *size up*

(support de l'extensibilité)

Architecture Big Data pour un size up en taille de données à traiter

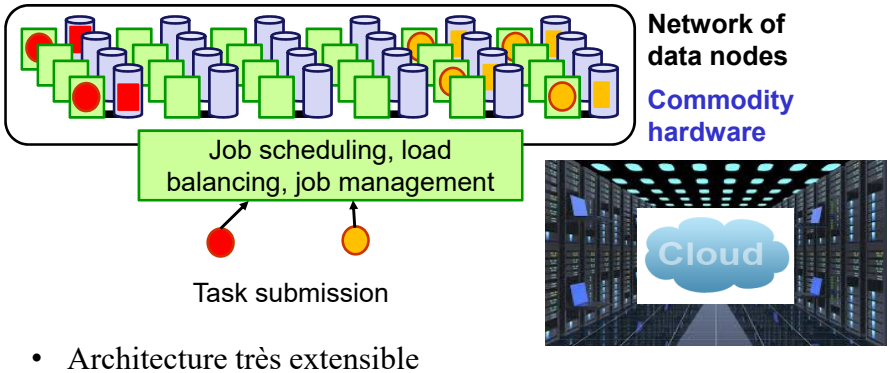

- Architecture très extensible
- **Matériel standard** (pas trop cher), moyennement fiable
- Tolérance aux pannes par redondance matérielle et logicielles…
- **Beaucoup d'architectures Big Data dans des « clouds »**

Passage à l'échelle en taille de pb

Définition : Prolongement d'une démarche de *size up*

- Supporter le *size up* avec une maîtrise des coûts en ressources
- Reproduire le profil d'accélération pour chaque taille de pb

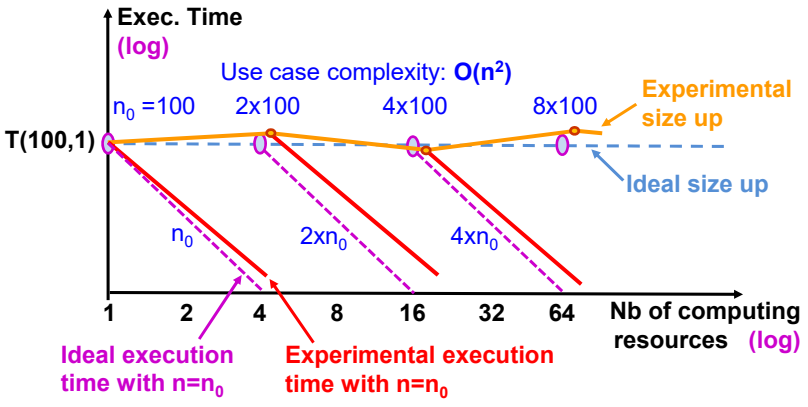

Passage à l'échelle en taille de pb

Quand la taille du problème augmente :

On ne peut plus réaliser une exécution séquentielle, ou même sur un seul nœud ! (pas assez de RAM, exécution trop longue…)

→ on ne peut pas mesurer de référence séquentielle
→ on ne peut pas calculer de *Speedup*

Il faut définir une nouvelle métrique pour qualifier la qualité d'un *passage à l'échelle* en taille de problème

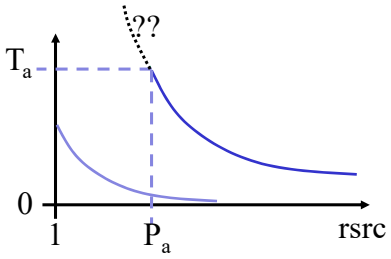

Métrique de *passage à l'échelle*

Courbes de passage à l'échelle (*scalability*) :

$T^{ideal}(p) = T(1)/p$: hyperbole
$Log(T^{ideal}(p)) = Log(T(1)) - Log(p)$: droite de pente -1

→ on mesure T(p) pour différentes tailles de problèmes et nbr de rsrc
→ on trace les courbes T(p) en échelle log

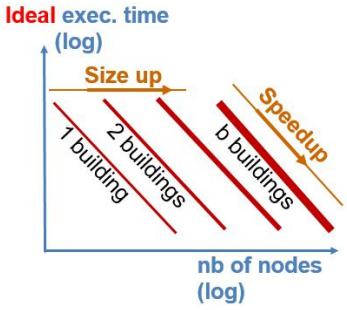

Pour chaque taille de pb on doit obtenir une « droite » parallèle aux autres, simplement translatée vers la droite!

Validation du passage à l'échelle :

On compare aux courbes attendues (pente et position)

Métrique de *passage à l'échelle*

Courbes de passage à l'échelle (*scalability*) :

$T^{ideal}(p) = T(1)/p$: hyperbole
$Log(T^{ideal}(p)) = Log(T(1)) - Log(p)$: droite de pente -1

→ on mesure T(p) pour différentes tailles de problèmes et nbr de rsrc
→ on trace les courbes T(p) en échelle log

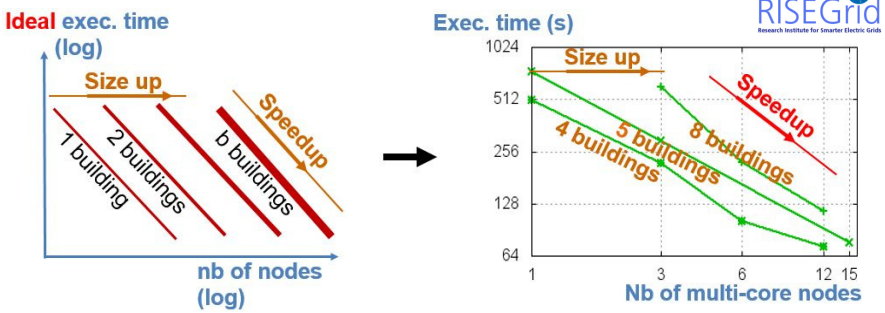

« On a su traiter régulièrement plus gros avec plus de moyens »

Métrique de *passage à l'échelle*

Courbes de passage à l'échelle (*scalability*) :

$T^{ideal}(p) = T(1)/p$: hyperbole
$Log(T^{ideal}(p)) = Log(T(1)) - Log(p)$: droite de pente -1

→ on mesure T(p) pour différentes tailles de problèmes et nbr de rsrc
→ on trace les courbes T(p) en échelle log

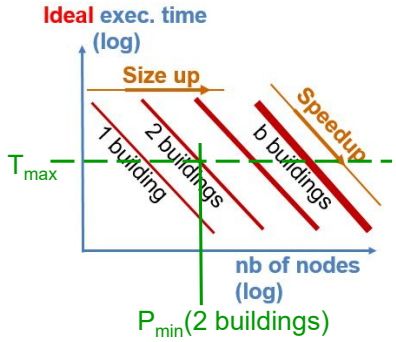

Utilisation en mode « abaque » :
Pour une taille de problème donnée on peut identifier le nombre de ressources de calcul à utiliser pour respecter le temps d'exécution imposé/voulu.

CentraleSupélec

Métrique de *passage à l'échelle*

- Pouvoir utiliser efficacement plus de rsrc pour traiter des problèmes plus gros
- Pouvoir maintenir le temps d'execution cst quand la taille du problème augmente
- Pouvoir utiliser seulement le nombre de ressources théoriquement nécessaires

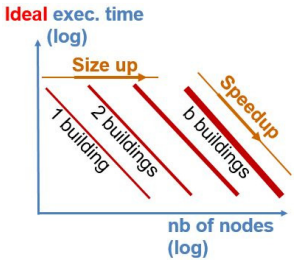

+ Avoir une solution logicielle extensible et déployable sur une architecture matérielle extensible

→ **Pouvoir traiter des problèmes sans limite de taille**

Google, Amazon, Facebook … ont des problèmes et des solutions « *web scale* » sur des architectures énormes.

Beaucoup d'autres ont des problèmes plus petits mais avec le même souci de passage à l'échelle : ne pas avoir de limites dans le futur

CentraleSupélec

Métriques de performance et de passage à l'échelle